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

TESIS DE GRADO

PREDICCION DEL CONSUMO DEL AGUA POTABLE DE LA CIUDAD DE LA PAZ APLICANDO REDES NEURONALES Y LOGICA DIFUSA

PARA OPTAR AL TÍTULO DE LICENCIATURA EN INFORMÁTICA

MENCIÓN: INGENIERÍA DE SISTEMAS INFORMÁTICOS

Postulante : Rubén Quispe Condori

Docente Tutor : Lic. Efraín Silva Sánchez

Docente Revisor : Lic. Celia Tarquino Peralta

LA PAZ - BOLIVIA

2011

DEDICATORIA

A Dios, por la inspiración y fortaleza de todo momento.

A mis padres queridos Bonifacio Quispe Roque y Máxima Condori Vargas, ejemplos de voluntad, esfuerzo y amor, quienes son el gran impulso de salir siempre adelante ante cualquier inconveniente.

AGRADECIMIENTOS

Para el inicio, elaboración y conclusión de este trabajo agradezco en especial:
A mi docente tutor, Lic. Efraín Silva Sánchez, por su guía responsable y orientación prestada en la conclusión de éste trabajo de investigación.

A mi revisor Lic. Celia Tarquino Peralta, por su colaboración, comprensión e interés en la revisión de la investigación, que fue crucial para su emprendimiento, coadyuvando con mucha paciencia durante todo el desarrollo del trabajo, y el buen consejo en aquellos momentos de incertidumbre.

También me gustaría agradecer a mi hermano y hermanas por contar con su apoyo y compañía.

A todos mis amigos y compañeros de la carrera.

RESUNEN

PREDICCION DEL CONSUMO DEL AGUA POTABLE DE LA CIUDAD DE LA PAZ APLICANDO REDES NEURONALES Y LOGICA DIFUSA

Con el avance de la ciencia, es pertinente aplicar nuevos modelos a teorías ya desarrolladas, en este caso se toma en cuenta proyecciones de consumo de agua, para predecir el consumo de agua en la población de la ciudad de La Paz.

Se describen los fundamentos de las Redes Neuronales Artificiales y Lógica Difusa, en cuanto a sus características, modelos y aplicaciones más importantes. A si mismo se realiza estudios sobre las variables que intervienen para el entrenamiento de la red neuronal, para la predicción del consumo de agua.

Se aprovecha las capacidades de predicción y clasificaciones de la Redes Neuronales Artificiales y la Lógica Difusa para maximizar los resultados de la predicción del consumo de agua potable de las redes neuronales, con un margen de error del menos del 5%, mejorando a si la eficacia de la predicción.

El estudio desarrollado se lo realiza con datos de la ciudad de La Paz, empleado para los cálculos el software de aplicación Matlab 7.0, una herramienta útil en el manejo de los modelos que presenta la Inteligencia Artificial.

ABSTRACT

PREDICTION OF THE CONSUMPTION OF THE DRINKABLE WATER OF THE CITY OF THE PEACE APPLYING NETS NETWORKS AND DIFFUSE LOGIC

With the advance of the science, it is pertinent to already apply new models to theories developed; in this case he/she takes into account projections of consumption of water, to predict the consumption of water in the population of the city of The Peace.

The basics of the Nets Artificial Networks and Diffuse Logic are described, as for their characteristics, models and more important applications. To if same he/she is carried out studies on the variables that intervene for the training of the net Networks, for the prediction of the consumption of water.

He/she takes advantage the prediction capacities and classifications of the Nets Artificial Networks and the Diffuse Logic to maximize the results of the prediction of the consumption of drinkable water of the nets Networks, with an error margin of the one less than 5%, improving to if the effectiveness of the prediction.

The developed study is carried out it with data of the city of The Peace, employee for the calculations the application software Matlab 7.0, an useful tool in the handling of the models that presents the Artificial intelligence.

INDICE GENERAL

1. MARCO REFERENCIAL 1

1.1 INTRODUCCION 1

1.2 ANTECEDENTES 2

1.3 PLANTEAMIENTO DEL PROBLEMA 5

1.3.1 PROBLEMA PRINCIPAL 5

1.3.2 PROBLEMAS ESPECIFICOS 5

1.4 HIPOTESIS 6

1.5 OBJETIVOS 6

1.5.1 OBJETIVO PRINCIPAL 6

1.5.2 OBJETIVOS ESPECIFICOS 7

1.6 JUSTIFICACION 7

1.6.1 Justificación Técnica 7

1.6.2 Justificación Social 7

1.6.3 Justificación Económica 8

1.7 LIMITES Y ALCANCES 8

2. MARCO TEORICO 10

2.1 EL AGUA 10

2.1.1 El agua en la vida humana 11

2.2 DISPONIBILIDAD MUNDIAL DE LOS RECURSOS HIDRICOS 12

2.2.1 Ubicación y Distribución 12

2.2.2 La Demanda de Agua en el Mundo 15

2.3 DEMANDA DE AGUA EN BOLIVIA 16

2.4 VARIABLES QUE AFECTAN AL CONSUMO DE AGUA POTABLE 18

2.4.1 CONDICIONES METEOROLOGICAS 18

2.4.1.1 Precipitaciones 18

2.4.1.2 Temperatura 19
2.4.1.3 Humedad Relativa 20
2.4.1.4 Vientos 21
2.4.1.5 Anomalías Climáticas 22
2.4.2 POBLACION 22
2.4.3 PRECIO DEL AGUA 24
2.4.4 DEMANDA DE AGUA 24
2.4.5 DISPONIBILIDAD DE AGUA 26
2.5 REDES NEURONALES ARTIFICIAL 28
2.5.1 DEFINICION 28
2.5.2 CARACTERISTICAS DE LAS REDES NEURONALES ARTIFICIALES 28
2.5.3 REDES NEURONALES BIOLOGICAS 29
2.5.4 RED NEURONAL ARTIFICIAL 30
2.5.4.1 Estado de Activación 32
2.5.4.2 Función de salida o transferencia 32
2.5.5 TOPOLOGIA DE LAS REDES NEURONALES 34
2.5.5.1 Redes Mono Capa 34
2.5.5.2 Redes Multicapa 35
2.5.6 CONEXIÓN DE REDES 36
2.5.6.1 Redes con conexión hacia adelante 36
2.5.6.2 Redes con conexión hacia atrás 36
2.5.6.3Redes con conexión hacia adelante y atrás 37
2.5.7 MECANISMO DE APRENDISAJE 37
2.5.7.1 APRENDIZAJE SUPERVISADO 38
2.5.7.1.1 Aprendizaje por corrección de error 38
2.5.7.1.2 Aprendizaje por refuerzo 38
2.5.7.1.3 Aprendizaje estocástico 38

