



UNIVERSIDAD TÉCNICA DEL NORTE

**FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA INDUSTRIAL**

**TRABAJO DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE
INGENIERA INDUSTRIAL**

TEMA:

**MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE AGUA
POTABLE DE EMAPA-I APLICANDO REDES NEURONALES
ARTIFICIALES**

AUTORA: JAIRO FABRICIO PAVÓN VALENCIA

DIRECTOR: ING. LEANDRO LEONARDO LORENTE LEYVA MSC.

IBARRA – ECUADOR

2019



**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			
CÉDULA IDENTIDAD:	DE	100402360-0	
APELLIDOS NOMBRES:	Y	PAVÓN VALENCIA JAIRO FABRICIO	
DIRECCIÓN:	La Dolorosa de Priorato calle B1 1-23 bloque 22		
EMAIL:	jfpavonv@utn.edu.ec		
TELÉFONO FIJO:	2 580931	TELÉFONO MÓVIL:	0989236086
DATOS DE LA OBRA			
TÍTULO:	MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE AGUA POTABLE EN EMAPA-I APLICANDO REDES NEURONALES ARTIFICIALES		
AUTOR (ES):	PAVÓN VALENCIA JAIRO FABRICIO		
FECHA: AAAAMMDD	2019/02/28		
SÓLO PARA TRABAJOS DE GRADO			
PROGRAMA:	<input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO		
TITULO POR EL QUE OPTA:	INGENIERO INDUSTRIAL		
ASESOR /DIRECTOR:	ING. LEANDRO LORENTE MSC.		



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

CONSTANCIAS

El autor (es) manifiesta (n) 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 (son) el (los) titular (es) de los derechos patrimoniales, por lo que asume (n) la responsabilidad sobre el contenido de la misma y saldrá (n) en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 19 días del mes de marzo de 2019

EL AUTOR:

(Firma).....

Nombre: Jairo Fabricio Pavón Valencia



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

**CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE GRADO A FAVOR DE LA
UNIVERSIDAD TÉCNICA DEL NORTE**

Yo, Jairo Fabricio Pavón Valencia, con cédula de identidad Nro. 100402360-0, manifiesto mi voluntad de ceder a la Universidad Técnica del Norte los derechos patrimoniales consagrados en la Ley de Propiedad Intelectual del Ecuador, artículos 4, 5 y 6, en calidad de autor (es) de la obra o trabajo de grado denominado: MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE AGUA PAOTABLE EN EMAPA-I APLICANDO REDES NEURONALES ARTIFICIALES, que ha sido desarrollado para optar por el título de: Ingeniero Industrial en la Universidad Técnica del Norte, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente. En mi condición de autor me reservo los derechos morales de la obra antes citada. En concordancia suscribo este documento en el momento que hago entrega del trabajo final en formato impreso y digital a la Biblioteca de la Universidad Técnica del Norte.

Ibarra, a los 19 días del mes de marzo de 2019

(Firma).....

Nombre: Jairo Fabricio Pavón Valencia

Cédula: 1004023600



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

CERTIFICACIÓN

Ing. Leandro Leonardo Lorente Leyva MSc., director de la Tesis de Grado desarrollada por el señor estudiante Jairo Fabricio Pavón Valencia.

CERTIFICA

Que, el Proyecto de Tesis de grado titulado “MODELO PARA EL PRONÓSTICO DE LA DEMANDA DE AGUA POTABLE EN EMAPA-I APLICANDO REDES NEURONALES ARTIFICIALES”, ha sido realizado en su totalidad por el señor estudiante Jairo Fabricio Pavón Valencia bajo mi dirección, para la obtención del título de Ingeniero Industrial. Luego de ser revisada, considerando que se encuentra concluido y cumple con las exigencias y requisitos académicos de la Facultad de Ingeniería en Ciencias Aplicadas, Carrera de Ingeniería Industrial, autoriza su presentación y defensa para que pueda ser juzgado por el tribunal correspondiente.

Ing. Leandro Leonardo Lorente Leyva MSc
DIRECTOR DE TESIS



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

DEDICATORIA

A:

Mis padres Antonio Pavón y Elvia Valencia, quienes han sido mis guías, sustento y principal fuente de motivación y apoyo en el trascurso de mi educación. Porque de ellos he aprendido que el esfuerzo y la dedicación tienen su recompensa, por ser mí ejemplo de superación. Mis hermanos Patricio, Pablo, Abigail por estar siempre a mi lado en todo momento, a mi querido primo Jimmy por su apoyo y confianza que han logrado formar en mí, los valores que me identifican y definen.

A mis demás familiares y amigos por su gran apoyo y compartir momentos especiales.

Jairo Fabricio Pavón Valencia



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

AGRADECIMIENTO

A:

Dios, por brindarme la oportunidad de vivir y estar presente en cada momento de mi vida, de igual forma por haberme hecho coincidir con personas que han sido mi compañía y soporte durante todo el proceso de formación permitiéndome cumplir varias de mis metas y sueños.

A mi familia y amigos por ser parte de los momentos e inigualables recuerdos que durante mi formación profesional y personal, han contribuido con el apoyo y comprensión que me han convertido en un reflejo de todos los valores y principios que me han regalado día a día.

Al departamento de Agua No Contabilizada de EMAPA-I por permitirme desarrollar el trabajo de titulación, contribuyendo profesionalmente con los conocimientos para conseguir los resultados del presente trabajo.

La Universidad Técnica del Norte, a mi querida Carrera de Ingeniería Industrial que con sus excelentes docentes han aportado a la formación académica, especial agradecimiento al Ing. Leandro Lorente MSc por el incondicional apoyo académico y personal.

Jairo Fabricio Pavón Valencia

ÍNDICE

IDENTIFICACIÓN DE LA OBRA.....	ii
CONSTANCIAS.....	iii
CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE GRADO A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE.....	iv
CERTIFICACIÓN	v
DEDICATORIA	vi
AGRADECIMIENTO	vii
ÍNDICE.....	viii
RESUMEN	1
ABSTRACT.....	2
CAPÍTULO I	3
1. GENERALIDADES	3
1.1. Problema	3
1.1. Objetivos	4
1.1.1. Objetivo General.....	4
1.1.2. Objetivos Específicos.....	4
1.2. Alcance	4
1.3. Metodología	5
1.3.1. Método documental o bibliográfico.....	5
1.3.2. Método deductivo	5
1.3.3. Método descriptivo	5
1.3.4. Método General del pronóstico.....	6
1.3.5. Técnicas	6
1.3.6. Herramientas	6
1.3.7. Fuente.....	6
1.3.8. Metodología de aplicación de Redes Neuronales Artificiales	6
1.3.9. Entrevista	7
1.4. Justificación	7
1.5. Contexto.....	9
CAPÍTULO II.....	11
2. MARCO TEÓRICO.....	11
2.1. Sistema de Agua Potable	11
2.1.1. Captación	12
2.1.2. Producción	12
2.1.4. Distribución.....	13
2.2. Pronóstico de demanda	13
2.2.1. Horizontes de tiempo para el pronóstico de la demanda de agua potable	14
2.2.2. Pronóstico basado en Series de Tiempo.....	14
2.3. Errores en el Pronóstico	15

2.4.	Redes Neuronales Artificiales.....	18
2.4.1.	Antecedentes de Redes Neuronales	19
2.4.2.	Redes Neuronales Biológicas	21
2.4.3.	Características de las Redes Neuronales Artificiales.....	22
2.4.4.	Aprendizaje adaptativo	22
2.4.5.	Autoorganización.....	22
2.4.6.	Tolerancia a fallos.....	23
2.4.7.	Operación en tiempo real.....	23
2.4.8.	Fácil inserción dentro de la tecnología existente	24
2.5.	Modelo de una red neuronal	24
2.5.1.	Propiedades de las redes neuronales	24
2.5.2.	Elementos básicos de componen una red.....	25
2.5.3.	Fase de entrenamiento.....	26
2.5.3.1.	El Algoritmo de Levenberg-Marquardt	27
2.5.4.	Aprendizaje supervisado.....	27
2.5.5.	Aprendizaje no supervisado.....	28
2.5.6.	Aprendizaje por refuerzo	29
2.6.	Similitudes terminológicas entre Redes Neuronales Artificiales y Modelos estadísticos clásicos.....	29
2.7.	Redes neuronales con conexión hacia delante	30
2.8.	Desarrollo de las Redes Neuronales con MATLAB	31
2.8.1.	La clasificación y clustering de las redes.....	31
CAPÍTULO III.....		33
3.	DIAGNÓSTICO SITUACIONAL	33
CAPÍTULO IV.....		48
4.	DESARROLLO DEL MODELO PARA EL PRONÓSTICO.....	48
4.1.	Algoritmo del modelo de pronóstico de la demanda de agua potable	49
4.2.	Selección de la variable	51
4.3.	Obtención de datos.....	51
4.4.	Preprocesamiento de la información.....	53
4.5.	Definición del conjunto de Entrenamiento, Validación y Prueba.....	54
4.5.1.	Conjunto de entrenamiento	54
4.5.2.	Conjunto de validación	54
4.5.3.	Conjuntos de prueba	55
4.6.	Selección de la Arquitectura de la Red Neuronal	55
4.6.1.	Número de neuronas de entrada.....	56
4.6.2.	Número de capas ocultas	56
4.6.3.	Número de neuronas ocultas.....	56
4.6.4.	Número de neuronas de salida	57
4.7.	Selección del algoritmo de entrenamiento.....	57
4.8.	Criterios de evaluación	58
4.9.	Entrenamiento de la Red Neuronal	58
4.10.	Diagramas	59
4.11.	Resultados del modelo de pronóstico	60
CAPÍTULO V.....		62

5.	ANÁLISIS DE LOS RESULTADOS	62
5.1.	Interpretación de resultados	62
5.2.	Comparación del modelo de Redes Neuronales Artificiales	64
	CONCLUSIONES	68
	RECOMENDACIONES	69
	BIBLIOGRAFÍA	70
	ANEXOS	75
	ANEXO 1. SECTORIZACIÓN VOLUMEN.....	75
	ANEXO 2. SECTORIZACIÓN ABONADOS.....	75

ÍNDICE TABLAS

Tabla 1: <i>Método general del pronóstico</i>	6
Tabla 2: <i>Equivalencia en la terminología estadística y de redes neuronales</i>	29
Tabla 3: <i>Valores iniciales para el cálculo de la demanda</i>	36
Tabla 4: <i>Dotaciones recomendadas</i>	38
Tabla 5: <i>Cálculo de diseño de caudales y periodo</i>	39
Tabla 6: <i>Dotaciones contra incendios</i>	40
Tabla 7: <i>Caudal de diseño para los elementos del sistema de agua potable</i>	40
Tabla 8: <i>Cálculo de la población futura del sistema de agua potable</i>	43
Tabla 9: <i>Cálculo del caudal del sistema de agua potable</i>	44
Tabla 10: <i>Resumen de los valores de caudal y población futura</i>	45
Tabla 11: <i>Plan y ruta de distribución sector Caranqui</i>	51
Tabla 12: <i>Sectorización 2017 Volumen de consumo (m³)</i>	52
Tabla 13: <i>Sectorización 2017 clientes abonados</i>	52
Tabla 14: <i>Resumen de volumen consumido</i>	53
Tabla 15: <i>Resumen de clientes abonados</i>	54
Tabla 16: <i>Pronóstico consumo volumen de agua potable (m³) Caranqui</i>	61
Tabla 17: <i>Pronóstico consumo volumen de agua potable (m³) Ibarra</i>	62
Tabla 18: <i>Comparación de pronósticos</i>	64
Tabla 19: <i>Comparación de pronósticos</i>	67

ÍNDICE FIGURAS

Figura 1: Sistema de abastecimiento por gravedad con tratamiento.....	11
Figura 2: Célula Nerviosa	21
Figura 3: ejemplo de una red neuronal totalmente conectada.....	25
Figura 4: Esquema de funcionamiento de un proceso de aprendizaje supervisado	27
Figura 5: Red neuronal de propagación hacia adelante.	31
Figura 6: Gráficos de posprocesamiento para analizar el rendimiento de la red.....	32
Figura 7: Sectorización de estudio.....	35
Figura 8: Algoritmo del modelo de RNA.	50
Figura 9: Porcentajes de muestra de datos de la red	55
Figura 10: Arquitectura de la red.....	56
Figura 11: Selección del algoritmo de entrenamiento	57
Figura 12: Entrenamiento de la red para ajustar las entradas y objetivos.....	58
Figura 13: Resultados del algoritmo	59
Figura 14: Performance del entrenamiento.....	59
Figura 15: Correlación entre valores reales y pronóstico.	60
Figura 16: Comportamiento del consumo de agua potable	63
Figura 17: Proyección del consumo de agua potable.....	64
Figura 18: Comportamiento del consumo de agua potable RNA y el modelo de Box-Jenkins SRT.	65
Figura 19: Comportamiento del pronóstico de agua potable	66

RESUMEN

En este trabajo se presenta una aplicación de un modelo de redes neuronales artificiales en el pronóstico de la demanda de agua potable de EMAPA-I, haciendo uso de la herramienta computacional Neural Network del Matlab. Teniendo en cuenta que en todo proceso de planificación, los pronósticos tienen un papel fundamental, siendo una de las premisas para planificar, organizar y controlar un conjunto de actividades o procesos, es importante señalar que se debe tener en cuenta en el desarrollo del modelo como por ejemplo el horizonte temporal del pronóstico para evaluar las variables que serán las entradas en el modelo ya sean dependientes como el volumen de consumo de agua de los años posteriores al pronóstico y los meses y años que son las variables independientes. El desarrollo del modelo llevó a obtener resultados como un Error Cuadrático Medio de 4,71 y un coeficiente de correlación del 0,98 que representa un alto nivel de confiabilidad del pronóstico en relación con el comportamiento de los valores reales que se ha contrastado con modelos estadísticos tradicionales, arrojando mejores resultados en cuanto a los criterios mencionados anteriormente. El pronóstico obtenido es importante en el estudio técnico y desarrollo de proyectos de la empresa, dicha información es de vital importancia para la empresa por la relación con los departamentos y la influencia del pronóstico en sus actividades.

ABSTRACT

This paper presents an application of a model of Artificial Neural Networks in the forecast of drinking water demand of EMAPA-I, making use of the computational tool Neural Network of Matlab. Bearing in mind that in any planning process, forecasts have a fundamental role, being one of the premises to plan, organize and control a set of activities or processes, it is important to point out that it must be taken into account in the development of the model for example the temporal horizon of the forecast to evaluate the variables that will be the inputs in the model whether they depend on the volume of water consumption of the years after the forecast and the months and years that are the independent variables. The development of the model led to results such as an Average Square Error of 4,71 and a correlation coefficient of 0,98 that represents a high level of reliability of the forecast in relation to the behavior of real values that has been contrasted with traditional statistical models, yielding better results in terms of the criteria mentioned above. The obtained prognosis is important in the technical study and development of projects of the company, such information is of vital importance for the company by the relationship with the departments and the influence of the forecast in their activities.

CAPÍTULO I

1. GENERALIDADES

1.1. Problema

La Empresa de Agua Potable y Alcantarillado de Ibarra maneja una eficiente red de distribución de agua potable en la ciudad de Ibarra, sin embargo existen zonas como la urbana y rural donde se presentan diferentes escenarios de planificación y distribución por las necesidades de la población, en dependencia de la cantidad de habitantes por zonas. La zona de Caranqui tiene una proyección de crecimiento poblacional por lo cual realizar un adecuado pronóstico de la demanda de agua potable en un horizonte temporal de mediano o largo plazo, para que la planificación de los recursos que se destinen y dispongan para la zona sean los adecuados.

La planificación adecuada es el fin del pronóstico de la demanda ya que al no tener claro que actividades se desarrollarán en un futuro generan un comportamiento difuso de las variables y criterios de planificación de la demanda genera una incertidumbre de dicha demanda, que afecta a las áreas de la empresa como distribución de agua, operacionales y ambientales, que además, generará problemas internos como la priorización de zonas.

El trabajo de la planificación es de vital importante porque implica una inversión significativa para la empresa, ya que se trata de un enorme proceso de gestión, definición de estrategias y plan de inversiones que se traducen en un trabajo de identificación de pérdidas dentro del proceso de distribución, reparación de tuberías, implementación de estructuras, entre otros.

La planificación inadecuada se representa en el nivel de calidad del servicio a los clientes, porque no se tienen en cuenta los tiempos de abastecimiento, ni la variable de crecimiento

poblacional y por lo que no se genera la flexibilidad para establecer los cambios más notables para cubrir las necesidades completa o parcialmente de agua potable abastecida.

