

UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE CIENCIAS PURAS Y NATURALES
CARRERA DE INFORMÁTICA



TESIS DE GRADO

**“PREDICCIÓN DEL CONSUMO DE AGUA EN LA
CIUDAD DE LA PAZ MEDIANTE REDES NEURONALES
ARTIFICIALES”**

PARA OPTAR AL TÍTULO DE LICENCIATURA EN INFORMÁTICA
MENCIÓN INGENIERÍA DE SISTEMAS INFORMÁTICOS

POSTULANTE: Univ. Paola Alicia Quilla Garcia

TUTOR: Mg.Sc. Rosa Flores Morales

REVISOR: Lic. Brigida Carvajal Blanco

LA PAZ – BOLIVIA
2011

Dedicatoria

A Dios que me dio fortaleza para realizar este trabajo.

A mis padres que me acompañaron y apoyaron en todo momento.

A mis abuelos que siempre me apoyaron.

A mi mejor amigo, que me brindó siempre su apoyo, ánimo y colaboración.

A mis amig@s con los que compartí esta etapa de mi vida.

AGRADECIMIENTOS

Primeramente agradecer a mis padres José Luis y Flora, y a mis abuelos que me brindaron todo su apoyo durante este tiempo.

Agradecer especialmente a la MSc. Rosa Flores Morales por su comprensión, su conocimiento transmitido y por la disponibilidad de su tiempo a lo largo de la elaboración y culminación de este trabajo.

A la licenciada Brigida Carvajal Blanco por su colaboración y sus recomendaciones hechas en la revisión de este trabajo, y por su valioso tiempo.

Un agradecimiento especial al licenciado Lucio Torrico que siempre estuvo dispuesto a guiarme en mis dudas.

También agradecer a la carrera de Informática de la Universidad Mayor de San Andrés por su formación brindada a lo largo de estos años, en especial a todos los docentes.

Finalmente agradecer a todos mis amig@s, con los que compartimos muchos momentos lindos y siempre estuvieron a mi lado para apoyarme.

RESUMEN

El recurso agua es de vital importancia para la vida del hombre, pero este recurso se está volviendo escaso, por lo que es importante prever el consumo de agua para años futuros. En la ciudad de La Paz el consumo de agua se ha ido incrementando debido a factores como: el crecimiento poblacional, la contaminación de ríos, deshielo de los nevados, condiciones climatológicas, el mal uso del agua, las fugas en las redes de conexión y la falta de planes de gestión de los recursos hídricos.

Para realizar planes y gestiones sobre el recurso agua, es importante tener una herramienta que permita predecir qué cantidad de agua se consumirá a futuro. Las herramientas que brinda la inteligencia artificial en cuanto a predicción se ajustan a esta necesidad, en particular las redes neuronales artificiales. Las redes neuronales artificiales son herramientas que puede trabajar con información imprecisa, devolviendo datos sin ruido y reduciendo la incertidumbre.

En este trabajo se realiza el análisis de las variables que influyen en el consumo de agua, se diseña y desarrolla un modelo de predicción con redes neuronales tomando en cuenta variables como la población, la precipitación y temperatura media; también se desarrolla el modelado del consumo de agua con medias móviles ponderadas y finalmente, se comparan los errores que presentan ambos modelos, llegando a la conclusión que el modelo más preciso es el de las redes neuronales artificiales con un error absoluto porcentual de la media de 2,67 %, valor que es inferior al producido por el modelo de medias móviles ponderadas que es 2,76%.

Posterior al modelado, se realizó la predicción del consumo de agua con los dos métodos propuestos para los años 2011 y 2012, teniendo un error relativo máximo entre ambas predicciones del 7%.

Palabras Clave: Consumo de agua, Predicción del Consumo de Agua, Redes Neuronales Artificiales, Medias Móviles Ponderadas.

ÍNDICE ESPECÍFICO

CAPITULO I

MARCO REFERENCIAL

1.1. INTRODUCCIÓN	1
1.2. ANTECEDENTES	2
1.3. PLANTEAMIENTO DEL PROBLEMA	4
1.3.1. Problema General	5
1.4. HIPÓTESIS	6
1.5. OBJETIVOS	6
1.5.1. Objetivo General	6
1.5.2. Objetivos Específicos	6
1.6. JUSTIFICACIÓN	6
1.6.1. Justificación Social	6
1.6.2. Justificación Económica	6
1.7. METODOLOGÍA	7
1.8. LIMITES Y ALCANCES	7
1.8.1. Limites	7
1.8.2. Alcances	8
1.9. HERRAMIENTAS	8

CAPITULO II

MARCO TEORICO

2.1. EL RECURSO AGUA	9
2.1.1. GESTIÓN INTEGRADA DE LOS RECURSOS HÍDRICOS	9
2.1.1.1. Principios y marco de trabajo en el uso eficiente de agua	10
2.1.1.2. Conservación del agua	10
2.1.2. RELACIÓN ENTRE LA DEMANDA Y EL USO EFICIENTE DEL AGUA	10
2.1.3. ESTRATEGIAS PARA EL USO EFICIENTE DEL AGUA	12
2.1.4. GESTIÓN DE SERVICIO DE AGUA POTABLE Y SANEAMIENTO EN BOLIVIA	13
2.1.4.1. Marco legal y normativo	13
2.1.5. ASPECTOS GENERALES DE LAS ENTIDADES PRESTADORAS DE SERVICIO DE AGUA	15
2.1.6. FUNCIONES DE LAS ENTIDADES PRESTADORAS DE SERVICIO DE AGUA	15
2.1.7. AGUA POTABLE Y SANEAMIENTO EN LA CIUDAD DE LA PAZ	15
2.1.8. FACTORES QUE INFLUYEN EN EL CONSUMO DE AGUA POTABLE	18
2.2. METODOS DE PREDICCIÓN	20
2.2.1. INTRODUCCIÓN	20
2.2.2. TIPOS DE MÉTODOS DE PREDICCIÓN	20
2.2.3. MÉTODO DE SERIE TEMPORAL	21
2.2.3.1. Componentes de una serie de tiempo	22
2.2.4. MÉTODO DE MEDIAS MÓVILES	23

2.2.5. PRECISIÓN DEL PRONÓSTICO	26
2.3. REDES NEURONALES	28
2.3.1. INTRODUCCIÓN	28
2.3.2. ELEMENTOS BÁSICOS QUE COMPONEN UNA RED NEURONAL	28
2.3.3. FUNCIÓN DE ENTRADA	30
2.3.4. FUNCIÓN DE ACTIVACIÓN	31
2.3.5. FUNCIÓN DE SALIDA	32
2.3.6. MODELOS DE REDES NEURONALES	32
2.3.7. PERCEPTRÓN MULTICAPA	33
2.3.7.1. Arquitectura	34
2.3.7.2. Aprendizaje	35
2.3.7.2.1. Algoritmo backpropagation	36
2.3.8. MÉTODO DE VALIDACIÓN	39
2.3.9. VENTAJAS QUE OFRECEN UNA RED NEURONAL	39
2.4. METODOLOGIAS	41
2.4.1. METODOLOGIA PARA LA PREDICCIÓN CON REDES NEURONALES PREDICTIVAS	41
2.4.1.1. Preparación de los datos	41
2.4.1.2. Determinación de la arquitectura de la red	43
2.4.1.3. Diseño de la estrategia de aprendizaje o entrenamiento de la red	43
2.4.1.4. Evaluación global de los resultados de la predicción	43
2.4.2. METODOLOGIA DE DESARROLLO	44
2.4.2.1. Modelo en Cascada	44
CAPITULO III	
MODELADO DEL CONSUMO DE AGUA CON MEDIAS MÓVILES PONDERADAS	
3.1. INTRODUCCIÓN	46
3.2. PRESENTACION DE DATOS	46
3.3. MODELADO CON MEDIAS MÓVILES PONDERADAS	47
3.4. COMPARACIÓN DE DATOS	58
CAPITULO IV	
MODELADO DEL CONSUMO DE AGUA CON REDES NEURONALES ARTIFICIALES	
4.1. METODOLOGÍA PARA LA PREDICCIÓN CON REDES NEURONALES PREDICTIVAS	60
4.2. PREPARACIÓN DE LOS DATOS	60
4.2.1. Adquisición de los datos	60
4.2.2. Estructuración de los datos	64
4.2.3. Normalización de datos	65
4.2.4. División de los datos	67
4.3. DETERMINACIÓN DE LA ARQUITECTURA DE LA RED	69
4.3.1. Presentación de las pruebas para la Arquitectura de la Red Neuronal Artificial	70
4.4. DISEÑO DE APRENDIZAJE O ENTRENAMIENTO DE LA RED	71

4.5. METODOLOGIA DE DESARROLLO DE LA HERRAMIENTA	72
4.5.1. FASE DE ANÁLISIS DE LOS REQUISITOS	72
4.5.1.1. Casos de Uso	72
4.5.1.2. Descripción de casos de uso	73
4.5.1.3. Diagrama de Clases	75
4.5.1.4. Diagrama de Secuencia	76
4.5.2. FASE DE DISEÑO	78
4.5.2.1. Diagrama de Componentes	78
4.5.2.2. Diseño de la Red Neuronal Artificial	79
4.5.3. FASE DE CODIFICACIÓN	80
4.5.3.1. Código de la Red Neuronal	80
4.5.3.2. Diseño de la herramienta	80
4.6. FASE DE PRUEBA O EVALUACIÓN GLOBAL DE LOS RESULTADOS	82
4.6.1. Validación del Modelo	82
4.6.2. Aprendizaje de la Red Neuronal Artificial	84
4.6.3. Validación de la Red Neuronal Artificial	86
4.6.4. Prueba de la Red Neuronal	86
4.6.5. Comparación del método estadístico y la red neuronal artificial	87
CAPITULO V	
PREDICCIÓN DEL CONSUMO DE AGUA EN LA CIUDAD DE LA PAZ	
5.1. PREDICCIÓN DEL CONSUMO DE AGUA CON MEDIAS MÓVILES PONDERADAS	90
5.2. PREDICCIÓN DEL CONSUMO DE AGUA CON REDES NEURONALES ARTIFICIAL	93
5.3. COMPARACIÓN DE LA PREDICCIÓN DEL CONSUMO DE AGUA	96
5.4. PRUEBA DE HIPOTESIS	98
CAPITULO VI	
CONCLUSIONES Y RECOMENDACIONES	
4.1. CONCLUSIONES	101
4.4. RECOMENDACIONES	103
BIBLIOGRAFÍA	104
ANEXOS	
ANEXO A1.	107
ANEXO A2.	109
ANEXO A3.	111
ANEXO A4.	113

CAPITULO I

MARCO REFERENCIAL

RESUMEN

En este capítulo describiremos la introducción al tema, los antecedentes, el planteamiento del problema, la hipótesis, los objetivos, los límites y alcances, y la metodología que se utilizara para el desarrollo de la investigación.

1.1. INTRODUCCIÓN

El agua es un recurso natural incompensable, escaso y estratégico, elemento clave para la vida y el desarrollo social, difícilmente se puede exagerar la importancia del agua, es superiormente el más valioso e imprescindible de los existentes en el planeta Tierra. El agua debería ser un derecho humano y, sin embargo, muchas personas carecen de acceso al agua potable en todo el mundo.

El recurso agua es de vital importancia para la vida del hombre, pero el rápido crecimiento de la población humana en los últimos años, ha sido un factor muy importante para que la demanda de agua dulce se incrementa, convirtiéndose en un problema a nivel mundial. En la ciudad de La Paz al igual que en muchos otros lugares se ha ido incrementando el consumo de agua potable debido a diversos factores como ser: el crecimiento poblacional, la contaminación de ríos, deshielo de los nevados, condiciones climatológicas, el mal uso del agua, las fugas en las redes de conexión y la falta de planes de gestión de los recursos hídricos.

Para realizar una coordinación más eficiente en el desarrollo y gestión del recurso agua, se propuso realizar la predicción del consumo de agua utilizando una herramienta de la inteligencia artificial como ser las redes neuronales artificiales; esto coadyuvaría en la prevención de problemas a futuro como el racionamiento, desabastecimiento o escases de agua potable.

Las redes neuronales son técnicas no paramétricas muy utilizadas en diversos ámbitos de la ciencia e ingeniería porque permiten resolver problemas complejos, que muchas veces no son fáciles de resolver utilizando técnicas tradicionales como la regresión lineal o polinómica. Las redes neuronales permiten obtener un modelo no explícito que relaciona

un conjunto de variables de salida con un conjunto de variables de entrada. Así, estos modelos permiten predecir cuál es el valor de salida, dados unos valores de entrada del modelo. Para estudiar el modelo es necesario disponer de un conjunto de observaciones de las variables. Estas observaciones son usadas como patrones de entrenamiento para que la red aprenda y sea capaz de predecir una salida del modelo, ante nuevas observaciones. Por tanto, las capacidades de la red van a depender en gran medida de esta fase de entrenamiento. En la fase de entrenamiento es necesario controlar muchos parámetros y distintos algoritmos de optimización, por lo que el usuario de una red neuronal debe tener conocimiento suficiente de cuáles son estos parámetros y cómo funcionan. Por otro lado, una vez entrenada la red, es muy importante también evaluar la robustez del modelo creado, comprobando que es adecuado para nuevos datos (Moreno Rodríguez, 2011).

En la presente investigación se realizó una comparación de un modelo estadístico como las medias móviles ponderadas y un tipo red neuronal artificial como ser el perceptrón multicapa, se contrastó a los modelos para observar cual presenta menor error de precisión. Para la predicción del consumo de agua se identificaron tres variables como: el crecimiento poblacional, la precipitación y la temperatura media. Los datos de crecimiento poblacional fueron obtenidos del Instituto Nacional de Estadísticas (INE) y los datos de precipitación y temperatura del Servicio Nacional de Meteorología e Hidrología (SENAMHI).

El presente trabajo está organizado en seis capítulos, que son: el primer capítulo que nos muestra una introducción al tema a ser estudiado y el objetivo de este, el capítulo dos nos da un conocimiento teórico sobre lo que se aplicará en el desarrollo del tema, en el capítulo tres se realizó el modelado con el método de medias móviles ponderadas, posteriormente en el capítulo cuatro se realizó el modelado con la red neuronal artificial, en el capítulo cinco se realizó pronóstico del consumo de agua para dos años posteriores y en el capítulo seis se describió las conclusiones a las que se llegó al finalizar la investigación.

1.2. ANTECEDENTES

En la gestión de recursos hídricos se han ido implementando técnicas de la inteligencia artificial, particularmente en problemas sobre predicción son útiles las redes neuronales artificiales, que se aplicaron en proyectos como: predicción del consumo de agua, calidad del agua, identificación de fuentes de contaminación, depuración de aguas subterráneas y pronóstico de sequías.

Actualmente, se realizaron diversos estudios de la demanda de agua con diversos métodos de predicción. La investigación realizada por Aafjes (1997) sobre la predicción del consumo de agua a corto plazo en una comunidad, utilizando dos métodos de predicción una red neuronal y un modelo de análisis estadístico convencional, para este estudio relacionó datos de consumo de diferentes días de la semana y otros factores como por ejemplo la

presión del aire, la radiación global, la temperatura y la precipitación. Para la predicción a corto plazo, comparando a los métodos, las redes neuronales demuestran una mejor predicción.

En el estado de Guanajuato se realizó un estudio sobre el consumo de agua utilizando un modelo Económico (Guzmán, 2011), cuyo objetivo es determinar económicamente los factores que determinan el comportamiento que tiene el consumo de este recurso en los diferentes sectores, además de cuantificar el consumo de agua por sectores y determinar las tarifas que se deberían cobrar para hacer más racional el uso del agua en dicho estado.

En el artículo "El problema del agua y la inteligencia artificial", Gonzales (2011) nos propone la relación de la inteligencia artificial con la gestión de recursos hídricos, aplicando métodos como las redes neuronales artificiales y la lógica difusa. Dada la participación e interdependencia de diversos sectores en el agua, como recurso natural, define una serie de tareas derivadas de la aplicación de redes neuronales y lógica difusa como: la evaluación, diseño, planificación, operación y mantenimiento; teniendo en cuenta que varias de las tareas mencionadas se puede realizar efectivamente utilizando las técnicas de la inteligencia artificial.

En el estudio realizado de la "predicción del consumo de agua en Córdoba", (Caridad, Millán, Palomares, 2000) proponen métodos como los modelos Arima Estacional Multiplicativos¹, modelos de Regresión Dinámica² y los métodos VAR; en el caso que el objetivo de la predicción sea la planificación a medio y largo plazo, o la toma de decisiones sobre instalaciones de la red de distribución, es necesario incluir unas variables causales que tengan en cuenta la estructura y caracterización de abonados, la segmentación de las zonas de suministro homogéneas, la previsión sobre el desarrollo urbanístico y del sector industrial, y lógicamente, la demanda y su evolución.

También se realizó el estudio de la demanda de agua en zonas urbanas en Andalucía (Daza, 2008); el objetivo principal de este trabajo fue desarrollar una novedosa metodología de predicción del consumo de agua, que trate de superar las limitaciones de los métodos tradicionales y con la que se complete la información precisa para la toma de decisiones tanto de las administraciones públicas como de las empresas suministradoras. Se realizó la predicción de la demanda de agua con dos métodos, los modelos Arima y las Redes Neuronales, y posteriormente se propuso un nuevo modelo Híbrido; en una comparación

¹ Modelos Arima Estacional Multiplicativos, son modelos Arima que recogen no solo las relaciones entre periodos, sino también las relaciones dentro de los periodos y la interacción entre ambas estructuras.

² Modelos de Regresión Dinámica, es un método de predicción basado en series temporales. Para la utilización de este modelo son necesarias una o varias series explicativas, las cuales ayudan a explicar el comportamiento de la serie a predecir.

³ Métodos VAR, es un método de valoración del riesgo que mide la peor de las pérdidas esperadas en el valor de una cartera para un período de tiempo determinado y para un nivel de confianza específico en condiciones normales de mercado.

del modelo Ari a frente a las Redes Neuronales, este último presenta mayor poder de predicción; pero conjuntamente a los modelos, es decir, el modelo híbrido obtuvo una mayor precisión que cada uno por separado. Las futuras líneas de investigación de este trabajo, son la aplicación del modelo híbrido de predicción a otros mercados como es el inmobiliario, pretendiendo efectuar predicciones sobre precios de venta de inmobiliarios efectuando comparaciones entre los distintos métodos de Análisis de Series Temporales⁴.

1. . PLANTEAMIENTO DEL PROBLEMA

En la actualidad la empresa encargada de la distribución de agua potable en la ciudad de La Paz es la Empresa Pública Social de Agua y Saneamiento (EPSAS), dicha distribución es realizada desde seis represas y treinta pozos (Tabla 1.1).

TABLA 1.1. Reservas de Agua (Fuente: UNICOM – MMAyA)

Nº	Represa o fuente	Capacidad
1	Represa Milluni	10.800.000
2	Represa Tuni	21.549.000
	Represa Condoriri	2 0.000
4	Represa Incachaca	4.560.000
5	Represa Ajuan Khota	. 60.500
6	Represa Hapaturi	. 40.000
7	30 pozos Tilata (producción)	5. 62.480
TOTALES		49.201.980

El año 2008 el consumo de agua potable en el departamento de La Paz con respecto al año 2007, para usuarios domésticos se incrementó en 2.21 %, para usuarios comerciales decreció el 1.55 %, en usuarios industriales se registró un incremento de .1 % y el consumo de agua por parte de organismos oficiales se incrementó en 9.5 %, como se puede apreciar en la Tabla 1.2; se únen datos del Instituto Nacional de Estadística (INE).

⁴ Una serie temporal es una secuencia ordenada de observaciones cada una de las cuales está asociada a un momento de tiempo.

TABLA 1.2. Consumo de Agua (Fuente: INE)

TIPO DE USUARIO	2007 (m ³)	2008 (m ³)	INCREMENTO (%)
Domésticos	7, 4,261	8,159,169	2,21
Usuarios comerciales	4,725,561	4,652,492	-1,55
Industriales	1,572,0 4	1,621,278	,1
Organismos Oficiales	2,7 5,542	2,996,2	9,5

En enero del 2011, la ciudad de La Paz estaba amenazada con un posible racionamiento de agua, a raíz de una disminución sustancial en los niveles de reserva del recurso hídrico en las represas de Incachaca y Hapaturí. En una inspección realizada por la Línea de Defensa del Medio Ambiente (Lidema) se pudo evidenciar que, en el primer caso, los niveles de agua disminuyeron hasta en 11 metros con 20 centímetros, mientras que en el segundo se constató la baja de 7 metros con 65 centímetros. Pero en febrero del mismo año las lluvias incrementaron este recurso en las reservas, lo que evitó el racionamiento (La Paz sufrir racionamiento de agua por falta de reservas, 2011).

La demanda de agua en los últimos años se ha ido convirtiendo en un problema mundial, lo que conlleva una preocupación para cualquier ciudadano. La ciudad de La Paz no es ajena a esta preocupación debido a que la población ha ido creciendo y existe escasez de agua potable, los recursos hídricos existentes en la ciudad de La Paz están en peligro de extinción o no son aprovechados, además los cambios climáticos son constantes y se cuenta con pocas reservas de agua.

El agua es una necesidad básica para la sobrevivencia de las personas, y además implica un mejor desarrollo económico y social debido a que se utiliza en diferentes actividades como ser: industrial, agricultura, etc.

La creciente demanda de agua en la ciudad de La Paz, es un factor que requiere mejorar la eficiencia del uso de agua y actuar de acuerdo a los objetivos ambientales, y promover nuevas políticas en cuanto a este recurso; por lo que es necesario realizar la predicción del consumo de agua en la ciudad de La Paz.

1.1. Problema General

¿La aplicación de un modelo de Red Neuronal Artificial para la predicción del consumo de agua en la ciudad de La Paz, nos permitirá contar con datos más precisos en comparación con el modelo de medias móviles ponderadas?

1.4. HIPOTESIS

El modelo de redes neuronales artificiales lograr mayor precisión en la predicción del consumo de agua en la ciudad de La Paz, frente al uso del modelo de medias móviles ponderadas.

1.5. OBJETIVOS

1.5.1. Objetivo General

Desarrollar un modelo de red neuronal artificial a partir de los datos históricos existentes que permita realizar la predicción del consumo de agua en la ciudad de La Paz, de tal manera que el error obtenido sea menor en comparación con una predicción del consumo de agua con un modelo estadístico.

1.5.2. Objetivos Específicos

- Plantear un modelo conceptual para la predicción del consumo de agua.
- Desarrollar un prototipo en base al modelo conceptual planteado que permita realizar la predicción del consumo de agua.
- Realizar la validación del modelo de simulación.
- Realizar un análisis de la evolución del consumo de agua potable en la ciudad de La Paz.

1.6. JUSTIFICACIÓN

1.6.1. Justificación Social

En vista de que el agua se está convirtiendo en un recurso limitado para la población a nivel mundial y también esto afecta en particular a la ciudad de La Paz; es importante para la sociedad la realización de un pronóstico del consumo de agua para que pueda ayudar a las autoridades encargadas al respecto en la toma de decisiones y se pueda realizar una mejor planificación de la distribución y conservación del agua.

1.6.2. Justificación Económica

En la actualidad no existe un software de predicción que sea exclusivamente para el consumo de agua, el software StartTools es un software predictivo con fines generales, es decir, se puede utilizar en muchos ámbitos, pero este tiene un costo de 595 us, el software que se desarrollara para la predicción del consumo de agua no tendrá costo alguno, lo cual facilitara su uso.

1.7. METODOLÓGIA

- Recolección de información. Se realizará la recolección de datos históricos de consumo de agua potable, conexiones de agua potable, crecimiento de la población, temperatura, precipitación pluvial, etc.

- Selección de datos de entrada para la red neuronal. Después de tener la información necesaria se identificarán los factores que influirán en el pronóstico del consumo de agua, los cuales serán los datos de entrada para la red neuronal.
- Búsqueda de topología de la red neuronal para el problema. De todas las topologías existentes de redes neuronales, se realizará la selección de una topología que presente un error aceptable.
- Procesamiento de datos de entrada. Los datos seleccionados anteriormente pasarán por un proceso de normalización, de tal manera que estén en un rango de $[0,1]$ o $[-1, 1]$.
- Predicción del consumo de agua con modelo estadístico. Se seleccionará un método estadístico con el cual se realizará la predicción.
- Cálculo del error de la predicción del modelo estadístico. Se calculará el error absoluto porcentual de la media (MAPE).
- Aprendizaje de la red neuronal. Dependiendo de la topología de la red neuronal se utilizará un algoritmo para su entrenamiento.
- Procesamiento de datos de salida. Para obtener los datos del pronóstico del consumo de agua, se realizará el proceso inverso al realizado con los datos de entrada.
- Cálculo del error de la red neuronal con los datos de prueba. Para verificar que la red neuronal presente un error aceptable, se realizará el cálculo del error absoluto porcentual de la media (MAPE).
- Análisis y comparación de ambos resultados. Teniendo las predicciones del consumo de agua con ambos métodos se realizará una comparación, para ver cuál se ajusta mejor a los datos reales.
- Conclusión. Se realizará la conclusión sobre ambos métodos realizados y se darán unas recomendaciones.

Para el proceso de construcción de la red neuronal se utilizará la Metodología para la Predicción con Redes Neuronales Predictivas y para el desarrollo del software se utilizará el Modelo en Cascada y se aplicará también el Lenguaje de Modelado Unificado (UML).

1.8. LIMITES Y ALCANCES

1.8.1. Límites

El consumo de agua puede ser de diferentes fuentes, como ser: lluvias, vertientes, ríos, etc.; y estos datos no pueden ser restringidos, por lo que esta investigación se limita a realizar la predicción del consumo de agua potable, a partir de datos restringidos por la empresa EPSAS.

La predicción se realizará solamente a nivel urbano, es decir, sin tomar en cuenta el área rural, que cuenta con otro sistema de distribución y en algunos casos no disponen de distribución de agua potable.

La predicción del consumo de agua en la ciudad de La Paz es a corto plazo, es decir, no más de dos años.

1.8.2. Alcances

Luego de haber realizado un estudio preliminar de las necesidades, determinamos que la presente investigación se enfocará estrictamente a:

- El prototipo predecir valores futuros mensuales del consumo de agua en la ciudad de La Paz, tomando en cuenta indicadores significativos como: población, precipitación y temperatura media.
- El prototipo trabajará con datos reales de prueba, los cuales serán cargados desde un archivo .txt.
- El prototipo podrá predecir un solo dato o varios datos al mismo tiempo.

1.9. HERRAMIENTAS

Para la implementación del prototipo se utilizará Matlab 7.6.0. 24(R2008a), que es un software de aplicación matemática y cuenta con su lenguaje de programación propio, este software cuenta con una variedad de programas, que son llamados toolbox, que tienen incorporadas una gran cantidad de funciones de inteligencia artificial como lógica difusa, redes neuronales, algoritmos genéticos, simulación y sistemas difusos, también incorpora otras áreas como la estadística, la matemática simbólica, la ingeniería, la bioinformática y otros.

CAPITULO II.

MARCO TEORICO

RESUMEN

En el presente capítulo presentaremos características sobre la gestión integrada de los recursos hídricos y la gestión del servicio de agua potable en Bolivia; también daremos una introducción a los métodos predicción y describiremos algunas características sobre las redes neuronales artificiales. Además describiremos los pasos que se seguirán para el desarrollo de las metodologías.

2.1. EL RECURSO AGUA

2.1.1. GESTIÓN INTEGRADA DE LOS RECURSOS HÍDRICOS

La gestión de los recursos hídricos es una actividad central para la vida humana, la salud social, la economía y el bienestar político de cualquier región o país. La escasez de agua que se prevé para los próximos años, producto de la creciente demanda del recurso, debida al crecimiento de la población, cambios en los patrones de consumo, la contaminación y la falta de controles ambientales, ha contribuido a poner el tema de conservación y gestión del recurso en la agenda política internacional (Comisión Europea, 1999).

Para prevenir una degradación continua de los recursos hídricos, se ha proveído una estrategia holística, conocida como Gestión Integrada de los Recursos Hídricos (GIRH). A partir de la cumbre de Mar del Plata en Argentina, en 1977, hasta el Tercer Foro Mundial del Agua en Kyoto, Japón, se han celebrado reuniones internacionales que han contribuido a definir un número de principios y recomendaciones para la gestión integrada de los recursos hídricos (Sánchez T. Sánchez Torres, 2004).

De acuerdo con la Asociación Mundial para el Agua (Global Water Partnership - GWP), es un proceso que promueve la gestión y el aprovechamiento coordinado del agua, la tierra y los recursos relacionados, con el fin de maximizar el bienestar social y económico de manera equitativa sin comprometer la sostenibilidad de los ecosistemas vitales.

Un estudio reciente del Banco Interamericano de Desarrollo (BID) manifiesta que la gestión integrada del agua implica tomar decisiones y manejar los recursos hídricos para varios usos de forma tal que se consideren las necesidades y deseos de diferentes usuarios y partes interesadas. Según este estudio, la gestión integrada del agua comprende la gestión del agua superficial y subterránea en un sentido cualitativo, cuantitativo y ecológico desde una perspectiva multidisciplinaria y centrada en las necesidades y requerimientos de la sociedad en materia de agua.