2.5.7.2 APRENDIZAJE NO SUPERVISADO 39
2.5.7.2.1 Aprendizaje Hebbiano 39
2.5.7.2.2 Aprendizaje Competitivo 39
2.5.7.2.3 Representación de Características 39
2.5.8 PERCEPTRON SIMPLE 39
2.5.9 PERCEPTRON MULTICAPA..... 40
2.5.10 REDES DE PROPAGACION HACIA ATRÁS (BACKPROPAGATION)40
2.5.11 ALGORITMO DE ENTRENAMIENTO..... 41
2.5.11.1 Propagación hacia adelante 41
2.5.11.2 Propagación hacia Atrás 42
2.5.12 APLICACIÓN DE LAS REDES NEURONALES ARTIFICIALES 45
2.5.13 REDES NEURONALES UTILIZADAS EN LA PREDICCION..... 46
2.5.14 METODOLOGIA PARA LA PREDICCION CON REDES NEURONALES..... 46
a)Preparación de los datos 46
b)Determinación de la arquitectura de la red 48
c)Diseño de la estrategia de aprendizaje o entrenamiento de la red 48
d)Evaluación global 49
2.5.15 COMBINACION DE LAS REDES NEURONALES Y LOGICA DIFUSA..... 49
2.6 CONJUNTOS DIFUSOS 50
2.6.1 FUNCION CARACTERISTICA 53
2.6.2 CORTE DE NIVEL ALFA 56
2.6.3 VARIABLES LINGUISTICAS 57
2.6.4 OPERACIONES LOGICAS 57
2.7 SERIES DE TIEMPO 58
3. DISEÑO Y DESARROLLO 61
3.1 MODELO GENERAL 61

3.2 PREPARACION DE LOS DATOS 62
3.2.1 Selección de variables para el entrenamiento de la red 62
3.2.2 Estructuración de los datos 63
3.2.3Preparación de la información de entrada 64
3.2.4División de los datos 67
3.3 DETERMINACION DE LA ARQUITECTURA DEL MODELO DE RED NEURONAL 67
3.3.1 Estructura de la red neuronal 67
3.3.2 Numero de neuronas en la capa oculta 68
3.3.3 Descripción formal 69
Definición 3.1 69
Definición 3.2 69
Definición 3.3 70
Definición 3.4 70
3.4 DISEÑO TEORICO DEL MODELO DE RED NEURONAL PARA EL ENTRENAMIENTO 70
3.5 REGLA DE APRENDIZAJE 73
3.6 APLICACIÓN DE LA LOGICA DIFUSA A LOS DATOS DE LA PREDICCION DE LA RED NEURONAL 74
Definición 3.5 75
4. EXPERIMENTACION 77
4.1 ENTRENAMIENTO DE LA RED 77
4.1.1 SOPORTE INFORMATICO PARA EL MODELO 77
4.1.2 PREDICCION 80
4.1.3 PREDICCION CON DATOS CONOCIDOS POR EL MODELO RED NEURONAL 81
4.1.4 PREDICCION CON DATOS NO CONOCIDOS POR EL MODELO RED NEURONAL 82

4.1.5 ANALISIS POST-ENTRENAMIENTO 83

4.1.6 APLICACIÓN DE LA FUNCION TRIANGUALR DE LA LOGICA DIFUSA A LA PREDICCION DE LA RED NEURONAL 86

4.1.7 PROTOTIPO 89

5. CONCLUSIONES Y RECOMENDACIONES..... 91

5.1 CONCLUSIONES 91

5.2 ESTADO DE LA HIPOTESIS 91

5.3 RECOMENDACIONES 92

5.4 TRABAJOS FUTUROS 92

6. BIBLIOGRAFIA..... 94

ANEXOS

DOCUMENTACION

INDICE DE FIGURAS

Fig.1 Molécula de Agua 11

Fig.2 El Ciclo Hidrológico 14

Fig.3 Disponibilidad de Agua y Población 1 5

Fig.4 Precipitación en promedio en un año 19

Fig.5 Temperatura promedio en un año 20

Fig.6Esquema de captación y distribución de agua potable en la ciudad de La Paz 27

Fig.7Red Neuronal Biológica 29

Fig.8 Comparación de una neurona Biológica y Artificial 30

Fig.9 Redes neuronales 34

Fig.10 Redes neuronales mono capa 35

Fig.11 Redes Multicapa 36

Fig.12 Pasos y fórmulas para aplicar el algoritmo de aprendizaje 43

Fig.13 Modelo macro 48

Fig.14 Conjunto clásico, $X = [0,10]$, $A = [5,8]$ donde $A \subseteq X$ 52

Fig.15 Función triangular $A(x;a,m,b)$ 53

Fig.16 Conjunto difuso consumo normal 55

Fig.17 Corte de nivel alfa para el conjunto difuso 56

Fig.18 Modelo General 61

Fig.19 Estructura del modelo red neuronal *Backpropagation* 68

Fig.20Modelo teórico del entrenamiento 73

Fig.21 Función triangular 74

Fig.22Código para el entrenamiento 78

Fig.23Código para la predicción 80

Fig.24Consumo real y predicciones red neuronal 81

Fig.25Predicción con datos no entrenados..... 83

Fig.26Análisis de regresión del modelo de red neuronal..... 84

Fig.27 consumo real vs consumo predicho red neuronal (todos los datos) 85

Fig.28Ventana de inicio 89

Fig.29Ventana de cálculos 89

Fig.30Inicialización de datos..... 90

Fig.31Resultados de redes neuronales y lógica difusa..... 90

INDICE DE TABLAS

Tabla 1. Variables de estudio 9

Tabla 2. Volumen de agua disponible en el mundo 13

Tabla 3. Consumo de agua potable total Bolivia y total La Paz, por tipo de servicio, 2000-2007(Miles de metros cúbicos) 17