1.1.Objetivos

1.1.1. Objetivo General

Realizar el pronóstico de la demanda de agua potable en EMAPA-I aplicando Redes Neuronales Artificiales.

1.1.2. Objetivos Específicos

- Elaborar el marco teórico referencial de la investigación mediante la revisión del estado del arte de los modelos de pronóstico de la demanda y la aplicación de Redes Neuronales Artificiales.
- Diagnosticar la situación actual de la planificación de consumo de agua potable de la empresa aplicando diferentes técnicas de investigación.
- Desarrollar el pronóstico de la demanda de agua potable de la zona de Caranqui con el empleo de Redes Neuronales Artificiales.
- Realizar un análisis de los cambios que se producirán en la empresa en base a los resultados obtenidos a partir del pronóstico de la demanda.

1.2.Alcance

La trascendencia de la investigación radica en la necesidad de pronosticar la demanda en EMAPA-I, mediante la aplicación de las Redes Neuronales Artificiales como técnica novedosa en el desarrollo del pronóstico, basado en la búsqueda de los algoritmos de entrenamiento de la red a diseñar, presentando las mejores opciones de entrenamiento en el software MATLAB, que

corresponde a la herramienta a utilizar para la predicción del consumo de agua potable, como objetivo de esta investigación.

Con la finalidad de enfocarse en el mejoramiento del desarrollo del pronóstico de agua potable en la zona de Caranqui por la proyección de crecimiento que presenta dicha zona, para que sirva como modelo de referencia que ayude a partir desde ese punto de relación y sea de utilidad para la empresa en la toma de decisiones en las otras zonas que abastece la empresa, así también es importante para el desarrollo de las diversas actividades de la empresa.

1.3. Metodología

Se establece la metodología a seguir en el presente estudio, mediante la aplicación de las diferentes estrategias con la finalidad de dar cumplimiento a los objetivos planteados y los resultados a obtener.

1.3.1. Método documental o bibliográfico

La base de este método se encuentra relacionada con la recopilación y obtención de información basada en fuentes bibliográficas, libros, artículos científicos, entre otros.

1.3.2. Método deductivo

Se analiza el desarrollo de la evolución y aplicación en diferentes áreas como la del pronóstico de la demanda usando Redes Neuronales Artificiales, con la finalidad de reducir los errores al pronosticar, obteniendo como resultado valores con un alto nivel de exactitud.

1.3.3. Método descriptivo

Se identifican las características y la situación actual de la empresa, mediante el estudio de los procesos y actividades. Además, se considera la información acerca de los recursos y los criterios o variables que influyen en la investigación.

1.3.4. Método General del pronóstico

Tabla 1: *Método general del pronóstico*

Nº	Paso	Descripción
1	Identificar el horizonte temporal	Corto, mediano y largo plazo
2	Observar los hechos	Identificar las variables a predecir y sus incidencias
3	Seleccionar una técnica	Seleccionar las técnicas que se ajusten mejor al tipo de problema presentado
4	Aplicar técnicas seleccionadas	Desarrollo del pronóstico

Fuente: (Vidaurre, 2012)

1.3.5. Técnicas

Redes Neuronales Artificiales

1.3.6. Herramientas

MATLAB Neuronal Network Toolbox

1.3.7. Fuente

El archivo histórico de datos es proporcionado por la Empresa de Agua Potable y Alcantarillado de Ibarra, para el desarrollo del pronóstico.

1.3.8. Metodología de aplicación de Redes Neuronales Artificiales

La metodología consta de los siguientes pasos:

1. Selección de la variable
2. Recolección de datos

3. Preprocesamiento de los datos
4. Definición del conjunto de Entrenamiento, Validación y Prueba
 - a) Conjunto de Entrenamiento
 - b) Conjunto de Validación
 - c) Conjunto de Prueba
5. Selección de la arquitectura de Redes Neuronales Artificiales
 - a) Número de Neuronas de Entrada
 - b) Número de Capas Ocultas
 - c) Número de Neuronas Ocultas
 - d) Número de Neuronas de Salida
 - e) Función de Transferencia
6. Criterios de Evaluación
7. Entrenamiento de las Redes Neuronales Artificiales
 - a) Número de Iteraciones
 - b) Tasa de Aprendizaje y Momentum
8. Implementación del Modelo de Redes Neuronales Artificiales

1.3.9. Entrevista

La primera entrevista se realiza a expertos y encargados de la empresa, posteriormente entrevistar a los trabajadores, para identificar los factores decisivos e influyentes a tomar en cuenta dentro del proceso de distribución de agua potable.

1.4. Justificación

En la actualidad las empresas buscan garantizar un servicio de agua potable de calidad llevando a un nivel competitivo dentro del contexto que se encuentran, para responder

eficientemente a las necesidades actuales, que se han vuelto muy inconsistentes, echo por el cual la flexibilidad y la adaptabilidad de las empresas es fundamental, sobre todo en las zonas que proyectan un gran crecimiento poblacional que influirá en la distribución futura del servicio de agua potable y que debe constar dentro de una planificación para que las actividades tengan un lógico y eficiente desarrollo (Ghiassi, Zimbra y Saidane, 2008). Uno de los principales inconvenientes es la incertidumbre generada por dichos cambios y la inadecuada planificación de la empresa en cuanto a establecer la cantidad de clientes que generarán cambios en el sistema de distribución de agua potable. Surgiendo de estos la necesidad de tener en cuenta una herramienta para la toma de decisiones, eficiente e inteligente sobre costos de producción y prestación de servicio, por lo que se presenta el pronóstico de la demanda que ayuda a establecer los criterios necesarios a evaluar para planificar las actividades en el periodo requerido.

Con la predicción adecuada se trata de prevenir lo que podría ocurrir en un futuro, incrementando la generación de utilidades y ofrecer un servicio de alto nivel para los clientes. Dentro de los parámetros de análisis del pronóstico de la demanda está la cantidad de clientes a suministrar el volumen de agua a potabilizar que se convierten en criterios importante porque influye directamente en la capacidad de instalaciones, cantidades de reabastecimiento y el control de inventario.

Actualmente el uso de las Redes Neuronales Artificiales como un método novedoso y en virtud de la tendencia del comportamiento difuso de la planificación en las empresas, se encuentra desplazando a los métodos estadísticos más tradicionales, sobre todo por los resultados tan prometedores que se empiezan a consolidar como un modelo práctico y dinámico para la toma de decisiones, siendo una opción muy factible para la empresa (Leclerna, 2007).

1.5.Contexto

Aunque el 70% de la superficie del mundo está cubierta por agua, aproximadamente el 97% de agua del planeta es agua salina, en mares y océanos: apenas el 3% del total es agua dulce y de esa cantidad apenas dos terceras partes se encuentra congelada en los glaciares y casquetes de los polos y altas montañas. La tercera parte de países en regiones con gran demanda de agua podría enfrentarse a escases severa de agua en este siglo y para el 2025, dos tercios de la población mundial vivan en países con escases moderadas o severas (Vidaurre, 2012).

En 2010, la Asamblea General de las Naciones Unidas reconoció explícitamente el derecho humano al abastecimiento de agua y al saneamiento. Todas las personas tienen derecho a disponer de forma continuada de agua suficiente, salubre, físicamente accesible, asequible y de una calidad aceptable, para uso personal y doméstico (OMS, 2015).

El agua es un derecho humano irrenunciable, y constituye patrimonio nacional estratégico de uso público, inalienable, imprescriptible, inembargable y esencial para la vida (Constitución de la República del Ecuador, 2008. Art 12).

El agua debe ser conservada, protegida y recuperada mediante una gestión sostenible y sustentable, que garantice su duración, cantidad y calidad, siendo responsabilidad del Estado a través de los GAD Municipales y los usuarios de los sistemas públicos y comunitarios de agua potable y riego, puesto que solo una pequeña cantidad de agua existente es agua dulce y apta para el consumo de los seres vivos (INEC, 2016).

Enmarcando la Estadística de Información Ambiental Económica en Gobiernos Autónomos Descentralizados Municipales; con los Objetivos de Desarrollo Sostenible, puntualmente con el Objetivo 6: Garantizar la disponibilidad de agua y su gestión sostenible y el saneamiento para todos.

Dentro del ámbito de predicción de consumo de agua pueden encontrarse investigaciones como: “Aplicación de redes Neuronales Artificiales para el pronóstico de la demanda de agua en zonas urbanas de Andalucía”, este proyecto consiste en la elaboración de una red con mayor capacidad de predicción que otras técnicas, comprobando así que la utilización de las RNA para resolver problemas de pronóstico de series temporales es más eficiente que recurrir a modelos basados en técnicas clásicas (Sánchez, 2008).

Básicamente, las redes neuronales son una herramienta matemática que emula la estructura de una red neuronal biológica, con el fin de aprender patrones y asociar eventos a partir de un set de datos. La factibilidad de las redes neuronales como herramienta de pronóstico, está basada en estudios existentes en la literatura, donde son utilizadas para la predicción de datos en distintos contextos industriales, han llegado a ser muy populares en el pronóstico de series de tiempo en un gran número de áreas incluyendo finanzas, generación de energía, medicina, recursos del agua y ciencias ambientales, entre otras. Particularmente, las predicciones de consumo de agua mediante redes neuronales ya han sido implementadas con excelentes resultados. Se utiliza Matlab con la librería Neural Network Toolbox para el desarrollo de la red neuronal predictiva (Rodríguez, 2016).

El objetivo principal de los pronósticos se convierte en la entrada para el resto de los planes operativos. Para realizar eficientes programas de producción que atiendan la demanda sin incurrir en excesivos costos de capital, es deseable un adecuado manejo de la información de ventas con el fin de realizar pronósticos con buen nivel de confianza para todos los departamentos de la empresa (Ruelas & Laguna, 2014).

CAPÍTULO II

2. MARCO TEÓRICO

Se presenta la información relacionada con la investigación, así como las técnicas y metodologías para el desarrollo del pronóstico con el uso de Redes Neuronales Artificiales, haciendo énfasis en la aplicación en el entorno de la planificación y la importancia del desarrollo de la predicción en un contexto nacional y mundial.

2.1. Sistema de Agua Potable

El agua potable, de forma generalizada, llega a los consumidores a través de un sistema sanitario que consiste en una obra ingenieril con la función de distribuir y potabilizar agua proveniente de fuentes naturales.

La red de abastecimiento se compone por una serie de etapas que procesan el agua cruda y la distribuyen a los diversos puntos de abastecimiento. A continuación, la Figura 1 nos muestra un sistema de agua potable.

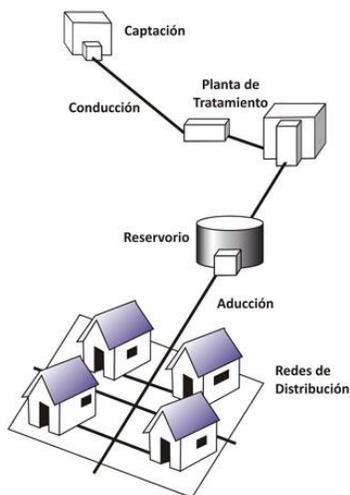


Figura 1: Sistema de abastecimiento por gravedad con tratamiento.

Fuente: <http://www.bvsde.paho.org/bvsacg/guiaicalde/2sas/2-3sas.htm>

Las etapas de un sistema de este tipo en cuanto al trabajo con agua potable incluyen la captación de agua cruda, la producción, regulación y distribución de agua potable.

2.1.1. Captación

La etapa de captación concierne a la extracción de agua bruta desde una fuente natural, la cual puede poseer distintos orígenes. Algunos de los orígenes son; agua de lluvia almacenada, agua subterránea proveniente de manantiales, pozos, agua superficial proveniente de ríos, arroyos o lagos, e incluso agua proveniente del mar (la cual requiere de procesos adicionales de desalinización).

2.1.2. Producción

La etapa de producción está conformada por procesos determinados de potabilización, que corresponden a varios tratamientos de desinfección y filtración. Además, el tratamiento de agua incluye etapas de retención de material grueso y de material fino en suspensión, tratamientos químicos de decantación de materiales muy finos y desinfección en general.

2.1.3. Regulación

La etapa de regulación del sistema de agua potable está conformada por una bomba de extracción que suministra con agua tratada a un estanque de regulación (conocido comúnmente como copa de agua), la cual tiene la función de compensar las variaciones horarias del consumo versus la frecuencia de funcionamiento de la bomba de extracción. Es por esto que la frecuencia de producción, que corresponde a la frecuencia de la bomba de extracción, es diferente de la frecuencia de consumo de agua (Zhou, 2002).

Así también, el estanque de regulación tiene la tarea de almacenar un volumen específico para casos de emergencia, de tal forma, garantizar el abastecimiento de agua a los consumidores.

2.1.4. Distribución

La red de distribución corresponde al sistema de conductos que llega a cada uno de los puntos de abastecimiento para los consumidores. Esta red empieza en el estanque de regulación, y está constituida por estaciones de bombeo, tuberías, sistema de transporte de agua (Aducción), válvulas que sectorizan el suministro de agua en caso de rupturas y emergencias por escasez de agua, y finalmente de dispositivos de medición de volumen de agua en los puntos de abastecimiento.

2.2.Pronóstico de demanda

El tipo de demanda que se estudie depende de las decisiones que se toman en cuenta, si estas son ajenas a la empresa se convierte a una demanda independiente y si son decisiones tomadas por la propia empresa es una demanda dependiente.

Pronosticar es muy importante en muchos tipos de empresas, ya que la predicción de muchos hechos futuros se puede incorporar al proceso de toma de decisiones (Bowerman, O' Connell y Koehler, 2007).

Para predecir lo que ocurrirá en el futuro se debe tener plena confianza en la información de los hechos suscitados en el pasado. Es decir, para elaborar un pronóstico se deben basar en los datos anteriores y la predicción en los resultados del análisis.

Para determinar la demanda actual, se estudian los grupos de consumidores de características homogéneas, considerando el tipo de consumo (comercial, residencial e industrial), la cobertura actual de servicio y la facturación promedio mensual para cada grupo definido.

Se analiza y estima la demanda futura por grupo de consumidores en base al crecimiento esperado de la población, a la cobertura proyectada y a la dotación de consumo esperada. Los

consumos comerciales se proyectan proporcionalmente al crecimiento de los residenciales, y los consumos industriales se proyectan de acuerdo al crecimiento del rubro. (Galán Ordax, 2007).

Responder eficientemente a las necesidades actuales, que se han vuelto muy inconsistentes, echo por el cual la flexibilidad y la adaptabilidad de las empresas es fundamental, sobre todo en las zonas urbanas que trazan crecimiento poblacional elevado ya que influirá en la futura distribución del servicio de agua potable y que debe consignar dentro de una planificación para que las actividades tengan un lógico y eficiente desarrollo, además de la gestión sostenible de los recursos naturales (Firat, Turan, y Yurdusey,2009; Caiado, 2010).

2.2.1. Horizontes de tiempo para el pronóstico de la demanda de agua potable

El pronóstico de la demanda de agua potable se clasifica principalmente en tres horizontes de tiempo:

Corto plazo es de hasta un año pero generalmente se lo usa menor a 3 meses.

Mediano plazo tiene una extensión de 3 meses hasta 3 años.

Largo plazo es de 3 años o más.

El pronóstico de la demanda de agua potable es a cierto grado aleatorio sin importar que los límites de confianza se fijen cuidadosamente, el pronóstico se basa básicamente en la probabilidad. El trabajo del pronosticador es de proporcionar un pronóstico con el mayor nivel de fiabilidad posible, elaborar el pronóstico identificando el problema que resolverá, recopilar los datos que requiera, construir un modelo matemático y para así finalmente generar y validar dicho pronóstico.

2.2.2. Pronóstico basado en Series de Tiempo

Debido a que el mundo en el que operan las organizaciones cambia constantemente, siempre han sido necesarios los pronósticos. Entre los más utilizados están promedio móvil simple,

promedio móvil ponderado, suavización exponencial y suavización exponencial ajustada. Sin embargo, en la actualidad se ha incrementado la dependencia de métodos que implican técnicas sofisticadas de manipulación de datos.

De la noche a la mañana han surgido nuevas tecnologías y disciplinas, se ha intensificado la actividad gubernamental en todos sus niveles, la competencia en muchas áreas se ha vuelto más reñida, ha aumentado el comercio internacional en casi todas las industrias, se han creado y han crecido agencias de ayuda social y de servicios, e internet se ha vuelto una fuente muy importante de datos e información para la toma de decisiones. Estos factores se combinan para crear un clima organizacional más complejo, rápido y competitivo que en el pasado. Las organizaciones que no reaccionen de inmediato ante las condiciones cambiantes y que no puedan prever el futuro con un cierto grado de precisión, están condenadas a extinguirse (Hanke y Wichern, 2006).