2.1.1.1. PRINCIPIOS Y MARCO DE TRABAJO EN EL USO EFICIENTE DE AGUA

El uso eficiente de agua es parte del marco conceptual de la gestión integrada de los recursos hídricos, por lo que las discusiones en las diferentes conferencias internacionales han establecido una serie de principios que deben considerarse al momento de realizar las intervenciones en este tema. Los principios orientadores para el uso eficiente son los que se articularon en Dublín (1992):

- El agua dulce es un recurso finito y vulnerable, esencial para sostener la vida, el desarrollo y el medio ambiente.
- El desarrollo y la gestión del agua debe basarse en un enfoque participativo, involucrando a usuarios, planificadores y los responsables de las decisiones a todos los niveles.
- La mujer desempeña un papel fundamental en el abastecimiento, la gestión y la protección del agua.
- El agua tiene un valor económico y social en todos sus usos en competencia y debería reconocérsele como un bien económico (Conferencia internacional sobre el Agua y el Ambiente, Dublín 1992).

2.1.1.2. CONSERVACIÓN DEL AGUA

En la literatura se encuentra el término conservación del agua, que la USEPA (1998) define como: cualquier reducción benéfica en las pérdidas de agua, generación de residuos o uso. Es un concepto simplificado porque se centra en la reducción de pérdidas y el uso, y no tanto en el uso eficiente de agua, además, el término puede generar algunas confusiones, ya que puede ser interpretado como la manera de conservar o preservar agua para el futuro, por ejemplo, en una represa (Sánchez Torres, 2004).

2.1.2. RELACIÓN ENTRE LA DEMANDA Y EL USO EFICIENTE DEL AGUA

El uso eficiente del recurso incluye todo tipo de acciones, medidas, prácticas e incentivos, que las compañías de agua pueden implementar u ofrecer para reducir permanentemente el nivel o cambio en el patrón de demanda para un servicio dado (USEPA, 1998). Estas medidas se pueden aplicar durante toda la cadena de abastecimiento y uso del agua

(Herbertson, 2003). Todas estas medidas permiten influenciar la demanda de agua como una estrategia integral de largo plazo, para la gestión de los recursos hídricos.

La Figura 2.1 presenta de manera esquemática, un caso hipotético en el cual la gestión de la demanda de agua a través de acciones de uso eficiente influye en la predicción de la demanda en el futuro. También, muestra cómo no habría necesidad de recurrir a sustraer agua del ambiente y a la construcción de nueva infraestructura para almacenar agua y satisfacer la demanda, ya que las acciones de uso eficiente de agua pueden tener el mismo efecto. Este mismo esquema puede aplicarse a diferentes sectores: abastecimiento de agua para ciudades, industria o distritos de riego.

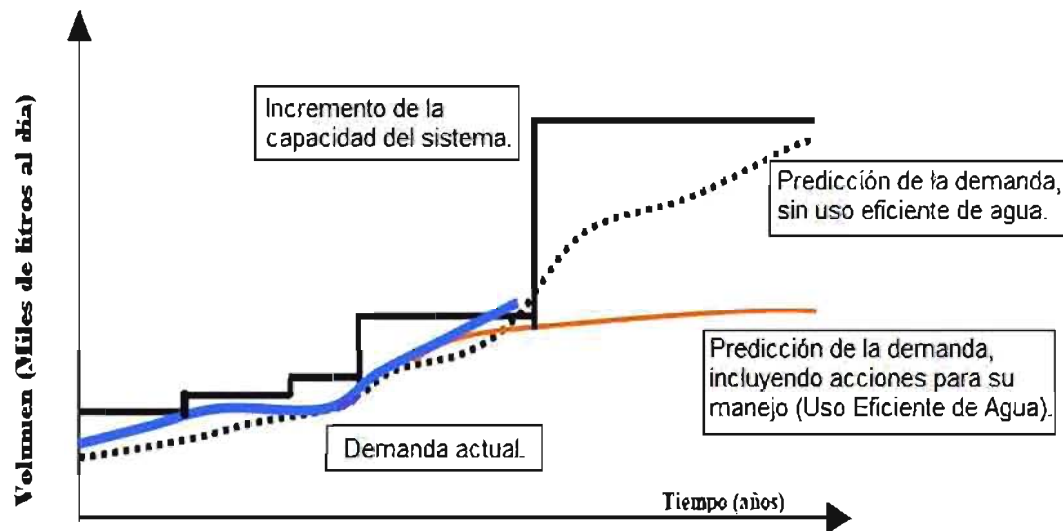


Figura 2.1. Efecto de las acciones de uso eficiente del agua en el manejo y proyección de la demanda de agua. (Fuente: Adaptado de Herbertson, 2003.)

Algunos beneficios que se desprenden de la Figura 2.1 son:

- Reducción del volumen de agua abstraída del ambiente o cuenca hidrográfica; es bastante significativo si la cuenca hidrográfica está en condiciones de escasez o estrés.
- Permite que exista más agua disponible para el ambiente y la conservación de los hábitats nativos.
- Se mejora la corriente de los ríos en términos de tiempo y cantidad, lo cual tiene un impacto sobre la calidad o su capacidad autodepuradora, en especial en períodos secos.
- Se reduce el potencial de sobreexplotación de acuíferos y su contaminación.
- Se reduce el volumen de agua residual y por ende, la capacidad necesaria para la planta de tratamiento de aguas residuales.

- Se reduce la necesidad de energía para la operación de sistemas de bombeo en acueductos, redes de distribución y sistemas de tratamiento y disposición.
- Se aumenta la concentración del contaminante, lo que presenta ventajas importantes para el tratamiento biológico de aguas residuales, ya que se incrementa la cantidad de sustrato por unidad de volumen.

2.1. . ESTRATEGIAS PARA EL USO EFICIENTE DEL AGUA

Para encarar el uso eficiente del agua se requiere desarrollar una estrategia que incluya trabajo pro resivo en divulgación de información, desarrollo conceptual e inversión a diferentes niveles. Además, se requiere trabajo en equipo entre organizaciones prestadoras de servicios, usuarios, instituciones de inversión y desarrollo, entes financiadores y ONGs⁵, en donde se susinistren elementos conceptuales, se identifiquen casos exitosos y el personal clave que trabaja en el desarrollo de proyectos, así como el desarrollo de inversiones con mecanismos de divulgación para quienes trabajan en este campo (Sánchez T. Sánchez Torres, 2004).

En la Tabla 2.1 se hace una síntesis de las diferentes acciones que pueden implementarse para el uso eficiente del agua.

Tabla 2.1. Acciones para el uso eficiente del agua (**Fuente:** Arreúin Cortés, 2011)

Usuario	Técnicas	Ejes
Hogares	Reducción de la demanda interior	Instalar equipo de bajo consumo (inodoros, duchas, lavadoras de bajo consumo). Mantenimiento de llaves en las casas.
	Reducción de la demanda exterior	Riego eficiente de jardines. Manejo de piscinas. Uso de plantas nativas.
Industria	Recirculación	Sistema de enfriamiento. Sistemas de lavado.
	Reutilización	Purificación de agua. Segunda red para agua tratada para otros usos
	Reducción del consumo	Optimización de procesos (lavado, producción de celulosa etc.).

⁵ ONG es una organización no gubernamental, una entidad de carácter civil o social, con diferentes fines y objetivos humanitarios y sociales definidos por sus integrantes, creada independientemente de los gobiernos ya sea locales, regionales o nacionales y que jurídicamente adoptan diferentes estatus, tales como asociación, fundación, corporación y cooperativa, entre otras formas.

		Optimización de uso de agua para zonas verdes.
Ciudad	Reducción por	Progrmas de educación escolar e institucional.
	Reducción por reparación	Detección y reparación de fugas (distritos pitométricos).
	Reducción por edición	Auditorías de agua. Progrmas de macro y micro-edición.
	Reducción por	Tarifas escalonadas.
	Reducción por re la entación	Restricción en el uso, definición de metas para reducción de consumos, incentivos para el ahorro, etc.
Agricultura	De campo	Reducción de evapotranspiración (cuidar en el subsuelo, uso del rastrojo). Mejorar la infiltración (nivelación de tierras, compactación de surcos).
	Administrativas	Programación de riegos según necesidad (monitoreo de humedad). Riego limitado favoreciendo cultivos de bajo consumo.
	De sistemas	Reemplazo de riederas por tuberías. Sistema de recuperación de colas. Reducción de área riega. Riego por goteo.

2.1.4. GESTIÓN DE SERVICIO DE AGUA POTABLE Y SANEAMIENTO EN BOLIVIA

2.1.4.1. MARCO LEGAL Y NORMATIVO

El marco legal que rige las actividades de administración, operación y mantenimiento de la infraestructura de saneamiento básico, está dado por las siguientes leyes y disposiciones reglamentarias:

➤ **Ley 2066 de Servicios de Agua Potable y Alcantarillado Sanitario**

La ley 2066 (ver anexo A1) determina el marco legal y las condiciones de regulación para las personas que presten o sean usuarios de al menos uno de los servicios de agua potable o alcantarillado sanitario. También establece los principios para fijar los precios, tarifas, tasas y cuotas, así como la determinación de infracciones y sanciones (Urquidí, Barrañán, Cacho, 2004).

➤ **Ley 1551 de Participación Popular**

Reconoce, promueve y consolida el proceso de Participación Popular, articulando a toda organización social campesina, indígena y vecinal en la vida jurídica, política y económica del país. Procura mejorar la calidad de vida de la mujer y el hombre bolivianos, con una justa distribución y mejor administración de los recursos públicos (Urquidí, Barrañán, Cacho, 2004).

Gobierno Municipal: Responsable de la distribución de recursos económicos para la construcción, administración y mantenimiento de la infraestructura de educación, salud y saneamiento básico en la Sección Municipal. Mediante la Planificación Participativa se elabora la programación y el presupuesto del municipio.

➤ **Ley 1 de Medio Ambiente**

Determina la política nacional ambiental para mejorar la calidad de vida de la población y racionalizar el uso del agua, suelo, aire y otros recursos naturales para garantizar su disponibilidad a mediano y largo plazo. Establece los criterios y acciones para la preservación del agua natural, protegiendo en particular su explotación y contaminación, producto de cualquier actividad pública o privada (Urquidí, Barrañán, Cacho, 2004).

➤ **Ley 2028 de Municipalidades**

El Municipio es responsable de la Planificación, Programación y Administración autónoma en su jurisdicción municipal (Urquidí, Barrañán, Cacho, 2004).

Gobierno Municipal

Se establece como entidad autónoma con responsabilidad sobre su jurisdicción municipal para construir, operar y mantener los servicios básicos.

Realiza la planificación y programación presupuestaria en la totalidad de su jurisdicción municipal (Urquidí, Barrañán, Cacho, 2004).

➤ **Decreto Supremo 27486 - Fundación de Apoyo a la Sostenibilidad en Saneamiento Básico (FUNDASAB)**

La FUNDASAB (ver anexo A2) tiene por objeto ser un mecanismo institucional sostenible de asistencia técnica, que brinde asesoría técnica y liderar e impulse los procesos de asistencia técnica para la ejecución de los Programas de Modernización Institucional del Sector Saneamiento Básico, promoviendo para ello modelos de gestión para la prestación de servicios de agua potable y saneamiento (Urquidí, Barrañán, Cacho, 2004).

2.1.5. ASPECTOS GENERALES DE LAS ENTIDADES PRESTADORAS DE SERVICIO DE AGUA

La entidad prestadora de agua (EPSA) es toda organización comunitaria, asociación civil, entidad privada, pública o asociación mixta responsable de la administración, operación y mantenimiento de los servicios de agua potable y/o saneamiento (Urquidí, Barralán, Cachaño, 2004).

Las formas de constitución de las EPSA son:

- Comité de Agua Potable y Saneamiento (CAPYS).
- Cooperativa de Servicios Públicos.
- Organizaciones de Base de la Comunidad responsables de agua y saneamiento.
- Empresa Privada.
- Asociación Civil.
- Sociedad Anónima Mixta.
- Empresa Pública Municipal.

2.1.6. FUNCIONES DE LAS ENTIDADES PRESTADORAS DE SERVICIO DE AGUA

Para la prestación de los servicios en poblaciones menores a 10.000 habitantes y/o comunidades rurales, la Entidad Prestadora de Servicios de Agua y Alcantarillado Sanitario, debe realizar las siguientes cuatro funciones básicas:

- **Administrativa – Financiera:** Dirigida a la administración de los recursos económicos, humanos y materiales de la entidad.
- **Comercial:** Dirigida a la relación con el usuario respecto a la medición de consumo, facturación, información y atención del usuario sobre sus quejas y solicitudes de conexión.
- **Técnica:** Dirigida a la operación y mantenimiento eficiente de la infraestructura del sistema de agua potable o saneamiento.
- **Planificación:** Dirigida a la programación física y financiera de las acciones técnicas, sociales y comerciales de la EPSA, para el suministro del agua y/o saneamiento a un grupo de personas.

Estas funciones se aplican a cada EPSA, independiente de su forma o forma de constitución (CAPYS, Cooperativas, etc.).

2.1.7. AGUA POTABLE Y SANEAMIENTO EN LA CIUDAD DE LA PAZ

La entidad encargada de realizar las conexiones y distribuciones de agua potable en la ciudad de La Paz es la Empresa Pública Social de Agua y Saneamiento (EPSAS), la distribución de agua potable se realiza a partir de 6 represas y 0 pozos. En la tabla 2.2 pueden observarse las capacidades de las diferentes cuencas existentes.

Tabla 2.2. Capacidades de las cuencas (Fuente: EPSAS)

Cuenca	Aporte H /A o		Caudal l/s
	A o Seco	A o Hú edo	
Tuni	5,58	12,55	177
Condoriri	6,82	15, 5	216
Huayna Potosí	9,98	22,47	17
Milluni	11,87	26,71	76
Choqueyapu	8,82	19,82	280
Incachaka	5,98	1 ,45	189
Ajuan Khota	8,1	18,	258
Ha paturi Bajo	6,26	14,07	198
Total	6 ,44	142,72	2011

En la ciudad de La Paz la empresa EPSAS suministra el servicio a partir de tres subsestas que son: Achachicala, Pa pahasi y Ladera. En la figura 2.2 puede os observar un esquema de captación y distribución de agua potable en la ciudad de La Paz.

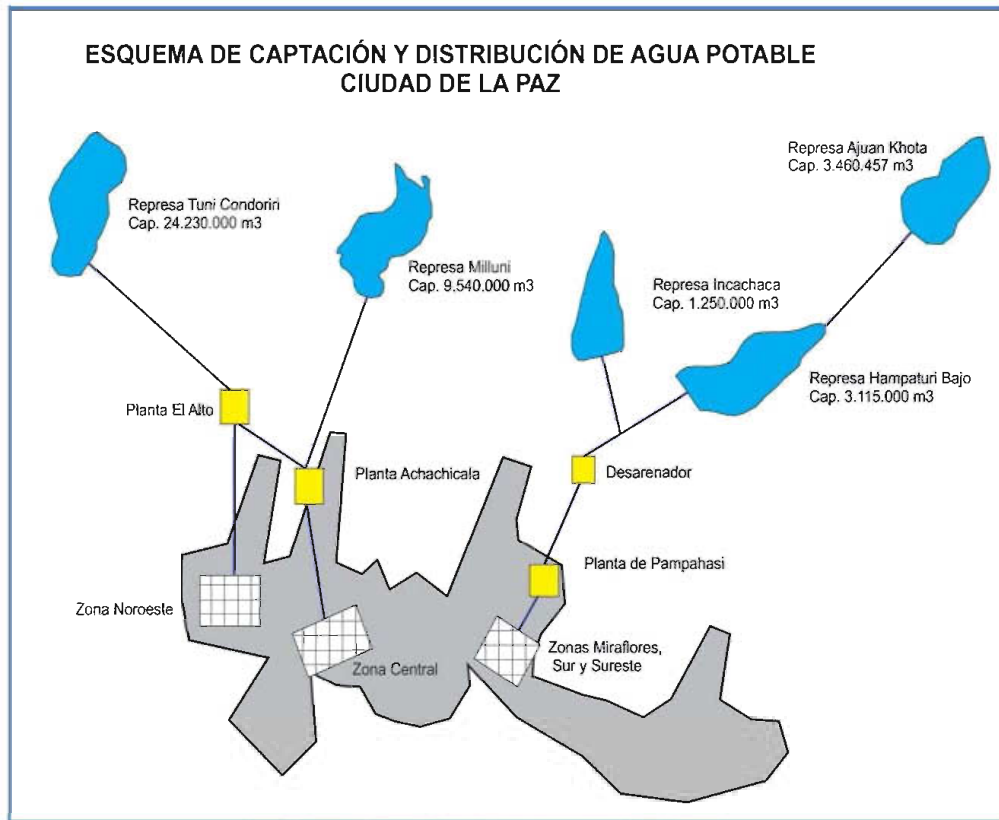


Figura 2.2. Esquema de captación y distribución de agua potable (Fuente: EPSAS)

El consumo de agua potable en la ciudad de La Paz ha ido variando en los últimos 10 años, en la figura 2.3 se pueden observar estas cantidades de consumo en metros cúbicos.

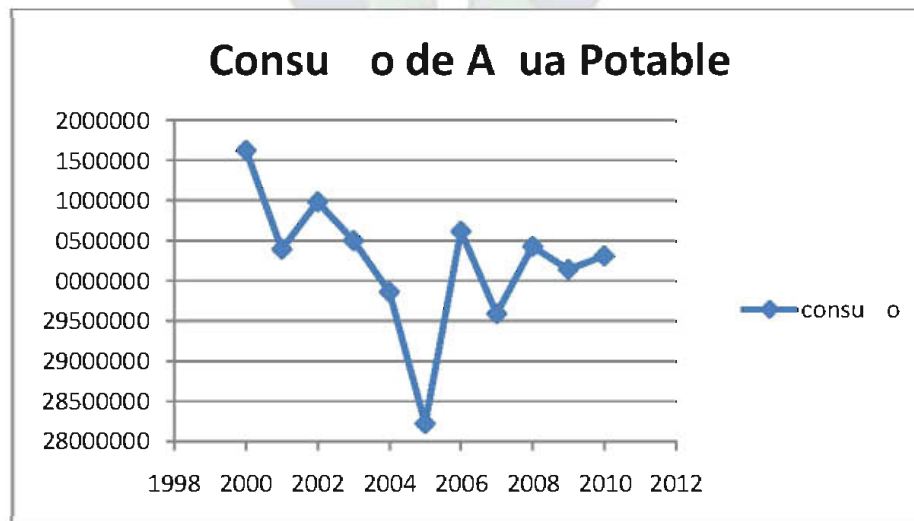


Figura 2.3. Consumo de agua potable en la ciudad de La Paz (Fuente: EPSAS)

Cada año la empresa proveedora de agua EPSAS realiza nuevas conexiones de agua potable y alcantarillado sanitario, en los últimos cinco años se registraron los datos que se muestra en la tabla 2.

Tabla 2. Conexiones de agua potable y alcantarillado sanitario.

Año	Conexiones de Agua Potable	Conexiones de Alcantarillado Sanitario
2005	142	1584
2006	766	922
2007	2794	2051
2008	221	1916
2009	1070	129
2010	57	1172

2.1.8. FACTORES QUE INFLUYEN EN EL CONSUMO DE AGUA POTABLE

Desde hace mucho tiempo se han ido estudiando los factores que pueden influir en el consumo de agua, entre estos estudios está el de Moran y Solen (1976) los cuales consideran para su modelo variables como la precipitación, la temperatura y la evapotranspiración efectiva; posteriormente Miaou (1992) realizó varios trabajos relacionando el consumo de agua con factores climáticos como temperatura, precipitación y los días de lluvia entre otros. Aular (nn) considera variables climáticas como precipitación y temperatura, y variables socioeconómicas como el precio del agua y las características habitacionales. En el estudio realizado de la demanda de agua doméstica, Obregón (nn) sugiere utilizar tres categorías de variables: las socioeconómicas como habitantes por vivienda e ingreso familiar, las meteorológicas como temperatura y precipitación pluvial, y el consumo histórico y precio del agua.

Según Saavedra y Uriarte (nn) otros factores que determinan la demanda del agua, para uso doméstico y uso público, en el consumo urbano y rural, son:

- El precio o la tarifa que se cobra por el servicio.
- El ingreso per cápita.

- El número de personas que habita la vivienda.
- La disponibilidad de alcantarillado o características del sistema sanitario utilizado en la vivienda.
- Otras variables como: clima, factores culturales, características de la vivienda y otras variables de menor importancia.



2.2. METODOS DE PREDICCIÓN

2.2.1. INTRODUCCIÓN

En la actualidad todo plan y toda decisión está basada en estimados futuros, a estos estimados futuros se los llama predicciones o pronósticos, dependiendo del grado de objetividad que se utilice en el proceso. Los estimados más objetivos se conocen como pronósticos y los más subjetivos predicciones, pero en la práctica los procesos se funden en uno solo (Devaris, 2007).

La estimación del comportamiento futuro de algunas variables puede realizarse utilizando diversas técnicas de pronóstico. Cada una de las técnicas de proyección tiene una aplicación de carácter especial que hace de su selección un problema de decisión influido por diversos factores, como por ejemplo, la validez y disponibilidad de los datos históricos, la precisión deseada del pronóstico, el costo del procedimiento, los beneficios del resultado, los periodos futuros que se desee pronosticar y el tiempo disponible para hacer el estudio entre otros (Chain, 2000).

El propósito de los métodos de predicción es acercarse cada vez más a la realidad futura; de manera que difícilmente se puede encontrar un método único que sirva de unos resultados confiables. El grado de confiabilidad puede variar significativamente dependiendo del riesgo que se aplique a cualquiera de los métodos.

2.2.2. TIPOS DE MÉTODOS DE PREDICCIÓN

Existen diversos métodos para realizar predicciones con diferentes propósitos. A continuación observaremos en la figura 2.4 la clasificación de los métodos de predicción.

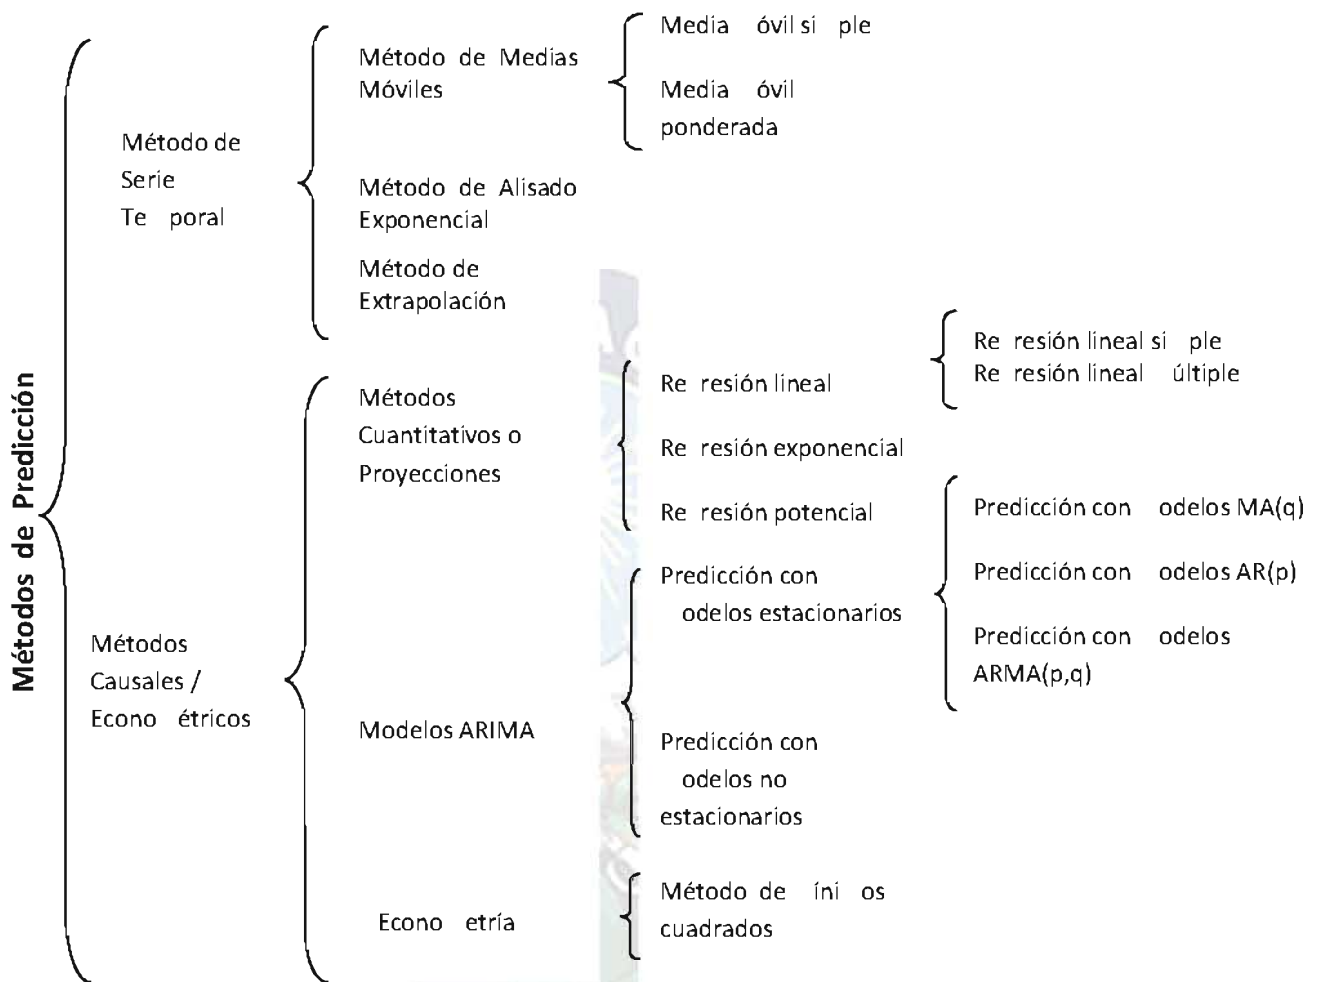


Figura 2.4. Tipos de métodos de predicción

Para el presente trabajo de investigación se utilizará el método de Medias Móviles Ponderadas, debido a que los datos históricos de consumo de agua presentan una estacionalidad en un determinado periodo, es decir que un año el consumo de agua varía dependiendo de la temporada.

2.2. MÉTODO DE SERIE TEMPORAL

Los métodos de serie temporal utilizan datos históricos como base para estimar resultados futuros. Una serie de tiempo es una colección o conjunto de ediciones de cierto fenómeno o experimento registrados secuencialmente en el tiempo, en forma equiespaciada (en intervalos de tiempo iguales) (Galbiati Riesco, 2011).

Las observaciones de una serie de tiempo serán denotadas por

$$Y(t_1), Y(t_2), \dots, Y(t_n)$$

Donde $Y(t_i)$ es el valor tomado por el proceso en el instante t_i .

2.2. .1. Componentes de una serie de tiempo

En el análisis de series temporales la gráfica es un paso importante para identificar los componentes de dicha serie, como ser: tendencia, estacionalidad, ciclicidad e irregularidad. En la figura 2.5 observaremos un ejemplo de la gráfica de una serie.




Figura 2.5. Gráfica de una serie (Fuente: Galbiati, 2011)

✓ Tendencia

La tendencia representa el comportamiento predominate de la serie. Esta puede ser definida como el cambio de la media a lo largo de un extenso periodo de tiempo (Galbiati Riesco, 2011). En la figura 2.6 observaremos un ejemplo de una gráfica con tendencia creciente.




Figura 2.6. Serie con tendencia. (Fuente: Galbiati, 2011)

✓ Estacionalidad o Ciclicidad

La variación estacional representa un movimiento periódico de la serie de tiempo. La duración del período puede ser un año, un trimestre, un mes, un día, etc. En la figura 2.7 observaremos la gráfica de una serie con estacionalidad y ciclicidad.




Figura 2.7. Serie con estacionalidad y ciclicidad. (Fuente: Galbiati, 2011)

Se suele hacer una distinción entre cíclicas y estacionarias. Estas últimas ocurren con períodos identificables, como la estacionalidad del empleo, o de la venta de ciertos productos, cuyo período es un año. El término variación cíclica se suele referir a ciclos grandes, cuyo período no es atribuible a una causa. Por ejemplo, fenómenos climáticos, que tienen ciclos que duran varios años. Las tendencias y estacionalidades pueden darse simultáneamente (Galbiati Riesco, 2011).

✓ **Irregularidad**

Se refiere a puntos de la serie que se escapan de lo normal. Si se sospecha que una observación es irregular, se debe reunir información adicional sobre posibles factores que afectaron el proceso. En la figura 2.8 observamos un ejemplo sobre el estudio de producción diaria de cobre que presentó una irregularidad en la serie.




Figura 2.8. Serie con estacionalidad y ciclicidad. (Fuente: Galbiati, 2011)

2.2.4. MÉTODO DE MEDIAS MÓVILES

El método de las medias móviles en estadística es un método utilizado para analizar un conjunto de datos en orden de puntos para crear series de promedios. Así las medias móviles son una lista de números en la cual cada uno es el promedio de un subconjunto de los datos originales.

Este método de suavizado es uno de los más usados para describir la tendencia. Consiste en fijar un número k , preferentemente impar, como 3, 5, 7, etc., y calcular los promedios de todos los grupos de k términos consecutivos de la serie. Se obtiene una nueva serie suavizada por promedios móviles de orden k . De este modo se tienden a anular las variaciones aleatorias (Galbiati Riesco, 2011).

Por ejemplo, considere una serie de seis observaciones y fije el orden $k=3$. Entonces los términos de la serie suavizada son:

t	$Y(t)$	$Z(t)$ <i>media móvil de orden $k=3$</i>
1	$Y(1)$	-
2	$Y(2)$	$Z(2) = \frac{Y(1) + Y(2) + Y(3)}{3}$
3	$Y(3)$	$Z(3) = \frac{Y(2) + Y(3) + Y(4)}{3}$
4	$Y(4)$	$Z(4) = \frac{Y(3) + Y(4) + Y(5)}{3}$
5	$Y(5)$	$Z(5) = \frac{Y(4) + Y(5) + Y(6)}{3}$
6	$Y(6)$	-

Podemos notar en la serie suavizada no se pueden calcular $Z(1)$ y $Z(6)$. En general, se pierden $k/2$ términos en cada extremo.

a) Media móvil simple

La media móvil previa

Una media móvil simple (SMA) es la media aritmética de los n datos anteriores. Mientras más grande sea n , mayor será la influencia de los datos antiguos.