Tabla 4. Consumo de agua de hogares por procedencia y según área 1998-2007(Porcentaje) 17

Tabla 5. Estructura de tarifas 2009 – 2010 24

Tabla 6. Fuentes de procedencia de agua 25

Tabla 7. consumo facturado anual 1998-2010(m3 año) la paz - Bolivia 26

Tabla 8. Capacidad en fuentes 27

Tabla 9. Funciones de transferencia 33

Tabla 10. Grados de pertenencia 55

Tabla 11. Valores de verdad resultado de operaciones lógicas 58

Tabla 12. Variables que intervienen en el aprendizaje de la red 63

Tabla 13. Datos para el entrenamiento de la red 64

Tabla 14. Datos de entrada normalizados en escala [0-1] 66

Tabla 15. División de la Muestra 67

Tabla 16. Consumo real y predicciones red neuronal 81

Tabla 17. Predicción con datos no entrenados 82

Tabla 18. Promedio de incremento de consumo de agua por mes y año 86

Tabla 19. Intervalo de consumo con nivel de confianza del 80% 88

1

Marco Referencial

Resumen

En este capítulo se proporcionan una introducción y antecedentes al tema. Se describe el planteamiento del problema, los objetivos, la hipótesis, justificación y alcances.

1.1 INTRODUCCION

Como en muchos tiempos el agua es un recurso muy importante para la sobrevivencia del ser humano, el ser humano no puede estar sin beberla más de cinco o seis días sin poner en peligro su vida. [Jiménez, 2000]Por diversas razones en los últimos tiempos el agua haempezado a disminuir más que todo por el cambio climático. Tal factor hace que el agua apta para el consumo del ser humano se vea disminuida, razón por el cual se debe realizar un cuidado de este recurso. Lo que conlleva a solucionar problemas como el de desabastecimiento, captación de agua en represas, planificación, mejor uso de recursos hidráulicos y otros problemas que sea relacionada con la misma, mas con el problema geográfico que presenta la ciudad de La Paz lo que hace muy dificultosa el transporte de agua potable.

Las series de tiempo son datos estadísticos que se recopilan, observan o registran en intervalos de tiempo regulares (diario, semanal, semestral, anual, entre otros). El término serie de tiempo se aplica por ejemplo a datos registrados en forma periódica que muestran, por ejemplo, las ventas anuales totales de almacenes, el valor trimestral total de contratos de construcción otorgado. [Sepúlveda, 2007]

Una herramienta muy útil para las predicciones de tiempo son las redes neuronales. En las últimas décadas las Redes Neuronales Artificiales han recibido un interés particular como una tecnología para minería de datos, puesto que ofrece los medios para modelar de manera efectiva y eficiente problemas grandes y complejos. [Matich, 2001]

Los modelos de Redes Neuronales Artificiales son dirigidos a partir de los datos, es decir, son capaces de encontrar relaciones (patrones) de forma inductiva por medio de los algoritmos de aprendizaje basado en los datos existentes más que requerir la ayuda de un modelador para especificar la forma funcional y sus interacciones.

En aéreas de tratar la incertidumbre la *lógica difusa* es una herramienta muy útil, debido a que los valores de verdad no-deterministas utilizados en la lógica difusa tienen una connotación de incertidumbre, por lo que se equipara la incertidumbre con la difusidad, es decir, con la propiedad de indeterminismo, por lo tantoun elemento, puede estar lleno de incertidumbre eso no quiere decir que los valores de verdad asumidos por enunciados no deterministas sean desconocidos, de hecho, lo difuso puede entenderse como la posibilidad de asignar más valores de verdad a los anunciados de falso o verdadero e incluso en determinadas áreas de conocimiento estos enunciados van asociados a valores de verdad que son grados de veracidad o falsedad.[Choque, 2002]

En el presente trabajo se realizara el desarrollo de un modelo de predicción del consumo de agua, para ello se utilizara las redes neuronales para realizar predicciones en untiempo*t*,la utilización de la lógica en los datos predichos por la red neuronalofrecerá un resultado más confiable. El modelo desarrollado prestara información, confiable que ayudara en la planificación y toma de decisiones.

1.2 ANTECEDENTES

Estudios realizados sobre el consumo de agua por organizaciones e instituto de estadísticas.

La población de las ciudades de los países en desarrollo crece de forma alarmante, lo que genera un aumento de la demanda muy por encima de las capacidades de los servicios y de la infraestructura de abastecimiento y saneamiento de agua, hoy en día insuficientes. Según el Informe de las Naciones Unidas sobre el desarrollo de los recursos hídricos en el mundo, en el 2050, al menos una de cada cuatro personas vivirá en un país con escasez crónica o recurrente de agua. [ONU, 2006]

La Organización Mundial de la Salud (OMS) considera que la cantidad adecuada de agua para consumo humano (beber, cocinar, higiene personal y limpieza del hogar) es de 50 l/hab-día. A estas cantidades debe sumarse el aporte necesario para la agricultura, la

industria y, por supuesto, la conservación de los ecosistemas acuáticos, fluviales y, en general, dependientes del agua dulce. Teniendo en cuenta estos parámetros, se considera una cantidad mínima de 100 l/hab-día. [INE, 2008]

En Bolivia la proyección de crecimiento para el 2008 es superior a los 45.000 usuarios del servicio de agua potable domiciliario, de este total el 98 por ciento corresponde a la categoría doméstica y un dos por ciento está distribuido entre la industria y el comercio. [INE, 2008]

Estudios realizados en universidades del exterior.

Modelo de Pronóstico del Consumo de Agua Potable. M.I., Francisco Aguilar Ortega. Centro de Estudios Multidisciplinarios, UAZ, 2000.

El estudio realizado sobre el consumo de agua utilizando técnicas de la teoría de estadística el cual buscan que los modelos multivariables presentan las mejores correlaciones con probabilidades significativas donde las variables como la temperatura máxima y tipo de conexión son las que más implican en el consumo de agua.

Pronósticos en el mercado de derivados utilizando redes neuronales y modelos ARIMA: una aplicación al Cete de 91 días en el MexDer., Iván Cruz Torres, Facultad de Contaduría y Administración Universidad Autónoma México, 2006.