2.3. Errores en el Pronóstico

De acuerdo con B. Zavala, 2015, para evaluar el desempeño del pronóstico (\hat{X}), se utilizarán medidas que comparan la predicción con el valor real. Estas medidas también pueden ser utilizadas para la calibración de los datos.

Para una serie $(X_n) = 1$ de media \bar{X} , se tienen las siguientes medidas de error:

1. **Error Absoluto Medio (MAE):** Indicador que entrega el promedio del error absoluto del pronóstico en toda la serie.

$$MAE = \frac{1}{n} \sum_{t=1}^T |X_t - \hat{X}|$$

(1)

2. **Error porcentual absoluto medio (MAPE):** Indicador que entrega en promedio el error absoluto en el pronóstico de toda la serie, como porcentaje de la serie original.

$$MAPE = \frac{1}{n} \sum_{t=1}^T \left| \frac{X_t - \hat{X}}{X_t} \right|$$

(2)

3. **Error Porcentual Absoluto Medio Ponderado (Weighted MAPE):** Equivalente a calcular un error MAPE, ponderado por el tamaño del error relativo al valor original.

El MAPE pondera cada error en el pronóstico por igual, independiente del nivel de los valores de la serie que se está pronosticando. WMAPE pondera cada error dependiendo del nivel de valores de la serie. WMAPE compensa el tamaño del error relativo al porcentaje del valor original.

$$WMAPE = \frac{\sum_{t=1}^T |X_t - \hat{X}| * X_t * 100}{\sum_{t=1}^T X_t} \quad (3)$$

Se define MSE (Mean Square Error) como la media de e_t^2 , es decir el promedio de los errores entre el estimador y lo que se estima al cuadrado:

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (4)$$

Donde n es el número de muestras y \hat{y}_t es la estimación de y_t . De la fórmula anterior se deduce que la función de pérdida de la medida es la cuadrática o error medio al cuadrado.

Coefficiente de correlación (R^2), donde:

$$R^2 = \frac{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}{\frac{1}{n} \sum_{t=1}^n (y_t - \bar{y})^2}$$

(5)

Donde \hat{y} es el pronóstico de la demanda, y_t es la demanda media, y_t es la media del pronóstico de la demanda, y n es el número de observaciones.

Según R. Hyndman, 2006, el indicador más recomendado para comparar modelos para una misma serie es el MAE, porque es de fácil cálculo e interpretación, además de ser una medida objetiva para medir el desempeño de los modelos. Sin embargo, al ser escala-dependiente, hace que pierda el sentido si se quiere comparar modelos para diferentes series.

El MAPE tiene la ventaja de ser independiente de la escala, de manera que es útil para comparar modelos entre series. Sin embargo, cuando se quieren pronosticar valores pequeños, se producen errores pequeños que arrojan un gran MAPE, ya que significan un gran porcentaje del valor real. Para corregir este problema, se utiliza el WMAPE, que pondera el error por el porcentaje que representa el valor de la serie en un punto versus el valor real. Así, grandes valores del MAPE tienen poco peso si es que el nivel del valor real es bajo.

Dado lo anterior, se utilizará el WMAPE como métrica para comparar el desempeño de los modelos.

Errores Bayesianos

Una diferencia fundamental de la inferencia Bayesiana respecto a la clásica es el carácter subjetivo (y no frecuencial) de las probabilidades, ya que no se plantea el problema de muestreo repetido ni requiere del concepto de distribución muestral. Las probabilidades subjetivas pueden definirse para cualquier proposición, mientras que la probabilidad frecuencial se define sólo para sucesos en un espacio muestral (O'Hagan y Forster, 2004). De tal manera, el método bayesiano utiliza la información previa disponible mientras que los métodos clásicos no toman en cuenta esta información.

También existe la posibilidad de cambiar los modelos e interpretaciones a lo largo del análisis, mientras que en inferencia clásica se supone que las hipótesis y modelos se establecen antes de recoger los datos y no se cambian. Esto es poco razonable, pues dejar a los datos “hablar

por sí mismos” es una idea básica en la modelización matemática, donde asumimos que los modelos son útiles para describir los datos, pero no son exactamente iguales a los datos y por tanto sería posible cambiar de modelo a lo largo del análisis (Pruzek, 1997; McLean, 2001).

2.4. Redes Neuronales Artificiales

Las redes neuronales son una herramienta matemática, capaz de aprender a partir de la “experiencia”. El comportamiento de la red es memorizado por un gran número de nodos que finalmente, definen su función. Estos nodos, son elementos procesadores que se encuentran dispuestos en capas y operan de forma paralela en su aprendizaje (Herrera, Torgo, Izquierdo y Pérez, 2010).

Las redes neuronales artificiales pretenden emular la estructura de las redes neuronales biológicas con el objetivo de construir sistemas de procesamiento de información. Los elementos que la componen se distribuyen de manera jerárquica y tienen la cualidad de adaptarse a los objetos del mundo real, tal como lo hace el sistema nervioso biológico (Rodríguez, 2016).

Las redes neuronales artificiales nacen de la idea de imitar el comportamiento del cerebro humano a través de una computadora. Las computadoras de hoy en día pueden resolver complejos cálculos matemáticos a una velocidad impensada para el ser humano. Sin embargo hay muchas tareas que en el hombre resultan sencillas pero por sus características la computadora no puede realizar (García y Osella, 2003).

Las principales áreas de estudio y aplicación de las redes neuronales descritas por Martí, 2009

son las siguientes:

- Finanzas y Negocios: predicción de índices, detección de fraudes y falsificaciones, riesgo de créditos, predicción de rentabilidad de acciones, interpretación de firmas, marketing, venta cruzada y campanas de venta.

- Alimentación: perfilamiento de clientes en función de la compra, análisis de olor y aroma, control de calidad y desarrollo de productos.
- Medicina: ayuda al diagnóstico, análisis de imágenes, desarrollo de medicamentos, analizadores de habla, predicción de reacciones adversas a medicamentos, y causalidad de los ataques epilépticos.
- Transportes: optimización de rutas, optimización en la distribución de recursos, optimización de plazas y horarios de vuelos y explotación de bases de datos.
- Energía: predicción del consumo eléctrico, distribución de recursos hidráulicos para la producción eléctrica, predicción de consumo de gas ciudad.
- Militares: clasificación de las señales de radar, armas inteligentes, reconocimiento y seguimiento en el tiro al blanco.
- Manufacturación: control de robots, control de calidad, control de procesos e inspección de calidad.
- Biología: obtención de modelos de retina, mejorar aprendizaje sobre el cerebro y otros sistemas.
- Ciencia: análisis de datos y clasificación, análisis de tendencias y patrones.

2.4.1. Antecedentes de Redes Neuronales

Daza, 2008 en su tesis doctoral propone la elaboración de una red neuronal con un alto nivel de predicción en comparación con otras técnicas, se selecciona una red neuronal de tipo perceptrón multicapa por la combinación en el diseño de la red neuronal, la función de activación y los retardos en las entradas y nodos de las capas ocultas. La arquitectura de la está definida por el número de capas, nodo por capa y la conexión entre estos.

Se logró determinar que el uso de las RNA's es más eficiente para resolver problemas de pronóstico de series de tiempo que la utilización de los modelos clásicos.

Toro, Ocampo, Mejía y Salazar, 2004, enfocan su investigación en la comparación de la aplicación de las técnicas tradicionales y las Redes Neuronales Artificiales. Referenciando a un problema de pronóstico de ventas, se aplican varios criterios para obtener un excelente comportamiento de la red neuronal como son las funciones de transferencia obteniendo como resultado una fuerte capacidad para la aplicación.

Basado en la información previa al periodo estimado para el pronóstico ya que se trata de un problema de ventas estacionales, la aplicación tiene la finalidad de analizar las condiciones de la empresa para elaborar un programa de producción estricto y flexible que cumpla con la creciente demanda (Babel, Gupta y Pradhan, 2007).

La exigencia de una mayor variedad de productos conlleva a la búsqueda permanente de lograr maximizar el uso de los equipos para la fabricación, mano de obra y la inversión, de esta manera se cumplirá eficientemente en los plazos de tiempo determinados, cumpliendo los lotes y pedidos razón por lo cual las redes neuronales arrojan resultados más cercanos a la realidad (Sahoo, 2009).

Sarmiento y Villa, 2008, aplican las redes neuronales en el pronóstico de la demanda de energía eléctrica en Colombia, usando redes *MultiLayerPerceptron* con los algoritmos de *Backpropagation* y *Radial Basic Function* para realizar el entrenamiento de la red. Se plantea el pronóstico como una tarea de clasificación de información donde las anteriores redes han demostrado un buen desempeño basado en la demanda horaria en megavatios. La aplicación de la herramienta de Matlab para el desarrollo de la programación de la red.

2.4.2. Redes Neuronales Biológicas

Según Colina y Rivas (1998) y Adamowski y Chan (2011): "Las neuronas son células nerviosas que constituyen los elementos primordiales del sistema nervioso central. Son capaces de recibir señales provenientes de otras neuronas, procesar estas señales, generar pulsos nerviosos, conducir estos pulsos, y transmitirlos a otras neuronas" como se muestra en la Figura 2 la estructura de una neurona.

El cerebro humano tiene la capacidad de procesar a una enorme rapidez gran cantidad de señales provenientes de los sentidos. Es capaz de mezclarlas o relacionarlas con información pasada y dar respuestas adecuadas, aún en situaciones nuevas. Lo más destacable es la habilidad de aprender a entregar información o respuestas sin la necesidad de instrucciones explícitas. (Rodríguez, 2016)

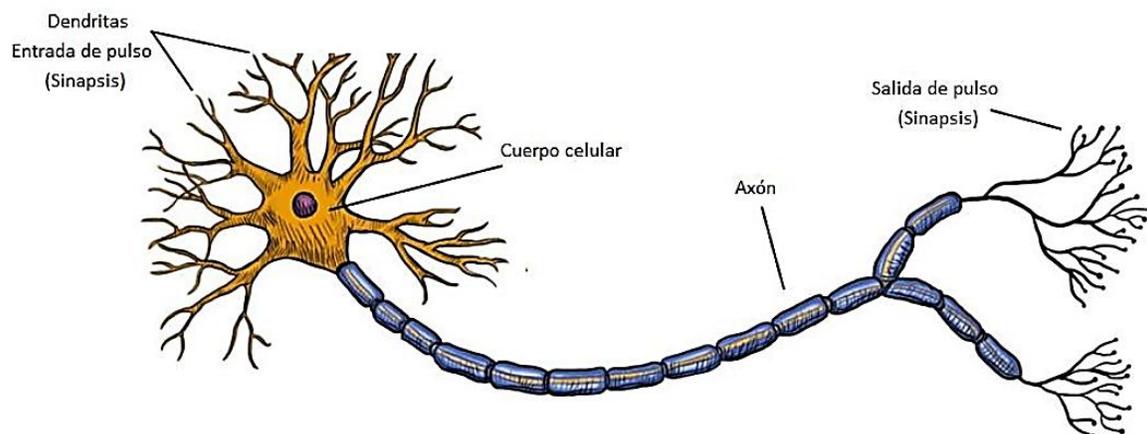


Figura 2: Célula Nerviosa

Fuente: Rodríguez, 2016

En términos biológicos, el aprendizaje de la red neuronal se genera en el momento en que el impulso es o no aceptado por la neurona receptora, es decir, el aprendizaje se genera en la

sinapsis. La codificación del aprendizaje se ve cuando los neurotransmisores inhiben o excitan la neurona, lo cual cambia el grado de influencia que ciertas neuronas tienen sobre otras. Por lo tanto, la estructura de la red y las conexiones neuronales son las que finalmente caracterizan el conocimiento de la red (Rodríguez, 2016).

2.4.3. Características de las Redes Neuronales Artificiales

Puesto que a su naturaleza y estructura, las características de las redes neuronales artificiales se contempla gran nivel de semejanza con el cerebro. Es decir, tienen la capacidad de almacenar la experiencia, evaluar los casos anteriores con los nuevos, establecer patrones y tendencias que son características esenciales a partir de entradas que se convierte en información irrelevante, etc. Es por eso la importancia y aplicación del estudio de esta herramienta de inteligencia artificial (Matich, 2001).

2.4.4. Aprendizaje adaptativo

La capacidad de aprendizaje adaptativo es una de las más interesantes características que presentan las redes neuronales. Dicho de otro modo, aprenden a realizar tareas mediante un entrenamiento con ejemplos claros. Además las redes son adaptables por la capacidad de autoajustarse de los elementos procesales (neuronas) que constituyen el sistema. Son dinámicos, porque tienen la capacidad de ir adaptándose a las nuevas condiciones que se presenten.

2.4.5. Autoorganización

Se usa la capacidad adaptativa de la red neuronal para autoorganizar la información que recibe durante el proceso de aprendizaje y/o la operación. El aprendizaje es la adaptación de los elementos al sistema, la autoorganización radica en modificar completamente la red neuronal. Cuando se usan las redes neuronales para el reconocimiento de patrones, son capaces de ir

autoorganizando a la información que ya ha sido usada, como por ejemplo la red Backpropagation genera una representación de sí misma para reconocer los patrones.

2.4.6. Tolerancia a fallos

Los primeros métodos computacionales con la capacidad propia de tolerancia a fallos son las redes neuronales. Comparándolos con los sistemas computacionales tradicionales que cuando sufren un pequeño error pierden completamente su funcionalidad, mientras que las redes neuronales con un pequeño error en sus neuronas no influyen completamente en la operatividad del sistema.

Existen dos enfoques muy importantes en la tolerancia a fallos: el primero, la red aprende a reconocer factores respecto a los datos de patrones incompletos y/o distorsionados. El segundo puede continuar funcionando aunque está afectada parte de la red.

La razón por la que las redes neuronales son tolerantes a fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento. La mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos almacenan cada pieza de información en un espacio único, localizado y direccionable. Las redes neuronales almacenan información no localizada, por tanto, la mayoría de las interconexiones entre los nodos de la red tendrán unos valores en función de los estímulos recibidos, y se generará un patrón de salida que represente la información almacenada (Matich, 2001).

2.4.7. Operación en tiempo real

La prioridad en la mayoría de las aplicaciones es realizar procesos con datos de manera muy rápida. Por lo que se adaptan bien las redes neuronales por su ejecución paralela. Los cambios

deben ser mínimos en los pesos de las conexiones o entrenamientos para que las redes puedan operar en escenarios de tiempo real.

2.4.8. Fácil inserción dentro de la tecnología existente

Por la facilidad y rapidez con la que se puede entrenar, comprobar, verificar y trasladar a una implementación las redes neuronales son adecuadas para ser insertadas dentro de aplicaciones ya existentes, con la finalidad de usarlas para el mejoramiento de sistemas donde cada paso pueda ser evaluado antes de ser puesto a un amplio desarrollo.

2.5. Modelo de una red neuronal

Partiendo de la similitud de la realidad biológica de las redes neuronales se podría clasificar los modelos de la siguiente manera:

- El modelo de tipo biológico. Se trata de simular los sistemas neuronales biológicos, relacionando principalmente a las funciones básicas auditivas y de visión.
- El modelo dirigido a aplicación. La finalidad de la aplicación de este modelo es ligar el diseño de los sistemas neuronales con las necesidades del uso de la inteligencia artificial en la resolución de problemas enfocados a simular la realidad.

2.5.1. Propiedades de las redes neuronales

De acuerdo a Bonilla, 2005 entre las propiedades más sobresalientes de las redes neuronales, se tienen las siguientes:

- No linealidad: es la capacidad para simular y predecir procesos no lineales.
- Generalización: tiene la capacidad de aprendizaje, autoorganizarse y generalizar, dicho de otra forma, de hallar resultados satisfactorios para inputs que no han sido tenidos en cuenta en la fase de entrenamiento.

- Adaptabilidad: la flexibilidad para adaptar los pesos sinápticos ante los cambios en el entorno permite representar procesos y sistemas dinámicos muy complejos. Son apropiadas para funcionamiento en tiempo real.
- Tolerancia a fallos: se puede redistribuir la operación sobre su estructura en paralelo, ya que están en la capacidad de aprender a reconocer patrones con ruido, incompletos o distorsionados.
- Fácil inserción dentro de la tecnología existente: se pueden conseguir chips especializados para redes neuronales que mejoran sus tareas.
- Confiabilidad: es la valoración del nivel de confianza obtenido con la respuesta.