La media móvil central

En lugar de utilizar sólo datos anteriores, se utilizan también datos posteriores a aquél del cual se quiere obtener la media.

b) Media móvil ponderada

La media móvil ponderada es una media multiplicada por ciertos factores, que le dan determinado peso a determinados datos.

Por ejemplo si el objetivo fuera pronosticar las ventas del siguiente año para un determinado producto teniendo la demanda histórica, aplicando el método de media móvil ponderada tenemos la siguiente tabla:

Tabla 2.4. Ejemplo del método de media móvil ponderada

TRIM.	VENTAS	MEDIA MOVIL k=4	MEDIA MOVIL CENTRADA (MMC)	COMPONENTE ESTACIONAL (Venta/MMC)	ÍNDICE ESTACIONAL (Tabla .2)	SERIE DEESTACIONALIZADA (Venta/IE)
1	4,800				0,9 2	5,149
2	4,100	5, 50			0,8 8	4,894
	6,000	5,600	5,475	1,096	1,09	5,488
4	6,500	5,875	5,7 8	1,1	1,14	5,685
1	5,800	6,075	5,975	0,971	0,9 2	6,222
2	5,200	6, 00	6,188	0,840	0,8 8	6,207
	6,800	6, 50	6, 25	1,075	1,09	6,219
4	7,400	6,450	6,400	1,156	1,14	6,472
1	6,000	6,625	6,5 8	0,918	0,9 2	6,4 6
2	5,600	6,725	6,675	0,8 9	0,8 8	6,684
	7,500	6,800	6,76	1,109	1,09	6,860
4	7,800	6,875	6,8 8	1,141	1,14	6,822
1	6, 00	7,000	6,9 8	0,908	0,9 2	6,758
2	5,900	7,150	7,075	0,8 4	0,8 8	7,04
	8,000				1,09	7, 17
4	8,400				1,14	7, 47

En la tabla 2.5 observaremos el cálculo del índice estacional en los cuatro trimestres. Para este cálculo se copia todos los componentes estacionales correspondientes a cada trimestre, luego se promedia estos datos para obtener su índice estacional.

Tabla 2.5. Índice estacional.

TRIM	COMPONENTE			INDICE
1	0,971	0,918	0,908	0,9 2
2	0,840	0,8 9	0,8 4	0,8 8
	1,075	1,109	1,096	1,09
4	1,156	1,141	1,1	1,14

Con la serie desestacionalizada obtenida en la tabla 2.4 realiza los una regresión lineal, cuyos resultados son los siguientes:

$$y^* = a + b x$$

$$a = 0,14714 \quad \text{y} \quad b = 5,09961$$

Con estos datos halla los el pronóstico desestacionalizado para los siguientes cuatro trimestres, que son:

$$y^*(17) = 0,14714 + 5,09961(17) = 7,600968265$$

$$y^*(18) = 7,748106980$$

$$y^*(19) = 7,895245696$$

$$y^*(20) = 8,04284412$$

Posteriormente a los datos anteriores se aplica el índice estacional, y se obtiene el pronóstico final:

$$Y = y^* \times \text{Índice Estacional}$$

$$Y(17) = 7,085626244$$

$$Y(18) = 6,49104798$$

$$Y(19) = 8,62257741$$

$$Y(20) = 9,194899458$$

2.2.5. PRECISIÓN DEL PRONÓSTICO

La precisión de un pronóstico se mide a partir del error que esté presente. El error del pronóstico es la diferencia entre el valor real y el pronosticado del período correspondiente.

$$E_t = Y_t - F_t \quad (2.1)$$

Donde:

E_t : es el error del pronóstico del período t

Y_t : es el valor real para ese período t

F_t : es el valor que se había pronosticado para el período t

Existen distintas medidas de error, que son:

- Error absoluto de la media (MAD)

$$MAD = \frac{\sum_{t=1}^N |E_t|}{N} \quad (2.2)$$

- Error absoluto porcentual de la media (MAPE)

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{E_t}{Y_t} \right|}{N} \quad (2.3)$$

- Desviación porcentual de la media (PMAD)


$$PMAD = \frac{\sum_{t=1}^N |E_t|}{\sum_{t=1}^N |Y_t|} \quad (2.4)$$

- Error cuadrático de la media (MSE)

$$MSE = \frac{\sum_{t=1}^N E_t^2}{N} \quad (2.5)$$

- Raíz del error cuadrático de la media (RMSE)

$$RMSE = \sqrt{\frac{\sum_{t=1}^N E_t^2}{N}} \quad (2.6)$$



2. . REDES NEURONALES

2. .1. INTRODUCCIÓN

Las redes neuronales no son más que un modelo artificial y simplificado del cerebro humano, que es el ejemplo perfecto del que dispone los seres vivos para un sistema que es capaz de adquirir conocimiento a través de la experiencia. Una red neuronal es “un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona” (Matich, 2001).

Todos los procesos del cuerpo humano se relacionan en una u otra forma con la actividad de estas neuronas. Las células son un componente relativamente simple del ser humano, pero cuando billares de ellas se conectan en forma conjunta se hacen muy poderosas. Lo que básicamente ocurre en una neurona biológica es lo siguiente: la neurona es estimulada o excitada a través de sus entradas (inputs) y cuando se alcanza un cierto umbral, la neurona se dispara o activa, pasando una señal hacia el axón. Posteriores investigaciones condujeron al descubrimiento de que estos procesos son el resultado de eventos electroquímicos (Matich, 2001).

Una red neuronal, según Freeman y Skapura (1991), es un sistema de procesadores paralelos conectados entre sí en forma de red dirigida. Esquemáticamente cada elemento de procesamiento (neuronas) de la red se representa como un nodo. Estas conexiones establecen una estructura jerárquica que tratando de emular la fisiología del cerebro busca nuevos modelos de procesamiento para solucionar problemas concretos del mundo real. Lo importante en el desarrollo de la técnica de las RNA es el útil comportamiento al aprender, reconocer y aplicar relaciones entre objetos y trayectorias de objetos propios del mundo real. En este sentido, se utilizan las RNA como una herramienta que podrá utilizarse para resolver problemas difíciles.

2. .2. ELEMENTOS BÁSICOS QUE COMPONEN UNA RED NEURONAL

En la figura 2.8 podemos distinguir los componentes de una red neuronal artificial.

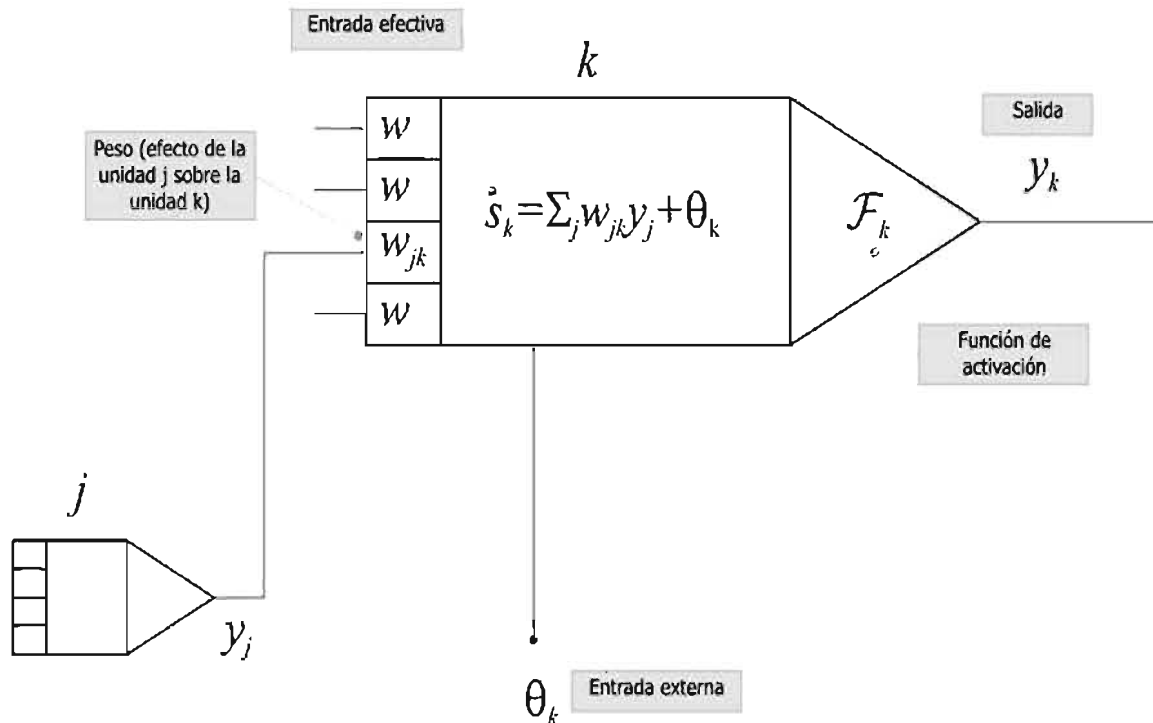


Figura 2.8. Componentes básicos de una red neuronal artificial. (Fuente: Arana no, Benavides, Rostagnol, 2006)

Los componentes básicos de una red neuronal, son:

- Un conjunto de nodos, unidades o elementos de procesamiento.
- Un estado de activación y_k para cada nodo, el cual es equivalente a la salida del mismo.
- Conexiones entre los nodos. Generalmente cada conexión posee un peso w_{jk} denotado también fuerza o fortaleza de conexión el cual determina el efecto que la señal del nodo j tiene sobre el nodo k .
- Una regla de propagación, la cual determina la entrada efectiva s_k de un nodo a partir de sus entradas externas.
- Una función de activación F_k , la cual determina el nuevo nivel de activación a partir de la entrada efectiva $s_k(t)$ y la activación actual $y_k(t)$.
- Una entrada externa θ_k para cada nodo.
- Un método para obtener información, también conocido como regla de aprendizaje.
- Un entorno dentro del cual el sistema debe operar. El entorno provee señales de entrada y, en caso de ser necesario, señales de error (Arana no, Benavides, Rostagnol, 2006).

2. . . FUNCIÓN DE ENTRADA

La neurona trata a muchos valores de entrada como si fueran uno solo; esto recibe el nombre de *entrada global*. Por lo tanto, ahora nos enfrenta al problema de cómo se pueden combinar estas simples entradas (in_{i1}, in_{i2}, \dots) dentro de la entrada global, gin_i . Esto se logra a través de la función de entrada, la cual se calcula a partir del *vector entrada*. La función de entrada puede describirse como sigue:

$$input_i = (in_{i1} \circ w_{i1}) * (in_{i2} \circ w_{i2}) * \dots (in_{in} \circ w_{in})$$

Donde: \circ representa al operador apropiado (por ejemplo: \times o, sustracción, productoria, etc.)

n es el número de entradas a la neurona N_i y w_i al peso.

Los valores de entrada se multiplican por los pesos anteriormente ingresados a la neurona. Por consiguiente, los pesos que generalmente no están restringidos cambian la medida de influencia que tienen los valores de entrada. Es decir, que permiten que un gran valor de entrada tenga solamente una pequeña influencia, si estos son lo suficientemente pequeños (Matich, 2001).

Algunas de las funciones de entrada más utilizadas y conocidas son:

- 1) **Sustracción de las entradas pesadas:** es la sustracción de todos los valores de entrada a la neurona, multiplicados por sus correspondientes pesos.

$$\sum_j (n_{ij} w_{ij}), \text{ con } j = 1, 2, \dots, n$$

- 2) **Productoria de las entradas pesadas:** es el producto de todos los valores de entrada a la neurona, multiplicados por sus correspondientes pesos.

$$\prod_j (n_{ij} w_{ij}), \text{ con } j = 1, 2, \dots, n$$

- 3) **Máximo de las entradas pesadas:** solamente toma en consideración el valor de entrada más fuerte, previamente multiplicado por su peso correspondiente.

$$\max_j (n_{ij} w_{ij}), \text{ con } j = 1, 2, \dots, n$$

2. 4. FUNCIÓN DE ACTIVACIÓN

La función de activación es una relación que combina las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función F produce un nuevo estado de activación en una neurona a partir del estado (a_i) que existía y la combinación de las entradas con los pesos de las conexiones (net_i) (Hilera Martínez, 1995).

Dado el estado de activación $a_i(t)$ de la unidad U_i y la entrada total que llega a ella, Net_i , el estado de activación siguiente, $a_i(t + 1)$, se obtiene aplicando una función F , llamada función de activación.

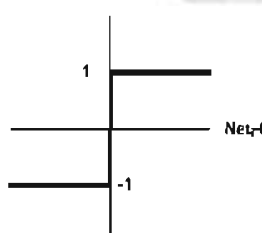
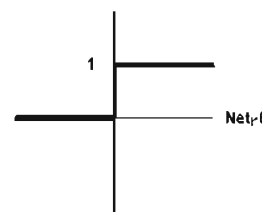
$$a_i(t + 1) = F(a_i(t), Net_i)$$

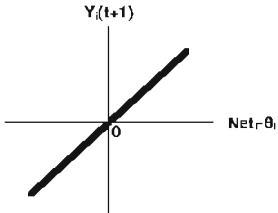
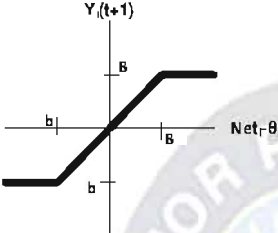
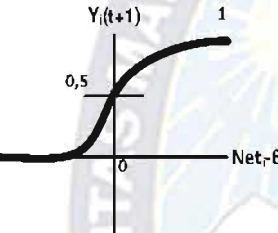
Considerando únicamente la función f , que denotaremos indistintamente de transferencia o de activación. Esta función normalmente no está cerrada en el origen del eje que representa el valor de la entrada neta, sino que existe cierto desplazamiento debido a las características internas de la propia neurona y que no es igual en todas ellas. Este valor se denota como θ_i y representa el umbral de activación de la neurona i .

$$y_i(t + 1) = f(Net_i - \theta_i) = \left(\sum_{j=1}^N w_{ij} y_j(t) - \theta_i \right)$$

En la tabla 2.6 podemos observar las diferentes funciones f que se pueden aplicar.

Tabla 2.6. Tipos de funciones de activación (Fuente: Hilera Martínez, 1995)

FUNCIÓN	GRAFICA	DESCRIPCIÓN ANALÍTICA
Escalón (conjunto de activación $E = \{-1,1\}$)		$y_i(t + 1) = \begin{cases} +1 & \text{si } [Net_i > \theta_i] \\ y(t) & \text{si } Net_i = \theta_i \\ -1 & \text{si } [Net_i < \theta_i] \end{cases}$
Escalón (conjunto de activación $E = \{0,1\}$)		$y_i(t + 1) = \begin{cases} 1 & \text{si } [Net_i > \theta_i] \\ y(t) & \text{si } Net_i = \theta_i \\ 0 & \text{si } [Net_i < \theta_i] \end{cases}$

Lineal o identidad		$y_i(t + 1) = Net_i - \theta_i$
Lineal- ixta		$y_i(t + 1) = \begin{cases} b & Net_i \leq b + \theta_i \\ Net_i - \theta_i & b + \theta_i < Net_i < B + \theta_i \\ B & Net_i \geq B + \theta_i \end{cases}$
Si oidal		$y_i(t + 1) = \frac{1}{(1 + e^{-(Net_i - \theta_{i0})})}$

2. .5. FUNCIÓN DE SALIDA

El último componente que una neurona necesita es la función de salida. El valor resultante de esta función es la salida de la neurona i (out_i); por ende, la función de salida determina que valor se transfiere a las neuronas vinculadas. Si la función de activación está por debajo de un umbral determinado, ninguna salida se pasa a la neurona subsiguiente. Por el contrario, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango $[0, 1]$ o $[-1, 1]$. También pueden ser binarios $0, 1$ o $-1, 1$ (Matich, 2001).

Dos de las funciones de salida más comunes son:

- Ninguna: este es el tipo de función más sencillo, tal que la salida es la misma que la entrada. Es también llamada función identidad.
- Binaria: $\begin{cases} 1 & \text{si } act_i \geq \xi_i \\ 0 & \text{de lo contrario} \end{cases}$, donde ξ_i es el umbral.

2. .6. MODELOS DE REDES NEURONALES

En la tabla 2.7 se muestra algunos de los modelos de redes neuronales más conocidos y sus características más relevantes.

Tabla 2.7. Modelos de redes neuronales. (Fuente: Hilera y Martínez, 1995)

Modelo de red neuronal	Topología	Aprendizaje			Asociación Auto / Hetero	Información de Entrada y Salida	Autor
		ON / OFF Line	Supervisada / No Supervisada	Relación			
Perceptron	2 capas Feedforward	OFF Line	Supervisado	Corrección Error	Heteroasociativa	E: analógica S: Binaria	Rosenblatt 1958
Backpropagation	N capas Feedforward	OFF Line	Supervisado	Corrección Error (relación delta generaliza)	Heteroasociativa	Analógica	Rumelhart 1986
Red de Kohonen	2 capas	OFF Line	No supervisado competitivo	Sensibilidad con respecto al vecindario o historia	Mapas autoasociativos	E: continuos normalizados S: secuenciales	Tuevo Kohonen 1989
Adaline/Madaline	2 capas Feedforward	OFF Line	Supervisado	Corrección Error ("Least Mean Square")	Heteroasociativa	E: analógica S: Binaria	Widrow Hoff 1960
Continuous Hopfield	1 capa Conexiones Laterales	OFF Line	No supervisado	Hebbiano	Autoasociativos	Analógica	Hopfield 1984
Discrete Hopfield	1 capa Conexiones Laterales	OFF Line	No supervisado	Hebbiano	Autoasociativos	Binarias	Hopfield 1982

2.7. PERCEPTRÓN MULTICAPA

El perceptrón multicapa es una red neuronal artificial (RNA) formada por múltiples capas, esto le permite resolver problemas que no son linealmente separables, lo cual es la principal limitación del perceptrón (tanto el perceptrón simple). El perceptrón multicapa puede ser totalmente o localmente conectado.

Es capaz de actuar como un aproximador universal de funciones: una red backpropagation conteniendo al menos una capa oculta con suficientes unidades no lineales puede aproximar cualquier tipo de función o relación continua entre un grupo de variables de

entrada y salida. Esta propiedad convierte a las redes perceptrón multicapa en herramientas de propósito general, flexibles y no lineales (Marín Diazaraque, 2011).

En el presente trabajo se utilizara este modelo de red neuronal, debido a que es una herramienta de propósito general y además esta red tiene la capacidad de generalización, es decir, la facilidad de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento.

2. 7.1. ARQUITECTURA

La topología o arquitectura de las redes neuronales consiste en la organización y disposición de las neuronas en la red formando capas o agrupaciones de neuronas más o menos alejadas de la entrada y salida de la red. Se distinguen dos tipos de redes:

- **Redes con una sola capa o redes monocapa:** es una red en su forma más simple porque tiene solamente una capa que constituye la red.
- **Redes con múltiples capas o redes multicapa:** son aquellas que disponen de conjuntos de neuronas agrupadas en varios niveles o capas. En estos casos una forma para distinguir la capa a la que pertenece una neurona, consistiría en fijarse en el origen de las señales que recibe a la entrada y el destino de la señal de salida. Normalmente, todas las neuronas de una capa reciben señales de entrada de otra capa anterior, más cercana a las entradas de la red, y envían las señales de salida a una capa posterior, más cercana a la salida de la red.

Un perceptrón multicapa tiene una arquitectura de red multicapa porque está compuesto por una capa de entrada, una capa de salida y una o más capas ocultas; aunque se ha demostrado que para la mayoría de problemas bastaría con una sola capa oculta (Marín Diazaraque, 2011). En la figura 2.9 podemos observar un perceptrón multicapa formado por una capa de entrada, una capa oculta y una de salida.




Figura 2.9. Perceptrón multicapa (Fuente: Wikipedia, La Enciclopedia Libre, 2010)

Las conexiones entre neuronas son siempre hacia delante: las conexiones van desde las neuronas de una determinada capa hacia las neuronas de la siguiente capa; no hay conexiones laterales ni conexiones hacia atrás. Por tanto, la información siempre se transmite desde la capa de entrada hacia la capa de salida (Marín Diazaraque, 2011).

2.7.2. APRENDIZAJE

El proceso de aprendizaje de las redes neuronales se denomina proceso de entrenamiento o acondicionamiento. Para este proceso de aprendizaje se utiliza un conjunto de datos de entrenamiento. El aprendizaje de una red neuronal artificial es la adaptación de los pesos de la red. En otras palabras el aprendizaje es el proceso por el cual una red neuronal modifica sus pesos en respuesta a una información de entrada. Los cambios que se producen durante el mismo se reducen a la destrucción, modificación y creación de conexiones entre las neuronas. En los sistemas biológicos existe una continua destrucción y creación de conexiones entre las neuronas. En los modelos de redes neuronales artificiales, la creación de una nueva conexión implica que el peso de la misma pasa a tener un valor distinto de cero. De la misma manera, una conexión se destruye cuando su peso pasa a ser cero (Hilera Martínez, 1995).

Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren modificaciones, por lo tanto, se puede afirmar que este proceso ha terminado o que la red ha aprendido cuando los valores de los pesos permanecen estables.

Existen dos métodos de aprendizaje importantes: aprendizaje supervisado y no supervisado. La diferencia fundamental entre ambos tipos estriba en la existencia o no de un agente externo que controle el proceso de aprendizaje de la red (Hilera Martínez, 1995). En la figura 2.10 veremos los diferentes tipos de aprendizaje.

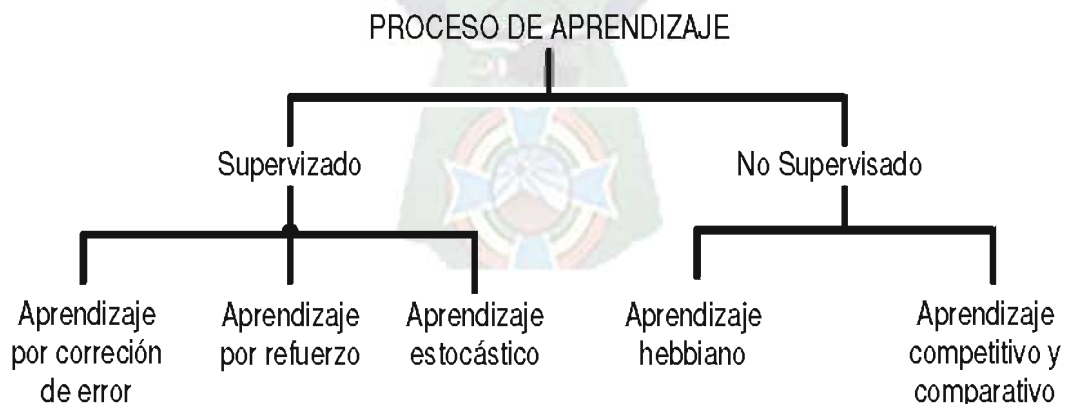


Figura 2.10. Proceso de Aprendizaje (Fuente: Hilera Martínez, 1995)

El perceptrón multicapa utiliza para su entrenamiento el aprendizaje supervisado y el algoritmo de corrección de error, conocido también como el algoritmo backpropagation o regla delta.

El aprendizaje supervisado se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor controla la salida de la red y en caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada. El 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 a la salida de la red, es decir, en función del error cometido en la salida (Hilera Martínez, 1995).

2. 7.2.1. Algoritmo backpropagation

Se considera una etapa de funcionamiento donde se presenta, ante la red entrenada, un patrón de entrada y éste se transmite a través de las sucesivas capas de neuronas hasta obtener una salida y, después, una etapa de entrenamiento o aprendizaje donde se modifican los pesos de la red de manera que coincida la salida deseada por el usuario con la salida obtenida por la red (Marín Diazaraque, 2011).

- **Etapa de funcionamiento**

Cuando se presenta un patrón p de entrada $X^p: x_1^p, \dots, x_i^p, \dots, x_N^p$, éste se transmite a través de los pesos w_{ji} desde la capa de entrada hacia la capa oculta. Las neuronas de esta capa intermedia transforman las señales recibidas mediante la aplicación de una función de activación proporcionando, de este modo, un valor de salida. Este se transmite a través de los pesos v_{kj} hacia la capa de salida, donde aplicando la misma operación que en el caso anterior, las neuronas de esta última capa proporcionan la salida de la red (Marín Diazaraque, 2011).

Este proceso se resume en lo siguiente:

La entrada total o neta que recibe una neurona oculta j , net_j^p , es:

$$net_j^p = \sum_{i=1}^N w_{ji} x_i^p + \theta_j$$

donde θ_j es el umbral de la neurona que se considera como un peso asociado a una neurona ficticia con valor de salida igual a 1.

El valor de salida de la neurona oculta j , y_j^p , se obtiene aplicando una función f sobre su entrada neta:

$$y_j^p = f(\text{net}_j^p)$$

De igual forma, la entrada neta que recibe una neurona de salida k , net_k^p , es:

$$\text{net}_k^p = \sum_{j=1}^H v_{kj} y_j^p + \theta_k$$

Por último, el valor de salida de la neurona de salida k , y_k^p , es:

$$y_k^p = f(\text{net}_k^p)$$

- **Etapas de aprendizaje**

En la etapa de aprendizaje, el objetivo es hacer mínimo el error entre la salida obtenida por la red y la salida deseada por el usuario ante la presentación de un conjunto de patrones denominado conjunto de entrenamiento. Así el aprendizaje en las redes backpropagation es de tipo supervisado (Marín Diazaraque, 2011).

La función de error que se pretende minimizar para cada patrón p viene dada por:

$$E^p = \frac{1}{2} \sum_{k=1}^M (d_k^p - y_k^p)^2$$

donde d_k^p es la salida deseada para la neurona de salida k ante la presentación del patrón p .

A partir de esta expresión se puede obtener una medida general de error mediante:

$$E = \sum_{p=1}^P E^p$$

La base del algoritmo backpropagation para la modificación de los pesos es la técnica conocida como gradiente decreciente.

Como E^p es función de todos los pesos de la red, el gradiente de E^p es un vector igual a la derivada parcial de E^p respecto a cada uno de los pesos. El gradiente toma la dirección que determina el incremento requerido en el error, mientras que la dirección opuesta, es decir, la dirección negativa, determina el decremento requerido en el error. Por tanto, el error puede reducirse ajustando cada peso en la dirección:

$$-\sum_{p=1}^P \frac{\partial E^p}{\partial w_{ji}}$$

Un peligro que puede surgir al utilizar el método de gradiente decreciente es que el aprendizaje converja a un mínimo local. Sin embargo, el problema potencial de los mínimos locales se da en raras ocasiones en datos reales.

A nivel práctico, la forma de modificar los pesos de forma iterativa consiste en aplicar la regla de la cadena a la expresión del gradiente y añadir una tasa de aprendizaje η . Así, en una neurona de salida

$$\Delta v_{kj}(n+1) = -\eta \frac{\partial E^p}{\partial v_{kj}} = \eta \sum_{p=1}^P \delta_k^p y_j^p$$

Donde

$$\delta_k^p = (d_k^p - y_k^p) f'(net_k^p)$$

y n indica la iteración.

En una neurona oculta:

$$\Delta w_{ji}(n+1) = \eta \sum_{p=1}^P \delta_j^p x_i^p$$

Donde

$$\delta_j^p = f'(net_j^p) \sum_{k=1}^M \delta_k^p v_{kj}$$

Se puede observar que el error o valor delta asociado a una neurona oculta j , viene determinado por la suma de los errores que se cometen en las k neuronas de salida que reciben como entrada la salida de esa neurona oculta j . De ahí que el algoritmo también se denomine propaación del error hacia atrás.

Para la modificación de los pesos, la actualización se realiza después de haber presentado todos los patrones de entrenamiento. Este es el modo habitual de proceder y se denomina aprendizaje por lotes o modo batch.

Otra modalidad denominada aprendizaje en serie o modo on line consistente en actualizar los pesos tras la presentación de cada patrón de entrenamiento. Ha de hacerse en orden aleatorio.

Para acelerar el proceso de convergencia de los pesos, Rumelhart et al. (1986) sugirieron añadir un factor momento, α , que tiene en cuenta la dirección del incremento tomada en la iteración anterior:

$$\Delta v_{kj}(n+1) = \left(\sum_{p=1}^P \delta_k^p y_j^p \right) + \alpha \Delta v_{kj}(n)$$

2.8. MÉTODO DE VALIDACIÓN

El método de la validación que se utilizar para la estimación de la exactitud en el aprendizaje, es el método de validación cruzada (cross-validation), este método es de propósito general, es decir, que se puede utilizar para cualquier modelo de red neuronal. El conjunto de datos D se divide aleatoriamente en k subconjuntos mutuamente excluyentes D_1, D_2, \dots, D_k de aproximadamente el mismo tamaño. El clasificador es entrenado y validado k veces. Cada instante de tiempo $t \in \{1, 2, \dots, k\}$ es entrenado en D/D_t y validado en D_t . La estimación de la exactitud por medio del método cross-validation es el número total de bien clasificados, dividido entre el número total de instancias del conjunto de datos. Formalmente, la estimación de la predicción del cross-validation es:

$$acc_{cv} = \frac{1}{N} \sum_{t=1}^k \sum_{(x^{(i)}, c^{(i)}) \in D_t} \delta(\mathcal{J}(D/D_t, x^{(i)}), c^{(i)}) \quad (2.7)$$

La estimación cross-validation es un número aleatorio que depende de la división previa realizada (Robles Forcada, 2000).