Realiza un estudio de las redes neuronales y el modelo Arima, para hacer predicciones del comportamiento financiero, la gran importancia de saber el comportamiento de determinado activo financiero o instrumento derivado en un futuro permite tomar previsiones para evitar tomar riesgos innecesarios o tener la oportunidad de obtener mayores beneficios que la mayoría de las personas no puede aprovechar.

Desarrollo de un modelo de Redes Neuronales para Predecir la resistencia a La compresión y la resistividad del concreto, Ing. Juna Manuel LizarazuMárraga, Universidad Nacional de Colombia, 2006.

Desarrolla un modelo de redes neuronales para predecir la resistencia la compresión y resistividad del concreto y con un programa experimental de 41 mesclas de concreto con diferentes características para medirla resistencia de la compresión, la velocidad de sonido ultrasónico, el peso unitario, y la resistividad eléctrica de las probetas del concreto a los 28 días transcurridos.

Demanda de Agua en Zonas Urbanas en Andalucía, Dra. Francisca Daza Sánchez, Universidad Córdoba,Departamento de Estadística, Econometría, I.O. y Organización de Empresas, 2008.

Se realiza un análisis de la demanda de agua urbana en Andalucía, partiendo de los datos de consumo de agua en una zona urbana, tanto global como desagregada, correspondiente al periodo 1984-2007. Así mismo se desarrolla una nueva metodología que resulta fundamental para obtener predicciones de demanda con mayor precisión.

Algunos temas relacionados al trabajo y desarrollados en la Universidad Mayor de San Andrés.

-Tesis. Predicción en Series de Tiempo con Redes Neuronales. Lic. Rosalía Arista Matinés, UMSA, 1988.

Redes neuronales en la predicción de Series de Tiempo, cuyo propósito es utilizar a la redes neuronales artificiales para predecir series de tiempo caóticos, esto usando diferentes tipos de arquitecturas de redes neuronales.

-Tesis. Predicción de la Demanda Eléctrica utilizando Redes Neuronales Artificiales. Lic. Juan Pablo Quispe Poma, UMSA, 2005.

Realiza un trabajo con Redes Neuronales Artificiales como instrumento de modelización y predicción de la demanda eléctrica, poniendo de relieve la superioridad mostrada por las mismas en el modelado de los fenómenos no-lineales, que permitirá predecir la evolución de la demanda horaria de energía eléctrica en la ciudad de La Paz.

- Tesis. Redes Neuronales y Logia Difusa en la Predicción del Crecimiento de una Matrícula Estudiantil-Docente. Lic. Freddy Mendoza Quispe, UMSA, 2007.

En este trabajo se realiza un trabajo sobre la predicción del crecimiento de una matrícula estudiantil, a corto y mediano plazo. Para ello se aplica las redes neuronales y la lógica difusa, para determinar la cantidad de personal docente necesario para cubrir el crecimiento de la matricula estudiantil.

1.3 PLANTEAMIENTO DEL PROBLEMA

1.3.1 PROBLEMA PRINCIPAL

El crecimiento de una población que demanda cada vez más agua para satisfacer sus necesidades, requiere de una mayor responsabilidad en el estudio del consumo del agua y uso de los avances tecnológicos que permitan hacer uso eficiente y sustentable del recurso del agua, ya que el agua constituye la vida misma. Por otro lado, el clima y las condiciones socioeconómicas de la población tienen una gran influencia sobre los patrones de consumo de agua para una población. Los factores como crecimiento poblacional, temperatura, operan de una manera independiente o combinada, aunados a los aspectos culturales, socioeconómicos como estrato social, y el bienestar social. Pocos estudios realizados sobre la estimación del consumo de agua hace notar una deficiencia a la hora de una buena distribución del agua, métodos estadísticos y matemáticos no brindan una suficiente información verídica o estimación confiable del consumo de agua. Lo que hace notar que la información que se cuenta no es muy buena.

Por lo tanto como no hay mucha información del consumo de agua a futuro se ve por necesario realizar un modelo predictivo dela demanda del consumo de agua potable utilizando redes neuronales y lógica difusa.

1.3.2 PROBLEMA ESPECIFICOS

- Por falta de una información más precisa sobre el consumo de agua potable existe una deficiencia en la distribución adecuada del agua hacia la ciudad de La Paz. [Quiroz, 2009]
- La captación de volúmenes de agua en represas es inadecuada por no tener una información de la cantidad de consumo en un tiempo presente, se debe hacer notar que las represas son alimentadas por los deshielos de los grandes glaciares y no se tiene un aprovechamiento en la captación de agua de las vertientes, posos o ríos cercanos, y como no hay un cuidado en la distribución del agua potable hacia la ciudad, las represas tienden a disminuir lo que puede llevar a la no continuidad de la distribución del agua potable.

- La poca información sobre el consumo de agua repercute en la planificación de recursos, como en la construcción de nuevas represas, previsión, mejoramiento de recursos hidráulicos que mejore la distribución de agua potable, y toma de decisiones.
- Los pocos estudios sobre el consumo de agua hacia futuro hace que no se tenga buena información del consumo promedio de agua que consume la ciudad llevando a la ineficacia en la distribución del agua.
- Tratamiento insuficiente de factores exógenos y endógenos como el clima, crecimiento de la población, consumo del agua por parte de la población, hacen que a la hora de realizar cálculos estadísticos el resultado no sea la óptima.
- La información provista por métodos estadísticos y matemáticos son limitados ya que no contemplan con una retroalimentación de variables que fluctúan en el tiempo como el crecimiento poblacional y o el factor climatológico, a si que estos métodos estadísticos y o matemáticos realizan estimaciones que no son de las mejores.
- Todo este factor lleva a que exista desabastecimiento de agua hacia la población, llevando al perjuicio a los ciudadanos, empresas y otros.

1.4 HIPOTESIS

La aplicación de redes neuronales y lógica difusa al consumo de agua potable,permitirá predecir la demanda del agua en los siguientes años, con una efectividad del 60%.

1.5 OBJETIVOS

1.5.1 OBJETIVO PRINCIPAL

Predecir la demanda del consumo de agua potable en la ciudad de La Paz por medio de un modelo de red neuronal y lógica difusa.