2.5.2. Elementos básicos de componen una red

El esquema de la siguiente figura representa una red neuronal:

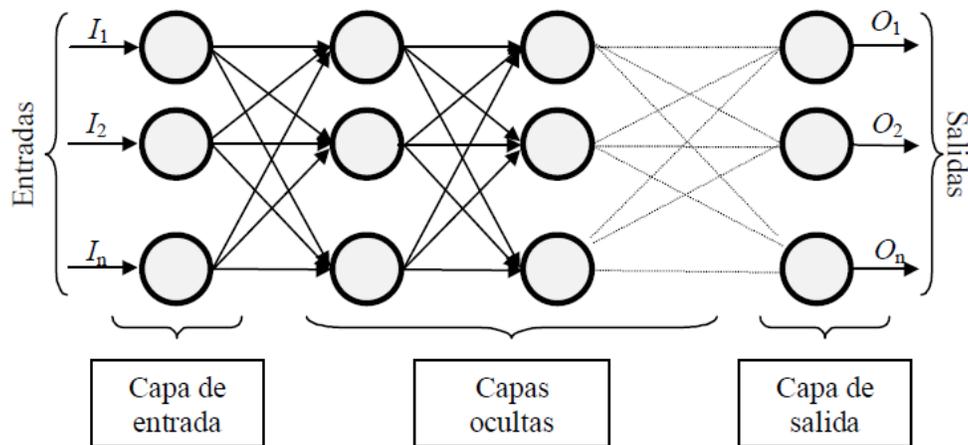


Figura 3: ejemplo de una red neuronal totalmente conectada.

Fuente: Match, 2001

La red está constituida por neuronas interconectadas y conformadas en tres capas (el número de capas puede variar), la información ingresa por la primera capa de entrada, pasando a través

de la capa oculta y salen por la capa de salida. La capa oculta puede estar constituida por varias capas.

Las neuronas artificiales se conocen también como unidades de proceso, y su funcionamiento es simple, pues consiste en recibir las entradas de las neuronas vecinas y calcular un valor de salida, el cual es enviado a todas las células restantes. Existen tres tipos de células o unidades: (Hilera & Martínez, 2000).

- Neuronas de entrada: reciben señales desde el entorno; estas entradas (que son a la vez entradas a la red) provienen generalmente de una serie de tiempo con datos anteriores al que se pretende predecir, resultado generalmente de preprocesamientos tales como normalizaciones, derivadas, umbralizaciones, entre otros.
- Neuronas de salida: Las unidades de salida envían una señal fuera de la red; en la aplicación de predicción la salida correspondería al valor futuro o estimado.
- Neuronas ocultas: Son aquellas cuyas entradas y salidas se encuentran dentro del sistema; es decir, no tienen contacto con el exterior. Las redes neuronales pueden aprender de experiencias que son provistas como entrada salida de la red sin necesidad de expresar la relación exacta entre la(s) entrada(s) y la salida, éstas pueden generalizar la experiencia aprendida y obtener la salida correcta cuando nuevas situaciones son encontradas.

2.5.3. Fase de entrenamiento

El proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar adecuadamente una tarea determinada. Durante el proceso de aprendizaje se va puliendo de forma iterativa la solución hasta alcanzar un nivel de operación suficientemente correcto como se muestra en la figura 4.

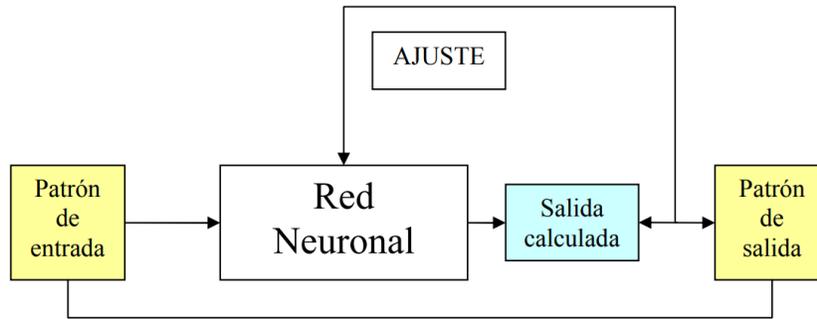


Figura 4: Esquema de funcionamiento de un proceso de aprendizaje supervisado

Fuente: (Isasi y Galván, 2004), (Yao, 1999).

El proceso de aprendizaje se puede dividir en tres grandes grupos de acuerdo con sus características (Isasi y Galván, 2004), (Yao, 1999).

2.5.3.1. El Algoritmo de Levenberg-Marquardt

Es un método iterativo para resolver problemas no lineales de estimación de parámetros por mínimos cuadrados. La técnica fue derivada primero por Levenberg modificando la norma ordinaria de mínimos cuadrados. Más tarde, Marquardt derivó básicamente la misma técnica mediante una estrategia diferente. La intención de Marquardt fue obtener un método que se encamine al método de Gauss en la vecindad del mínimo de la norma ordinaria de mínimos cuadrados y que tendiera al método del descenso infinito en la proximidad de la consideración inicial (Cortés, 2004).

2.5.4. Aprendizaje supervisado

Se presenta a la red un conjunto de patrones de entrada junto con la salida esperada. Los pesos se van modificando de manera proporcional al error que se produce entre la salida real de la red y la salida esperada, por lo que se debe modificar los pesos de las conexiones. En este caso, los

pesos se obtienen minimizando alguna función de error que mide la diferencia entre los valores de salida deseados y los calculados por la red. Hilera y Martínez (2000) distinguen asimismo entre:

- Aprendizaje por corrección de error. Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red.
- Aprendizaje por refuerzo. Basado en un conjunto ideal de comportamiento de una red similar, para que los ajustes de los pesos se adapten a las salidas deseadas.
- Aprendizaje estocástico. Partiendo del objetivo deseado consiste en evaluar los efectos del cambio aleatoriamente en los pesos de las conexiones de la red en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red.

2.5.5. Aprendizaje no supervisado

Se presenta a la red un conjunto de patrones de entrada. No hay información disponible sobre la salida esperada. El proceso de entrenamiento en este caso deberá ajustar sus pesos en base a la correlación existente entre los datos de entrada. Entre algunos métodos de aprendizaje no supervisado se encuentran los siguientes:

- Aprendizaje Hebbiano, que consiste en modificar los pesos de acuerdo con algún criterio de correlación entre las actividades neuronales (Hebb, 1949).
- Aprendizaje competitivo, donde las neuronas diferentes se conectan con pesos negativos que fuerzan una competición para ganar la actividad neuronal.

- Representación de características (feature mapping), que concierne a la ordenación geométrica de los vectores peso de las unidades competitivas (Kohohen, 1997).

2.5.6. Aprendizaje por refuerzo

Este tipo de aprendizaje se ubica entre los dos anteriores. Consiste en indicar si la salida es correcta o no, cuando inicialmente se ha ingresado un conjunto de patrones de entrada. Sin embargo, no se le proporciona el valor de la salida esperada. Caso particular en el que no se sabe exactamente los valores de la salida deseada.

2.6. Similitudes terminológicas entre Redes Neuronales Artificiales y Modelos estadísticos clásicos

Uno de los aspectos que han fomentado la idea errónea acerca de las diferencias entre RNA y estadística versa sobre la terminología utilizada en la literatura de ambos campos (Jain, y Ormsbee,2002). Recordemos que el campo de las RNA surge como una rama de la Inteligencia Artificial con una fuerte inspiración neurobiológica y su desarrollo ha sido debido a la contribución de investigadores procedentes de una gran variedad de disciplinas. A continuación, se presenta la tabla 2 en la que se pone de manifiesto que las RNA y la estadística utilizan términos diferentes para nombrar el mismo objeto (Sarle, 1994; Vicino, 1998).

Tabla 2: *Equivalencia en la terminología estadística y de redes neuronales*

Terminología estadística	Terminología de redes neuronales
---------------------------------	---

Observación	Patrón
Muestra	Datos de entrenamiento
Muestra de validación	Datos de validación, test
VARIABLES explicativas	VARIABLES de entrada
VARIABLES de respuesta	VARIABLES de salida
Modelo	Arquitectura
Residual	Error
Error aleatorio	Ruido
Estimación	Entrenamiento, aprendizaje
Interpolación	Generalización
Interacción	Conexión funcional
Coefficientes	Pesos de conexión
Constantes	Peso umbral
Regresión y análisis discriminante	Aprendizaje supervisado o hetero asociación
Reducción de datos	Aprendizaje no supervisado o auto asociación
Análisis de cluster	Aprendizaje competitivo

Fuente: (Sarle, 1994; Vicino, 1998).

2.7. Redes neuronales con conexión hacia delante

Las redes neuronales artificiales son muy efectivas para resolver problemas de difícil clasificación y reconocimiento de patrones. La más utilizada es la llamada de propagación hacia delante. La figura 5 muestra una red de propagación hacia delante con dos capas ocultas. El número de entradas es directamente dependiente de la información disponible para ser clasificada mientras que el número de neuronas de salida es igual al número de clases a ser separadas. Las unidades de una capa se conectan unidireccionalmente con las de la siguiente, en general todas con todas, sometiendo a sus salidas a la multiplicación por un peso que es diferente para cada una de las conexiones (Villada, Muñoz y García, 2012).

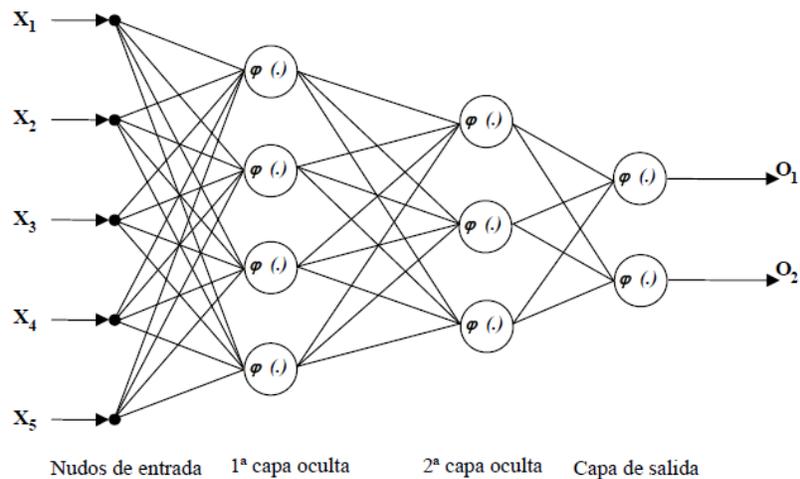


Figura 5: Red neuronal de propagación hacia adelante.

Fuente: (Villada, Muñoz y García, 2012)

2.8. Desarrollo de las Redes Neuronales con MATLAB

MATLAB permite construir aplicaciones en base a los resultados. La implementación de los modelos es extensamente relevante en diversas áreas de la industria. (MathWorks, 2018).

MATLAB permite desarrollar redes neuronales de forma sencilla. Con la creación de modelos de fácil y rápida visualización.

2.8.1. La clasificación y clustering de las redes

La finalidad de las aplicaciones en la industria es el desarrollo de una herramienta y de modelos dinámicos para la resolución de problemas.

El entrenamiento de redes neuronales aumenta su eficiencia cuando se tiene un adecuado preprocesamiento de la información. El análisis del rendimiento que se genera después de el procesamiento de la información es importante en la implementación de los modelos de inteligencia artificial.

Uno de los problemas generalmente presentados en el desarrollo de los modelos de redes neuronales es el sobreajuste. El sobreajuste se produce cuando hay entradas nuevas y la red tiene estudiado únicamente el conjunto de entrenamiento, generando errores en el entrenamiento de nuevas entradas.

Se soluciona mediante la modificación de la función de rendimiento para reducir el error en el entrenamiento. Además, con la revisión del preprocesamiento sin ruido de las nuevas entradas (MathWorks, 2018).

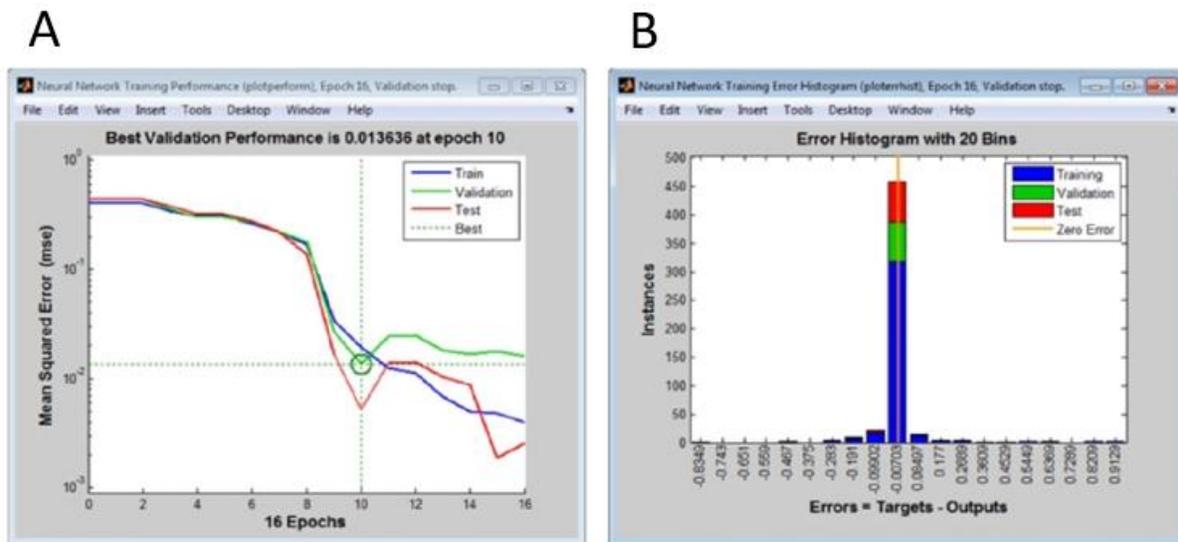


Figura 6: Gráficos de posprocesamiento para analizar el rendimiento de la red.

Fuente: <https://es.mathworks.com/discovery/neural-network.html>

En la figura 6 se presentan dos gráficas importantes en el posprocesamiento donde el gráfico A es la etapa de validación del modelo y la gráfica B es un Histograma del Error de la capa de salida.

CAPÍTULO III

3. DIAGNÓSTICO SITUACIONAL

EMAPA-I es una empresa que, a través de una administración eficiente, suministra servicios de agua potable y saneamiento con calidad, para mejorar las condiciones de vida de los habitantes del cantón, enmarcados en valores, principios y normativas vigentes.

La Empresa Municipal de Agua Potable y Alcantarillado de Ibarra, siguiendo fielmente los propósitos para los cuales fue creada. Hasta el 31 de diciembre de 1973, instaló el servicio de agua potable en 17 de las 18 parroquias e inició la construcción de los sistemas de alcantarillado, según los estudios prioritarios que hasta ese entonces se tenían.

Uno de los aspectos que con más detenimiento ha tratado de llevar adelante la Empresa es la concienciación del ciudadano ibarreño de que estos servicios no pueden, ni deben ser gratuitos, razón por la cual tiene que convertirse en un ente positivo en bien de la comunidad al reconocer que las inversiones realizadas tienen que ser recuperables y, más que eso, tienen que ser mantenidas por medio de retribuciones establecidas, a través del cobro de las tarifas, mismas que aseguran la permanencia y buen funcionamiento de estos servicios.

EMAPA-I de acuerdo con la Secretaria del Agua del Ecuador se alinea a los objetivos de desarrollo sostenible de las Naciones Unidas que radican en ofrecer acceso libre y equitativo de agua potable y servicio de saneamiento, con la finalidad de administrar eficientemente los recursos hídricos y así abastecer de manera sostenible a la sociedad. Además, maneja un enfoque ambientalista que protege y restablece los ecosistemas relacionados con el agua.

En el departamento de Agua No Contabilizada de EMAPA-I se elabora el análisis de oferta y demanda que ayuda a obtener la predicción de niveles de agua no contabilizada (pérdida de agua) en un periodo determinado. La predicción de agua no contabilizada se obtiene de la diferencia entre los pronósticos de demanda de agua producida y demanda de agua facturada. Dicha unidad se encarga de mitigar los factores que aportan al deterioro del sistema de distribución de agua, que pueden ser de varios tipos: físicos, operacionales, y ambientales, etc.

La empresa realiza las actividades conforme señala la Secretaria del Agua con sus leyes, normas y reglamentos. Por lo cual se realiza el análisis de la demanda de todo el cantón no se sectoriza por parroquias para tener un mejor enfoque en cuanto a la planificación.