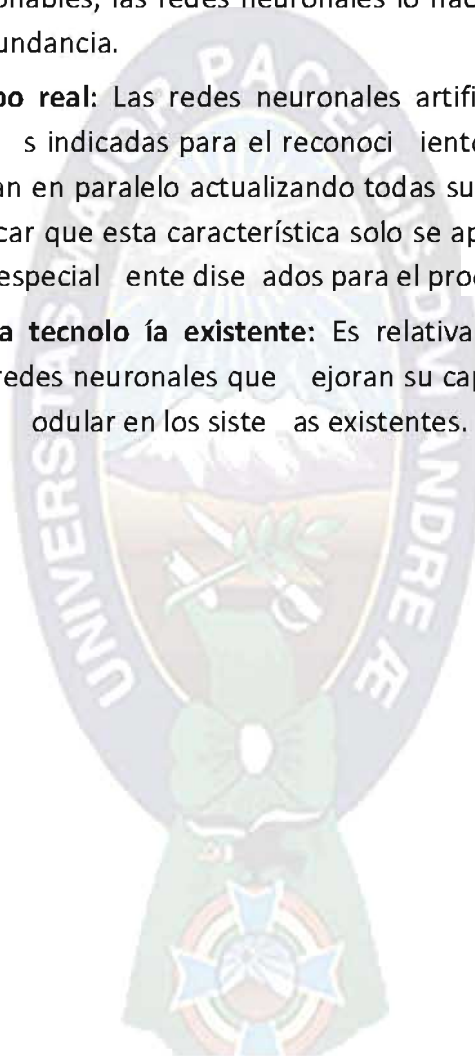
2.9. VENTAJAS QUE OFRECEN UNA RED NEURONAL

La ventaja que ofrece una red neuronal es la posibilidad de resolver problemas difíciles, esto se debe gracias a los principios de las redes neuronales, los cinco más importantes son citados por Hilera y Martínez (1995). Estos son enunciados a continuación:

- **Aprendizaje adaptativo:** Esta es quizás la característica más importante de las redes neuronales, pueden comportarse en función de un entrenamiento con una serie de ejemplos ilustrativos. De esta forma, no es necesario elaborar un modelo a priori, ni establecer funciones probabilísticas. Una red neuronal artificial es adaptativa porque puede modificarse constantemente con el fin de adaptarse a nuevas condiciones de trabajo.
- **Autoorganización:** Mientras que el aprendizaje es un proceso donde se modifica la información interna de la red neuronal artificial, la autoorganización consiste en la modificación de la red completa con el fin de llevar a cabo un objetivo específico.

Autoorganización significa generalización, de esta forma una red puede responder a datos o situaciones que no ha experimentado antes, pero que puede inferir sobre la base de su entrenamiento. Esta característica es muy útil sobre todo cuando la información de entrada es poco clara o se encuentra incompleta.

- **Tolerancia a fallos:** En la computación tradicional la pérdida de un fragmento pequeño de información puede acarrear comúnmente la inutilización del sistema. Las redes neuronales artificiales poseen una alta capacidad de tolerancia a fallos. Se entiende por ello que las redes pueden reconocer patrones de información con ruido, distorsión o incompletos, pero que, además, pueden seguir trabajando aunque se destruya parte de la red (con cierta degradación). La explicación de este fenómeno se encuentra en que mientras la computación tradicional almacena la información en espacios únicos, localizados y direccionables, las redes neuronales lo hacen de forma distribuida y con un alto grado de redundancia.
- **Operación en tiempo real:** Las redes neuronales artificiales, de todos los métodos existentes, son las más indicadas para el reconocimiento de patrones en tiempo real, debido a que trabajan en paralelo actualizando todas sus instancias simultáneamente. Es importante destacar que esta característica solo se aprecia cuando se emplean redes con hardware especialmente diseñados para el procesamiento paralelo.
- **Fácil inserción en la tecnología existente:** Es relativamente sencillo obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Esto facilita la integración modular en los sistemas existentes.



2.4. METODOLOGÍAS

El presente trabajo se desarrollo bajo dos metodologías que se detallan a continuación.

2.4.1. METODOLOGIA PARA LA PREDICCIÓN CON REDES NEURONALES PREDICTIVAS

Según los autores Palit y Popovic (2005), la metodología para la predicción es generalmente entendida como un conjunto de enfoques, métodos y herramientas para la recopilación de datos a ser utilizados para la predicción de valores futuros de series de datos, esta metodología incluye algunas etapas que están descritas en la figura 2.11.

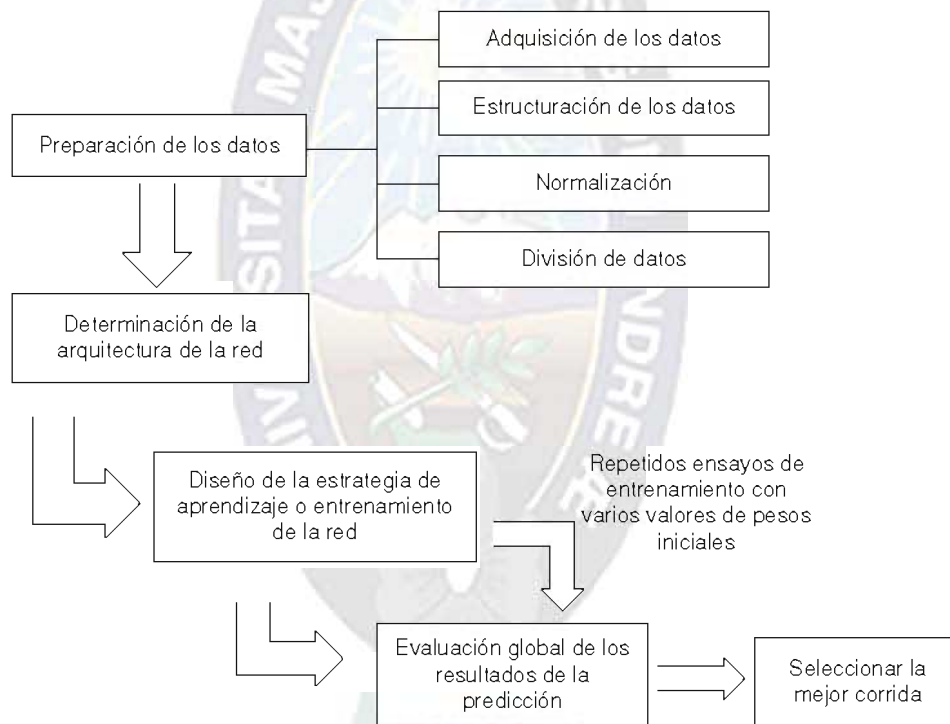


Figura 2.11. Modelo de proceso de la metodología de predicción con redes neuronales.

(Fuente: Neolopan Mendoza, 2010)

2.4.1.1. Preparación de los datos

La preparación de datos para el pronóstico consta de cuatro etapas, que son: la adquisición de datos, estructuración de datos, normalización y división de datos; cada etapa se detalla a continuación.

- a) Adquisición de datos.** Es la etapa donde se realiza la recolección de los datos que se utilizarán para la red neuronal, es decir los datos de entrada y los datos de salida.
- b) Estructuración de los datos.** Se debe obtener el par (entrada, salida deseada), es decir, se obtendrá la siguiente ecuación:

$$(x(t - (D - 1)\Delta), \dots, x(t - \Delta), x(t); x(t + R))$$

Donde $x(t + R)$ son los valores predichos basados en los valores pasados de una serie de tiempo hasta un punto t siendo R el instante para el cual se quiere predecir, D ser el número de patrones de la muestra, Δ ser el intervalo entre los valores de la serie de tiempo y $x(t)$ ser el valor de la serie de tiempo en un instante t .

- c) Normalización de los datos.** La preparación de los datos incluye limpiar y transformar estos datos. El objetivo de la normalización es quitar el ruido, las inconsistencias de la resolución y acentuar las relaciones importantes en las variables de entrada. En muchas ocasiones los resultados de la predicción dependen de la normalización de los datos, debido a la discrepancia que existe en los datos originales, como ser valores grandes o demasiado pequeños. Para realizar la normalización de los datos, utilizamos la siguiente ecuación:

$$P_n = \frac{2 * (P - P_{min})}{P_{max} - P_{min}} - 1 \quad (2.8)$$

Donde:

- P_n : es el valor normalizado
- P_{min} : es valor mínimo de la serie
- P_{max} : es el valor máximo de la serie
- P : es el valor a normalizar

- d) División de los datos.** En la práctica es común dividir la serie de tiempo en tres distintos conjuntos: entrenamiento, prueba y validación. El conjunto de entrenamiento es el más grande y se usa para que la red neuronal pueda aprender. El conjunto de prueba oscila entre el 10 al 30 del conjunto de entrenamiento, se usa para evaluar la habilidad de la generalización de una red supuesta mente entrenada. El conjunto de validación debe consistir en las series recientes

observaciones continuas. Se debe tener cuidado de no usar el conjunto de validación como un conjunto de prueba (Pissarenko, 2002).

2.4.1.2. Determinación de la arquitectura de la red

En un modelo neuronal estándar para realizar la predicción de una serie de tiempo se debe usar un juego de d-tuplas como las entradas y un solo valor designado a la salida de la red. La estructura a nivel macro del modelo predictivo es ilustrado en la figura 2.12, en el cual se observa un conjunto de d-tuplas como variables predictivas $[x(t-d), \dots, x(t-1), x(t)]$ y una única salida $[x(t+1)]$, como variable predicha (Davey, Frank, Hunt, 1999).

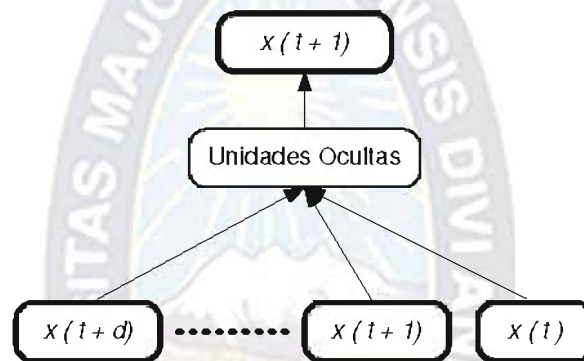


Figura 2.12. Modelo estándar para realizar predicción de serie de tiempo con redes neuronales artificiales. (Fuente: Davey, Frank, Hunt, 1999)

2.4.1.3. Diseño de la estrategia de aprendizaje o entrenamiento de la red

El entrenamiento de la red neuronal es un proceso en el que la red aprende a reconocer el modelo inherente a los datos de entrenamiento. El objetivo del entrenamiento es encontrar el conjunto conveniente para los valores de los pesos en la conexión de los nodos de la red neuronal a través de la afinación de los pesos durante el entrenamiento de la red, haciendo que la red pueda lograr el atributo de la generalización más alta.

2.4.1.4. Evaluación global de los resultados de la predicción

El entrenamiento de la red puede requerir de repetidos ensayos de entrenamiento con varios valores de pesos iniciales. Después de cada corrida de entrenamiento los resultados obtenidos deben compararse con los resultados de las corridas anteriores, en orden para seleccionar la mejor corrida.

2.4.2. METODOLOGIA DE DESARROLLO

La metodología que se utilizará para el desarrollo de esta aplicación es el modelo en cascada, que se detallará a continuación.

2.4.2.1. Modelo en Cascada

El modelo en cascada es el más conocido, está basado en el ciclo convencional de una ingeniería, el paradigma del ciclo de vida abarca las siguientes actividades, ver figura 2.1.

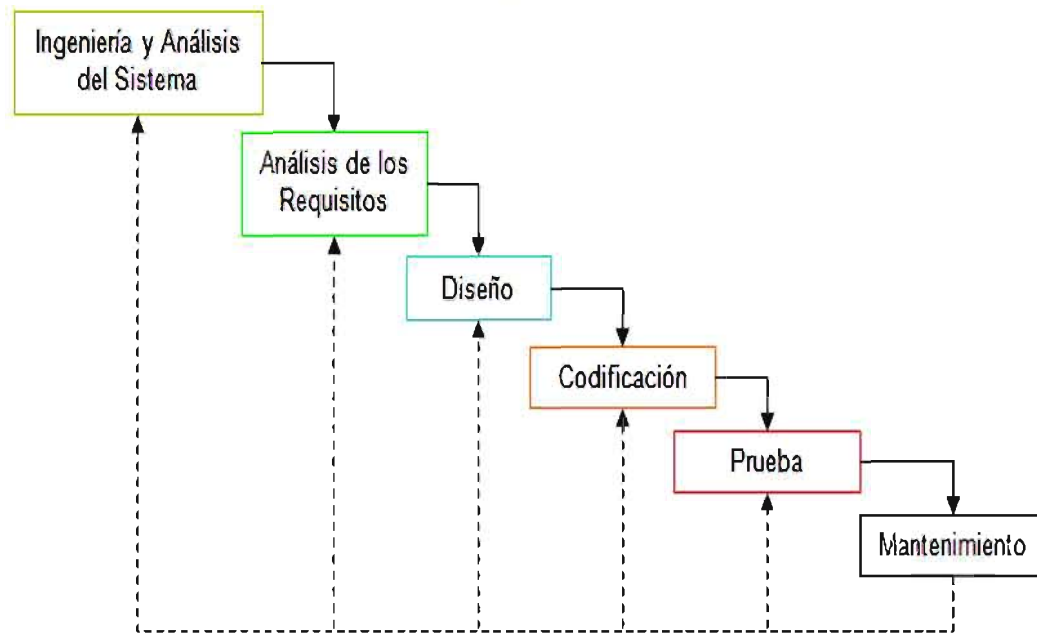


Figura 2.1. Actividades del modelo en cascada. (Fuente: Rojas Boucchechter, 2005)

- **Ingeniería y Análisis del Sistema:** Debido a que el software es siempre parte de un sistema mayor el trabajo comienza estableciendo los requisitos de todos los elementos del sistema y luego organizando al menos un subconjunto de estos requisitos al software.
- **Análisis de los requisitos del software:** el proceso de recopilación de los requisitos se centra e intensifica especialmente en el software. El ingeniero de software (Analistas) debe comprender el propósito de la información del software, así como la función, el rendimiento y las interfaces requeridas.
- **Diseño:** el diseño del software se enfoca en cuatro atributos distintos del programa: la estructura de los datos, la arquitectura del software, el detalle procedimental y la caracterización de la interfaz. El proceso de diseño traduce los requisitos en una representación del software con la calidad requerida antes de que comience la codificación.

- **Codificación:** el diseño debe traducirse en una forma legible para la máquina. El paso de codificación realiza esta tarea. Si el diseño se realiza de una manera detallada la codificación puede realizarse mecánicamente.
- **Prueba:** una vez que se ha generado el código comienza la prueba del programa. La prueba se centra en la lógica interna del software, y en las funciones externas, realizando pruebas que aseguren que la entrada definida produce los resultados que realmente se requieren.
- **Mantenimiento:** el software sufre cambios después de que se entregue al cliente. Los cambios ocurren debido a que hayan encontrado errores, a que el software deba adaptarse a cambios del entorno externo (sistema operativo o dispositivos periféricos), o debido a que el cliente requiera ampliaciones funcionales o del rendimiento.

Desventajas que se presentan en este modelo:

- Los proyectos reales rara vez tienen el flujo secuencial que propone el modelo, siempre hay iteraciones y se crean problemas en la aplicación del paradigma.
- Normalmente, es difícil para el cliente establecer explícitamente al principio todos los requisitos. El ciclo de vida clásico lo requiere y tiene dificultades en abordar posibles incertidumbres que pueden existir al comienzo de muchos productos.
- El cliente debe tener paciencia. Hasta llegar a las etapas finales del proyecto, no estará disponible una versión operativa del programa. Un error importante no detectado hasta que el programa esté funcionando puede ser desastroso.

La ventaja de este método radica en su sencillez ya que sigue los pasos intuitivos necesarios a la hora de desarrollar el software.

CAPITULO III

MODELADO DEL CONSUMO DE AGUA CON MEDIAS MÓVILES PONDERADAS

RESUMEN

En el presente capítulo se realizará el modelado del consumo de agua con el método medias móviles ponderadas, para posteriormente realizar una comparación con los datos reales de consumo de agua.

.1. INTRODUCCIÓN

Para la predicción del consumo de agua con un modelo estadístico se eligió el método de Medias Móviles Ponderadas debido a que los datos históricos de consumo de agua se presentan de acuerdo a una serie⁶ y además esta serie presenta una estacionalidad.

.2. PRESENTACIÓN DE DATOS

Para realizar la predicción del consumo de agua en la ciudad de La Paz se utilizaron como variables los datos históricos de consumo de agua en la ciudad de La Paz. Se trabajó con datos de consumo mensual de agua, ver Tabla .1.

⁶ Una serie es una colección de datos registrados secuencialmente en el tiempo, en intervalos de tiempo iguales.

Tabla 1.1. Consumo histórico de agua en la ciudad de La Paz (**Fuente:** EPSAS)

MESES	CONSUMO DE AGUA ()	MESES	CONSUMO DE AGUA ()
ene-08	2.550.711,48	feb-09	2.466.044,65
feb-08	2.128.900,58	mar-09	2.211.190,57
mar-08	2.250.766,58	abr-09	2.520.571,08
abr-08	2.554.466,86	may-09	2.564.418,62
may-08	2.646.688,45	jun-09	2.504.980,21
jun-08	2.668.666,70	jul-09	2.540.040,54
jul-08	2.468.767,75	ago-09	2.518.145,46
ago-08	2.611.100,57	sep-09	2.595.560,49
sep-08	2.642.425,66	oct-09	2.687.057,98
oct-08	2.728.645,20	nov-09	2.720.508,28
nov-08	2.724.580,90	dic-09	2.177.000,74
dic-08	2.592.111,25	ene-10	2.498.847,85
ene-09	2.510.108,45	feb-10	2.297.405,58

1.1. MODELADO CON MEDIAS MÓVILES PONDERADAS

El primer paso para realizar el modelado con medias móviles ponderadas es elegir el valor de la constante k , en este caso particular utilizaremos un $k=4$ que significa que cada año estará dividido en periodos de 4 meses cada uno y también refleja la estacionalidad en los datos; con esta constante k calculamos la media móvil que es el promedio de los k datos correspondientes, es decir:

$$Media\ Móvil = \frac{CM_1 + CM_2 + CM_3 + CM_4}{K} \quad (3.1)$$

Donde: CM_1 es el consumo de agua correspondiente al mes uno, CM_2 el consumo de agua del mes dos, CM_3 el consumo de agua del mes tres y CM_4 el consumo de agua del mes cuatro.

Reemplazando en la ecuación .1 los primeros cuatro datos de consumo de agua de la tabla .1, obtendremos la media móvil.

$$Media\ Móvil_1 = \frac{2.550.711,48 + 2.128.930,58 + 2.250.766,58 + 2.554.466,86}{4} = 2.371.218,875 (m^3)$$

$$Media\ Móvil_2 = \frac{2.128.930,58 + 2.250.766,58 + 2.554.466,86 + 2.646.688,45}{4} = 2.395.213,12 (m^3)$$

Como podemos observar en el cálculo anterior, tenemos para el primer dato la media móvil igual a 2.371.218,875 (), que es el promedio de consumo de agua de los meses de enero, febrero, marzo y abril del año 2008. Para el segundo dato la media móvil es 2.395.213,12 (), que es el promedio de los meses de febrero hasta mayo de 2008. En la tabla .2 realizamos el cálculo de la media móvil para todos los datos de consumo.

Tabla .2. Cálculo de la media móvil

NUMERACIÓN DE LOS MESES	MESES	CONSUMO DE AGUA MENSUAL ()	MEDIA MOVIL k=4 ()
1	ene-08	2.550.711,48	
2	feb-08	2.128.930,58	2.371.218,88
	mar-08	2.250.766,58	2.395.213,12
4	abr-08	2.554.466,86	2.501.147,15
5	may-08	2.646.688,45	2.584.647,44
6	jun-08	2.668.666,70	2.598.806,62
7	jul-08	2.468.767,75	2.597.740,92
8	ago-08	2.611.101,57	2.612.715,55
9	sep-08	2.642.425,66	2.676.688,8
10	oct-08	2.728.645,20	2.671.940,75
11	nov-08	2.724.580,90	2.688.868,95
12	dic-08	2.592.111,25	2.571.218,81
13	ene-09	2.510.118,45	2.472.401,48
14	feb-09	2.466.044,65	2.454.518,44
15	mar-09	2.211.191,57	2.461.088,48

16	abr-09	2.520.571,08	2.470.82 ,12
17	may-09	2.564.418,62	2.525.504,11
18	jun-09	2.504.98 ,21	2.524.897,71
19	jul-09	2.540.04 ,54	2.596.68 ,18
20	ago-09	2.518.145,46	2.585.276,87
21	sep-09	2.595.560,49	2.604.400,55
22	oct-09	2.687.57,98	2.580.297,62
23	nov-09	2.720.58,28	2.541.69,46
24	dic-09	2.177 ,74	2.448.888,86
25	ene-10	2.498.847,85	
26	feb-10	2.297.45,58	

Luego calculamos la media móvil centrada, que es el promedio de cada par de datos de la columna de media móvil, a continuación realizaremos el cálculo para el primer dato de media móvil centrada.

$$\text{Media Móvil Centrada} = \frac{2.371.218,875 + 2.395.213,118}{2} = 2.383.215,996 \text{ (m}^3\text{)}$$

La media móvil centrada para el primer dato es 2.383.215,996 (), que es el promedio de la media móvil de los meses de enero hasta mayo de 2008. En la tabla 2. se observa el cálculo de la media móvil centrada para todos los datos de media móvil de la tabla 2.

Tabla . . C lculo de la edia óvil centrada.

NUMERACIÓN DE LOS MESES	MESES	CONSUMO DE AGUA MENSUAL ()	MEDIA MOVIL k=4 ()	MEDIA MOVIL CENTRADA ()
1	ene-08	2.550.711,48		
2	feb-08	2.128.900,58	2.71.218,88	
	mar-08	2.250.766,58	2.95.210,12	2.80.215,996
4	abr-08	2.554.466,86	2.50.147,15	2.462.680,1
5	may-08	2.646.688,45	2.584.647,44	2.557.97,294
6	jun-08	2.668.666,70	2.598.806,62	2.591.727,029
7	jul-08	2.468.767,75	2.597.740,92	2.598.270,769
8	ago-08	2.611.100,57	2.612.705,55	2.605.208,2
9	sep-08	2.642.425,66	2.676.688,8	2.644.712,189
10	oct-08	2.728.645,20	2.671.940,75	2.674.14,79
11	nov-08	2.724.580,90	2.688.868,95	2.655.404,851
12	dic-08	2.592.111,25	2.570.218,81	2.606.040,881
1	ene-09	2.510.100,845	2.472.400,48	2.522.811,146
14	feb-09	2.466.044,65	2.454.518,44	2.460.460,959
15	mar-09	2.210.19,57	2.461.088,48	2.457.800,459
16	abr-09	2.520.571,08	2.470.820,12	2.465.955,800
17	may-09	2.564.418,62	2.525.504,11	2.498.160,616
18	jun-09	2.504.980,21	2.524.897,71	2.525.200,910
19	jul-09	2.540.040,54	2.596.680,18	2.522.290,441
20	ago-09	2.518.145,46	2.585.276,87	2.562.480,021
21	sep-09	2.595.560,49	2.604.400,55	2.607.800,710
22	oct-09	2.687.057,98	2.580.297,62	2.605.49,088
2	nov-09	2.720.508,28	2.541.069,46	2.560.800,54
24	dic-09	2.1770,74	2.440.888,86	2.492.629,16
25	ene-10	2.498.847,85		
26	feb-10	2.297.405,58		

Posteriormente realizamos el cálculo del componente estacional para cada uno de los datos de la columna de media móvil centrada, de la siguiente manera:

$$\text{Componente Estacional} = \frac{\text{Consumo Mensual}}{\text{Media Movil Centrada}} \quad (3.2)$$

$$\text{Componente Estacional} = \frac{2.250.766,58}{2.383.215,996} = 0,944$$

El cálculo realizado para el primer dato del componente estacional es 0,944, que es la estimación de la variación del consumo de agua real respecto a la media móvil centrada correspondiente. En la tabla 4 realizaremos el cálculo para todos los datos.

Tabla 4. Cálculo de los componentes estacionales.

NUMERACIÓN DE LOS MESES	MESES	CONSUMO DE AGUA MENSUAL ()	MEDIA MOVIL CENTRADA ()	COMPONENTE ESTACIONAL
1	ene-08	2.550.711,48		
2	feb-08	2.128.905,58		
	mar-08	2.250.766,58	2.383.215,996	0,944
4	abr-08	2.554.466,86	2.462.680,1	1,07
5	may-08	2.646.688,45	2.557.972,94	1,05
6	jun-08	2.668.666,70	2.591.727,029	1,00
7	jul-08	2.468.767,75	2.598.270,769	0,950
8	ago-08	2.611.100,57	2.605.208,2	1,002
9	sep-08	2.642.425,66	2.644.712,189	0,999
10	oct-08	2.728.645,20	2.674.014,79	1,020
11	nov-08	2.724.580,90	2.655.404,851	1,026
12	dic-08	2.592.111,25	2.606.040,881	0,995
1	ene-09	2.510.108,45	2.522.811,146	0,995
14	feb-09	2.466.044,65	2.460.460,959	1,001
15	mar-09	2.210.195,57	2.457.800,459	0,944
16	abr-09	2.520.571,08	2.465.955,800	1,022

17	may-09	2.564.418,62	2.498.160,616	1,015
18	jun-09	2.504.980,21	2.525.200,910	0,992
19	jul-09	2.540.040,54	2.522.290,441	1,00
20	ago-09	2.518.145,46	2.562.480,021	0,98
21	sep-09	2.595.560,49	2.607.800,710	0,995
22	oct-09	2.687.057,98	2.605.049,088	1,01
23	nov-09	2.720.508,28	2.560.800,54	1,062
24	dic-09	2.177.000,74	2.492.629,16	0,90
25	ene-10	2.498.847,85		
26	feb-10	2.297.405,58		

Luego se realiza el cálculo del índice estacional, para esto se crea una columna para poner el periodo, como el periodo tiene 4 meses, numerados de 1 a 4 consecutivamente. Estos datos nos ayudarán a construir la tabla del índice estacional, donde la primera columna será el número k que va de 1 a 4, para cada fila de esta columna copiamos los valores de la componente estacional correspondiente a ese periodo, es decir, para la primera fila copiamos todos los componentes estacionales correspondientes al periodo 1; la última columna corresponde al índice que es resultado de promediar toda la fila del componente. Los índices de variación estacional representan el incremento o la disminución porcentual que el componente estacional produce en cada estación. En la tabla 5.5 observaremos el cálculo del índice estacional.

Tabla 5. Cálculo del índice estacional.

PERIODO	MESES	COMPONENTE ESTACIONAL	INDICE ESTACIONAL							
			k=4	COMPONENTE						INDICE
1	1									
2	2		1	1,0 5	0,999	0,995	1,015	0,995		1,008
		0,944	2	1,0 0	1,020	1,001	0,992	1,0 1		1,015
4	4	1,0 7		0,944	0,950	1,026	0,944	1,00	1,062	0,988
1	5	1,0 5	4	1,0 7	1,002	0,995	1,022	0,98	0,9 0	0,995
2	6	1,0 0								
	7	0,950								
4	8	1,002								
1	9	0,999								
2	10	1,020								
	11	1,026								
4	12	0,995								
1	1	0,995								
2	14	1,001								
	15	0,944								
4	16	1,022								
1	17	1,015								
2	18	0,992								
	19	1,00								
4	20	0,98								
1	21	0,995								
2	22	1,0 1								
	2	1,062								
4	24	0,9 0								
1	25									
2	26									

Después de realizar la tabla de índice estacional lleva los estos cuatro datos de índice a la tabla original, copiando los índices correspondientes a cada periodo, como se ven en la tabla .6.

Tabla .6. Índice estacional.

PERIODO	MESES	COMPONENTE ESTACIONAL	ÍNDICE ESTACIONAL
1	1		1,008
2	2		1,015
		0,944	0,988
4	4	1,07	0,995
1	5	1,05	1,008
2	6	1,00	1,015
	7	0,950	0,988
4	8	1,002	0,995
1	9	0,999	1,008
2	10	1,020	1,015
	11	1,026	0,988
4	12	0,995	0,995
1	1	0,995	1,008
2	14	1,001	1,015
	15	0,944	0,988
4	16	1,022	0,995
1	17	1,015	1,008
2	18	0,992	1,015
	19	1,00	0,988
4	20	0,98	0,995
1	21	0,995	1,008
2	22	1,01	1,015
	2	1,062	0,988
4	24	0,90	0,995
1	25		1,008
2	26		1,015

Luego realiza los el cálculo de la serie desestacionalizada, que se realiza mediante la siguiente ecuación:

$$\text{Serie Desestacionalizada} = \frac{\text{Consumo Mensual}}{\text{Índice Estacional}} \quad (3.3)$$

Para el primer dato de la tabla .6 la serie desestacionalizada ser :

$$\text{Serie Desestacionalizada} = \frac{2.550.711,48}{1,008} = 2.530.901,891 (m^3)$$

El primer dato de la serie desestacionalizada es 2.530.901,891 (). Los datos de la serie desestacionalizada ya no contienen movimientos estacionales, ni irregulares. En la tabla .7 observaremos la serie desestacionalizada para todos los datos.

Tabla .7. Cálculo de la serie desestacionalizada.