1.5.2 OBJETIVOS ESPECIFICOS

- Proporcionar información adecuada para la planificación y distribución del agua potable con los resultados obtenidos por el modelo de red neuronal y lógica difusa..
- Considerar variables como el cambio climático, crecimiento poblacional, conexiones de agua a domicilio y empresas, utilizadas para la predicción del consumo de agua.
- Construir un prototipo de software con base en el modelo de red neuronal y lógica difusa.
- Analizar los resultados obtenidos por la red neuronal, con la lógica difusa para obtener resultados más confiables.

1.6 JUSTIFICACION

1.6.1 Justificación técnica

Se justifica técnicamente, por el desarrollo de un prototipo computacional basado en redes neuronales artificiales y lógica difusa, para ello no es necesario equipos ni herramientas sofisticadas, bastara con un equipo computacional PENTIUM IV o superior, puesto que ella será instalada el programa Matlab 7.0, que dispone de un amplio abanico de programas de apoyo especializado, denominado toolbox[1], que tiene varias funciones incorporadas, que en la actualidad cubren muchas áreas del mundo de la ingeniería y la simulación, como ser procesos de imágenes, estadísticas, matemática simbólica, redes neuronales, lógica difusa, sistemas neuro-difusos, ente otros.

1.6.2 Justificación Social

Se plantea el desarrollo de un modelo predictivo que sea útil a las personas involucradas en la toma de decisiones dentro del gobierno municipal, prefectura, EPSAS[2],tales decisiones ayudaran a la correcta planificación e inversión de recursos, como también a

[1] Herramientas para realizar cálculos estadísticos Proporciona una única mezcla de facilidad gráfica de uso y programabilidad Los despliegues gráficos interactivos le permiten aplicar métodos estadísticos fácilmente y de forma consistente

[2] Empresa Pública Social de Agua y Saneamiento

la prevención en cuanto al almacenamiento y abasto de agua que se tendrá que tener, ayudando a así a la población a no sufrir de desabastecimiento ni cortes de agua.

1.6.3 Justificación Económica

Está justificado económicamente por ser de utilidad a las autoridades del gobierno municipal, prefectura y EPSAS, ya que con la información que brinde el modelo de predicción del consumo de agua potable, las personas encargadas en aspectos financieros, tendrán una información que será de gran ayuda a la hora de tomar decisiones, en la planificación e inversiones de recursos económicos.

1.7 LIMITES Y ALCANCES

Los límites para el trabajo son:

Los estudios involucrados como los procesos de predicción llevaran a la culminación de la demostración de la hipótesis que está relacionado con la adopción de las redes neuronales y la lógica difusa en las metodologías de la investigación, puede haber otras formas de encarar la incertidumbredentro de un pronóstico el cual no se discutirá en esta tesis, como el modelo matemático, modelo de simulación, modelos formales.

El estudio realizado estará enmarcado en la ciudad de La Paz.

Se analizaran los métodos basados en la predicción, basada en series de tiempo porque es de gran interés practico, permite conocer un margen de error pequeño, valores futuros de una serie basado en sus valores pasados. Una serie de tiempo discreta es una secuencia cronológica de observaciones de una variable particular. Cuyo objetivo es predecir valores futuros de una serie a partir de valores pasados. [Bowerman&O`Connel, 1993]

Se utilizaran para el estudio las variables X, de las cuales se tomaran las variables que más aporten en el consumo de agua, en la siguiente tabla se muestran las variables:

Tabla 1. Variables de estudio

X	Variables	Descripción
1	Población	Es el número total estimado de personas que viven en la ciudad de La Paz
2	cantidad de consumo de agua	Es la cantidad en metros cúbicos de agua consumidos por parte de la población
3	tiempo	Sonlos datos estimados de cálculos pasados del consumo de agua y el futuras estimaciones
4	disposición del agua	Cantidades de agua disponibles en represas de almacenamiento de agua
5	clima	Cambios en el tiempo climático como precipitaciones pluviales, humedad, temperatura y contaminación
6	precio	Es el monto estimado de gasto que el consumidor paga por el total de agua consumida

Fuente: Elaboración propia

2

Marco Teórico

Resumen

En este capítulo se proporcionan los conceptos básicos del agua, la importancia del agua en el ser humano. Posteriormente se analiza las redes Neuronales Artificiales y la lógica Difusa, su definición, características, elementos, finalmente se define la integración de la lógica difusa con las redes neuronales.

2.1 EL AGUA

El agua es un componente de nuestra naturaleza que ha estado presente en la Tierra desde hace más de 3.000 millones de años, ocupando tres cuartas partes de la superficie del planeta. Su naturaleza se compone de tres átomos, dos átomos de hidrogeno, y uno de oxígeno que unidos entre sí forman una molécula de agua (Ver. Fig. 1), en la tabla periódica se simboliza como H_2O, la unidad mínima en que ésta se puede encontrar. La forma en que estas moléculas se unen entre sí determinará la forma en que encontramos el agua en nuestro entorno; como líquidos, en lluvias, ríos, océanos, etc., como sólidos en témpanos y nieves o como gas en las nubes. [IAMA, 2000]

Fig.1 Molécula de Agua

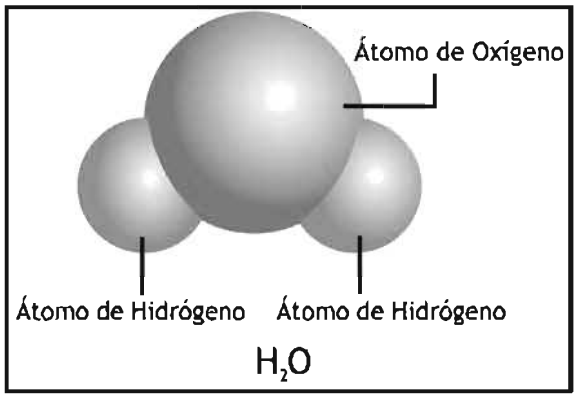

Fuente: [IAMA, 2000]

2.1.1 El agua en la vida humana

El agua es el principal e imprescindible componente del cuerpo humano. El ser humano no puede estar sin beberla más de cinco o seis días sin poner en peligro su vida. El cuerpo humano tiene un 75 % de agua al nacer y cerca del 60 % en la edad adulta. Aproximadamente el 60 % de este agua se encuentra en el interior de las células (agua intracelular). El resto (agua extracelular) es la que circula en la sangre y baña los tejidos. [Utz, 2003]