Para la investigación se ha tomado en cuenta la zona de Caranqui sectorizando como se muestra en la figura 7, la cual no cuenta con el pronóstico específico lo que podría ayudar a evitar imprecisiones al predecir el consumo de agua potable, lo que podría generar gastos innecesarios en insumos para la potabilización, materiales para el mantenimiento y reparación, además del control de calidad y herramientas para desarrollar los trabajos. Se pueden ver afectadas las actividades de la empresa en mediano y largo plazo por las imprecisiones y la finalidad de pronosticar es reducir los gastos en el nivel que sea posible.

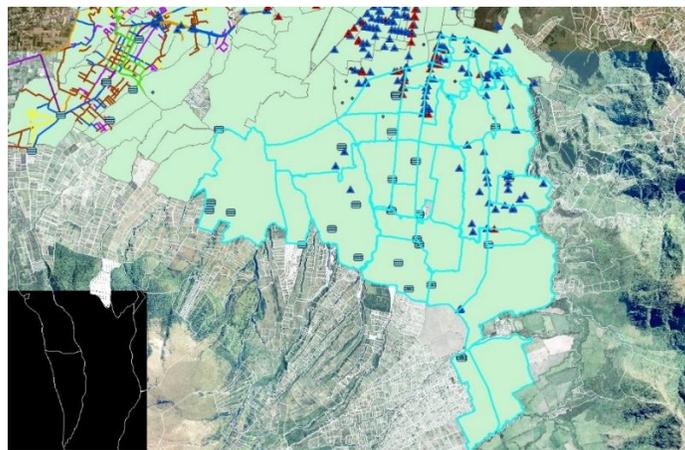


Figura 7: Sectorización de estudio

Fuente: Propia

Basándose en la Norma para estudio y diseños de sistemas de agua potable y disposición de aguas residuales para poblaciones mayores a 1000 habitantes (CO 10.07 - 601). La finalidad de la norma es conseguir que los diseños de los sistemas de abastecimiento de agua potable y de

eliminación de aguas residuales se ejecuten dentro del marco técnico legal adaptándose a la realidad ecuatoriana.

Ya que se constituye como un conjunto de criterios básicos de diseño para el desarrollo de proyectos de abastecimiento de agua potable y de alcantarillado y tratamiento de aguas residuales con los que se busca la aprobación de los proyectos.

Las etapas básicas que debe cumplir un proyecto en el cual influye el pronóstico de la demanda de un sistema de abastecimiento de agua potable son la prefactibilidad, la factibilidad y el proyecto definitivo. Los estudios de prefactibilidad se realizan con aproximaciones técnicas y económicas para tener en cuenta los costos de ejecución, operación y mantenimiento, en cambio en el estudio de factibilidad se realizan más profundamente señalando factores específicos en el diseño como son los factores técnicos, económicos, sociales, financieros y jurídicos para elegir la mejor alternativa. Los proyectos definitivos cuentan con los documentos y cálculos necesarios para cumplir con el conjunto de detalles de las partes de construcción y operación.

El análisis de la demanda de agua potable que se realiza en la empresa se basa en la estimación de la población futura que en la norma establece que el cálculo de la población futura se hará mediante las proyecciones de crecimiento utilizando por lo menos tres métodos conocidos (proyección aritmética, geométrica, incrementos diferenciales, comparativo, etc.) que permitan establecer comparaciones. La población futura se escogerá finalmente tomando en consideración, aspectos económicos, geopolíticos y sociales que influyan en los movimientos demográficos. Además, de tomar como referencia datos estadísticos del último censo poblacional realizado en el país.

Tabla 3: *Valores iniciales para el cálculo de la demanda*

Población de diseño

Población (2010)=	181175	hab
Periodo de Diseño:	25	años
Tasa de crecimiento(r)	1,63%	
Población final:	271423	Hab
Población futura(corregida):	305229	Hab
Dotación IP (Periodo Inicial)	200	lts/hab/día
Dotación FP (Periodo Futuro)	230	lts/hab/día
KMD= Factor de mayoración máximo diario	1,20	URBANO
KMH= Factor de mayoración máximo horario	2,00	URBANO

Fuente. (EMAPA-I, 2018)

La dotación de agua consiste en la producción de agua para satisfacer las necesidades de la población y otros requerimientos, se fija en base a estudios de las condiciones particulares de cada población, considerando:

- Las condiciones climáticas del sitio
- Las dotaciones fijadas para los distintos sectores de la ciudad, considerando las necesidades de los distintos servicios públicos
- Las necesidades de agua potable para la industria
- Los volúmenes para la protección contra incendios
- Las dotaciones para lavado de mercados, camales, plazas, calles, piletas, etc.
- Las dotaciones para riego de jardines
- Otras necesidades, incluyendo aquellas destinadas a la limpieza de sistemas de alcantarillado, etc.

Y en caso de falta de información es aconsejable tomar en cuenta la siguiente tabla:

Tabla 4: Dotaciones recomendadas

Población (habitantes)	Clima	Dotación media futura (l/hab/día)
Hasta 5000	Frío	120 – 150
	Templado	130 – 160
	Cálido	170 – 200
5000 a 50000	Frío	180 – 200
	Templado	190 – 220
	Cálido	200 – 230
Más de 50000	Frío	> 200
	Templado	> 220
	Cálido	> 230

Fuente. (Norma CO 10.07 - 601)

Para determinar la dotación se debe aplicar una investigación cualitativa de los aspectos como el costo de consumo de agua, hábitos de consumo y la disponibilidad hídrica del recurso.

La variación de consumo se debe de medir mediante la siguiente fórmula:

El consumo medio anual diario (en m³/s):

$$Q_{med} = q N / (1\ 000 \times 86\ 400) \quad (6)$$

Donde:

q = dotación tomada de la tabla en l/hab/día

N = número de habitantes.

El requerimiento máximo correspondiente al mayor consumo diario se debe calcular por la fórmula:

$$Q_{max. día} = K_{max. día} \times Q_{med}$$

(7)

El coeficiente de variación del consumo máximo diario ($K_{max. día}$) debe establecerse en base a estudios en sistemas existentes, y aplicar por analogía al proyecto en estudio. En caso contrario se recomienda utilizar los siguientes valores establecidos en la Norma CO 10.07 - 601:

$$K_{max. día} = 1,3 - 1,5$$

El coeficiente de consumo máximo horario ($K_{max. hor}$) se establece en base al estudio o es recomendable usar los siguientes valores determinados en la Norma CO 10.07 - 601:

$$K_{max. hor} = (1 a 2,3)Q_{med}$$

Tabla 5: Cálculo de diseño de caudales y periodo

SIERRA(Imbabura)	CAUDALES DE DISEÑO FINAL DE PERIODO		
		Qm:	1218,80
	QMD:	1462,56	(Lts/seg)
	QMH:	2437,60	(Lts/seg)
(GEOMETRICO)			
	PERIODO DE DISEÑO:	Xo	24,27
	a	0,5	
	r	6%	

Fuente. (EMAPA-I, 2018)

Para el calculo de los caudales se toman en cuenta el caudal medio (Qm), el caudal máximo diario (QMD) y el caudal máximo horario (QMH).

$$X_o^1 = \frac{2,6*(1-a)^{1,12}}{r} + \frac{0,30*(1-a)*X_o^{0,85}}{r^{0,50}} \quad (8)$$

Ecuación de cálculo de periodo de diseño

Las dotaciones de agua contra incendios, así como el número de incendios simultáneos debe adoptarse según las indicaciones de la tabla de acuerdo a la Norma CO 10.07 - 601:

Tabla 6: *Dotaciones contra incendios*

Número de habitantes (en miles)	Número de incendios simultáneos	Dotación por incendio (l/s)
5	1	10
10	1	10
25	2	10
50	2	20
100	2	25
200	3	25
500	3	25
1000	3	25
2000	3	25

Fuente. (Norma CO 10.07 - 601)

Para el diseño de las diferentes partes de un sistema de abastecimiento de agua potable, se usan los caudales que constan en la tabla 7:

Tabla 7: *Caudal de diseño para los elementos del sistema de agua potable*

Elemento	Caudal
Captación de aguas superficiales	Máximo diario + 20 %
Captación de aguas subterráneas	Máximo diario + 5 %
Conducción de aguas superficiales	Máximo diario + 10 %
Conducción de aguas subterráneas	Máximo diario + 5 %
Red de distribución	Máximo horario + incendio
Planta de tratamiento	Máximo diario + 10 %

Fuente. (Norma CO 10.07 - 601)

Volumen de almacenamiento

El volumen de regulación: en caso de no contar con los valores de la variación horaria, se debe de tomar en cuenta los siguientes valores que determina la Norma CO 10.07 - 601:

- a) Para poblaciones menores a 5 000 habitantes, se tomará para el volumen de regulación el 30% del volumen consumido en un día, considerando la demanda media diaria al final del período de diseño.
- b) Para poblaciones mayores de 5 000 habitantes, se tomará para el volumen de regulación el 25% del volumen consumido en un día, considerando la demanda media diaria al final del período de diseño.

El volumen contra incendios se debe tomar en cuenta lo siguiente:

- a) Para poblaciones de hasta 3 000 habitantes futuros en la costa y 5 000 en la sierra, no se considera almacenamiento para incendios.
- b) Para poblaciones de hasta 20 000 habitantes futuros se aplicará la fórmula $V_i = 50 \sqrt{p}$, en m^3 .

c) Para poblaciones de más de 20 000 habitantes futuros se aplicará la fórmula $V_i = 100 \sqrt{p}$, en m^3 . En estas fórmulas:

p = población en miles de habitantes

V_i = volumen para protección contra incendios, en m^3

Volumen de emergencia: Para poblaciones mayores de 5000 habitantes, se tomará el 25% del volumen de regulación como volumen para cubrir situaciones de emergencia. Para comunidades con menos de 5000 habitantes no se calculará ningún volumen para emergencias.

Volumen en la planta de tratamiento: El volumen de agua para atender las necesidades propias de la planta de tratamiento debe calcularse considerando el número de filtros que se lavan simultáneamente. Así mismo, se debe determinar, los volúmenes necesarios para contacto del cloro con el agua, considerando los tiempos necesarios para estas operaciones y para consumo interno en la planta.

Volumen total: El volumen total de almacenamiento se obtendrá al sumar los volúmenes de regulación, emergencia, el volumen para incendios y el volumen de la planta de tratamiento.

En las siguientes tablas se representa el cálculo del análisis de la demanda de agua potable realizado por la empresa.

Tabla 8: Cálculo de la población futura del sistema de agua potable

año	hab(Media geom)	hab(Media Aritm)	hab(Media exp)	Dotación	Perdidas	Qm	QMD	QMH	Dot_Incendio
2010	181175	181175	181175	200	45%	608,11	729,73	1216,22	20
2011	184128	184128	184152	201	45%	621,42	745,70	1242,83	20
2012	187129	187081	187179	202	44%	630,61	756,74	1261,23	20
2013	190180	190034	190255	203	44%	644,37	773,25	1288,75	20
2014	193280	192988	193381	204	44%	658,42	790,10	1316,83	20
2015	196430	195941	196559	205	43%	667,74	801,29	1335,48	20
2016	199632	198894	199789	206	42%	677,14	812,57	1354,28	20
2017	202886	201847	203073	208	41%	686,62	823,94	1373,23	20
2018	206193	204800	206410	209	40%	696,16	835,40	1392,33	20
2019	209554	207753	209802	210	39%	705,79	846,94	1411,57	20
2020	212970	210707	213250	211	38%	715,48	858,57	1430,96	20

Fuete. (EMAPA-I, 2018)

Tabla 9: Cálculo del caudal del sistema de agua potable

año	Dot_ Incendio	CAUDALES DE DISEÑO				VOLUMEN DE RESERVAS				
		1,05 Captación	1,05 Conducción	1,1 Tratamiento	1 Distribución	Vol_ Regulaci ón	Vol_ Incendio	Vol_ emerge ncia	Vol_ Tratamie nto	RESER VA
2010	20	766,22	766,22	802,71	1236,22	13135,19	1691,04	3283,80	45,00	18155,03
2011	20	782,98	782,98	820,27	1262,83	13422,57	1691,04	3355,64	45,00	18514,26
2012	20	794,57	794,57	832,41	1281,23	13621,26	1691,04	3405,31	45,00	18762,62
2013	20	811,91	811,91	850,57	1308,75	13918,49	1691,04	3479,62	45,00	19134,15
2014	20	829,61	829,61	869,11	1336,83	14221,81	1691,04	3555,45	45,00	19513,30
2015	20	841,35	841,35	881,42	1355,48	14423,22	1691,04	3605,80	45,00	19765,07
2016	20	853,20	853,20	893,83	1374,28	14626,26	1691,04	3656,57	45,00	20018,87
2017	20	865,14	865,14	906,33	1393,23	14830,92	1691,04	3707,73	45,00	20274,69
2018	20	877,17	877,17	918,94	1412,33	15037,16	1691,04	3759,29	45,00	20532,50
2019	20	889,29	889,29	931,64	1431,57	15244,98	1691,04	3811,24	45,00	20792,27
2020	20	901,50	901,50	944,43	1450,96	15454,34	1691,04	3863,59	45,00	21053,97

Fuete. (EMAPA-I, 2018)

Tabla 10: Resumen de los valores de caudal y población futura

TABLA RESUMEN												
ID	Año	Hab(Med exp)	Dotación	Perdidas	Qm	QMD	QMH	Oferta	Demanda	Déficit	Oferta	Demanda
								(Lts/seg)	(Lts/seg.)	(lts/seg)	(m ³ /año)	(m ³ /año)
0	2010	181175	200	45,00%	608	730	1216	523,78	730	-206	16517926,1	23012848,5
1	2011	184152	201	45,00%	621	746	1243	523,78	746	-222	16517926,1	23516340,8
2	2012	187179	202	44,00%	631	757	1261	523,78	757	-233	16517926,1	23864441,4
3	2013	190255	203	44,00%	644	773	1289	523,78	773	-249	16517926,1	24385188
4	2014	193381	204	44,00%	658	790	1317	523,78	790	-266	16517926,1	24916605,2
5	2015	196559	205	42,93%	668	801	1335	523,78	801	-278	16517926,1	25269476,6
6	2016	199789	206	41,86%	677	813	1354	523,78	813	-289	16517926,1	25625207,8
7	2017	203073	208	40,79%	687	824	1373	523,78	824	-300	16517926,1	25983764,4
8	2018	206410	209	39,71%	696	835	1392	523,78	835	-312	16517926,1	26345109,7
9	2019	209802	210	38,64%	706	847	1412	523,78	847	-323	16517926,1	26709204,3
10	2020	213250	211	37,57%	715	859	1431	523,78	859	-335	16517926,1	27076006,4

Fuente. (EMAPA-I, 2018)

Uno de los factores que afectan directamente en la predicción del consumo de agua potable es el desperdicio ocasionado por fugas ya sea por el deficiente uso de las instalaciones o de la falta de mantenimiento en las tuberías. La mayoría de los usuarios no son conscientes de la importancia del recurso hídrico que por la falta de conocimiento de preocupación por tener en cuenta aspectos en el hogar como llevar control del contador de agua, verificar el estado de los grifos y tuberías.

Los racionamientos y dosificación que se planifica la empresa en cuanto al consumo horario son imprescindible en temas de predicción y manejo de valores de la variación correspondientes, además de los cálculos que se realizan es importante tener en cuenta el factor de la experiencia ya que el resultado de esta actividad es brindar equitativamente el servicio de agua potable a todas las zonas de cobertura.

La problemática radica en proveer de agua potable a las zonas altas, para esto se toma en consideración que los tanques de agua deben cerrarse para que el sistema se vuelva a llenar y así compensar el nivel de agua dentro del mismo sistema para llegar hasta las zonas altas.

En el caso de que las plantas de producción de agua potable no cumplan con la totalidad de abastecimiento, las opciones más viables son la búsqueda de nuevas fuentes para agregarlas a la plata principal y la otra opción es tomar de otro sistema de distribución el déficit y complementarlo para que abastezca el consumo necesario.

Las proyecciones de consumo y de población o usuarios del servicio es muy importante para la creación o modificación de las nuevas tarifas que se aplicarían por el pago del consumo de agua potable, tomando en cuenta que en el país es un servicio subsidiado por el

estado y que es un factor muy importante en varias áreas de planificación y comercialización de la empresa.

Al buscar nuevas fuentes de agua cruda, se deben de realizar estudios técnicos, económicos y sociales de la fuente para obtener la concesión por parte de la Secretaria del Agua y así conseguir el poder para trabajar en esa fuente y explotar ese recurso hídrico de forma eficiente y sostenible. La proyección de la población y el consumo de agua potable ayudan a determinar el caudal que se utilizará de la fuente y que cubrirá el déficit o complementará el abastecimiento deseado.