MESES	CONSUMO DE AGUA MENSUAL ()	ÍNDICE ESTACIONAL	SERIE DESESTACIONALIZADA ()
ene-08	2.550.711,48	1,008	2.530.901,891
feb-08	2.128.905,58	1,015	2.097.751,4
mar-08	2.250.766,58	0,988	2.277.719,595
abr-08	2.554.466,86	0,995	2.567.714,48
may-08	2.646.688,45	1,008	2.626.114,475
jun-08	2.668.666,70	1,015	2.629.582,875
jul-08	2.468.767,75	0,988	2.498.117,7
ago-08	2.611.101,57	0,995	2.624.664,6
sep-08	2.642.425,66	1,008	2.621.901,792
oct-08	2.728.645,20	1,015	2.688.682,96
nov-08	2.724.580,90	0,988	2.757.207,860
dic-08	2.592.111,25	0,995	2.605.571,79
ene-09	2.510.184,45	1,008	2.490.641,964
feb-09	2.466.044,65	1,015	2.429.928,16
mar-09	2.211.19,57	0,988	2.249.117,460
abr-09	2.520.571,08	0,995	2.536.661,665

ay-09	2.564.418,62	1,008	2.516.720,04
jun-09	2.504.982,21	1,015	2.468.296,60
jul-09	2.540.042,54	0,988	2.570.460,658
ago-09	2.518.145,46	0,995	2.512.222,448
sep-09	2.595.560,49	1,008	2.575.402,590
oct-09	2.687.579,98	1,015	2.648.000,41
nov-09	2.720.582,28	0,988	2.752.116,829
dic-09	2.177.742,74	0,995	2.29.770,890
ene-10	2.498.847,85	1,008	2.420.899,261
feb-10	2.297.455,58	1,015	2.262.788,602

En la figura 1.1 observaremos la grafica de la serie desestacionalizada de agua y el consumo de agua mensual.



Figura 1.1. Grafica del consumo de agua y la serie desestacionalizada.

Después de haber obtenido la serie desestacionalizada realiza los una regresión lineal de la forma:

$$y^* = a + bx \quad (3.4)$$

Donde la variable dependiente es la columna de la serie desestacionalizada y la variable independiente es la numeración de los meses. Los resultados obtenidos de la regresión lineal son:

$$a = 2.514.617,78$$

$$b = 77,67972$$

Luego realiza los la evaluación de los datos deseados en la ecuación 3.5. En la tabla 3.8 observaremos la evaluación para los siguientes 10 meses, es decir de marzo a diciembre 2010.

$$y^*(x) = 2.514.617,738 + 77,37 * x \quad (3.5)$$

Tabla 3.5. Datos evaluados de la regresión lineal.

mar-10	$y^*(27)$	$2.514.617,78 + (77,67 * 27) = 2.516.706,658$ ()
abr-10	$y^*(28)$	2.516.784,025 ()
may-10	$y^*(29)$	2.516.861,9 ()
jun-10	$y^*(30)$	2.516.938,760 ()
jul-10	$y^*(31)$	2.517.016,128 ()
ago-10	$y^*(32)$	2.517.093,495 ()
sep-10	$y^*(33)$	2.517.170,862 ()
oct-10	$y^*(34)$	2.517.248,230 ()
nov-10	$y^*(35)$	2.517.325,597 ()
dic-10	$y^*(36)$	2.517.402,965 ()

Finalmente para obtener los datos pronosticados, evaluamos los datos en la siguiente ecuación 3.6, ver Tabla 3.6.

$$y = (y^*) * \text{Índice Estacional} \quad (3.6)$$

Tabla .6. Datos predichos de marzo a diciembre de 2010.

mar-10	y(27)	2.516.706,658 *0,988 = 2.486.925,629 ()
abr-10	y(28)	2.507.780,641 ()
may-10	y(29)	2.566.561,085 ()
jun-10	y(30)	2.554.488,41 ()
jul-10	y(31)	2.487.214,7 ()
ago-10	y(1)	2.504.088,512 ()
sep-10	y(2)	2.568.872,977 ()
oct-10	y(3)	2.554.662,411 ()
nov-10	y(4)	2.487.572,244 ()
dic-10	y(5)	2.504.968 ()

Estos datos son obtenidos para realizar un contraste con los datos reales, es decir, se realizó una predicción sobre datos de los que ya se conocen su valor real.

.4. COMPARACIÓN DE DATOS

En esta sección realizaremos una comparación de los datos obtenidos con el modelado del método de medias móviles ponderadas respecto de los datos reales, ver tabla .7.

Tabla .7. Comparación de datos.

MESES	CONSUMO DE AGUA ()	CONSUMO DE AGUA CON MMP ()	ERROR RELATIVO	DIFERENCIA DE CONSUMO ()
mar-10	2.400.487,920	2.486.925,629	0,0600892	86.477,709
abr-10	2.485.055,50	2.507.780,641	0,0074811	18.475,291
may-10	2.562.220,750	2.566.561,085	0,010400846	26.659,665
jun-10	2.512.072,410	2.554.488,41	0,016829105	42.275,91
jul-10	2.512.269,816	2.487.214,7	0,01797742	44.088,79
ago-10	2.577.616,870	2.504.088,512	0,02852571	73.528,58
sep-10	2.576.575,170	2.568.872,977	0,015408901	9.702,19
oct-10	2.617.025,590	2.554.662,411	0,0282979	62.663,179
nov-10	2.608.774,540	2.487.572,244	0,046472891	121.202,296
dic-10	2.709.908,890	2.504.968	0,07784985	199.507,507
MAPE			0,027609218	
MAPE			2,760921797	

El error absoluto de la media (MAPE) fue calculado con la ecuación 2. , y nos da un error de 2.76 %.

En la figura 2.2 observaremos la grafica de la comparación del consumo de agua real y el pronosticado con medias móviles ponderadas.

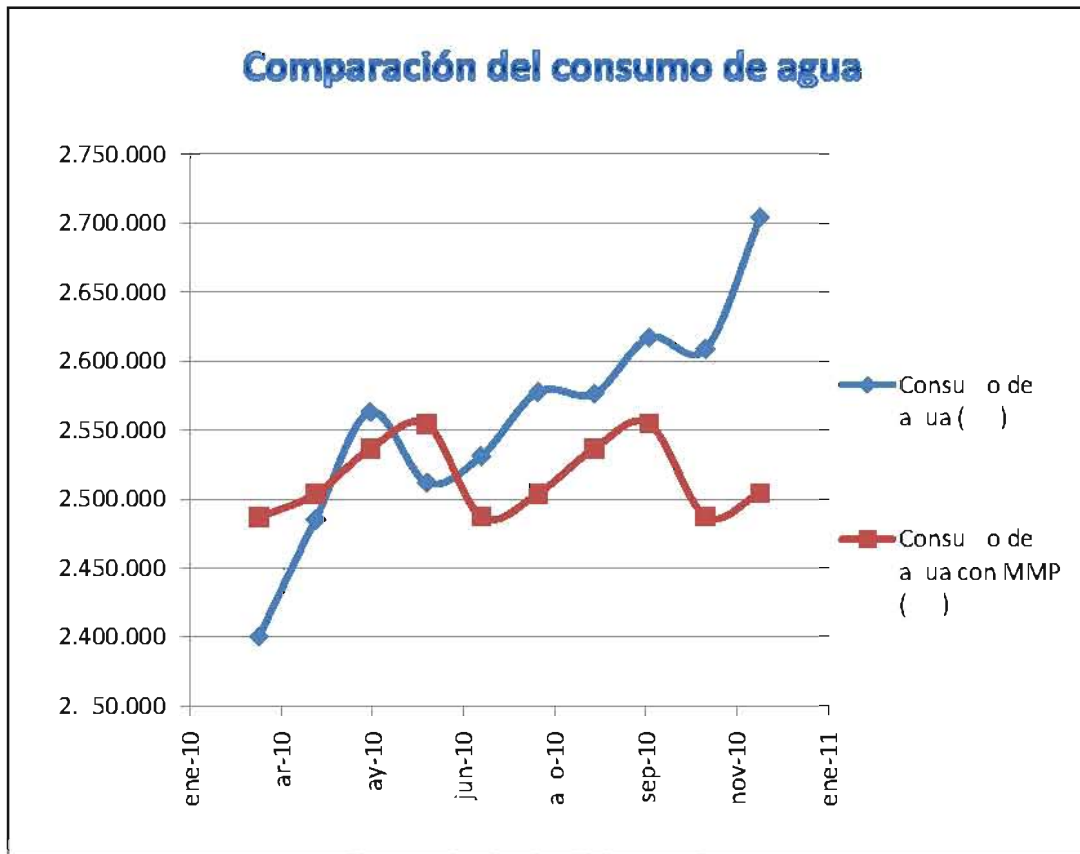


Figura 2.2. Comparación del consumo de agua.

Como podemos observar el gráfico de la predicción del consumo de agua con medias móviles ponderadas se asemeja a los datos reales pero presenta una ciclicidad marcada, lo cual es propio del modelo, además presenta un error considerable de 2.76 %.

CAPITULO IV

MODELADO DEL CONSUMO DE AGUA CON REDES NEURONALES ARTIFICIALES

RESUMEN

En este capítulo presentaremos el modelado del consumo de agua con redes neuronales artificiales, siguiendo la metodología propuesta para la construcción de redes neuronales predictivas, también se presentará la herramienta desarrollada y posteriormente se realizara la comparación con los datos reales de consumo de agua.

4.1. METODOLOGÍA PARA LA PREDICCIÓN CON REDES NEURONALES PREDICTIVAS

En este capítulo se empezará a desarrollar cada una de las etapas de la metodología para la predicción con redes neuronales predictivas descritas en el anterior capítulo.

4.2. PREPARACIÓN DE LOS DATOS

Para realizar la preparación de los datos realizaremos cuatro procesos: adquisición, estructuración, normalización y división de los datos, los cuales son detallados a continuación.

4.2.1. Adquisición de los datos

Para el pronóstico del consumo de agua en la ciudad de La Paz, se tomaron en cuenta tres variables de entrada, dos variables climáticas que son la precipitación y la temperatura media, y una variable demográfica como la población.

La variable precipitación y temperatura media fueron obtenidas de la estación meteorológica de Laikakota⁷ (ver anexo A), en la tabla 4.1 y 4.2 respectivamente observaremos los datos que se utilizaron.

⁷ La estación meteorológica de Laikakota es el punto de referencia para la obtención de datos meteorológicos de la ciudad de La Paz.

Tabla 4.1. Datos históricos de precipitación 2008-2010 en (). (Fuente: Sena hi)

A O	2008	2009	2010
ENE	165,4	61,4	119,7
FEB	75,5	116,9	141,6
MAR	65,1	5 ,4	1,9
ABR	,2	0,5	,9
MAY	4,7	0,	20,9
JUN	,4	0,0	0,0
JUL	2,7	15,1	2,8
AGO	,1	1,5	6,2
SEP	4,8	25,7	8,
OCT	2 ,6	27,0	50,
NOV	12,	75,7	9,8
DIC	111,8	1 7,1	109,7

Tabla 4.2. Datos históricos de temperatura edia 2008-2010 en (°C). (Fuente: Sena hi)

A O	2008	2009	2010
ENE	12,8	1 ,6	14,1
FEB	1 ,6	1 ,9	14,
MAR	12,7	1 ,4	14,6
ABR	12,9	12,8	14,1
MAY	11,6	12,2	12,4
JUN	11,2	11,4	11,8
JUL	10,9	10,7	11,
AGO	12,0	12,1	12,5
SEP	12,7	1 ,2	1 ,2
OCT	1 ,4	14,5	1 ,2
NOV	15,1	15,5	14,7
DIC	1 ,6	14,4	14,2

La variable demográfica de población fue obtenida del Instituto Nacional de Estadísticas (INE), estos datos son proyecciones obtenidas a partir del censo del 2001, en la tabla 4. observamos los datos que nos interesan para nuestro fin.

Tabla 4. La Paz: proyecciones de población, por sexo, según municipio, 2000 – 2010.(Fuente: INE)

DEPARTAMENTO, PROVINCIA Y SECCIÓN DE PROVINCIA – MUNICIPIO		Pedro Domingo Murillo	Sección Capital - La Paz	Primera Sección - Palca	Segunda Sección - Mecapaca	Tercera Sección - Achocalla	Cuarta Sección - El Alto
2000	Total	1.519.19	828.1	14.746	12.16	15.699	648.407
2001	Total	1.552.278	8.1849	14.861	12.26	15.80	677.412
2002	Total	1.585.222	8.466	14.971	12.508	15.955	707.125
2003	Total	1.618.176	8.681	15.065	12.688	16.065	777.527
2004	Total	1.651.15	8.8400	15.150	12.857	16.159	768.587
2005	Total	1.689.920	8.9169	15.218	13.018	16.242	800.27
2006	Total	1.716.670	8.9594	15.277	13.169	16.318	822.12
2007	Total	1.749.09	8.9718	15.326	13.311	16.379	864.575
2008	Total	1.781.915	8.9905	15.464	13.448	16.425	896.77
2009	Total	1.814.18	840.044	15.589	13.572	16.462	928.851
2010	Total	1.846.556	840.209	15.411	13.688	16.481	960.767

Como podemos observar los datos mostrados en la anterior tabla son anuales y los datos presentados de las otras dos variables son mensuales, por lo que no son útiles en una red neuronal debido a que no se encuentran igualmente espaciados. Para superar esta dificultad utilizaremos el método de interpolación de Lagrange⁸ que nos ayudará a obtener los datos mensuales de la población, estos datos se muestran en la tabla 4.4.

⁸ El método de interpolación de Lagrange, en análisis numérico es el polinomio que interpola un conjunto de puntos dado en la forma de Lagrange, cuya ecuación viene dada por:

$$P(x) = \sum_{k=0}^n f_k l_k(x), \quad l_k(x) = \prod_{\substack{j=0 \\ j \neq k}}^n \frac{x - x_j}{x_k - x_j}, \quad k = 0, \dots, n.$$

Tabla 4.4. Datos mensuales de la población.

MESES	2008	2009	2010
Enero	8 9.800,424	8 9.915,590	840.056,757
Febrero	8 9.809,028	8 9.926, 61	840.069,694
Marzo	8 9.817,81	8 9.9 7, 1	840.082,81
Abril	8 9.826,778	8 9.948,444	840.096,111
Mayo	8 9.8 5,924	8 9.959,757	840.109,590
Junio	8 9.845,250	8 9.971,250	840.12 ,250
Julio	8 9.854,757	8 9.982,924	840.1 7,090
A gosto	8 9.864,444	8 9.994,778	840.151,111
Septie bre	8 9.874, 1	840.006,81	840.165, 1
Octubre	8 9.884, 61	840.019,028	840.179,694
Novie bre	8 9.894,590	840.0 1,424	840.194,257
Dicie bre	8 9.905,000	840.044,000	840.209,000

Para la variable de salida tenemos el consumo de agua mensual de la ciudad de La Paz de los años 2008, 2009 y 2010, que fueron obtenidos de la Empresa Pública Social de Agua y Saneamiento (EPSAS), en la Tabla 4.5 observamos el consumo de agua.

Tabla 4.5. Consumo de agua mensual en () (Fuente: EPSAS)

MESES	2008	2009	2010
Enero	2.550.711,48	2.510.1 8,45	2.4 9.847,85
Febrero	2.128.9 0,58	2.466.044,65	2.297.4 5,58
Marzo	2.250.766,58	2. 21. 19,57	2.400.487,92
Abril	2.554.466,86	2.520.571,08	2.485. 05, 5
Mayo	2.646.688,45	2.5 6.418,62	2.56 .220,75
Junio	2.668.666,70	2.504.98 ,21	2.512.072,41
Julio	2.468.767,75	2.540.04 ,54	2.5 1.269,82
A gosto	2.611.10 ,57	2.518.145,46	2.577.616,87

Septiembre	2.642.425,66	2.595.560,49	2.576.575,17
Octubre	2.728.645,20	2.687.57,98	2.617.025,59
Noviembre	2.724.580,90	2.720.58,28	2.608.774,54
Diciembre	2.592.111,25	2.177,74	2.7090,89

4.2.2. Estructuración de los datos

En la tabla 4.6 observaremos la estructuración de los datos, es decir, la formación de los pares entrada y salida $(P_i; d_i)$. Donde P_1, \dots, P_n son los datos de entrada y d_1, \dots, d_n son las salidas deseadas.

Tabla 4.6. Estructuración de datos.

Entradas (P_i)				Salida deseada (d_i)	
	Población	Precipitación	Temperatura		Consumo de Agua ()
P_1	8 9.800,424	165,4	12,8	d_1	2.550.711,48
P_2	8 9.809,028	75,5	11,6	d_2	2.128.905,58
P_3	8 9.817,81	65,1	12,7	d_3	2.250.766,58
P_4	8 9.826,778	7,2	12,9	d_4	2.554.466,86
P_5	8 9.835,924	4,7	11,6	d_5	2.646.688,45
P_6	8 9.845,250	7,4	11,2	d_6	2.668.666,70
P_7	8 9.854,757	2,7	10,9	d_7	2.468.767,75
P_8	8 9.864,444	7,1	12	d_8	2.611.107,57
P_9	8 9.874,1	4,8	12,7	d_9	2.642.425,66
P_{10}	8 9.884,61	27,6	11,4	d_{10}	2.728.645,20
P_{11}	8 9.894,590	12,	15,1	d_{11}	2.724.580,90
P_{12}	8 9.905,000	111,8	11,6	d_{12}	2.592.111,25
P_{13}	8 9.915,590	61,4	11,6	d_{13}	2.510.184,45
P_{14}	8 9.926,61	116,9	11,9	d_{14}	2.466.044,65
P_{15}	8 9.937,1	57,4	11,4	d_{15}	2.211.19,57
P_{16}	8 9.948,444	0,5	12,8	d_{16}	2.520.571,08
P_{17}	8 9.959,757	0,	12,2	d_{17}	2.564.418,62

P ₁₈	8 9.971,250	0	11,4	d ₁₈	2.504.98 ,21
P ₁₉	8 9.982,924	15,1	10,7	d ₁₉	2.540.04 ,54
P ₂₀	8 9.994,778	1,5	12,1	d ₂₀	2.518.145,46
P ₂₁	840.006,81	25,7	1 ,2	d ₂₁	2.595.560,49
P ₂₂	840.019,028	27	14,5	d ₂₂	2.687. 57,98
P ₂	840.0 1,424	75,7	15,5	d ₂	2.720.5 8,28
P ₂₄	840.044,000	1 7,1	14,4	d ₂₄	2. 17.7 ,74
P ₂₅	840.056,757	119,7	14,1	d ₂₅	2.4 9.847,85
P ₂₆	840.069,694	141,6	14,	d ₂₆	2.297.4 5,58
P ₂₇	840.082,81	1,9	14,6	d ₂₇	2.400.487,92
P ₂₈	840.096,111	,9	14,1	d ₂₈	2.485. 05, 5
P ₂₉	840.109,590	20,9	12,4	d ₂₉	2.56 .220,75
P ₀	840.12 ,250	0	11,8	d ₀	2.512.072,41
P ₁	840.1 7,090	2,8	11,	d ₁	2.5 1.269,82
P ₂	840.151,111	6,2	12,5	d ₂	2.577.616,87
P	840.165, 1	8,	1 ,2	d	2.576.575,17
P ₄	840.179,694	50,	1 ,2	d ₄	2.617.025,59
P ₅	840.194,257	9,8	14,7	d ₅	2.608.774,54
P ₆	840.209,000	109,7	14,2	d ₆	2.70 .90 ,89

4.2. . Nor alización de datos

La nor alización de los datos es necesaria debido a que estos suelen presentar intervalos no uniformes como puede observarse en la tabla anterior, por lo que se precisa estandarizarlos. Nor alizaremos estos datos utilizando la ecuación 2.8 mostrada en el anterior capítulo. La tabla 4.7 ilustra los datos nor alizados.

Tabla 4.7. Datos normalizados.

Entradas (P_i)				Salida deseada (d_i)	
	Población	Precipitación	Temperatura		Consumo de Agua ()
P_1	-1,0000	1,0000	-0,1250	d_1	-0,22079
P_2	-0,9579	-0,0871	0,208	d_2	-1,00000
P	-0,9149	-0,2128	-0,1667	d	-0,77492
P_4	-0,8710	-0,961	-0,08	d_4	-0,2185
P_5	-0,8262	-0,942	-0,6250	d_5	-0,0448
P_6	-0,7806	-0,9589	-0,7917	d_6	-0,00288
P_7	-0,740	-0,9674	-0,9167	d_7	-0,7218
P_8	-0,6866	-0,9625	-0,458	d_8	-0,10922
P_9	-0,68	-0,9420	-0,1667	d_9	-0,0516
P_{10}	-0,5891	-0,7146	0,1250	d_{10}	0,1079
P_{11}	-0,590	-0,851	0,8	d_{11}	0,10042
P_{12}	-0,4881	0,519	0,208	d_{12}	-0,1441
P_{13}	-0,46	-0,2576	0,208	d_{13}	-0,29575
P_{14}	-0,85	0,415	0,	d_{14}	-0,7721
P_{15}	-0,299	-0,54	0,1250	d_{15}	-0,64458
P_{16}	-0,2754	-0,612	-0,1250	d_{16}	-0,27647
P_{17}	-0,2201	-0,9964	-0,750	d_{17}	-0,24720
P_{18}	-0,168	-1,0000	-0,708	d_{18}	-0,0527
P_{19}	-0,1067	-0,8174	-1,0000	d_{19}	-0,24050
P_{20}	-0,0486	-0,9819	-0,4167	d_{20}	-0,28096
P_{21}	0,010	-0,6892	0,0417	d_{21}	-0,1794
P_{22}	0,0701	-0,675	0,58	d_{22}	0,0165
P_{23}	0,108	-0,0846	1,0000	d_{23}	0,09295
P_{24}	0,192	0,6578	0,5417	d_{24}	-0,65120
P_{25}	0,2548	0,4474	0,4167	d_{25}	-0,42560
P_{26}	0,181	0,7122	0,5000	d_{26}	-0,68870
P_{27}	0,82	-0,614	0,6250	d_{27}	-0,4982

P_{28}	0,4474	-0,9528	0,4167	d_{28}	-0, 4162
P_{29}	0,51 4	-0,747	-0,2917	d_{29}	-0,19768
P_0	0,5802	-1,0000	-0,5417	d_0	-0,29217
P_1	0,6480	-0,9661	-0,7500	d_1	-0,2567
P_2	0,7166	-0,9250	-0,2500	d_2	-0,17109
P	0,7861	-0,8996	0,0417	d	-0,17 01
P_4	0,8565	-0, 918	0,0417	d_4	-0,09828
P_5	0,9278	-0,8815	0,6667	d_5	-0,11 5
P_6	1,0000	0, 265	0,458	d_6	0,06222

4.2.4. División de los datos

La división de los datos se realizó en tres conjuntos disjuntos, como lo había mencionado en el capítulo anterior. Los valores correspondientes a cada conjunto son: para el conjunto de entrenamiento se tomó el 70% del conjunto total de datos (Tabla 4.8), para el conjunto de validación se tomó el 15% (Tabla 4.9) y para el conjunto de prueba el otro 15% (Tabla 4.10).

Tabla 4.8. Conjunto de entrenamiento.

Entradas (P_i)			Salida deseada (d_i)		
	Población	Precipitación	Temperatura		Consumo de Agua ()
P_1	-1,00000	1	-0,125	d_1	0,406605 62
P_2	-0,95788	-0,0871	0,208	d_2	-1
P	-0,91488	-0,2128	-0,1667	d	-0,59 686744
P_4	-0,87100	-0,961	-0,08	d_4	0,419129252
P_5	-0,8262	-0,94 2	-0,625	d_5	0,7266808 4
P_6	-0,78057	-0,9589	-0,7917	d_6	0,799976529
P_7	-0,7 404	-0,9674	-0,9167	d_7	0,1 29616
P_8	-0,68662	-0,9625	-0,458	d_8	0,608008122
P_9	-0,6 8 1	-0,942	-0,1667	d_9	0,712464772
P_{10}	-0,58912	-0,7146	0,125	d_{10}	1
P_{11}	-0,5 905	-0,851	0,8	d_{11}	0,986445887

P_{12}	-0,48810	0, 519	0,208	d_{12}	0,54467026
P_1	-0,4 626	-0,2576	0,208	d_1	0,271297572
P_{14}	-0, 8 5	0,41 5	0,	d_{14}	0,124248297
P_{15}	-0, 2992	-0, 54	0,125	d_{15}	-0, 58 98199
P_{16}	-0,2754	-0,6 12	-0,125	d_{16}	0, 0608955
P_{17}	-0,22006	-0,9964	-0, 75	d_{17}	0, 589 9824
P_{18}	-0,16 80	-1	-0,708	d_{18}	0,254105261
P_{19}	-0,10665	-0,8174	-1	d_{19}	0, 7102864
P_{20}	-0,0486	-0,9819	-0,4167	d_{20}	0,298000 06
P_{21}	0,01028	-0,6892	0,0417	d_{21}	0,55617 201
P_{22}	0,07008	-0,67 5	0,58	d_{22}	0,862 10444
P_2	0,1 076	-0,0846	1	d_2	0,972964074
P_{24}	0,192 2	0,6578	0,5417	d_{24}	-0, 70 56654
P_{25}	0,25476	0,4474	0,4167	d_{25}	0,0 6884077
P_{26}	0, 1809	0,7122	0,5	d_{26}	-0,4 8049 84

Tabla 4.9. Conjunto de Validación.

Entradas (P_i)				Salida deseada (d_i)	
	Población	Precipitación	Temperatura		Consumo de Agua ()
P_{27}	0, 82	-0,614	0,6250	d_{27}	-0,498 2
P_{28}	0,4474	-0,9528	0,4167	d_{28}	-0, 4162
P_{29}	0,51 4	-0,747	-0,2917	d_{29}	-0,19768
P_{30}	0,5802	-1,0000	-0,5417	d_{30}	-0,29217
P_{31}	0,6480	-0,9661	-0,7500	d_{31}	-0,2567

Tabla 4.10. Conjunto de Prueba.

Entradas (P _i)			Salida deseada (d _i)	
	Población	Precipitación	Temperatura	Consumo de Agua ()
P ₂	0,7166	-0,9250	-0,2500	d ₂ -0,17109
P	0,7861	-0,8996	0,0417	d -0,17 01
P ₄	0,8565	-0, 918	0,0417	d ₄ -0,09828
P ₅	0,9278	-0,8815	0,6667	d ₅ -0,11 5
P ₆	1,0000	0, 265	0,458	d ₆ 0,06222

4. . DETERMINACIÓN DE LA ARQUITECTURA DE LA RED

Para la arquitectura del modelo neuronal se consideró un perceptrón multicapa, cuyas entradas y salida ya definidos anteriormente. Se utilizara este modelo debido a que es una herramienta de propósito general y además esta red tiene la capacidad de generalización, es decir, la facilidad de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento. En la figura .10 podemos observar la arquitectura del modelo de red neuronal seleccionado.

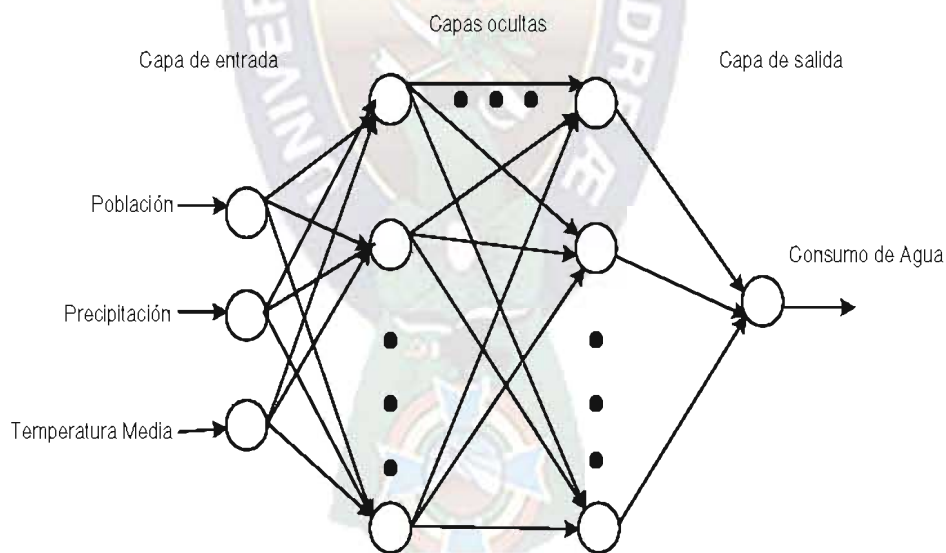


Figura 4.1. Arquitectura del perceptrón multicapa.

El perceptrón multicapa diseñado para nuestro propósito presenta tres capas, una capa de entrada con tres neuronas, una capa de salida con una neurona y n capas ocultas con n neuronas. El número de capas ocultas y de neuronas en cada capa oculta se obtendrá probando distintas configuraciones para determinar un mejor ajuste de la predicción.

Las funciones de transferencia que se utilizarán en las capas ocultas son del tipo tangencial (tansig) porque son las más utilizadas para resolver funciones continuas y la función de transferencia para la capa de salida es del tipo lineal.

4.1.1. Presentación de las pruebas para la Arquitectura de la Red Neuronal Artificial

Actualmente no existe una regla específica para determinar una arquitectura adecuada para el perceptrón multicapa, por lo que realizaremos unas pruebas con diferentes números de capas ocultas y de neuronas en cada capa oculta, y se escogerá la que mejores resultados presente. En la tabla 4.11 podemos observar los errores que presentaron cada una de estas pruebas.