Para evitar desórdenes, el cuerpo necesita alrededor de siete litros diarios de agua; la cantidad exacta variará en función del nivel de actividad, la temperatura, la humedad y otros factores. La mayor parte de esta agua se absorbe con la comida o bebidas, no se ha determinado la cantidad exacta de agua que debe tomar un individuo sano, aunque una mayoría de expertos considera que unos 6-7 vasos de agua diarios (aproximadamente dos litros) es el mínimo necesario para mantener una adecuada hidratación. [Utz, 2003] La literatura médica defiende un menor consumo, típicamente un litro de agua diario para un individuo varón adulto, excluyendo otros requerimientos posibles debidos a la pérdida de líquidos causada por altas temperaturas o ejercicio físico. [Williams &Wilkin, 2003]

En la historia muestra que las civilizaciones primitivas florecieron en zonas favorables a la agricultura, como las cuencas de los ríos. Es el caso de Mesopotamia, considerada la cuna de la civilización humana, surgida en el fértil valle del Éufrates y el Tigris; y también el de Egipto, una espléndida civilización que dependía por completo del Nilo y

sus periódicas crecidas. Muchas otras grandes ciudades, como Rotterdam, Londres, Montreal, París, Nueva York, Buenos Aires, Shanghái, Tokio, Chicago o Hong Kong deben su riqueza a la conexión con alguna gran vía de agua que favoreció su crecimiento y su prosperidad. [Crespo, 2006]

Como vemos el agua es la vida misma para la supervivencia del ser vivo.

2.2 DISPONIBILIDAD MUNDIAL DE LOS RECURSOS HIDRICOS

El agua es el elemento más importante en la Tierra: el 71% de nuestro Planeta es agua pero el 97.5% de los recursos hídricos es agua salada. El volumen total de agua es de aproximadamente 1.400 millones de km3, de los cuales sólo el 2,5%, o alrededor de 35 millones de km3, corresponde al agua dulce. [Shiklomanov, 1999]

2.2.1Ubicación y Distribución

La mayor parte del agua dulce (68.7%) se presenta en forma de hielo (glaciares) o nieves eternas, ubicados en la región antártica y en Groenlandia, o en profundos acuíferos de aguas subterráneas. Las principales fuentes de agua para uso humano son los lagos, ríos, la humedad del suelo y cuencas de aguas subterráneas relativamente poco profundas. La parte aprovechable proveniente de esas fuentes es aproximadamente de sólo 200.000 km3 de agua, es decir menos del 1 por ciento del total de agua dulce y sólo el 0,01 por ciento de toda el agua del planeta, en la tabla 1 se puede apreciar los porcentajes entre agua dulce y salada .[Marín& Alonso, 2005]

Tabla 2. Volumen de agua disponible en el mundo

Agua	Volumen (1.000 km3)	% del total de agua	% del total de agua dulce
Agua salada			
Océanos	1.338.000	96.54%	
Aguas subterranes salinas / salobres	12.870	0.93%	
Lagos de agua salada	85	0.01%	
Aguas Continentales			
Glaciares cubierta de nieve permanente	24.064	1.74%	68.70%
Agua dulce subterránea	10.530	0.76%	30.06%
Hielo del suelo, gelisuelo	300	0.02%	0.86%
Lagos de agua dulce	91	0.01%	0.26%
Humedad del suelo	17	0.001%	0.05%
Vapor de agua atmosférica	13	0.001%	0.04%
Pantanos, humedales*	12	0.001%	0.03%
Ríos	2	0.0002%	0.01%
Incorporados en la biota*	1	0.0001%	0.003%
Total de agua	1.385.984	100.00%	
Total de agua dulce	35.029		100%

Fuente: [Marín& Alonso, 2005]

La gran parte de esa agua disponible está ubicada lejos de las poblaciones humanas, lo que complica aún más las cuestiones relativas al aprovechamiento del agua.

La recarga de agua dulce depende de la evaporación proveniente de la superficie de los océanos. Cerca de 430,000 km3, se evaporan de los océanos cada año. Otros 70,000 km3 se evaporan de la tierra. Alrededor del 80% del total de las precipitaciones, es decir, alrededor de 390,000 km3/año, cae en los océanos y los restantes 110,000 km3/año, sobre la tierra. La diferencia entre la precipitación sobre la superficie terrestre y la evaporación de esa superficie (110,000 km3 menos 70,000 km3 por año) son las escorrentías, de aproximadamente 40,000 km3 por año. [Gleick, 1993]

La figura 2, se muestra un cálculo aproximado del balance hidrológico anual medio de las principales zonas continentales, con inclusión de precipitaciones, evaporación y escorrentías. Más de la mitad de las escorrentías totales ocurren en Asia y América del Sur, y una gran proporción, en un solo río, el Amazonas, que lleva más de 6,000 km3 de agua por año.[Marín& Alonso, 2005]

Fig.2 El Ciclo Hidrológico

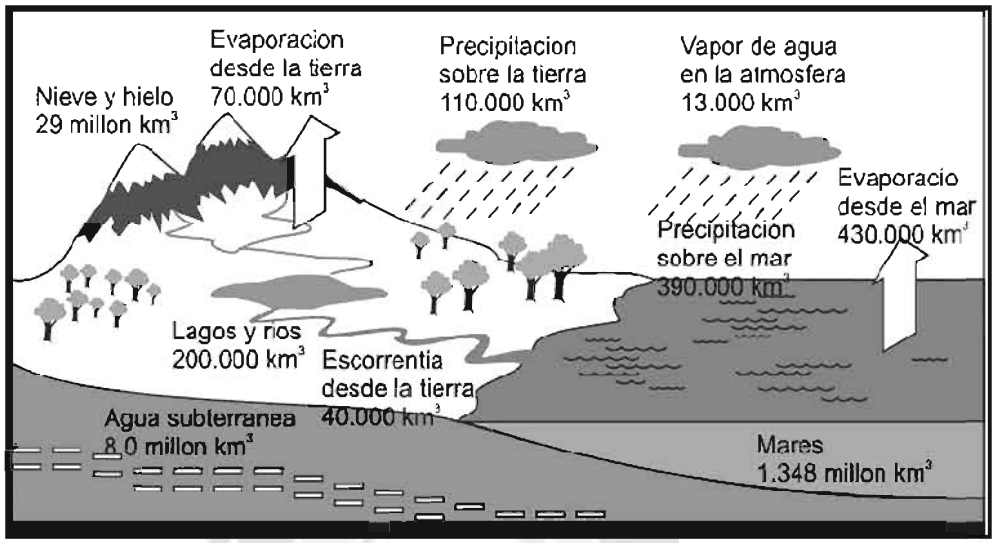

Fuente: [[Marín& Alonso, 2005]]