En cuanto al financiamiento para los proyectos se toma en cuenta la proyección de la población, el caudal que se debe abastecer en el periodo de diseño para que así también se tenga en consideración el tema de mantenimiento del sistema de distribución. Para la inversión en una zona se relacionan factores mismos que se definen en el estudio técnico previo al desarrollo del proyecto.

CAPÍTULO IV

4. DESARROLLO DEL MODELO PARA EL PRONÓSTICO

El desarrollo del modelo de Redes Neuronales Artificiales tiene el fin de pronosticar la demanda de agua potable teniendo en cuenta las variables que se manejan como el volumen de agua potable consumido, siendo fundamental para determinar el horizonte temporal de la predicción y además el nivel de confiabilidad del modelo que influye en la toma de decisiones en la empresa.

Este modelo, la neurona j recibe una serie de entradas (X_1, X_2, \dots, X_n) las variables temporales de meses y años del volumen de consumo de agua potable. Donde cada señal de entrada debe multiplicarse por el peso asociado a su conexión (W_1, W_2, \dots, W_n) en dependencia de las ponderaciones que se encuentren en relación del proceso de aprendizaje. Luego, se suman estas entradas ponderadas y se les aplica la función de activación para devolver una salida a partir de los valores de entrada.

Para entender el funcionamiento de una red es necesario visualizar el esquema de arquitectura de una red. Las entradas a la red generan un enlace con la siguiente neurona que pueden pasar por la conexión de una capa oculta y esa salida se representa en función de la ponderación de la conexión de la neurona y la capa anterior, como se muestra a continuación.

$$S_{2j} = F_{2j}(X_1 W_{1j}) \quad (9)$$

X_1 es el vector de entradas de la capa 1 y W_{1j} corresponde a los pesos que relacionan a la primera neurona, a la neurona j de la segunda capa. La función F_{2j} es la función que corresponde a la de activación de la neurona j de la segunda capa. Así mismo

con las neuronas de la segunda capa. Cada neurona i de la capa de salida debe generar una salida de valor como podemos ver en la siguiente ecuación:

$$S_{si} = F_{si}(W_{2i}S_2) \quad (10)$$

Donde W_{2i} es el vector de pesos son relacionados a las conexiones que van de las neuronas de la segunda capa a la neurona i de la capa de salida, y S_2 es el vector de salidas de las neuronas de la capa dos, que a su vez se convierten en entradas de las neuronas de la capa de salida.

4.1. Algoritmo del modelo de pronóstico de la demanda de agua potable

En la figura 8 se muestra el algoritmo de la Red Neuronal Artificial para el pronóstico de la demanda de agua potable, en la misma se señala los factores importantes a tomar en cuenta como la identificación y preprocesamiento de la información con los cuales se analizará el horizonte temporal de la predicción. Una vez identificadas las variables se procede a aplicar la técnica de redes neuronales tomando en cuenta que valores se conforman los conjuntos de entrenamiento, validación y prueba y así de esta manera determinar la arquitectura que tendrá la red y con dichos criterios se lleva a cabo el entrenamiento del modelo de la Red Neuronal Artificial para el pronóstico de la demanda de agua potable.

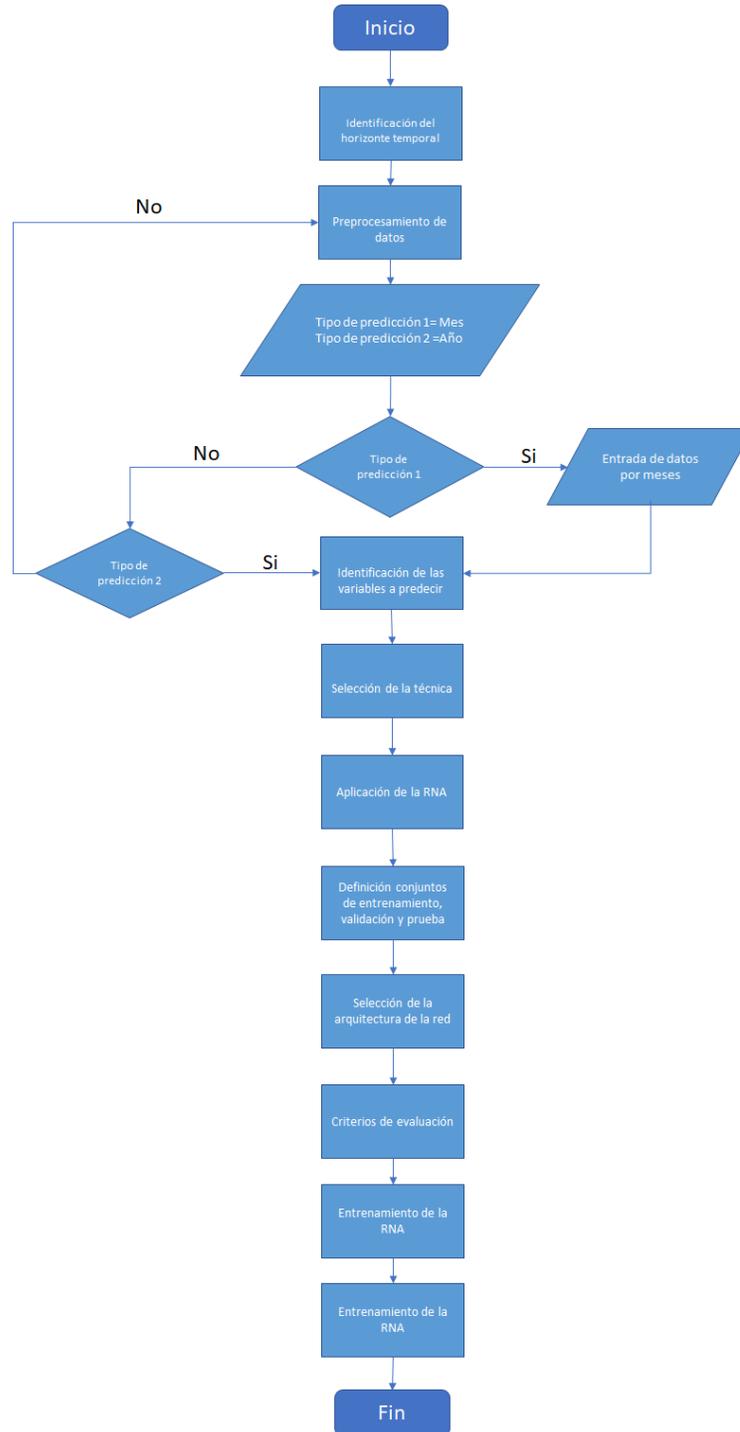


Figura 8: Algoritmo del modelo de RNA.

Fuente: Por el autor

4.2. Selección de la variable

Los datos técnicos de la demanda de agua potable en la elaboración del pronóstico son muy importantes por su valor decisivo en la predicción, por lo que las variables de entrada son fundamentales en el proceso.

- Variable a predecir: Cantidad de demanda de agua potable en la EMAPA-I
- Tipo de variable: Cuantitativa
- Unidad: Metro cúbico (m³)

4.3. Obtención de datos

Los clientes dependiendo del sector en el que se ubican, están codificados por un plan y la ruta del sistema de distribución. La sectorización para el caso de estudio es del sector de Caranqui que corresponde a los planes y rutas como se muestra en la siguiente tabla:

Tabla 11: Plan y ruta de distribución sector Caranqui

Plan						Ruta								
10	8	10	12	14	18									
14	2	4	6	8	10	12	14	16	18					
15	2	4	6	8										
16	18	20	22	24										
36	2	4	6	8	10	12	14	16	18	20	22	24	26	28

Fuente. Por el autor

En base al plan y la ruta de distribución se ordenan y agrupan los datos partiendo de una matriz general de clientes a los cuales brinda el servicio EMAPA-I, de cada año los datos se recopilan como se muestra a continuación:

Tabla 12: Sectorización 2017 Volumen de consumo (m³)

	10	14	15	16	36	TOTAL
Enero	49972	45273	43322	37872	37749	214188
Febrero	55245	46993	37647	34786	34071	208742
Marzo	51171	44926	39926	38217	39588	213828
Abril	51581	45645	40402	35880	36456	209964
Mayo	51322	45999	39439	35759	34636	207155
Junio	51767	45430	38892	36554	38018	210661
Julio	52490	46557	41635	37524	38232	216438
Agosto	51240	44396	38915	36359	44731	215641
Septiembre	53544	47286	43939	41518	37612	223899
Octubre	55722	49763	41419	38684	39485	225073
Noviembre	50273	45510	40313	39167	39847	215110
Diciembre	52145	44142	37552	33809	33808	201456
TOTAL	626472	551920	483401	446129	454233	2562155

Fuente. Por el autor

En la tabla 13 se muestra la recopilación de los datos de los clientes abonados correspondientes a cada plan y ruta como posteriormente se había realizado con el volumen consumido.

Tabla 13: Sectorización 2017 clientes abonados

	10	14	15	16	36	TOTAL
Enero	1653	2413	1796	902	1900	8664
Febrero	1677	2428	1789	903	1901	8698
Marzo	1673	2432	1810	927	1895	8737
Abril	1661	2424	1803	901	1904	8693
Mayo	1659	2438	1793	911	1885	8686
Junio	1656	2449	1807	918	1908	8738
Julio	1677	2474	1830	933	1945	8859
Agosto	1703	2525	1861	950	1973	9012
Septiembre	1706	2526	1862	954	1967	9015
Octubre	1720	2529	1874	952	1974	9049
Noviembre	1721	2523	1873	953	1957	9027
Diciembre	1717	2494	1865	944	1942	8962
TOTAL	20223	29655	21963	11148	23151	106140

Fuente. Por el autor

4.4. Preprocesamiento de la información

En este caso es necesario realizar el preprocesamiento de los datos antes de ingresarlos al software para que se hallen en un formato libre de ruido (sin valores nulos o inconsistentes) con la finalidad de prepararlos para el desarrollo del pronóstico. Como se muestra en las tablas 14 y 15 los datos tabulados del sector de Caranqui de abonados y volumen consumido desde el 2013 hasta el 2017.

Tabla 14: *Resumen de volumen consumido*

Mes	Volumen consumido (m ³)				
	2017	2016	2015	2014	2013
Enero	214188	1089767	4396911	4131349	3928938
Febrero	208742	923892	3691402	3710167	3719853
Marzo	213828	984884	3973450	3701854	3402837
Abril	209964	969027	3842442	3655319	3681741
Mayo	207155	974981	3988776	3840875	3757560
Junio	210661	988781	3996753	3739800	3549555
Julio	216438	1039832	4246655	3832171	3842532
Agosto	215641	1036875	4214157	4091927	3834200
Septiembre	223899	947316	3708790	4051405	3824123
Octubre	225073	1103062	4537799	3974116	4019610
Noviembre	215110	1028107	4124829	3934271	3865487
Diciembre	201456	938876	3739104	3540789	3524104
TOTAL	2562155	12025398	48461068	42072694	44950540

Fuente. Por el autor

Tabla 15: Resumen de clientes abonados

Mes	Abonados				
	2017	2016	2015	2014	2013
Enero	8664	8310	7867	7378	7038
Febrero	8698	8330	7841	7434	7059
Marzo	8737	8411	7943	7435	7052
Abril	8693	8373	7902	7435	7085
Mayo	8686	8323	7927	7459	7134
Junio	8738	8400	8028	7474	7135
Julio	8859	8486	8121	7596	7251
Agosto	9012	8622	8191	7633	7311
Septiembre	9015	8676	8242	7676	7409
Octubre	9049	8678	8329	7676	7437
Noviembre	9027	8676	8328	7642	7447
Diciembre	8962	8671	8224	7666	7465
TOTAL	106140	101952	96943	71798	86823

Fuente. Por el autor

4.5. Definición del conjunto de Entrenamiento, Validación y Prueba

4.5.1. Conjunto de entrenamiento

Es el conjunto de datos que a la red le servirán para aprender las tendencias y patrones de los datos, es decir los pesos de la red. En este caso es el 70% de los datos que representa los primeros 42 meses.

4.5.2. Conjunto de validación

Básicamente se utiliza para la etapa de comprobación conclusiva de la red, donde los datos son los valores consecuentes a los del entrenamiento que en este caso representan el 15% de los valores que son los 9 meses siguientes.

4.5.3. Conjuntos de prueba

Son los datos restantes luego de tomar los valores en el proceso de entrenamiento. La finalidad de este conjunto es de evaluar la precisión de la red. Está compuesto de los últimos 9 meses que representan el 15% de los datos.

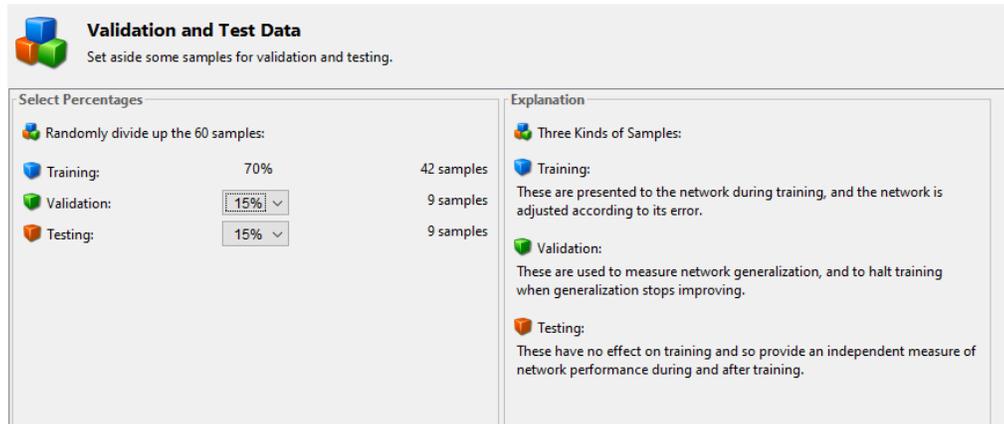


Figura 9: Porcentajes de muestra de datos de la red

Fuente: Matlab, 2015

4.6. Selección de la Arquitectura de la Red Neuronal

Existen muchas formas de establecer la arquitectura de una red neuronal, en la mayoría de los casos se emplean algoritmos de entrenamiento backpropagation. En este caso se utilizará el algoritmo de retropropagación Levenberg Marquardt.

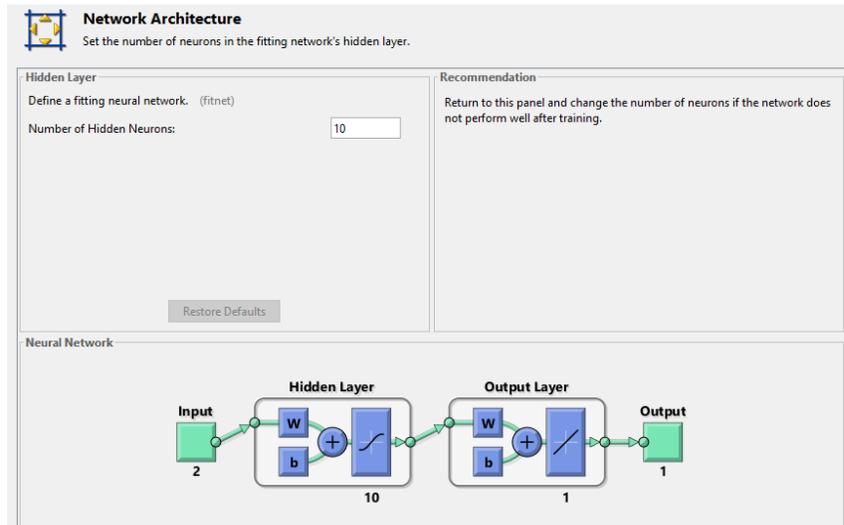


Figura 10: Arquitectura de la red.

Fuente: Matlab, 2015

4.6.1. Número de neuronas de entrada

Corresponde a las variables de entrada para el pronóstico de agua potable que en este caso son dos como se muestra en la figura 10.

4.6.2. Número de capas ocultas

Se muestran 1 capa oculta para que se genere un mejor desempeño ya que con el incremento de capas ocultas se incrementa el tiempo de procesamiento y se obtiene un sobreajuste provocando un deficiente desempeño de la predicción.

4.6.3. Número de neuronas ocultas

En este caso son 10 neuronas ocultas que representan la condición necesaria para que el principio de minimización de entropía se conserve en presencia de la retropropagación.

4.6.4. Número de neuronas de salida

El número de neuronas de salida en nuestra red es una, porque se predice el valor de la variable seleccionada para que no se disminuya la precisión de red.