Tabla 4.11. Pruebas de Arquitectura.

Algoritmo Aprendizaje	Capas Ocultas	Función Activación	Error	Algoritmo Aprendizaje	Capas Ocultas	Función Activación	Error
trainl	1	Tansig	0,1174	trainl	20	Tansig	0,0001
trainl	10	Tansig	0,0005	trainl	2-15	Tansig	4,47E-27
trainl	10-10	tansig	4, 1E-25	trainl	2-5	Tansig	0,015
trainl	10-10-10	tansig	9,15E- 1	trainl		Tansig	0,0072
trainl	10-9-11-5-11	tansig	8,60E-28	trainl	-10	Tansig	1,11E-04
trainl	1-10	tansig	0,0188	trainl	4-20	Tansig	7,74E-2
trainl	1-11	tansig	0,052	trainl	5	Tansig	0,0254
trainl	1-12	tansig	0,016	trainl	5-10-15	Tansig	2,24E-21
trainl	1-1	tansig	0,01 1	trainl	5-11-1 -1	Tansig	2,4 E-22
trainl	1-15	tansig	0,0225	trainl	5-11-1 -5	Tansig	5,24E-29
trainl	1-18	tansig	0,0147	trainl	5-5-5	Tansig	,95E-24
trainl	1-20	tansig	0,0021	trainl	5-5-5-5	Tansig	2,40E-0
trainl	12-8-12	tansig	1,24E-27	trainl	5-5-5-5-5	Tansig	1,70E-2
trainl	1 -20	tansig	8,47E-27	trainl	5-5-9-5-5	Tansig	,62E-2
trainl	14-14-14	tansig	5,82E-22	trainl	5-5-9-9	Tansig	5,75E-27
trainl	14-15	tansig	5, 4E-26	trainl	5-8-1 -5	Tansig	1,09E-27
trainl	15	tansig	0,0001	trainl	6-12	Tansig	1,42E-2
trainl	1-5	tansig	0,0489	trainl	7-5-5-5	Tansig	9,18E-2

trainl	15-10-14	tansi	6,12E-26	trainl	7-8-7	Tansi	,04E-25
trainl	15-16-16	tansi	1, 5E-2	trainl	8	Tansi	9, E-08
trainl	15-16-16	tansi	1, 5E-2	trainl	8-5-5	Tansi	1,15E-2
trainl	15-5	Tansi	1,51E-2	trainl	8-5-5-5-5	Tansi	2,70E-0
trainl	15-8--10	Tansi	, 2E-25	trainl	8-5-7	Tansi	5,52E-02
trainl	15-8-12	Tansi	8,87E-27	trainl	8-8	Tansi	,09E-25
trainl	1-9	Tansi	0,0055	trainl	8-9-9-10-10	tansi	2,06E- 0

De la tabla anterior puede escoger la arquitectura que tendrá el perceptrón multicapa, que constará de una capa de entrada con tres entradas, una capa de salida con una salida y tres capas ocultas cada una con 10 neuronas (ver figura 4.2).

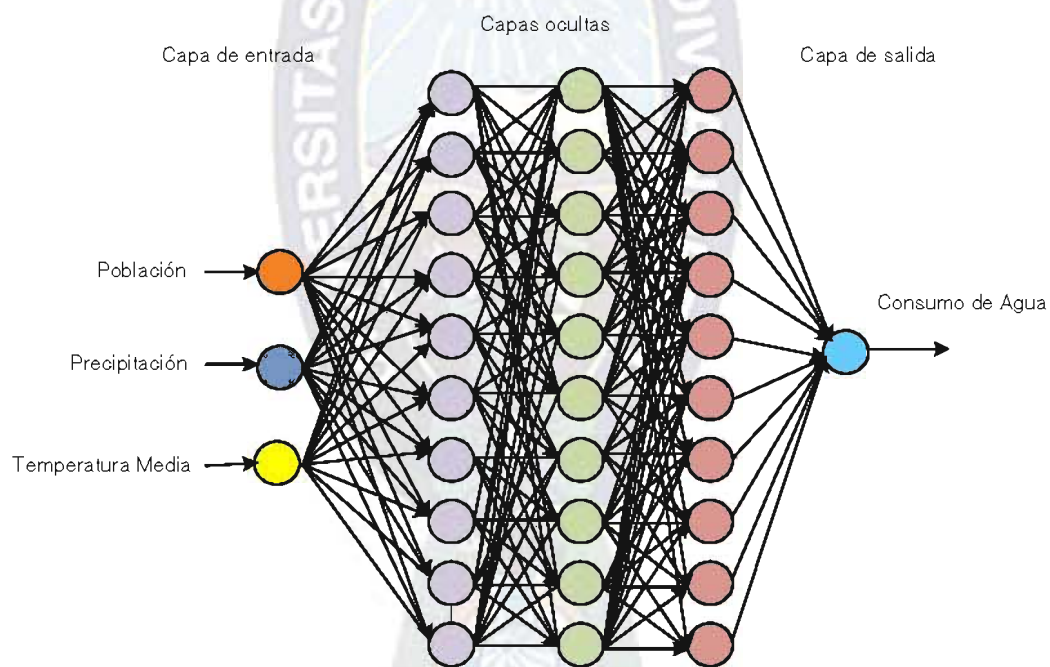


Figura 4.2. Arquitectura de la red Neuronal elegida.

4.4. DISEÑO DE APRENDIZAJE O ENTRENAMIENTO DE LA RED

El algoritmo de aprendizaje que se utilizó para el entrenamiento de la red neuronal, es el algoritmo backpropagation desarrollado en el capítulo anterior, en particular con MatLab utilizamos el algoritmo de Levenberg - Marquardt que está basado en el algoritmo de Backpropagation.

Este algoritmo de optimización se aplica a MLP con batch-training, tiene una función de error cuadrático medio. Es mejor que el método de descenso de gradiente, ya que combina distintos métodos de inicialización de funciones utilizando uno u otro dependiendo de los valores de las derivadas de la función error (Carballo, 2011).

4.5. METODOLOGIA DE DESARROLLO DE LA HERRAMIENTA

La metodología de desarrollo que se utilizó para la construcción de la herramienta es el modelo en cascada, a continuación detallaremos las fases de este modelo.

4.5.1. FASE DE ANÁLISIS DE LOS REQUISITOS

En esta fase se realizó el proceso de recopilación de los requisitos que se centra e intensifica especialmente en el software. Para esta fase utilizaremos algunas herramientas del Lenguaje de Modelado Unificado (UML).

4.5.1.1. Casos de Uso

Se elaboró casos de uso y sus respectivas descripciones, para definir las especificaciones de requerimientos.

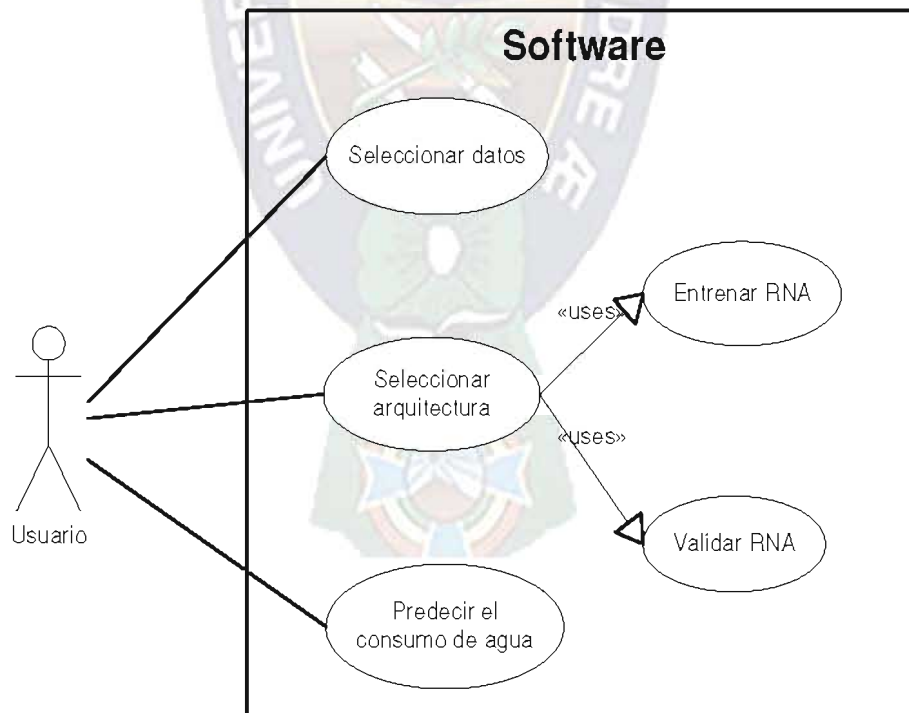


Figura 4.1. Diagrama de casos de uso.

4.5.1.2. Descripción de casos de uso

A continuación realizaremos la descripción de cada caso de uso, de manera que se comprenda la funcionalidad de cada uno.

Tabla 4.12. Descripción de caso de uso: Seleccionar Datos.

CASO DE USO :	Seleccionar Datos
ACTORES :	Usuario
DESCRIPCIÓN :	El usuario selecciona los datos con los que se entrenara a la red neuronal.
CURSO NORMAL DE LOS EVENTOS	
ACTOR	RESPUESTA DEL SISTEMA
1. Presiona la opción para seleccionar datos de entrada. 2. Selecciona la ubicación de los parámetros de entrada a procesar (población, precipitación y temperatura). 3. Presiona la opción para seleccionar datos de salida. 4. Selecciona la ubicación de los parámetros de salida a procesar (consumo de agua).	1. Despliega un explorador de archivos. 2. Carga datos y normaliza. 3. Despliega un explorador de archivos. 4. Carga datos y normaliza.

Tabla 4.1 . Descripción de caso de uso: Seleccionar Arquitectura.

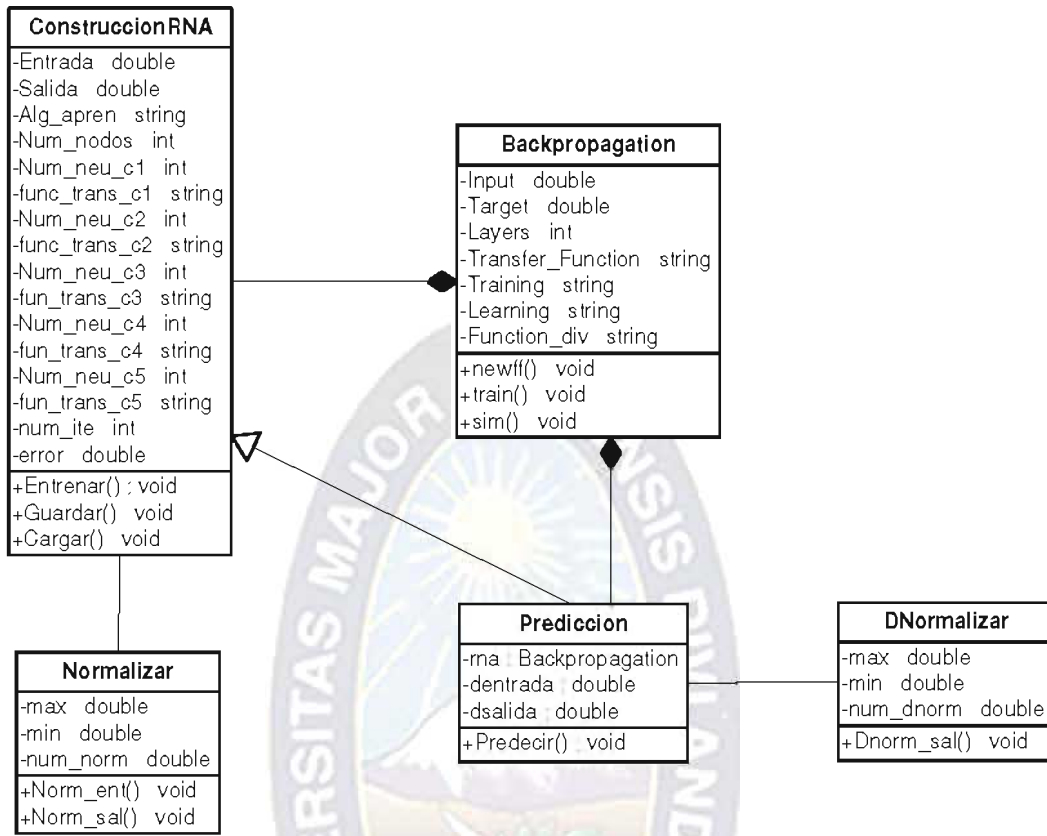
CASO DE USO :	Seleccionar Arquitectura
ACTORES :	Usuario
DESCRIPCIÓN :	El usuario seleccionara la arquitectura, realizando previa mente su entrena iento y su validación.
CURSO NORMAL DE LOS EVENTOS	
ACTOR	RESPUESTA DEL SISTEMA
<p>1. Selecciona las opciones que requiere el GUI, como ser: al orit o de aprendizaje, número de capas ocultas, número de neuronas en cada capa, función de transición en cada capa, número de iteraciones y el error.</p> <p>2. Presiona la opción entrenar.</p> <p>5. Verifica el error de entrena iento de la red, si es peque o se realiza la validación.</p> <p>6. Seleccionar datos para la validación.</p> <p>7. Presionar la opción predecir.</p>	<p>3. La red se entrena con las características dadas.</p> <p>4. Despliega las características del entrena iento.</p> <p>8. Simula la predicción con los datos introducidos.</p> <p>9. Devuelve los datos predichos.</p>

Tabla 4.14. Descripción de caso de uso: Predecir el consumo de agua.

CASO DE USO :	Predecir el Consumo de Agua
ACTORES :	Usuario
DESCRIPCIÓN :	Después de tener una configuración adecuada de la red neuronal a utilizarse, el usuario realiza la predicción del consumo de agua.
CURSO NORMAL DE LOS EVENTOS	
ACTOR	RESPUESTA DEL SISTEMA
1. Presionar la opción para seleccionar para cargar la red neuronal a utilizar. 2. Seleccionar la ubicación del archivo a utilizarse. 3. Presionar la opción para cargar. 4. Presionar la opción para cargar. 5. Introducir los datos de entrada (población, precipitación y temperatura). 6. Presionar la opción pronostico	1. Despliega un explorador de archivos. 2. Carga datos de la red neuronal y muestra algunas características. 3. Simula la predicción con los datos introducidos. 4. Muestra los datos predichos.

4.5.1. Diagrama de Clases

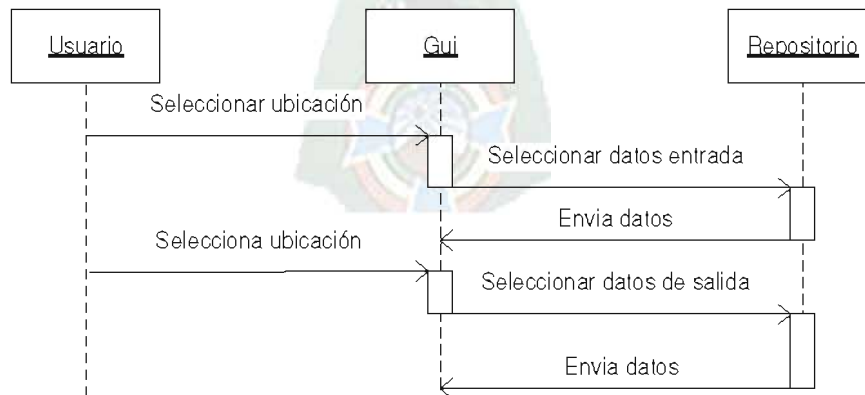
Un diagrama de clases presenta un conjunto de clases y relaciones entre ellas. En la figura 4.4 se presentan los diagramas de clases del software de predicción del consumo de agua.



Fi ura 4.4. Dia ra a de clases.

4.5.1.4. Dia ra a de Secuencia

A continuaci3n observare mos los dia ra as de secuencia para cada uno de los casos de uso propuestos.



Fi ura 4.5. Dia ra a de secuencias: Seleccionar datos.

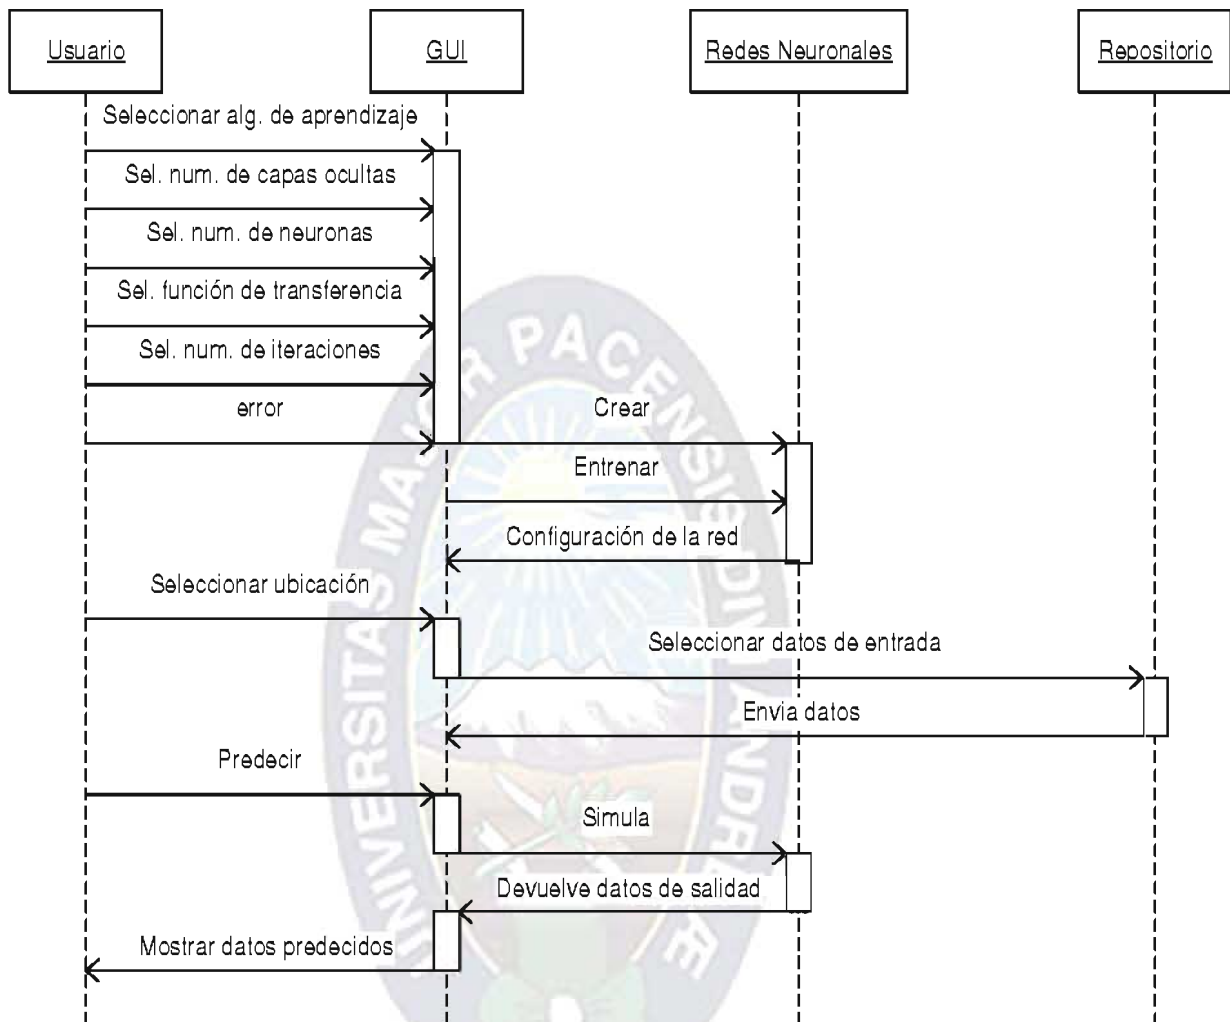


Figura 4.6. Diagrama de secuencia: Seleccionar arquitectura.

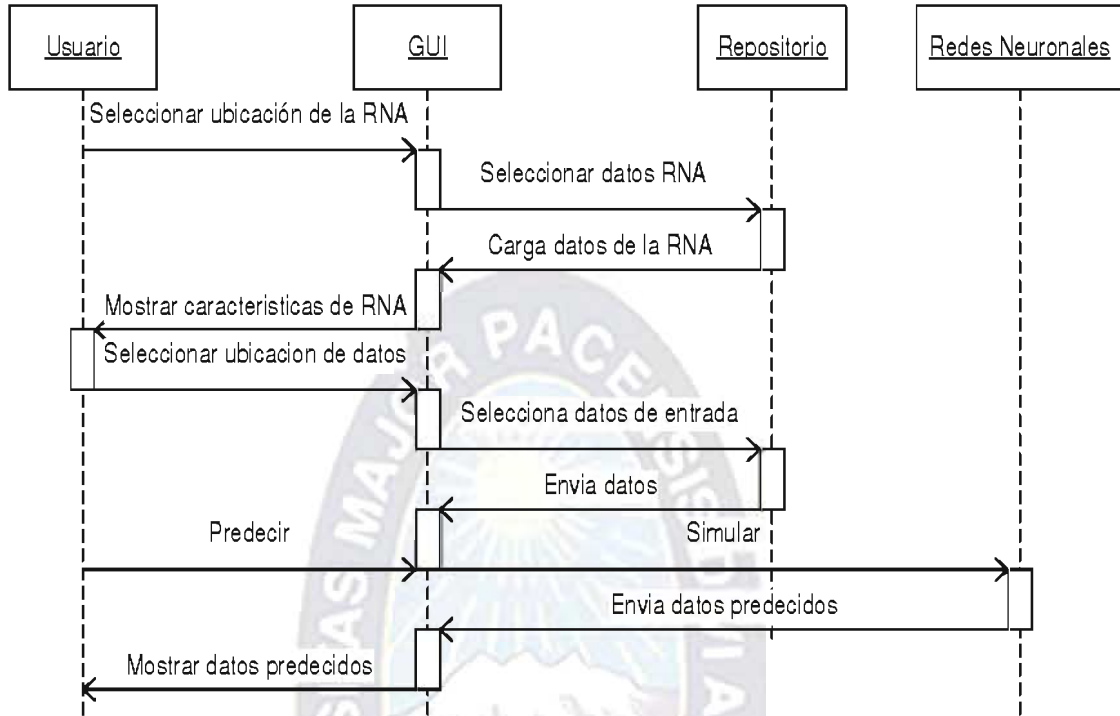


Figura 4.7. Diagrama de secuencia: Predecir consumo de agua.

4.5.2. FASE DE DISEÑO

El proceso de diseño traduce los requisitos en una representación del software con la calidad requerida antes de que comience la codificación.

4.5.2.1. Diagrama de Componentes

En la figura 4.8 observaremos el diagrama de componentes del software de predicción del consumo de agua.

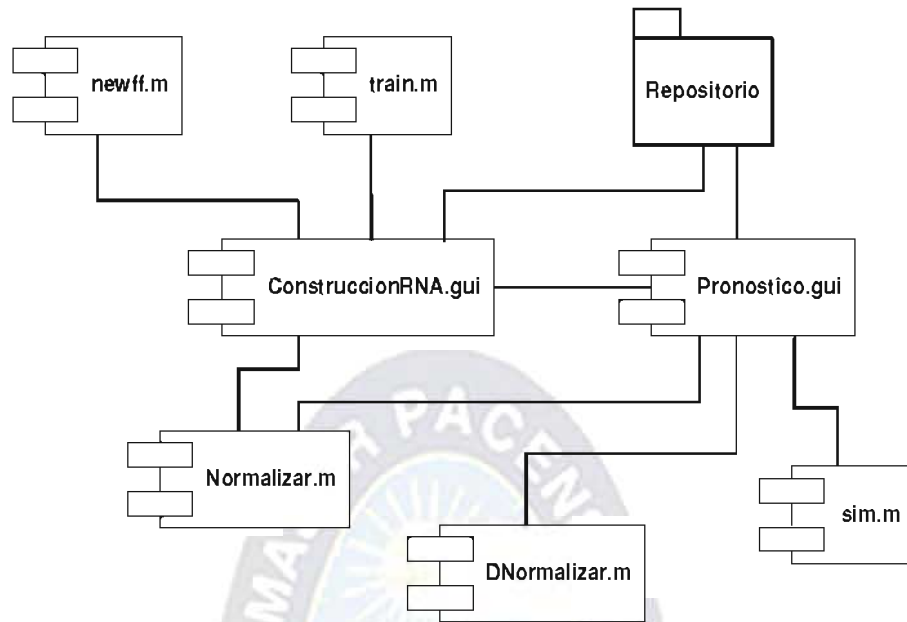


Figura 4.8. Diagrama de componentes.

4.5.2.2. Diseño de la Red Neuronal Artificial

A continuación en la figura 4.9 describiremos el diseño de una red neuronal artificial que sea capaz de predecir el comportamiento del consumo de agua respecto de las variables de entrada elegidas.

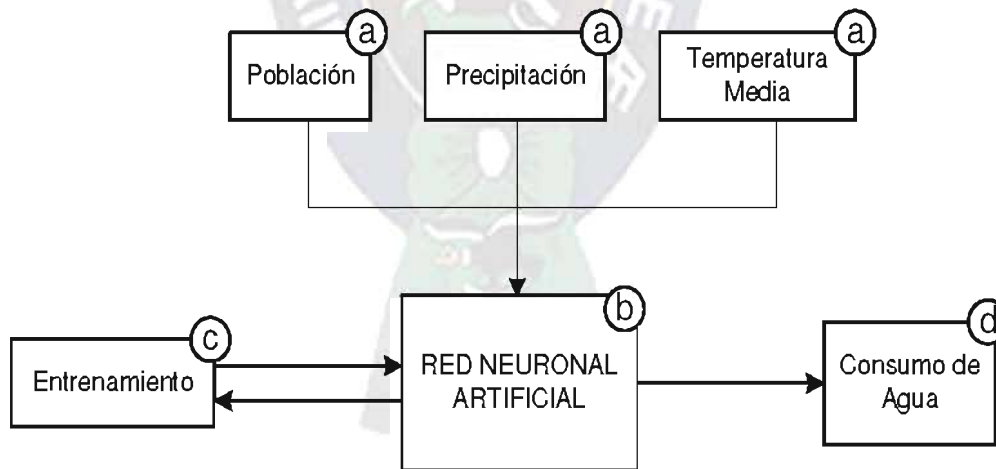


Figura 4.9. Esquema del modelo neuronal (Fuente: Adaptado Hilera Martínez, 1995)

a.- Hace referencia a los datos de entrada a la red neuronal, en este caso en particular a los valores de la población, precipitación y temperatura media.

b.- Es la red neuronal artificial construida para pronosticar el consumo de agua en base a la población, precipitación y temperatura media.

c.- Fase de entrenamiento de la red neuronal con los datos proporcionados.

d.- Resultado obtenido de la red neuronal, en este caso el consumo de agua en metros cúbicos.

4.5. . FASE DE CODIFICACIÓN

En la fase de codificación el diseño debe traducirse en una forma legible para la máquina. Si el diseño se realiza de una manera detallada la codificación puede realizarse automáticamente.

4.5. .1. Código de la Red Neuronal

Se realizaron pruebas para obtener las siguientes características generales para la red neuronal que se utilizará. Como ya había mencionado la red tendrá tres datos de entrada que son: la población, precipitación y temperatura media, y uno de salida que es el consumo de agua, tendrá tres capas ocultas, cada una con diez neuronas.

La función de transición de las capas ocultas son de cada capa oculta es la función tangente hiperbólica.

El algoritmo de aprendizaje que se utilizó es el Levenberg - Marquardt , que en MatLab es la sentencia `trainlm`.

```
net=newff(entradas, salidasd, [10 10 10], {'tansig' 'tansig' 'tansig'}, 'trainlm');
net.divideFcn = '';
net.trainParam.mu=0.000001;
net.trainParam.epochs = 250;
net.trainParam.lr = 0.05;
net.trainParam.goal = 0,000000000001;
[net, tr]=train(net, entradas, salidasd);
```

Figura 4.10. Código fuente de la red neuronal.

5.5. .2. Diseño de la herramienta

Para realizar el proceso de construcción de la red neuronal artificial se desarrolló una herramienta en MatLab 7.6.0. Esta herramienta nos permite crear una red neuronal, entrenarla y realizar las pruebas. En la figura 4.11 observa los el diseño del GUI de la presentación de la herramienta.

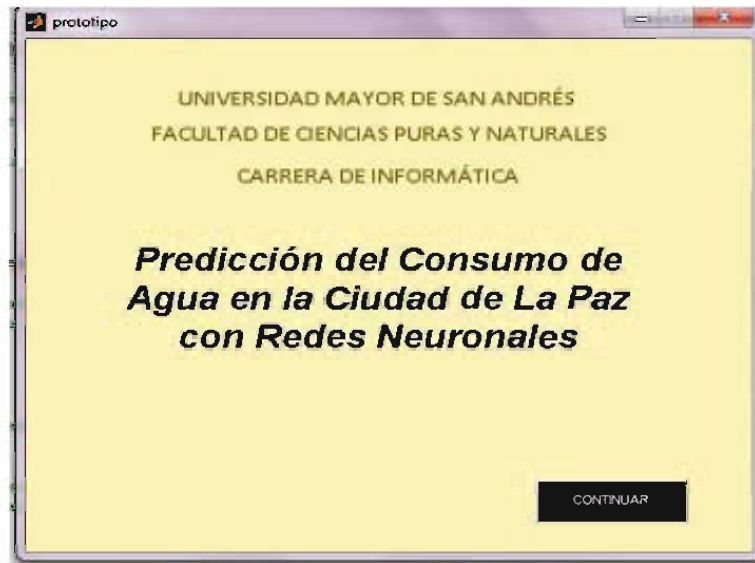


Figura 4.11. Interfaz de presentación.