La distribución del agua es muy desigual, no solo entre distintos países del mundo, sino entre regiones de un mismo país. Así en Europa, España es un ejemplo de esta desigualdad, e incluso países ricos en este recurso como es Brasil, tiene regiones en el noreste con una gran escasez. La desigual distribución del agua y su dotación es extrema, basta con comparar algunas regiones del planeta. Canadá, con una población del orden del 2.5% que de la de China, tiene aproximadamente la misma cantidad de agua que ésta. Asia, cuya población es aproximadamente el 60% de la población total mundial, solo dispone del 36% del agua dulce que fluye por el mundo y de esta cantidad, el 80% se contamina por inundaciones que se producen, en la figura 3 se muestra el agua disponible para el consumo y la población distribuida por regiones. [UNESCO, 2002]

Fig. 3 Disponibilidad de Agua y Población

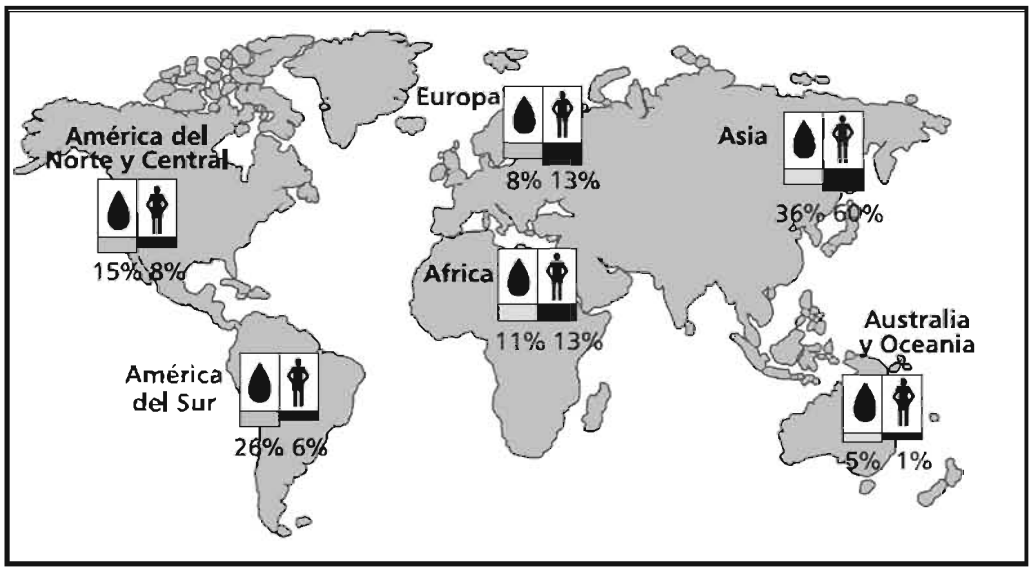

Fuente: [Marín& Alonso, 2005]

En el último siglo la población se ha cuadruplicado, mientras que el consumo de agua doméstico se ha multiplicado por nueve y el consumo para usos industriales se ha multiplicado por cuarenta. La disminución de las reservas de agua se verá agravada con el aumento de la población mundial, estimada en alrededor de un 40% sobre la actual en los próximos 25 años (según las Naciones Unidas: de los 6,000 millones de habitantes actuales, se pasará a 8,300 en el año 2025). [Foster, 2006]

2.2.2 La Demanda de Agua en el Mundo

Nos agradaría pensar que el agua del planeta es inagotable. Pero este planteamiento es trágicamente erróneo. El caudal de agua dulce no alcanza ni la mitad de un uno por ciento de toda el agua de la tierra. Lo demás es agua salada, o forma parte de los hielos polares. El agua dulce únicamente se renueva por la lluvia, que cae a un ritmo de 40.000 a 50.000 kilómetros cúbicos al año. Pero debido a la congestión de las grandes urbes, a la deforestación, al desvío de las aguas por necesidades de irrigación agrícola, hasta esta ínfima parte de agua dulce está desapareciendo a la par que se va secando la superficie de la tierra; a este ritmo, el agua de todas las cuencas de los ríos de todos los continentes irá agotándose de manera ininterrumpida. [Barlow, 2001]

El consumo mundial del agua dobla cada veinte años, es decir a un ritmo dos veces mayor que el del crecimiento de la población humana. Según las Naciones Unidas, el agua potable ya escasea para mil millones de personas. De seguir así, de aquí al año 2025, la demanda de agua dulce llegará a superar la disponible hoy día en un 56 por ciento. [Barlow, 2001]

A medida que se va intensificando la crisis del agua, los gobiernos del mundo entero presionados por las grandes multinacionales están abogando por una solución radical: la privatización, la reificación y el desvío masivo de las aguas. Los partidarios de este sistema opinan que esta sería la única manera de poder abastecer a los lugares del mundo donde se padece sed. Pero, sabemos por experiencia que la venta del agua en un mercado abierto no sirve para colmar las necesidades de los pobres y sedientos. Muy al contrario, el agua privatizada termina en manos de quiénes pueden pagar por ella, tales como las personas y ciudades pudientes, y las industrias que hacen un uso intensivo del agua, entre las que cabe mencionar la agricultura y la alta tecnología. "El agua fluye río arriba, hacia el dinero", como comenta un residente en pleno desierto de Nuevo México, cuando el agua de su localidad fue desviada para uso y beneficio de una industria de alta tecnología. [Barlow, 2001]

2.3 DEMANDA DE AGUA EN BOLIVIA

En Bolivia, igual que en otros países, se observa una creciente demanda por el uso del agua. Las demandas para consumo humano y saneamiento, uso agropecuario, industrial y otros, se incrementan cada vez más y generalmente, no se respeta la prioridad del uso para consumo humano y riego, generando y profundizando conflictos relacionados al acceso, aprovechamiento y derechos sobre el recurso. El uso ineficiente de los recursos hídricos, en cuanto a su utilización y su aprovechamiento es otro problema. En el sector de agua potable y saneamiento, existen problemas expresados en indicadores técnico financieros, que reflejan pérdidas fisicas y perdidas comerciales (agua no contabilizada y no facturada) por el uso indiscriminado del agua potable. [PND, 2005]

En las siguientes tablas 2 y 3 se puede apreciar los consumos de agua potable por tipo de servicios, y procedencia en Bolivia.