4.7. Selección del algoritmo de entrenamiento

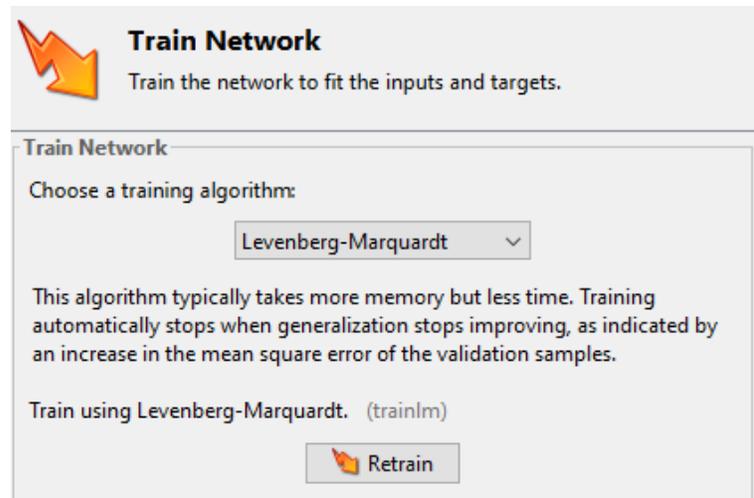


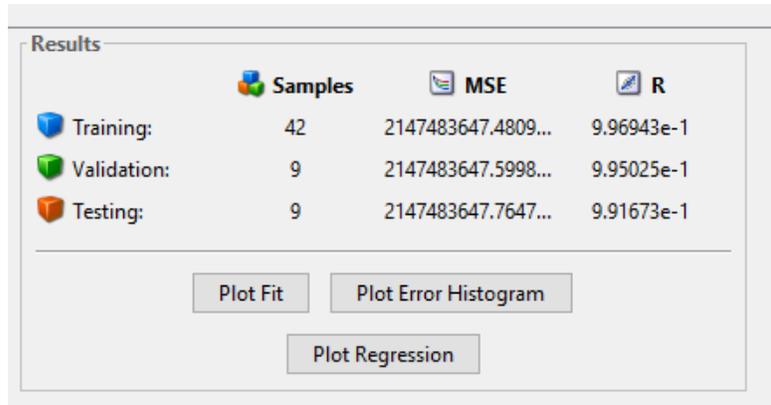
Figura 11: Selección del algoritmo de entrenamiento

Fuente: Matlab, 2015

El algoritmo de retropropagación Levenberg Marquardt está diseñado específicamente para minimizar la función del error cuadrático medio (MSE) con respecto al nuevo peso de los vectores.

El desempeño (*performance*) del entrenamiento se detiene cuando la generalización deja de mejorar por un aumento en el MSE de las muestras de validación

4.8. Criterios de evaluación



The screenshot shows a 'Results' window with a table of metrics. The table has four columns: 'Samples', 'MSE', and 'R'. The rows are 'Training', 'Validation', and 'Testing'. Below the table are three buttons: 'Plot Fit', 'Plot Error Histogram', and 'Plot Regression'.

	Samples	MSE	R
Training:	42	2147483647.4809...	9.96943e-1
Validation:	9	2147483647.5998...	9.95025e-1
Testing:	9	2147483647.7647...	9.91673e-1

Figura 12: Entrenamiento de la red para ajustar las entradas y objetivos

Fuente: Matlab, 2015

El significado del error cuadrado (MSE) en el entrenamiento es la diferencia cuadrada promedio entre salidas y objetivos. Los valores bajos son mejores mientras más cercanos a cero significa que no hay error. El análisis de regresión R se realiza para medir la correlación entre salidas y objetivos.

4.9. Entrenamiento de la Red Neuronal

El objetivo del entrenamiento es encontrar el mínimo error de la función de los pesos entre las neuronas a menos de que se tenga un modelo sobre ajustado. El entrenamiento usa una técnica de gradiente descendente del algoritmo de retropropagación.

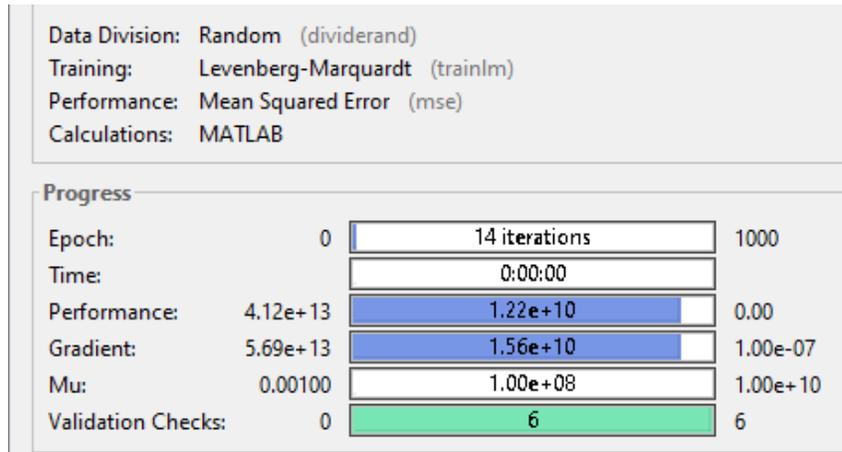


Figura 13: Resultados del algoritmo

Fuente: Matlab, 2015

4.10. Diagramas

Para concluir con la implementación del modelo presentan las gráficas de desempeño de la red:

En la figura 14 se muestra como el error en el entrenamiento va disminuyendo a través de las iteraciones

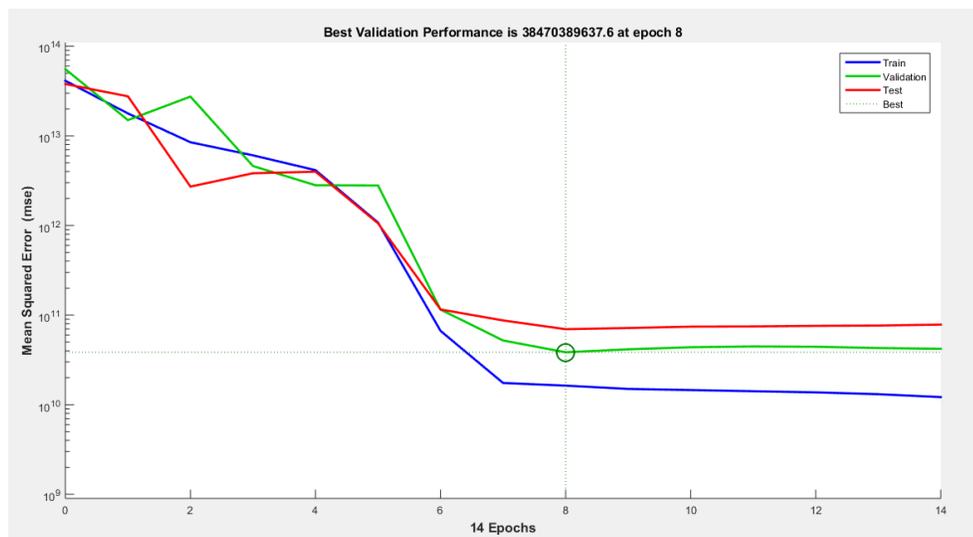


Figura 14: Performance del entrenamiento

Fuente: Matlab, 2015

En la figura 15 podemos apreciar como el coeficiente de correlación es de 0,99493 que es muy cercano a 1 lo que indica que existe un alto nivel de correlación entre los valores reales y los pronosticados.

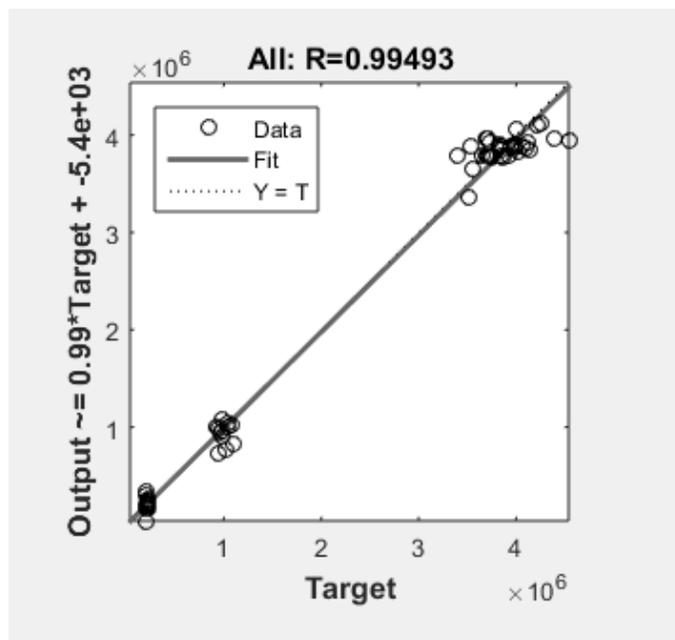


Figura 15: Correlación entre valores reales y pronóstico.

Fuente: Matlab, 2015

4.11. Resultados del modelo de pronóstico

Los resultados de la predicción con el modelo de redes neuronales en Matlab de los datos de la zona de Caranqui son los siguientes.

Tabla 16: *Pronóstico consumo volumen de agua potable (m³) Caranqui*

Mes	2018	2019
Enero	279560	295250
Febrero	286170	313890
Marzo	298170	343340
Abril	318360	383400
Mayo	282660	428160
Junio	235660	326980
Julio	279600	346640
Agosto	277950	312960
Septiembre	320950	328900
Octubre	316970	282660
Noviembre	155180	328950
Diciembre	320950	383400

Fuente. Por el autor

CAPÍTULO V

5. ANÁLISIS DE LOS RESULTADOS

Los resultados del modelo de pronóstico de la demanda de agua potable basado en Redes Neuronales Artificiales se analizan teniendo en cuenta los dos criterios importantes como es el Error Cuadrático Medio (MSE) y el índice de correlación (R) para compararlos con los del modelo de series de tiempo de Box-Jenkins SRT.

5.1. Interpretación de resultados

Los resultados analizados son sobre la variable de consumo de volumen de agua potable (m^3) de Ibarra, que consta de las zonas urbana y rural a las cuales brinda servicio la Empresa de Agua Potable y Alcantarillado de Ibarra.

En la tabla 17 se muestra el pronóstico del consumo como se muestra a continuación:

Tabla 17: *Pronóstico consumo volumen de agua potable (m^3) Ibarra*

	2017 REAL (m^3)	2018 (m^3)	2019 (m^3)
Enero	1.031.043	1.036.700	1.045.200
Febrero	964.803	995.580	1.023.300
Marzo	1.051.852	1.007.500	1.057.700
Abril	976.833	1.036.300	1.106.900
Mayo	984.244	1.056.200	1.137.200
Junio	1.027.504	1.075.200	1.142.300
Julio	1.030.985	1.099.000	1.131.300
Agosto	1.065.077	1.111.100	1.121.000
Septiembre	1.055.003	1.112.000	1.116.400
Octubre	1.087.140	1.100.300	1.109.800
Noviembre	1.068.179	1.061.000	1.086.700
Diciembre	930.510	976.830	1.014.000

Fuente: Por el autor

En la figura siguiente se muestra el comportamiento de la demanda de agua con respecto al 2017 y el pronosticado del 2018 y 2019, que muestra un comportamiento similar al real por lo cual visualmente se verifica que el pronóstico es correcto.

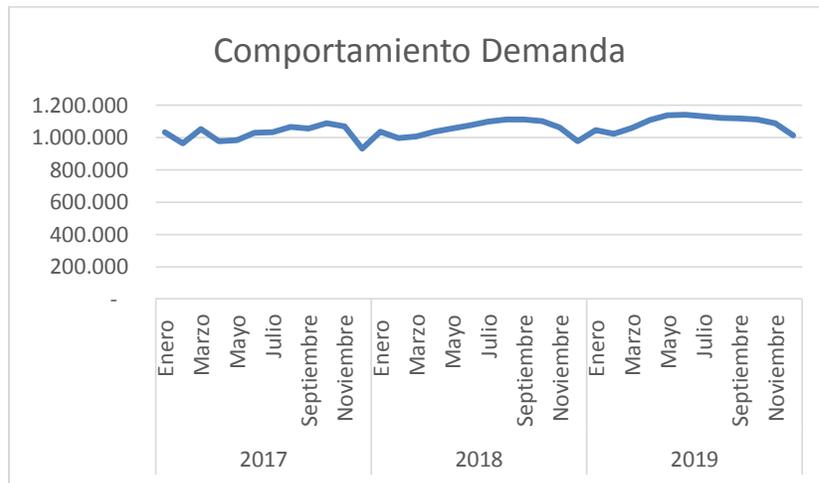


Figura 16: Comportamiento del consumo de agua potable

Fuente: Por el autor

En la figura 17 se muestra la proyección de la demanda de agua que señala como el incremento en cada año sube con respecto al mes del año anterior, que no es más que la respuesta al crecimiento poblacional que también genera un incremento en el consumo de agua potable en Ibarra.

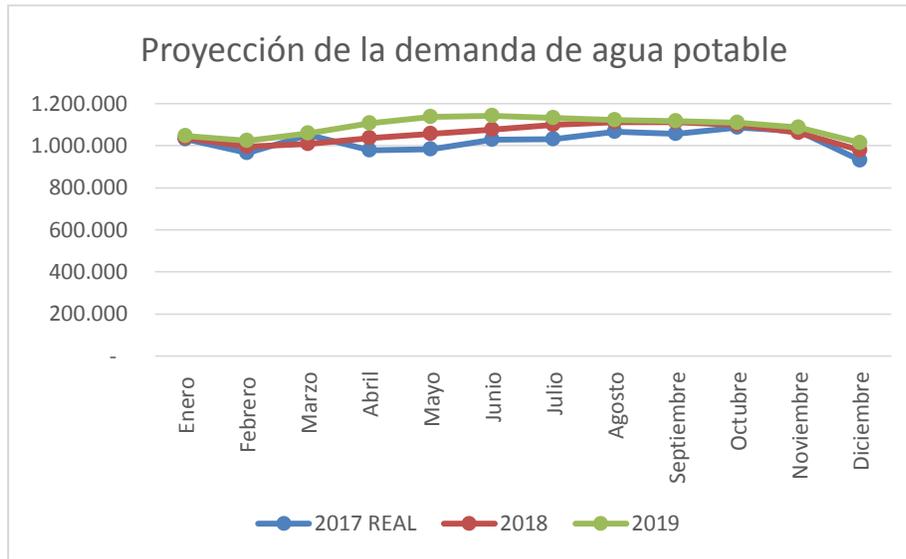


Figura 17: Proyección del consumo de agua potable

Fuente: Por el autor

5.2. Comparación del modelo de Redes Neuronales Artificiales

La comparación del modelo de Redes Neuronales Artificiales con el modelo de Box-Jenkins SRT (0,1,1), porque manejan los criterios que existen en las series de tiempo de tendencia aleatoria estacional.

Tabla 18: Comparación de pronósticos

	2017		2018		2019	
	REAL	Box-Jenkins SRT	NRA	Box-Jenkins SRT	NRA	
Enero	1.031.043	1.114.983	1.036.700	1.114.983	1.045.200	
Febrero	964.803	1.009.367	995.580	1.009.367	1.023.300	
Marzo	1.051.852	1.011.358	1.007.500	1.011.358	1.057.700	
Abril	976.833	1.013.350	1.036.300	1.013.350	1.106.900	

Mayo	984.244	1.015.341	1.056.200	1.015.341	1.137.200
Junio	1.027.504	1.017.333	1.075.200	1.017.333	1.142.300
Julio	1.030.985	1.019.324	1.099.000	1.019.324	1.131.300
Agosto	1.065.077	1.021.315	1.111.100	1.021.315	1.121.000
Septiembre	1.055.003	1.023.307	1.112.000	1.023.307	1.116.400
Octubre	1.087.140	1.025.298	1.100.300	1.025.298	1.109.800
Noviembre	1.068.179	1.027.290	1.061.000	1.027.290	1.086.700
Diciembre	930.510	1.029.281	976.830	1.029.281	1.014.000

Fuente. Por el autor

En la siguiente figura se muestran los comportamientos de la demanda de agua potable del 2017 y el pronosticado de 2018 y 2019 mediante las herramientas de Matlab con las Redes Neuronales Artificiales y el modelo de Box-Jenkins SRT con su análisis de predicciones.