En la figura 4.12 observaremos el diseño del GUI de construcción de la red neuronal.

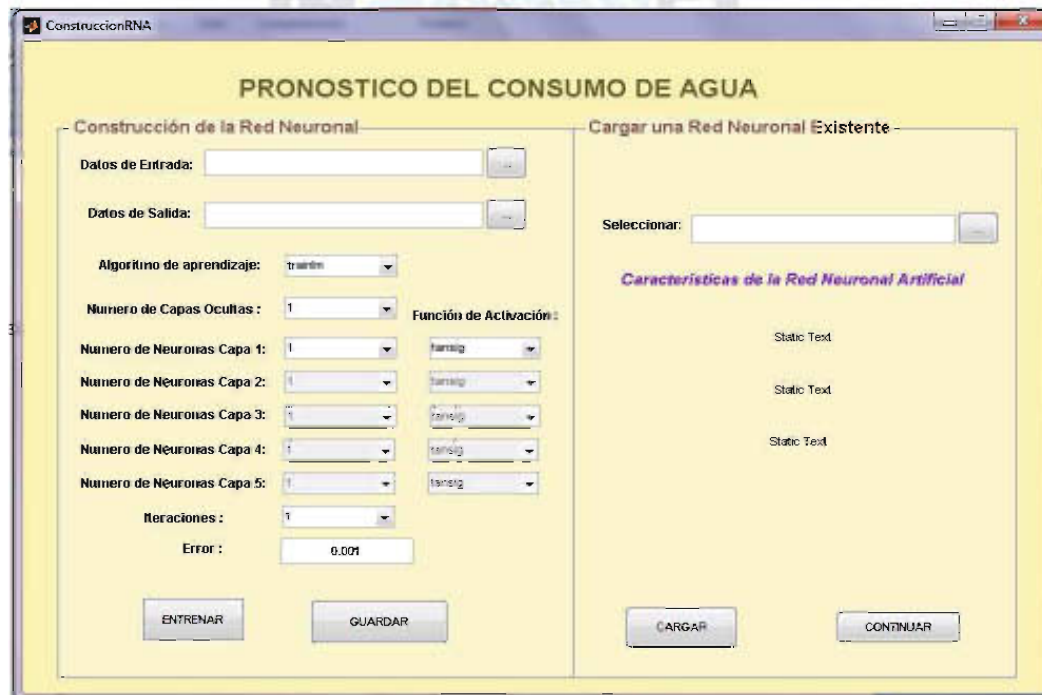


Figura 4.12. Interfaz de construcción de la red neuronal.

En la figura 4.13 observaremos el diseño del GUI donde se puede realizar la simulación de la red neuronal, es decir, la predicción.

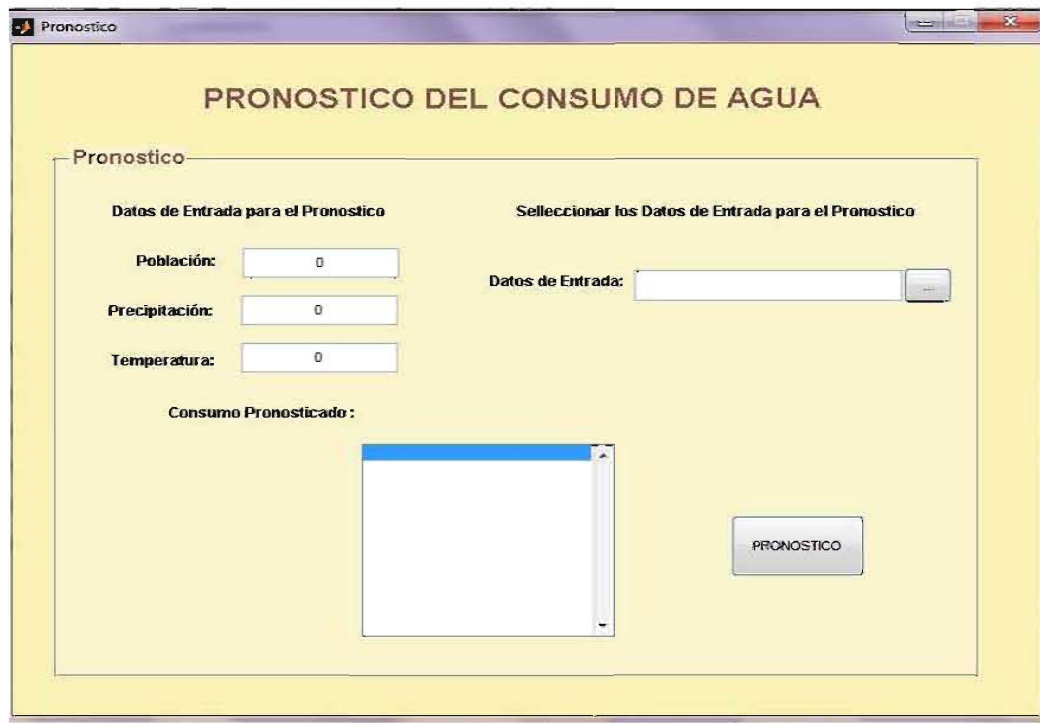


Figura 4.1 . Interfaz de predicción de datos.

La herramienta desarrollada nos permite crear redes neuronales con hasta 5 capas ocultas y cada una con 20 neuronas, además podemos escoger qué función de transición le asignaremos a cada capa oculta, el algoritmo de aprendizaje que utilizaremos. El código de desarrollo de la herramienta lo veremos en Anexo A5.

4.6. FASE DE PRUEBA O EVALUACIÓN GLOBAL DE LOS RESULTADOS

Después de haber generado el código comienza la prueba de la herramienta desarrollada. La prueba se centra en la lógica interna del software, y en las funciones externas, realizando pruebas que aseguren que la entrada definida produce los resultados que realmente se requieren.

4.6.1. Validación del Modelo

Para la validación del modelo se utilizó el método de validación cruzada (cross-validation) que detalla en el anterior capítulo en la sección 2.8, este método estima la exactitud de un clasificador (acc) inducido por un algoritmo de aprendizaje automático. Para este método dividimos todos los datos en k subconjuntos excluyentes con igual número de componentes, se divide los 6 datos obtenidos en seis subconjuntos cada uno con seis datos, realizamos el entrenamiento de la red con cinco subconjuntos y con el restante se

realiza la validación, después se selecciona otro subconjunto para la validación distinto del anterior y con los restantes cinco se realiza el entrenamiento y así sucesivamente hasta validar los seis subconjuntos. En la tabla 4.15 observamos el proceso realizado para obtener la exactitud del clasificador.

Tabla 4.15. Validación cruzada.

Consumo de Área ()	Consumo obtenido por la RNA en cada entrenamiento	Error Relativo ()	Validación (Menor 5 =1 Mayor 5 =0)
2550711,480	2626550,00	2,97 2 0042	1
21289 0,580	641540,00	71,050199	0
2250766,580	2649040,00	17,69501216	0
2554466,860	2492260,00	2,4 5218909	1
2646688,450	2528050,00	4,48252419	1
2668666,700	2598150,00	2,642 94421	1
2468767,750	2066990,00	16,27442476	0
261110 ,570	26682 0,00	2,187827042	1
2642425,660	2646560,00	0,1564600 1	1
2728645,200	27 2800,00	0,15226604	1
2724580,900	2669590,00	2,018 25094	1
2592111,250	262 50,00	1,20514696	1
25101 8,450	2587490,00	,08156508	1
2466044,650	2662080,00	7,949 8 642	0
2 21 19,570	2521 80,00	8,618 92426	0
2520571,080	2480620,00	1,585001126	1
25 6418,620	252 110,00	0,524701242	1
250498 ,210	2552940,00	1,914455546	1
254004 ,540	255 5 0,00	0,5 095 891	1
2518145,460	2751540,00	9,268509056	0
2595560,490	2614290,00	0,7215979	1
2687 57,980	2688820,00	0,05440 619	1

27205 8,280	2681 0,00	1,441195674	1
2 177 ,740	267 490,00	15, 49 15 2	0
24 9847,850	2 98710,00	1,686082597	1
22974 5,580	2 4420,00	1,60981 147	1
2400487,920	2515570,00	4,794112024	1
2485 05, 50	2760000,00	11,0527525	0
256 220,750	2886460,00	12,61066765	0
2512072,410	2769740,00	10,25717209	0
211519,470	2558820,00	20, 2 6965	0
2577616,870	25722 0,00	0,20898645	1
2576575,170	2589810,00	0,51 659766	1
2617025,590	2646 70,00	1,121288615	1
2608774,540	262 0,00	0,557942428	1
270 90 ,890	2409860,00	10,87479075	0
		aciertos	24
		acc_v	66,67

Como observamos en la tabla anterior, la estimación de la exactitud del clasificador es del 66,67% válido, lo que quiere decir que el modelo es preciso en un 66% para un error relativo del 5%.

4.6.2. Aprendizaje de la Red Neuronal Artificial

Para el aprendizaje de la red neuronal, le presentamos los patrones de entrada de la tabla 4.8 que ya están normalizados de acuerdo a la ecuación 2.8.

En la figura 4.14 observamos la curva de aprendizaje del entrenamiento de la red neuronal artificial.

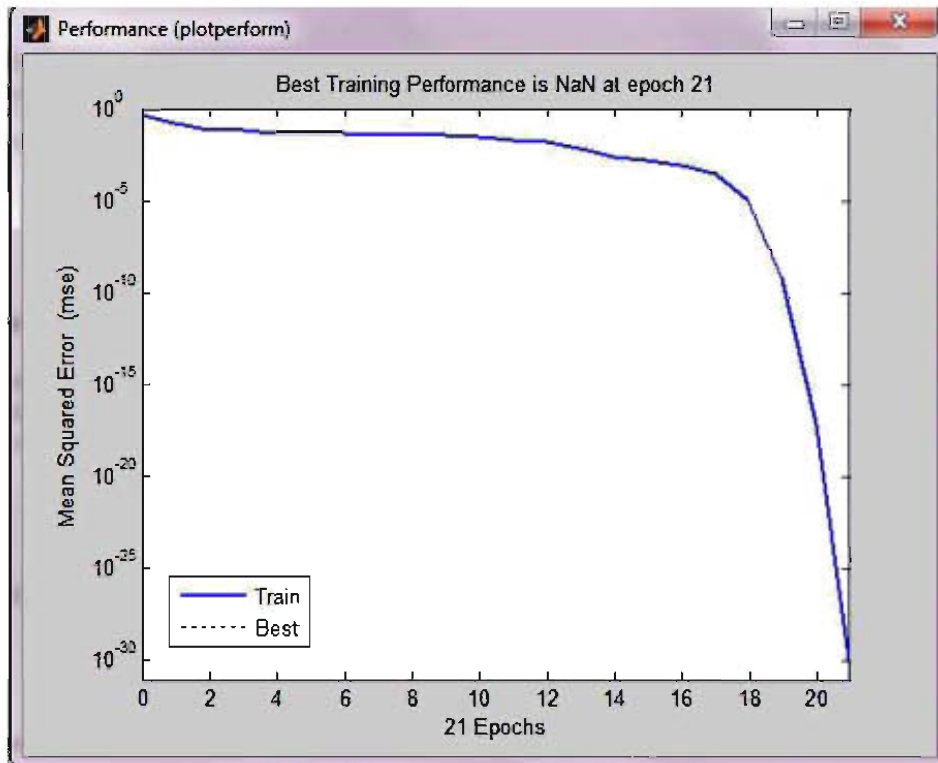


Figura 4.14. Aprendizaje de la RNA.

En la figura 4.15 observaremos la gráfica de la regresión lineal del entrenamiento, que tiene un coeficiente de correlación R igual a 1.




Figura 4.15. Gráfica de la regresión lineal del entrenamiento.

4.6. . Validación de la Red Neuronal Artificial

Para realizar la validación de la red neuronal artificial se presentan datos desconocidos por la red, como ya había sido mencionado anteriormente se realizó la validación con un conjunto del 15%. En la tabla 4.16 observaremos la validación de la red neuronal.

Tabla 4.16. Datos de validación de la RNA.

ENTRADAS			CONSUMO DE AGUA REAL ()	CONSUMO OBTENIDO POR LA RNA ()	ERROR RELATIVO	DIFERENCIA DE CONSUMO ()
POBLACIÓN	PRECIPITACIÓN	TEMPERATURA				
840082,81	1,9	14,6	2.400.487,92	2.586.950	0,07767674	186462,08
840096,111	,9	14,1	2.485.05,5	2.617.150	0,0504968	11844,65
840109,59	20,9	12,4	2.560.220,75	2.516.160	0,0186001	47060,75
840120,25	0	11,8	2.512.072,41	2.506.710	0,0021466	562,41
840170,09	2,8	11,	2.512.269,82	2.504.250	0,01067441	27019,82
				Su media	0,16189549	

Luego obtenemos el error absoluto porcentual de la media (MAPE) con la ecuación 2. de los 5 datos de validación, entonces tenemos:

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{E_t}{Y_t} \right|}{N}$$

$$MAPE = \frac{0,16}{5} = 0,032$$

$$MAPE \% = 0,032 * 100\% = 3,2\%$$

Por lo tanto, la red neuronal artificial presenta en la validación, un error absoluto porcentual de la media de 3,2%.

4.6.4. Prueba de la Red Neuronal

De la misma forma que realizamos la validación de la red neuronal artificial se realizó la prueba de la red neuronal con datos desconocidos por la red, como ya había sido mencionado anteriormente se realizó la prueba con un conjunto del 15%. En la tabla 4.17 observaremos la prueba de la red neuronal.

Tabla 4.17. Prueba de la red neuronal.

ENTRADAS			CONSUMO DE AGUA REAL ()	CONSUMO OBTENIDO POR LA RNA ()	ERROR RELATIVO	DIFERENCIA DE CONSUMO ()
POBLACIÓN	PRECIPITACIÓN	TEMPERATURA				
840151,111	6,2	12,5	2.577.616,87	2.525.580	0,02018798	520 6,87
840165, 1	8,	1 ,2	2.576.575,17	2.599.590	0,0089 2	2 014,8
840179,694	50,	1 ,2	2.617.025,59	2.558.660	0,022 0226	58 65,59
840194,257	9,8	14,7	2.608.774,54	2.6 1.110	0,00856167	22 5,46
840209	109,7	14,2	2.70 .90 ,89	2.581.260	0,045 5808	12264 ,89
Su atoria					0,105 42 2	

Luego obtenemos el error absoluto porcentual de la media (MAPE) con la ecuación 2. de los 5 datos de prueba, entonces tenemos:

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{E_t}{Y_t} \right|}{N}$$

$$MAPE = \frac{0,105}{5} = 0,021$$

$$MAPE \% = 0,021 * 100\% = 2,1\%$$

Por lo tanto, podemos decir que la red neuronal artificial presenta en la prueba, un error absoluto porcentual de la media de 2,1 %.

4.6.5. Comparación del método estadístico y la red neuronal artificial

Con los datos obtenidos del método aplicado de media móvil ponderada en el capítulo 4 y con los datos de la red neuronal artificial obtenidos en la tabla 4.16 y 4.17 realizamos una comparación, para demostrar cuál de los dos métodos es más preciso. En la tabla 4.18 observamos esta comparación.

Tabla 4.18. Comparación de métodos.

MESES	CONSUMO DE AGUA REAL ()	CONSUMO OBTENIDO POR MMP ()	ERROR RELATIVO	CONSUMO OBTENIDO POR LA RNA ()	ERROR RELATIVO
mar-10	2.400.487,92	2.486.925,6	0,0601	2.586.950	0,07767674
abr-10	2.485.055,5	2.507.780,64	0,0074	2.617.150	0,0504968
may-10	2.562.220,75	2.565.561,09	0,01040	2.516.160	0,0186001
jun-10	2.512.072,41	2.554.484,4	0,0168	2.506.710	0,0021466
jul-10	2.512.269,82	2.487.214,4	0,01740	2.504.250	0,01067441
ago-10	2.577.616,87	2.504.088,51	0,0285	2.525.580	0,02018798
sep-10	2.576.575,17	2.568.872,98	0,01541	2.599.590	0,00892
oct-10	2.617.025,59	2.554.662,41	0,028	2.558.660	0,0220226
nov-10	2.608.774,54	2.487.572,4	0,04647	2.611.110	0,00856167
dic-10	2.709.907,89	2.504.967,8	0,0778	2.581.260	0,0455808
		Su atoria	0,27609	Su atoria	0,26724
		MAPE	0,027609218	MAPE	0,0267278
		MAPE	2,760921788	MAPE	2,6727815

Como se observa en la anterior tabla las redes neuronales artificiales presentan un error absoluto porcentual de la media de 2,76 y el método de medias móviles ponderadas tiene un error absoluto porcentual de la media de 2,67, por tanto, puede concluirse que las redes neuronales artificiales son más precisas frente a las medias móviles ponderadas. En la figura 4.16 se observa la gráfica de la comparación de resultados.




Figura .16. Comparación de resultados.

Como podemos observar en la figura anterior los datos pronosticados están en el rango del dato del consumo de agua real, pero el método de medias móviles ponderadas presenta una ciclicidad en su gráfico, mientras que la red neuronal pronostica datos dispersos.

CAPITULO V

PREDICCIÓN DEL CONSUMO DE AGUA EN LA CIUDAD DE LA PAZ

RESUMEN

En este capítulo presentaremos la predicción del consumo de agua con el método de medias móviles ponderadas y redes neuronales artificiales para los años 2011 y 2012, para posteriormente realizar una comparación de ambas predicciones. Además se describirá la prueba de la hipótesis planteada.

5.1. PREDICCIÓN DEL CONSUMO DE AGUA CON MEDIAS MÓVILES PONDERADAS

En esta sección realizaremos la predicción del consumo de agua con medias móviles ponderadas para dos años, es decir 24 meses. Como en el capítulo realizamos ya el modelado de la predicción del consumo de agua, utilizaremos la ecuación 3.5 simplemente para reemplazar los datos deseados, en nuestro caso del dato 7 al 60.

$$y * (x) = 2.514.617,738 + 77,37 * x \quad (3.5)$$

En la tabla 5.1 realizaremos el cálculo para la regresión lineal.

Tabla 5.1. Cálculo de la regresión de lineal.

Meses	$y^*(x)$	Consumo de agua desestacionalizada ()
ene-11	$y^*(7)$	2.517.480, 2
feb-11	$y^*(8)$	2.517.557,699
mar-11	$y^*(9)$	2.517.6 5,067
abr-11	$y^*(40)$	2.517.712,4 4
may-11	$y^*(41)$	2.517.789,802
jun-11	$y^*(42)$	2.517.867,169
jul-11	$y^*(43)$	2.517.944,5 6
ago-11	$y^*(44)$	2.518.021,904
sep-11	$y^*(45)$	2.518.099,271
oct-11	$y^*(46)$	2.518.176,6 9
nov-11	$y^*(47)$	2.518.254,006
dic-11	$y^*(48)$	2.518. 3, 7
ene-12	$y^*(49)$	2.518.408,741
feb-12	$y^*(50)$	2.518.486,108
mar-12	$y^*(51)$	2.518.56 4,76
abr-12	$y^*(52)$	2.518.640,84
may-12	$y^*(53)$	2.518.718,210
jun-12	$y^*(54)$	2.518.795,578
jul-12	$y^*(55)$	2.518.872,945
ago-12	$y^*(56)$	2.518.950, 1
sep-12	$y^*(57)$	2.519.027,680
oct-12	$y^*(58)$	2.519.105,047
nov-12	$y^*(59)$	2.519.182,415
dic-12	$y^*(60)$	2.519.259,782

Posteriormente realizamos el último paso, que es calcular el consumo de agua predicho para los 24 meses, para esto reemplazamos en la ecuación .6, con los datos del índice estacional de la tabla .5.

$$y = (y^*) * \text{Índice Estacional} \quad (3.6)$$

Tabla 5.2. Calculo de los datos predichos para los años 2011 y 2012.

Meses	y(x)	Consumo de agua ()
ene-11	y(7)	2.5 7.184,869
feb-11	y(8)	2.554.976,480
mar-11	y(9)	2.487.84 ,052
abr-11	y(40)	2.504.704,25
may-11	y(41)	2.5 7.496,761
jun-11	y(42)	2.555.290,549
jul-11	y(43)	2.488.148,859
ago-11	y(44)	2.505.012,124
sep-11	y(45)	2.5 7.808,65
oct-11	y(46)	2.555.604,619
nov-11	y(47)	2.488.454,667
dic-11	y(48)	2.505. 19,995
ene-12	y(49)	2.5 8.120,544
feb-12	y(50)	2.555.918,688
mar-12	y(51)	2.488.760,474
abr-12	y(52)	2.505.627,865
may-12	y(53)	2.5 8.4 2,4 6
jun-12	y(54)	2.556.2 2,757
jul-12	y(55)	2.489.066,282
ago-12	y(56)	2.505.9 5,7 6
sep-12	y(57)	2.5 8.744, 28
oct-12	y(58)	2.556.546,826
nov-12	y(59)	2.489. 72,090
dic-12	y(60)	2.506.24 ,607

En la figura 5.1 observa los el grafico de la predicción del consumo de agua en la ciudad de La Paz para los años 2011 y 2012.




Figura 5.1. Grafico de la predicción.

Como observamos en la grafica, los datos predichos por las medias móviles ponderadas muestran una tendencia que se repite cada cuatro datos, se puede observar también que el consumo crece continuamente.

5.2. PREDICCIÓN DEL CONSUMO DE AGUA CON REDES NEURONALES ARTIFICIAL

En la tabla 5.1 observa los datos de entrada para la predicción del consumo de agua con redes neuronales. De igual forma que en la anterior sección se realizara la predicción para dos años.

Tabla 5.1. Datos de entrada para la RNA.

POBLACIÓN	PRECIPITACIÓN	TEMPERATURA
84022,985	1,086	1,5
84029,2099	9,45	1,5
840254,671	61,74	1,6
840270,659	22,15	1,2

840286,2917	7,84	12,1
840 02,4455	4, 5	11,1
840 18,8245	9,20	10,5
840 5,4261	11, 6	11,6
840 52,2472	19,29	12,4
840 69,2851	41,99	1 ,4
840 86,5 7	8,01	14,5
840404	94,50	14,1
840421,6714	1 0,86	1 ,
8404 9,548	9 ,45	1 ,5
840457,6278	61,74	1 ,6
840475,907	22,15	1 ,2
840494, 8 8	7,84	12,1
84051 ,0545	4, 5	11,1
8405 1,9167	9,20	10,5
840550,9674	11, 6	11,6
840570,204	19,29	12,4
840589,62 4	41,99	1 ,4
840609,22 1	8,01	14,5
840629	94,50	14,1

En la siguiente tabla 5.4 observa los datos de salida de la red neuronal artificial. Y en la figura 5.2 observa la grafica de la predicción.

Tabla 5.4. Datos de la predicción.

Meses	Mes	Consumo predicho por la RNA ()
ene-11	7	2.4 2.010
feb-11	8	2.5 4.8 0
mar-11	9	2.575.970
abr-11	40	2.557.860
may-11	41	2.502.080
jun-11	42	2.496.290
jul-11	4	2.508. 0
ago-11	44	2.499.940
sep-11	45	2.505.420
oct-11	46	2.558.160
nov-11	47	2.646.580
dic-11	48	2.552.860
ene-12	49	2.4 . 80
feb-12	50	2.482. 20
mar-12	51	2.545.950
abr-12	52	2.564.510
may-12	5	2.5 2.700
jun-12	54	2.5 1. 60
jul-12	55	2.5 1.1 0
ago-12	56	2.5 1.710
sep-12	57	2.5 4.640
oct-12	58	2.551.920
nov-12	59	2.664. 60
dic-12	60	2.504.270




Figura 5.2 . Grafico de la predicción.

Como podemos observar en los datos predichos, los valores del consumo de agua en la ciudad de La Paz están en el intervalo de 2.420.010 y 2.664.600, que no difiere en gran medida del consumo histórico obtenido, además como observamos en la gráfica los datos predichos son dispersos no tienen una tendencia.

5.3. COMPARACIÓN DE LA PREDICCIÓN DEL CONSUMO DE AGUA

En esta sección realizaremos una comparación del consumo de agua predicha, con ambos métodos, tomando como referencia el consumo predicho por las medias móviles ponderadas. En la tabla 5.5 observamos la comparación de ambos métodos.

Tabla 5.5. Comparación de la predicción.

Meses	Consumo predicho por MMP ()	Consumo predicho por la RNA ()	Error relativo porcentual	Diferencia de consumo ()
ene-11	2.571.184,87	2.420.010	4,1457	105174,869
feb-11	2.554.976,48	2.548.000	0,788519	20146,48
mar-11	2.487.840,05	2.575.970	,5420	88126,948
abr-11	2.504.704,25	2.557.860	2,12226	5155,747
may-11	2.574.496,76	2.502.080	1,9576	5416,761
jun-11	2.555.290,55	2.496.290	2,08957	59000,549
jul-11	2.488.148,86	2.508.000	0,811091	20181,141
ago-11	2.505.012,12	2.499.940	0,202479	5072,124
sep-11	2.578.808,65	2.505.420	1,276245	288,65
oct-11	2.555.604,62	2.558.160	0,099991	2555,81
nov-11	2.488.454,67	2.646.580	6,5459	158125,
dic-11	2.505.200,00	2.552.860	1,897562	47540,005
ene-12	2.581.120,54	2.400.800	4,126697	104740,544
feb-12	2.555.918,69	2.482.200	2,87959	7598,688
mar-12	2.488.760,47	2.545.950	2,297912	57189,526
abr-12	2.505.627,87	2.564.510	2,49995	58882,15
may-12	2.584.244	2.527.000	0,225826	57246
jun-12	2.556.227,76	2.510.600	0,97024	24872,757
jul-12	2.489.066,28	2.511.000	1,68994	4206,718
ago-12	2.505.957,74	2.517.100	1,028529	25774,264
sep-12	2.58.744,	2.546.400	0,161668	4104,28
oct-12	2.556.546,8	2.551.920	0,18098	4626,826
nov-12	2.489.72,09	2.664.600	7,0294	174987,91
dic-12	2.506.240,61	2.504.270	0,078748	197,607

Como podemos observar en la tabla anterior, los errores relativos porcentuales que presenta la comparación de ambos métodos son del 7%, es decir que los datos predichos por ambos métodos no son parecidos.

En la tabla 5.6 observaremos el crecimiento porcentual del consumo de agua de ambos métodos.

Tabla 5.6. Crecimiento del consumo de agua.

AÑO	Consumo de Agua Real (%)	Consumo de Agua MMP (%)	Consumo de Agua RNA (%)	Crecimiento Real (%)	Crecimiento MMP (%)	Crecimiento RNA (%)
2008	0.567.864,98					
2009	0.288.855,07			-1,076		
2010	0.155.574			0,2464		
2011		0.257.844,88	0.70.000,00		-0,187	0,1874
2012		0.269.001,65	0.408.250,00		0,069	0,1249

Si observamos la tabla, vemos que el método de medias móviles ponderadas tiene un decrecimiento y un crecimiento mínimo, y las redes neuronales presenta un crecimiento constante.

5.4. PRUEBA DE HIPOTESIS

Para la prueba de hipótesis utilizaremos la distribución t de student, con una muestra de tamaño 10. Los datos que se utilizarán son los de la tabla 4.18, trabajaremos para la prueba de hipótesis con el error relativo de cada método, ver tabla 5.7.

Tabla 5.7. Datos para la prueba de hipótesis.

MESES	ERROR RELATIVO MMP	ERROR RELATIVO RNA
ar-10	0,0 601	0,07767674
abr-10	0,0074	0,05 04968
ay-10	0,0104	0,018 6001
jun-10	0,0168	0,0021 466
jul-10	0,0174	0,01067441
a o-10	0,0285	0,02018798
sep-10	0,01541	0,0089 2
oct-10	0,02 8	0,022 0226
nov-10	0,04647	0,00856167
dic-10	0,07 78	0,045 5808
Media	0,28	0,27
Desv. Tip.	0,02	0,024

Para contrastar nuestra hipótesis lo que queremos concluir es, que la red neuronal produce menos error en comparación con las medias óviles ponderadas.

Entonces tenemos μ_1 y μ_2 que nos denotan los errores medios obtenidos con las medias óviles ponderadas y las redes neuronales artificiales, respectivamente.

Después definimos dos hipótesis complementarias, que se denominan: hipótesis nula e hipótesis alternativa.

Hipótesis nula (H_0): $\mu_1 = \mu_2$, y no existe diferencia entre los errores.

Hipótesis alterna (H_1): $\mu_1 > \mu_2$, el error de la red neuronal es menor al error de las medias óviles ponderadas.

Bajo la hipótesis H_0 , tenemos:

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sigma \sqrt{\frac{1}{N_1} + \frac{1}{N_2}}} \quad \text{donde} \quad \sigma = \sqrt{\frac{N_1 s_1^2 + N_2 s_2^2}{N_1 + N_2 - 2}}$$

Calculando tenemos,

$$\sigma = \sqrt{\frac{10(0,02)^2 + 10(0,024)^2}{10 + 10 - 2}} = 0,023 \quad \text{y} \quad t = \frac{0,28 - 0,27}{0,023 \sqrt{\frac{1}{10} + \frac{1}{10}}} = 0,972$$

Con un contraste de una cola al nivel de significación 0,2; rechazaremos H_0 si t es mayor que $t_{.80}$ que para 18 grados de libertad es 0,862. Luego podemos observar que t si es mayor, entonces rechazamos H_0 al nivel de significación de 0,2.



CAPITULO VI

CONCLUSIONES Y RECOMENDACIONES

RESUMEN

En este capítulo se describirán las conclusiones a las que se llegaron al finalizar el desarrollo de la investigación y se realizará algunas recomendaciones para posteriores trabajos.

4.1. CONCLUSIONES

Con la presente investigación de tesis podemos concluir que las redes neuronales artificiales pueden ser aplicables para predicciones de consumo de agua, con datos históricos en series de tiempo.

Para la investigación se tuvo que recolectar datos históricos de las tres variables de entrada seleccionadas (población, precipitación y temperatura media) y de la variable de salida (consumo de agua). El acceso a los datos de consumo de agua es restringido por lo que solo se obtuvieron datos mensuales de tres años. Con los datos de precipitación, temperatura media y población no se tuvo dificultad para obtenerlos, sin embargo, no se usaron esas variables debido a que su acceso es limitado y no se cuentan con registros de forma mensual. Además, un problema que se tuvo en la investigación, es que los datos históricos de consumo de agua son irregulares y no presentan una tendencia creciente o decreciente continua. Por otra parte, si requerimos tener una predicción más precisa es necesario obtener datos históricos de más años, información que no está disponible en nuestro medio.

A partir de los datos recolectados se construyó el modelo estadístico de predicción con el método de medias móviles ponderadas, se validó el modelo y se obtuvo un error absoluto de la media (MAPE) de 2,76 %.

Para la construcción de la red neuronal artificial se utilizó una red de tipo perceptrón multicapa con una capa de entrada con tres neuronas, tres capas ocultas cada una con diez neuronas y una capa de salida con una neurona; se utilizó como variables de entrada: la población, precipitación y la temperatura media, y la variable de salida es el consumo de

a ua. Esta red presenta un error absoluto porcentual de la media (MAPE) de 2,67 , este error en comparación con el error de las medias móviles ponderadas es menor, es decir que el modelo de red neuronal es más preciso.

Para la construcción de redes neuronales artificiales se aplicó como herramienta de desarrollo el software MatLab, lo cual facilitó el desarrollo de la herramienta en cuestión.

Los objetivos específicos se fueron cumpliendo a lo largo del presente trabajo, como ser:

- Se planteó el modelo conceptual para la predicción del consumo de agua con el método de medias móviles ponderadas y redes neuronales artificiales, obteniendo una diferencia de error de 0,1 .
- Se desarrolló una aplicación en Matlab 7.6.0 (R2008a) que realizó la predicción del consumo de agua con redes neuronales artificiales, posteriormente se validó el modelo y después se lo puso en ejecución, generando la predicción del consumo de agua para los dos siguientes años.
- Una vez realizado el análisis de los datos pronosticados, se observa que el método de medias móviles ponderadas presenta un crecimiento del 0,04 para el año 2012 y para el próximo año la red neuronal artificial tiene un crecimiento del 0,12 .

En síntesis podemos decir que ambos métodos presentan una mínima diferencia de error, pero el método que se ajusta más a la realidad es el de la red neuronal debido a que los datos pronosticados por la red presentan una irregularidad al igual que los datos de consumo de agua real.

Por último, respecto a la hipótesis planteada, se realizó un contraste de hipótesis de diferencia de medias con una distribución t de student en el parágrafo 5.4, donde se llegó a la conclusión de que el método de redes neuronales artificiales presenta menos error en comparación con el método de medias móviles ponderadas, con un nivel de significación de 0,2. Por lo que llegamos a la conclusión de que la red neuronal es fiable en un 80 .

4.4. RECOMENDACIONES

- Realizar la predicción identificando otras variables, como ser: número de conexiones nuevas, precio por el servicio, disponibilidad de alcantarillado, número de habitantes por vivienda, entre otros.
- Si desean obtener un modelo cuyos resultados sean más precisos, es importante tener más datos históricos, para que la red neuronal pueda entrenarse mejor. Esto requiere realizar un registro detallado de datos por las entidades correspondientes.
- Diseñar y analizar un modelo matemático que se ajuste al comportamiento del consumo de agua potable, para posteriormente comparar los resultados obtenidos con el presente trabajo.



BIBLIOGRAFÍA

Arriaga, G., Benavides, F., Rostagnol, C. (2006). *Proyecto Fibra*. Montevideo - Uruguay: Facultad de Ingeniería - Universidad de la República.

Arreola Cortés, F. I. (2011). *Uso eficiente*. Instituto Mexicano de Tecnología del Agua, CNA.

Arrojo, P. (2011). *El medio ambiente y la conflictividad en el campo del agua*. Universidad de Zaragoza.

Carballo, R. (2011). *Redes Neuronales*. Dpto. Matemática Aplicada y C. C.

Caridad, J. M., Moreno, I. (2011). *La demanda de agua en zonas urbanas: métodos alternativos de predicción a corto plazo*. Universidad de Córdoba, Universidad de Sevilla.

Caridad, J. M., Millán, G., Palomares, R. D. (2000). *Predicción del consumo de agua en Córdoba*. Córdoba: Universidad de Córdoba.

Chain, S. (2000). *Preparación y Evaluación de Proyectos*. Mc-Graw Hill.

Comisión Europea. (1999). *Hacia la gestión sostenible de los recursos hídricos: Un enfoque estratégico*. Bruselas, Bélgica.

Davey, N., Frank, R. J., Hunt, S. P. (1999). *Time Series Prediction and Neural Networks*. University of Hertfordshire Hatfield.

Daza, F. (2008). *Demanda de aguas en zonas urbanas en Andalucía*. Córdoba: Universidad de Córdoba.

Daza, F. (2008). *Demanda de aguas en zonas urbanas en Andalucía*. Córdoba: Universidad de Córdoba.

Devaris, P. J. (2007). *Introducción a la Predicción*.

Dickson, M. A. (2000). *II International Conference Efficient Use and Management of Urban Water Supply*. International Water Association.

Freeman, J. A., Skapura, D. M. (1991). *Redes Neuronales. Algoritmos, aplicaciones y técnicas de propagación*. México: Addison-Wesley.

Galbiati Riesco, J. (2011). *Métodos Elementales de Procesamiento de Series Temporales*. Revista Letra Media.

Global Water Partnership (GWP). (2000). *Agua para el Siglo XXI: La Región en el Contexto Mundial*.

González Casiro, M. P. (2009). *Técnicas de predicción económica*. Universidad del País Vasco.

Gonzales, I. M. (2011). *El problema del agua y la inteligencia artificial*. Universidad Carlos III de Madrid.

Guzmán, E. (2011). *Un modelo econométrico sobre el consumo de agua en el estado de Guanajuato*. Instituto Tecnológico de Celaya.

Herbertson, P. W. (200). *Master of science, diploma, certificate and professional development courses in hidroinformatics and management systems*. Newcastle: University of Newcastle.

Hilera, J. R., Martínez, V. J. (1995). *Redes Neuronales Artificiales*. Addison - Wesley Iberoamericana.

La Paz sufrir racionamiento de agua por falta de reservas. (19 de Enero de 2011). *Periódico El Cambio*.

Marín Diazaraque, J. M. (2011). *Introducción a las redes neuronales aplicadas*.

Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario: Universidad Tecnológica Nacional – Facultad Regional Rosario.

Moreno Rodríguez, A. (2011). *Desarrollo de una Interfaz Gráfica de Redes*. UNIVERSIDAD CARLOS III MADRID.

Neolopan Mendoza, A. I. (2010). *Redes Neuronales Predictivas para Mapas de Riesgo en Inundaciones*. La Paz.

Pissarenko, D. (2002). *Neural Network for Financial Time Series Prediction: Overview Over Recent Research*. BSc (Hons) Computer Studies.

Rabasa, A., Rodríguez, J. J., Santa María, L., Monje, J. F. (2006). *Predicción sobre Series Temporales*. Centro de Investigación Operativa - Universidad Miguel Hernández de Elche.

Robles Forcada, V. (200). *Clasificación Supervisada basada en Reyes Bayesianas. Aplicación en Biología Computacional*. Madrid: Universidad Politécnica de Madrid - Facultad de Informática.

Rojas, R., Boucchechter, I. (2005). *Ciclos de Vida de Ingeniería del Software*.

Saavedra, M. A., Uarte, N. R. (2011). *Abastecimiento de agua potable*. Cochabamba: Universidad Mayor de San Simón - Facultad de Ciencias y Tecnología.

Sánchez T., L. D., Sánchez Torres, A. (2004). *Uso eficiente del agua*. IRC International Water and Sanitation Centre.

Sánchez, T., Peña, V., L., D. (200). *Nueva industria. Producción más limpia y Competitividad*. Colombia: Universidad del Valle, CINARA.

United State Environmental Protection Agency (USEPA). *Water conservation plan guidelines*. U.S.A.

Urquidi, J., Barrañán, J., Cañacho, A. (2004). *Gestión de Servicios de Agua Potable y Saneamiento*. La Paz: Ministerio de Servicios y Obras Públicas de la Republica de Bolivia.

Urquidi, J., Barrañán, J., Cañacho, A., Franco, A. (2004). *Cálculo de Tarifas para Servicios de Agua Potable y Saneamiento*. La Paz: Vice Ministerio de Servicios y Obras Públicas.

Visscher, J. T., Bury, T., Gould, T., Moriarty. (1999). *Integrated water resource management in water and sanitation projects*. IRC International Water and Sanitation Centre.

Vivienda y Servicios Basicos. (2011). Fundación para el periodismo.

Wikipedia, La Enciclopedia Libre. (2010). *Perceptrón Multicapa*.



ANEXOS

ANEXO A1.

En el anexo A1 se detalla el primer capítulo de ley 2066 de Servicios de Agua Potable y Alcantarillado Sanitario.

LEY No 2066

LEY DE 11 DE ABRIL DE 2000

HUGO BANZER SUAREZ

PRESIDENTE DE LA REPUBLICA

Por cuanto, el Congreso Nacional ha sancionado la siguiente Ley:

EL HONORABLE CONGRESO NACIONAL,

D E C R E T A:

LEY MODIFICATORIA A LA LEY No. 2029 DE SERVICIOS DE AGUA

POTABLE Y ALCANTARILLADO SANITARIO

TITULO I

ASPECTOS GENERALES

CAPITULO I

DEL OBJETO Y ALCANCE DE LA LEY

ARTICULO 1°.- (OBJETO) La presente Ley tiene por objeto establecer las normas que regulan la prestación y utilización de los Servicios de Agua Potable y Alcantarillado Sanitario y el marco institucional que los rige, el procedimiento para otorgar Concesiones, Licencias y Relevo para la prestación de los servicios, los derechos y obligaciones de los prestadores y usuarios, el establecimiento de los principios para fijar los Precios, Tarifas y Cuotas, así como la determinación de infracciones y sanciones.

ARTICULO 2°.- (AMBITO DE APLICACION) Están sometidas a la presente Ley, en todo el territorio nacional, todas las personas naturales o jurídicas, públicas o privadas, cualquiera sea su forma de constitución, que presten, sean Usuarios o se vinculen con al menos uno de los Servicios de Agua Potable y Servicios de Alcantarillado Sanitario.

ARTICULO 3°.- (SANEAMIENTO BASICO) El sector de Saneamiento Básico comprende los Servicios de agua potable, alcantarillado sanitario, disposición de excretas, residuos sólidos y drenaje pluvial.

ARTICULO 4°.- (ALCANCE DE LA LEY) La presente Ley se aplica a los servicios básicos de Agua Potable y Alcantarillado y crea la Superintendencia de Saneamiento Básico.

ARTICULO 5°.- (PRINCIPIOS) Los principios que rigen la prestación de los Servicios de Agua Potable y Alcantarillado son:

- a. Universalidad de acceso a los servicios,
- b. Calidad y continuidad en los servicios, conformes con políticas de desarrollo humano,

- c. Eficiencia en el uso y en la asignación de recursos para la prestación y utilización de los servicios,
- d. Reconocimiento del valor económico de los servicios, que deben ser retribuidos por sus beneficiarios de acuerdo a criterios socio – económicos y de equidad social,
- e. Sostenibilidad de los servicios,
- f. Neutralidad de tratamiento a todos los prestadores y Usuarios de los servicios, dentro de una misma categoría,
- g. Protección del medio ambiente.

ARTICULO 6°.- (SISTEMA DE REGULACION SECTORIAL) Los Servicios de Agua Potable y Alcantarillado Sanitario del Sector de Saneamiento Básico quedan incorporados al Sistema de Regulación Sectorial (SIRESE) y sometidos a las disposiciones contenidas en la Ley No. 1600, Ley de Sistemas de Regulación Sectorial, de 28 de octubre de 1994, sus reglamentos y la presente Ley y sus reglamentos.

ARTICULO 7°.- (UTILIDAD PUBLICA) Las obras destinadas a la prestación de Servicios de Agua Potable y Alcantarillado Sanitario son de interés público, tienen carácter de utilidad pública y se hallan bajo protección del Estado.



ANEXO A2.

En el anexo A2 se detalla el decreto supremo 27486 con todos sus artículos.

DECRETO SUPREMO N° 27486

De 14 de Mayo de 2004

CONSTITUCIÓN DE LA FUNDACIÓN PARA EL APOYO A LA SOSTENIBILIDAD EN SANEAMIENTO BÁSICO (FUNDASAB)

Carlos D. Mesa Gisbert

Presidente Constitucional de la República

EN CONSEJO DE GABINETE, DECRETA:

ARTÍCULO 1° (OBJETO)

El presente Decreto Supremo tiene por objeto constituir la Fundación para el Apoyo a la Sostenibilidad en Saneamiento Básico -FUNDASAB.

ARTÍCULO 2° (FUNDASAB)

Se instruye al Ministerio de Servicios y Obras Públicas, que a través del Vice Ministerio de Servicios Básicos, prepare todos los documentos y obtenga las autorizaciones que sean necesarias para constituir la Fundación de Apoyo a la Sostenibilidad en Saneamiento Básico - FUNDASAB, como persona colectiva de derecho privado, sin fines de lucro, de interés público y naturaleza mixta, con personalidad jurídica y patrimonio propios, con competencia administrativa, técnica y financiera, cuyo funcionamiento se regirá por las previsiones de los Artículos 67 a 71 del Código Civil y por sus Estatutos, bajo los parámetros y lineamientos que se detallan en el presente Decreto Supremo.

ARTÍCULO 3° (MISIÓN)

La FUNDASAB tendrá por objeto ser un mecanismo institucional sostenible de asistencia técnica, que brinde asesoría técnica y lidere e impulse los procesos de asistencia técnica para la ejecución de los Programas de Modernización Institucional del Sector Saneamiento Básico, proviniendo para el efecto de los modelos de gestión.

ARTÍCULO 4° (ESTATUTOS Y REGLAMENTOS)

Se dispone que el régimen de organización, administración y funcionamiento de la FUNDASAB, así como la participación del Estado en la misma, estarán sujetos a sus estatutos y reglamentos, los cuales serán preparados por el Ministerio de Servicios y Obras Públicas a través del Vice Ministerio de Servicios Básicos en un plazo no mayor a noventa (90) días a partir de la publicación del presente Decreto Supremo, sobre la base de las políticas y necesidades del Sector Saneamiento Básico, considerando al efecto los Planes Sectoriales y Estratégicos del Vice Ministerio de Servicios Básicos y, los fines para los que se constituyó la FUNDASAB. La administración de los recursos públicos se efectuará en el marco de la normativa vigente para el efecto.

ARTÍCULO 5° (PATRIMONIO)

I. El Ministerio de Hacienda deberá efectuar las gestiones correspondientes para incorporar en el Presupuesto General de la Nación, los recursos de donación destinados al sostenimiento financiero

de la FUNDASAB, constituido por la transferencia de recursos, bienes, derechos y títulos valores, provenientes de recursos identificados de la cooperación internacional, pública o privada, que reciba el Gobierno de Bolivia para este fin.

II. Otros recursos generados por la prestación de servicios autorizados en sus estatutos.

ARTÍCULO 6° (FINES)

Dado el objeto de la FUNDASAB, ésta tendrá los siguientes fines:

- a) Proveer la demanda por los servicios de agua y saneamiento.
- b) Proveer la integración de las comunidades para generar economías de escala y sostenibilidad en el marco de los sistemas de agua y saneamiento.
- c) Apoyar el desarrollo institucional de las EPSA's y operadores, así como a los Gobiernos Municipales que inicien un proceso de transformación de la gestión de los servicios que administran directamente en EPSA's
- d) Asesorar y capacitar a las EPSA's, en políticas del Sector Saneamiento Básico.
- e) Prestar asistencia técnica para la sostenibilidad de los servicios, incorporando tareas relacionadas con la capacitación en las áreas de Recursos Humanos, Administrativas y Técnicas.
- f) Proveer asistencia técnica para el desarrollo de tecnología apropiada, que incluye el diseño para la proposición de normas técnicas, planos tipo y desarrollo de tecnología.
 - g) Orientar en políticas y estrategias con el fin de fortalecer la prestación de los servicios de agua potable y alcantarillado por parte de las EPSA's.
 - h) Proporcionar asistencia a los procesos de inversión, mediante el desarrollo de metodologías para toda la fase del proyecto (identificación, formulación, evaluación, seguimiento, monitoreo y otros).
 - i) Lograr el fortalecimiento y consolidación de las EPSA's, para que éstas puedan prestar servicios de calidad y eficiencia.
 - j) Promover la participación social efectiva en el manejo de las EPSA's públicas.
 - k) Otros establecidos en sus estatutos.

Los Señores Ministros de Estado en los Despachos de Hacienda y. Servicios y Obras Públicas quedan encargados de la ejecución y cumplimiento del presente Decreto Supremo.

Es dado en Palacio de Gobierno de la ciudad de La Paz, a los catorce días del mes de mayo del año dos mil cuatro.

ANEXO A .

En el anexo A se mostrar los datos obtenidos del Servicio Nacional de Meteorología e Hidrología (SENAMHI).

Estación:	Central La Paz - Laykacota	Latitud Sud:	16° 0' 17"
Departamento:	La Paz	Longitud Oeste:	68° 07' 24"
Provincia:	Murillo	Altura /s/n/ :	6 2

DATOS DE : PRECIPITACIÓN TOTAL ()

A O	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
2000	126,0	9,2	72,0	12,6	5,0	21,1	0,2	21,9	1,1	62,	6,	120,9
2001	189,2	105,1	82,	20,4	25,7	5,2	10,6	1,9	18,0	64,6	12,2	69,4
2002	96,9	108,1	78,6	54,8	12,7	9,9	26,6	5,7	29,2	81,6	47,1	72,8
2003	109,9	96,9	84,6	6,9	5,8	1,6	2,4	8,9	27,2	8,	10,4	97,9
2004	177,6	64,0	45,0	15,4	5,2	6,4	16,8	25,	8,5	19,8	45,7	7,
2005	126,6	85,5	28,	4,6	0,0	0,0	2,	0,4	0,1	55,2	60,2	58,4
2006	149,1	100,	76,1	6,2	1,4	0,1	0,0	19,9	12,2	29,6	70,7	127,9
2007	99,7	94,8	61,8	46,2	4,5	0,1	21,7	0,2	47,1	9,6	64,7	96,
2008	165,4	75,5	65,1	1,2	4,7	1,4	2,7	1,1	4,8	20,6	12,	111,8
2009	61,4	116,9	50,4	0,5	0,	0,0	15,1	1,5	25,7	27,0	75,7	107,1
2010	119,7	141,6	1,9	1,9	20,9	0,0	2,8	6,2	8,	50,	9,8	109,7

DATOS DE : TEMPERATURA MÁXIMA MEDIA (°C)

A O	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
2000	18,8	19,2	20,2	21,2	20,7	17,5	17,6	19,0	21,4	19,5	20,2	20,6
2001	17,2	18,0	19,1	20,6	19,6	18,8	18,5	17,8	20,0	20,	22,6	20,2
2002	20,4	18,6	19,0	18,7	19,	18,4	15,8	18,9	20,1	19,1	21,1	20,6
2003	19,5	20,0	18,9	20,	19,4	18,9	17,8	19,1	19,1	21,2	21,6	20,8
2004	17,8	18,9	20,0	20,5	19,4	18,	16,9	17,5	19,7	22,2	21,5	21,8
2005	19,2	18,4	20,9	19,6	20,5	19,0	18,8	20,1	18,	19,0	20,4	21,7
2006	17,6	19,7	19,8	19,5	18,9	18,0	18,8	18,9	19,6	20,9	20,4	20,2
2007	19,7	19,2	18,4	19,4	18,8	19,1	17,	19,5	17,5	20,8	20,	19,8

2008	18,0	19,7	18,6	19,9	19,4	19,1	18,8	20,1	20,8	20,6	22,7	19,9
2009	19,8	20,1	19,7	19,5	19,4	19,1	18,2	20,1	20,7	21,9	22,5	20,5
2010	19,8	20,1	21,1	21,6	19,5	19,5	19,1	20,8	20,6	20,1	22,5	20,7

DATOS DE : TEMPERATURA MÍNIMA MEDIA (°C)

A O	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
2000	7,2	7,2	7,5	6,2	4,6	,	2,1	4,0	5,1	5,8	6,6	6,6
2001	6,5	7,	7,0	6,1	4,7	,5	,4	,6	5,	6,4	7,9	7,5
2002	7,8	8,0	8,1	6,8	5,5	4,1	,1	4,4	5,7	6,6	7,2	8,0
200	8,	7,9	7,6	6,0	4,7	,5	2,4	2,9	,4	6,1	6,7	7,9
2004	7,8	7,5	7,4	6,7	,5	2,8	,1	,5	4,6	6,	7,6	8,0
2005	8,0	7,6	8,0	6,4	5,1	2,8	,1	,8	4,4	6,6	7,2	8,0
2006	7,6	7,6	8,0	6,6	,5	,9	,4	4,1	4,8	7,0	7,6	8,
2007	8,4	7,9	7,7	7,0	5,2	4,4	,0	4,1	5,	6,2	6,9	7,4
2008	7,6	7,5	6,9	6,0	,8	,4	,0	,9	4,6	6,	7,6	7,
2009	7,5	7,7	7,2	6,0	5,0	,6	,	4,1	5,6	7,1	8,6	8,2
2010	8,4	8,6	8,2	6,6	5,4	4,2	,5	4,2	5,7	6,4	6,9	7,8

DATOS DE : TEMPERATURA MEDIA (°C)

A O	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
2000	1 ,0	1 ,2	1 ,8	1 ,7	12,6	10,4	9,8	11,5	1 ,2	12,7	14,9	1 ,6
2001	11,8	12,6	1 ,1	1 ,	12,1	11,1	10,9	10,7	12,6	1 ,	15,2	1 ,8
2002	14,1	1 ,	1 ,5	12,7	12,4	11,2	9,4	11,6	12,9	12,8	14,1	14,2
200	1 ,8	14,0	1 ,2	1 ,1	12,0	11,2	10,1	11,0	11,	1 ,6	14,1	14,
2004	12,8	1 ,2	1 ,6	1 ,6	11,4	10,5	10,0	10,5	12,1	14,2	14,5	14,9
2005	1 ,6	1 ,0	14,4	1 ,0	12,8	10,9	10,9	11,9	11,	12,8	1 ,7	14,9
2006	12,6	1 ,6	1 ,9	1 ,0	11,2	11,0	11,1	11,5	12,2	1 ,9	14,0	14,2
2007	14,0	1 ,5	1 ,0	1 ,2	12,0	11,7	10,1	11,8	11,4	1 ,5	1 ,5	1 ,5
2008	12,8	1 ,6	12,7	12,9	11,6	11,2	10,9	12,0	12,7	1 ,4	15,1	1 ,6
2009	1 ,6	1 ,9	1 ,4	12,8	12,2	11,4	10,7	12,1	1 ,2	14,5	15,5	14,4
2010	14,1	14,	14,6	14,1	12,4	11,8	11,	12,5	1 ,2	1 ,2	14,7	14,2

ANEXO A5.

En el anexo A5 se mostrar el código de la herramienta.

botón entrenar

```
function Bentrenar_Callback(hObject, eventdata, handles)
entrada= load(handles. etricdata.url1); cargar los datos
handles. etricdata.entrada = entrada; volver a global
salida= load(handles. etricdata.url2);
handles. etricdata.salida = salida;
aprendi= et(handles.TBaprendizaje,'Value'); Devuelve el algoritmo seleccionado
nn= et(handles.TBco,'value') Devuelve el número de n de capas ocultas
if nn==1
    nn1= et(handles.TBnnc1,'value') Devuelve el número de neuronas en la capa 1
    fa1= et(handles.TBfunact1,'value') Devuelve la función de activación en la capa 1
    net= newff(handles. etricdata.entrada, handles. etricdata.salida, [nn1], f1 'purelin' ,apren);
end
if nn==2
    nn1= et(handles.TBnnc1,'value') Devuelve el número de neuronas en la capa 1
    nn2= et(handles.TBnnc2,'value') Devuelve el número de neuronas en la capa 2
    fa1= et(handles.TBfunact1,'value') Devuelve la función de activación en la capa 1
    fa2= et(handles.TBfunact2,'value') Devuelve la función de activación en la capa 2
    net= newff(handles. etricdata.entrada, handles. etricdata.salida, [nn1 nn2], f1 f2 'purelin' ,apren);
end
if nn==
    nn1= et(handles.TBnnc1,'value') Devuelve el número de neuronas en la capa 1
    nn2= et(handles.TBnnc2,'value') Devuelve el número de neuronas en la capa 2
    nn = et(handles.TBnnc , 'value') Devuelve el número de neuronas en la capa
    fa1= et(handles.TBfunact1,'value') Devuelve la función de activación en la capa 1
    fa2= et(handles.TBfunact2,'value') Devuelve la función de activación en la capa 2
    fa = et(handles.TBfunact , 'value') Devuelve la función de activación en la capa
    net= newff(handles. etricdata.entrada, handles. etricdata.salida, [nn1 nn2 nn ], f1 f2 f 'purelin' ,apren);
end
if nn==4
    nn1= et(handles.TBnnc1,'value') Devuelve el número de neuronas en la capa 1
    nn2= et(handles.TBnnc2,'value') Devuelve el número de neuronas en la capa 2
    nn = et(handles.TBnnc , 'value') Devuelve el número de neuronas en la capa
    nn4= et(handles.TBnnc4,'value') Devuelve el número de neuronas en la capa 4
    fa1= et(handles.TBfunact1,'value') Devuelve la función de activación en la capa 1
```



```

fa2= et(handles.TBfunact2,'value')    Devuelve la funcion de activacion en la capa 2
fa = et(handles.TBfunact ,'value')    Devuelve la funcion de activacion en la capa
fa4= et(handles.TBfunact4,'value')    Devuelve la funcion de activacion en la capa 4
net= newff(handles. etricdata.entrada, handles. etricdata.salida, [nn1 nn2 nn nn4], f1 f2 f f4
    'purelin' ,apren);
end
if nn==5
    nn1= et(handles.TBnnc1,'value')    Devuelve el nu ero de neuronas en la capa 1
    nn2= et(handles.TBnnc2,'value')    Devuelve el nu ero de neuronas en la capa 2
    nn = et(handles.TBnnc ,'value')    Devuelve el nu ero de neuronas en la capa
    nn4= et(handles.TBnnc4,'value')    Devuelve el nu ero de neuronas en la capa 4
    nn5= et(handles.TBnnc5,'value')    Devuelve el nu ero de neuronas en la capa 5
    fa1= et(handles.TBfunact1,'value') Devuelve la funcion de activacion en la capa 1
    fa2= et(handles.TBfunact2,'value') Devuelve la funcion de activacion en la capa 2
    fa = et(handles.TBfunact ,'value') Devuelve la funcion de activacion en la capa
    fa4= et(handles.TBfunact4,'value') Devuelve la funcion de activacion en la capa 4
    fa5= et(handles.TBfunact5,'value') Devuelve la funcion de activacion en la capa 5
    net= newff(handles. etricdata.entrada, handles. etricdata.salida, [nn1 nn2 nn nn4 nn5], f1 f2 f f4 f5
        'purelin' ,apren);
end
iterac= et(handles.TBite,'Value') Devuelve el de iteraciones
net.divideFcn = ";
net.trainPara . u=0.000001;
net.trainPara .epochs = iterac;
net.trainPara .lr = 0.05;
net.trainPara .goal = handles. etricdata.error;
net=train(net, handles. etricdata.entrada, handles. etricdata.salida);
handles. etricdata.net=net;
uidata(hObject,handles)

Botón Guardar
function B uardar_Callback(hObject, eventdata, handles)
no =inputdlg ('NOMBRE','GUARDAR COMO')
no bre=char(no );
net=handles. etricdata.net;
save(no bre,'net')

Botón Car ar
function Bcar ar_Callback(hObject, eventdata, handles)

```

```

load(handles. etricdata.url ); cargar los datos
i1='Nro. de Entradas : ';
i1=strcat(i1,num2str(net.numInputs))
i2='Nro. de Salidas : ';
i2=strcat(i2,num2str(net.numOutputs))
i3='Nro. de Capas Ocultas : ';
i3=num2str(net.numLayers-1);
i3=strcat(i3,num2str(i3));
handles. etricdata.rna = net; volver a los var local
set(handles.a,'String',i1)
set(handles.b,'String',i2)
set(handles.c,'String',i3)
update(hObject,handles)

Botón Pronóstico
function pronostico_Callback(hObject, eventdata, handles)
    local rn
    if handles. etricdata.pob==0 && handles. etricdata.prec==0 && handles. etricdata.tep==0
        datos=handles. etricdata.urlid4;
        datosentrada= load(datos)
        a=si(rn,datosentrada)
    else
        a=si(rn,[pobn;precn;tepn])
    end
    set(handles.salidas,'String',a);
    update(hObject,handles)

```