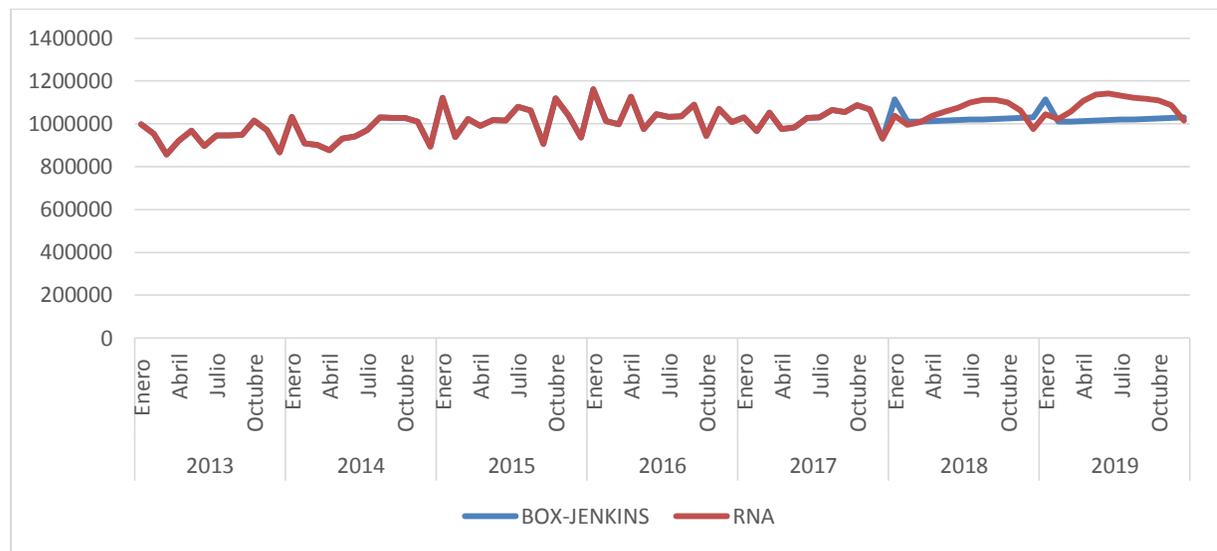


Figura 18: Comportamiento del consumo de agua potable RNA y el modelo de Box-Jenkins SRT.

Fuente: Por el autor

El pronóstico de las Redes Neuronales Artificiales se presenta con mayor equivalente en el comportamiento de la demanda real del consumo de agua potable de la empresa, ya que el comportamiento del pronóstico en el modelo de Box-Jenkins SRT tiende a suavizar y sobreajustar el modelo, esto por las medias móviles con las que se predice el modelo y tendencia a convertirse en una predicción de valores constantes. En el modelo de Redes Neuronales Artificiales los datos se auto entrenan y validan los patrones del comportamiento y al final se evalúan para progresivamente determinar la mejor opción de predicción. Se puede apreciar visualmente en la siguiente figura:

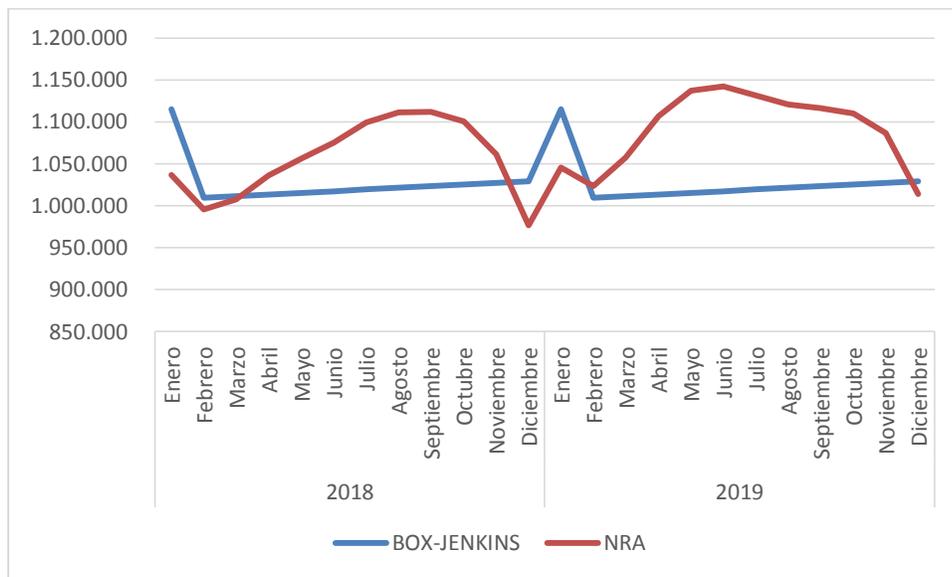


Figura 19: Comportamiento del pronóstico de agua potable

Fuente: Por el autor

La comparación del Error Cuadrático Medio entre el modelo de Redes Neuronales Artificiales y el modelo estadístico clásico de Box-Jenkins SRT, el criterio fundamental es que el error debe ser lo más cercano a cero los valores pronosticados son más cercanos a los

valores reales por lo que es evidente que el modelo de Redes Neuronales Artificiales con un 4,71% es mejor que el arrojado por el modelo Box-Jenkins SRT de 7,69% por ende es apreciable que usar el modelo de RNA brinda un nivel de confiabilidad mucho mayor que el expuesto por el modelo estadístico clásico como se muestra en la tabla 19.

En cuanto a la correlación entre el valor pronosticado y el real determina la fuerza y dirección de la relación entre dichos valores, mientras los valores de la correlación sean cercanos a 1 significa que los datos pronosticados se están comportando con mayor relación al sentido de los valores reales y como se muestra en la tabla 19 con el modelo de Redes Neuronales Artificiales la correlación es de 0,98 mientras que el valor de la correlación con el modelo de Box-Jenkins SRT es de 0,55 que indica una mejor relación en el sentido y fuerza del nivel de relación de los valores pronosticados con el modelo e RNA.

Tabla 19: *Comparación de pronósticos*

Modelo	MSE (%)	R
Red Neuronal Artificial	4,71	0,98
Box-Jenkins SRT	7,69	0,55

Fuente: Por el autor

CONCLUSIONES

- Con la elaboración del marco teórico referencial de la investigación se logró recolectar información suficiente para determinar la importancia del pronóstico en la industria, así también el empleo de las redes neuronales artificiales como técnica de predicción de datos complejos.
- Al determinar la situación actual de la empresa en cuanto la planificación que tiene el consumo de agua potable se determinó que se basaban las actividades en las normas establecidas por la Secretaría del Agua, donde se establecen las normas para diseño de y estudio de sistemas de agua potable con las respectivas proyecciones de consumo.
- Se utilizó las Redes Neuronales Artificiales como técnica de predicción para desarrollar el pronóstico de la demanda de agua potable, donde se analizaron las variables dependientes e independientes que se procesaron en la construcción de la red mediante los procesos de entrenamiento, validación y prueba de la red, obteniendo resultados que se comportan con mayor similitud al consumo real.
- El análisis y comparación de los resultados obtenidos con el modelo de Redes Neuronales Artificiales y el modelo estadístico tradicional de Box-Jenkins SRT, con la finalidad de reconocer las diferencias y similitudes en los modelos y facilitar la interpretación de los resultados donde los resultados arrojados por el modelo de RNA presenta mayor similitud en el comportamiento del consumo real, mientras que los resultados del modelo estadístico tradicional tiende a suavizarse y sobre ajustarse por

lo que se convierten en predicciones constante por el promedio móvil con el que se calculan.

RECOMENDACIONES

- Para lograr una investigación con una base robusta de referencias bibliográficas se debe complementar con mayor cantidad de artículos, libros e investigaciones similares para tomar en cuenta nuevas ideas que ya se han desarrollado o se pueden seguir estudiando y de esta manera darle mayor consolidación científica de la investigación.
- Contemplar la interacción de los resultados del pronóstico y cómo influye en la empresa entre los departamentos para tener en cuenta en la importancia de desarrollar un análisis adecuado de la demanda de agua potable en las actividades posteriores en los demás departamentos.
- La correcta interpretación de las variables y de las funciones objetivo dentro del modelo deben esclarecerse para tener un buen manejo de los resultados que se obtienen, buscando siempre el resultado con mejor correlación y mínimo error en la predicción.
- Contrastar los resultados obtenidos con el modelo de Redes Neuronales Artificiales con un modelo estadístico tradicional que ayudará a visualizar e interpretar los errores que pueden llegar a ocurrir y las tendencias que tendrá el pronóstico, para complementar la representación de los resultados.

BIBLIOGRAFÍA

Constitución de la República del Ecuador, 2008. Art 12.

INEC, Estadística Ambiental Económica en Gobiernos Autónomos Descentralizados, 2016.

Bowerman, B, R O'Connell y A Koehler. (2007). Pronósticos, Series Temporales y Regresión. Cuarta. México: Internacional Thomson Editores.

Galán Ordax, José M. Evaluación Integradora de Políticas de Agua: Modelado y Simulación con Sociedades Artificiales de Agentes, Tesis doctoral, Burgos, 2007 .

Hanke, J. y Wichern, D. (2006). Pronósticos en los negocios (8a Ed.) México: Pearson-Prentice Hall.

García, A. y Osella, G. (2003). Evolución de Redes Neuronales mediante sistemas de reescritura (tesis de pregrado). Universidad Nacional de la Plata. Argentina.

Rodríguez, N. 2016. Pronóstico de demanda de agua potable mediante redes neuronales. (Tesis pregrado). Universidad Técnica Federico Santa María, Valparaíso, Chile.

Colina, E. y Rivas, F. (1998). Introducción a la inteligencia artificial. Universidad de Los Andes. Mérida, Venezuela.

Matich, D. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional, Rosario, Argentina.

- Hilera, J. R., Martínez, V. J., (2000). Redes neuronales artificiales: fundamentos modelos y aplicaciones, 1ª ed., Editorial Alfaomega: Madrid.
- Yen-Chieh Ouyang and Li-Bin Yeh,(2001). “Predictive bandwidth control for mpeg video: A wavelet approach for self-similar parameters estimation,” in IEEE International Conference on Communications ICC 2001, vol. 5, pp. 1551–1555
- Sarle, W.S. (Ed.) (1998). Neural network FAQ. Periodic posting to the Usenet newsgroup comp.ai.neural-nets, URL: <ftp://ftp.sas.com/pub/neural/FAQ.html>.
- Vicino, F. (1998). Some reflections on artificial neural networks and statistics: two ways of obtaining solutions by working with data. Substance Use & Misuse, 33(2), 221-231
- Zabala, B. (2015). Pronóstico de demanda desagregado para una Empresa de productos de consumo masivo. Tesis Pregrado. Chile.
- Hyndman R., (2006). Another Look at Forecast: Accuracy Metrics for Intermittent Demand. Monash University, Australia.
- Villada, F., Muñoz, N. y Garcia, E., (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. Universidad de Antioquia, Colombia.
- Daza F., (2008). Demanda de Agua en zonas urbanas de Andalucía. Tesis Doctoral, Departamento de Estadística, Econometría, I.O y Organización de Empresas. Universidad de Córdoba, Argentina.
- Toro E., Mejía D., Salazar H., (2004). Pronóstico de Ventas usando Redes Neuronales. Redalyc Vol. X, n° 26, pp:25-30.

Sarmiento H., y Villa W., Inteligencia Artificial en el Pronóstico de la Demanda de Energía Eléctrica: Una aplicación en Optimización de recursos energéticos. Revista Colombiana de Tecnologías de Avanzada Vol. 2, n° 12 (2008).

O'Hagan, A. y Forster, J. (2004). Bayesian Inference. Kendall's Advanced Theory of Statistics. London: Arnold.

Pruzek. R.M. (1997). An introduction to bayesian inference and its applications. En L. L. Harlow, S. A. Mulaik y J. H. Steiger (Eds.). What if there were no significance tests? (pp. 287-318). Mahwah, NJ: Lawrence Erlbaum

McLean, A. (2001). Statistics in the catwalk. The importance of models in training researchers in statistics. En C. Batanero (Ed), Training Researchers in the Use of Statistics. Granada, Spain: International Association for Statistics Education and International Statistical Institute.

Hebb, D.O. (1949). The organization of behaviour. John Wiley and Sons. Nueva York.

Kohohen, T. (1997). Self-organizing maps. Springer-Verlag. Heidelberg.

Martí, P. (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. Tesis doctoral. Universidad Politécnica de Valencia. España.

MathWorks, (2018), párr. 20-27. Recuperado de: <https://es.mathworks.com/discovery/neural-network.html>

Isasi Viñuela, P., Galván León, I.M. (2004). Redes Neuronales Artificiales. Un enfoque Práctico. Prentice Hall

- Yao X (1999) Evolving Artificial Neural Networks. En Proceedings of the IEEE. Vol 87(9), pp.1423-1447.
- Leclerca, M., and T. B. M. J. Ouarda, (2007) Non-stationary regional flood frequency analysis at ungauged sites, J. Hydrol., vol.343, pp.254–265
- Sahoo, G. B., Schladow, S., Reuter, J. E. (2009).: Forecasting stream water temperature using regression analysis, artificial neural network, and chaotic non-linear dynamic models, J. Hydrol.,vol. 378, pp.325–342
- Bonilla, E., (2005). Reconocimiento de caracteres mediante redes neuronales con Matlab. (Tesis de pregrado) Escuela Politécnica Nacional, Quito Ecuador.
- Cortés, O., (2004), Aplicación del método de Levenberg-Marquardt y del gradiente conjugado en la estimación de la generación de calor de un aparato de placa caliente con guarda. (Tesis Posgrado) Centro Nacional de Investigación y Desarrollo Tecnológico. Morelos, México.
- Zhou, S. McMahon, A. Walton, y Lewis J., (2002). Forecasting operational demand for an urban water supply zone. J. Hydrol , vol. 259, pp.189–202.
- Firat, M., M. E. Turan, and M. A. Yurdusev, (2009).Comparative analysis of fuzzy inference systems for water consumption time series prediction, J. Hydrol., 374, 235–241
- Caiado, J, (2010). Performance of combined double seasonal univariate time series models for forecasting water demand, J. Hydrol. Eng., vol.15. n°3, 215–222.
- Jain, A., y Ormsbee, L., (2002). Short-term water demand forecast modeling techniques conventional methods versus AI, AWWA J., 94(7), 64–72.

- Herrera, M., Torgo, L. Izquierdo, J. y Pérez, R., (2010). Predictive models for forecasting hourlyurban water demand, *J. Hydrol.*, vol.387, pp.141– 150.
- Babel, M. Gupta, S. y Pradhan. P., (2007). A multivariate econometric approach for domestic water demand modeling: An application to Kathmandu, Nepal, *Water Resour. Manage.*, vol.21, pp.573–589.
- Adamowski, J., y Chan, H., (2011). A wavelet neural network conjunction model for groundwater level forecasting, *J. Hydrol.*, vol.407, pp.28–40.
- Ghiassi, M., Zimbra, D. K., y Saidane, H. ,(2008). Urban Water Demand Forecasting with a Dynamic Artificial. *Journal Of Water Resources Planning And Management.*, vol. 134, pp. 138-146.

ANEXOS

ANEXO 1. SECTORIZACIÓN VOLUMEN

Mes	Volumen facturado (m ³)				
	2017	2016	2015	2014	2013
Enero	214188	1089767	4396911	4131349	3928938
Febrero	208742	923892	3691402	3710167	3719853
Marzo	213828	984884	3973450	3701854	3402837
Abril	209964	969027	3842442	3655319	3681741
Mayo	207155	974981	3988776	3840875	3757560
Junio	210661	988781	3996753	3739800	3549555
Julio	216438	1039832	4246655	3832171	3842532
Agosto	215641	1036875	4214157	4091927	3834200
Septiembre	223899	947316	3708790	4051405	3824123
Octubre	225073	1103062	4537799	3974116	4019610
Noviembre	215110	1028107	4124829	3934271	3865487
Diciembre	201456	938876	3739104	3540789	3524104
TOTAL	2562155	12025398	48461068	42072694	44950540

ANEXO 2. SECTORIZACIÓN ABONADOS

Mes	Cantidad de abonados				
	2017	2016	2015	2014	2013
Enero	8664	8310	7867	7378	7038
Febrero	8698	8330	7841	7434	7059
Marzo	8737	8411	7943	7435	7052
Abril	8693	8373	7902	7435	7085
Mayo	8686	8323	7927	7459	7134

Junio	8738	8400	8028	7474	7135
Julio	8859	8486	8121	7596	7251
Agosto	9012	8622	8191	7633	7311
Septiembre	9015	8676	8242	7676	7409
Octubre	9049	8678	8329	7676	7437
Noviembre	9027	8676	8328	7642	7447
Diciembre	8962	8671	8224	7666	7465
TOTAL	106140	101952	96943	71798	86823