Tabla 3. Consumo de agua potable total Bolivia y total La Paz, por tipo de servicio, 2000-2007(Miles de metros cúbicos)

DEPARTAMENTO	2000	2001	2002	2003	2004	2005	2006	2007 p/
TOTAL	**104 937**	**104 579**	**107 963**	**110 876**	**114 681**	**119 429**	**123 548**	**128 205**
Doméstico	79 683	80 340	83 676	87 109	90 506	94 897	97 165	101 291
Comercial	16 866	15 741	15 527	15 233	15 544	15 785	16 575	16 895
Industrial	2 780	2 768	2 835	2 642	2 685	2 610	3 345	3 439
Oficial	5 607	5 730	5 925	5 892	5 946	6 137	6 463	6 580
La Paz	**42 764**	**41 447**	**41 995**	**43 195**	**44 108**	**45 271**	**46 317**	**46 367**
Doméstico	33 211	32 063	32 542	33 973	34 760	35 999	36 997	37 334
Comercial	5 129	5 030	5 167	5 027	4 997	4 937	4 814	4 726
Industrial	1 716	1 829	1 794	1 639	1 660	1 599	1 702	1 572
Oficial	2 708	2 525	2 493	2 556	2 691	2 736	2 803	2 736

p/ Preliminar
Nota La información corresponde al volumen de consumo de agua facturado por las Empresas Prestadoras del Servicio de Agua Potable y Saneamiento
Elaboración Secretaria General de la Comunidad Andina Estadísticas Ambientales Decisión 699

Fuente: [INE, 2007]

Tabla 4. Consumo de agua de hogares por procedencia y según área 1998-2007 (Porcentaje)

AGUA DE LA VIVIENDA	1998	1999	2000	2001	2002	2003-2004a/	2005	2006	2007
Bolivia	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**
Red por cañería	66,2	65,3	70,2	66,9	64,5	65,6	71,4	73,7	75,5
Pileta pública	8,6	5,0	4,5	4,4	5,2	5,5	2,9	2,1	3,2
Pozo o noria con bomba	10,6	3,0	2,3	3,6	2,9	2,6	3,3	2,2	1,8
Pozo o noria sin bomba	…	8,2	7,4	9,9	9,7	9,6	7,5	6,2	5,6
Río, vertiente o acequia	11,5	15,6	12,1	10,6	12,8	12,1	11,9	11,8	12,7
Lago, laguna o curiche	…	0,5	0,4	0,2	0,3	0,7	0,8	0,3	0,2
Carro repartidor (aguatero)	1,7	1,0	1,4	2,0	1,7	1,9	1,6	1,6	1,1
Otro 1/	1,5	1,4	1,6	2,5	2,9	2,0	0,7	2,1	0,1
Área Urbana	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**
Red por cañería	87,3	90,5	90,1	87,2	86,9	86,3	89,3	91,8	94,8
Pileta pública	5,7	2,0	2,7	1,5	2,5	3,0	1,6	1,1	0,7
Pozo o noria con bomba	3,0	1,4	1,3	1,1	0,9	1,4	2,7	0,8	0,6
Pozo o noria sin bomba	…	2,2	2,0	3,7	3,2	3,1	2,8	2,2	1,5
Río, vertiente o acequia	0,4	1,3	0,4	0,7	0,4	0,9	0,4	0,1	0,7
Lago, laguna o curiche	…	…	…	…	0,1	0,1	0,1	…	…
Carro repartidor (aguatero)	2,6	1,4	2,1	3,1	2,7	3,0	2,3	2,5	1,6
Otro 1/	1,1	1,1	1,3	2,7	3,3	2,3	0,8	1,5	0,1
Área Rural	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**	**100,0**
Red por cañería	30,3	23,0	35,6	33,6	27,3	33,6	38,8	42,9	39,4
Pileta pública	13,6	10,0	7,7	9,0	9,6	9,5	5,2	4,0	7,9
Pozo o noria con bomba	23,5	5,8	3,9	7,6	6,1	4,4	4,5	4,8	3,8
Pozo o noria sin bomba	…	18,1	16,9	19,9	20,6	19,7	16,0	12,8	13,3
Río, vertiente o acequia	30,3	39,7	32,5	26,9	33,4	29,5	32,8	31,5	35,0

Lago, laguna o curiche	…	1,4	1,1	0,5	0,7	1,6	2,0	0,9	0,4
Carro repartidor (aguatero)	0,1	0,2	0,1	0,2	0,1	0,3	0,1	0,1	0,1
Otro 1/	2,2	1,9	2,1	2,4	2,2	1,5	0,6	3,1	0,1

(…) No disponible
a/ Los datos corresponden a la Encuesta Continua de Hogares, realizada entre noviembre de 2003 y noviembre de 2004
1/ Si el abastecimiento se realiza por fuentes distintas a las anteriormente mencionadas, Ejemplo agua de lluvia,
Elaboración Secretaria General de la Comunidad Andina Estadísticas Ambientales Decisión 699,

Fuente: [INE, 2007]

2.4 VARIABLES QUE AFECTAN AL CONSUMO DE AGUA POTABLE

2.4.1 CONDICONES METEOROLOGICAS

El estado del tiempo en la Tierra está regido por leyes científicas, que por cierto son bastante complejas y no siempre perfectamente conocidas. Por eso es tan dificil prever el tiempo que hará en un lugar determinado o durante un periodo prolongado, con la precisión que generalmente se atribuye a las ciencias exactas. No obstante, gracias a muchas estaciones meteorológicas repartidas por la superficie terrestre, y una moderna tecnología, basada en potentes herramientas informáticas y en técnicas matemáticas muy elaboradas, se hacen pronósticos meteorológicos a un día con mucha precisión (86% de fiabilidad) y a 3-7 días con bastante precisión (80 % a 3 días). A más largo plazo es prácticamente imposible hacer previsiones con un grado de fiabilidad razonable. [Walhs, 2010]

El análisis de los parámetros meteorológicos se inicia con la caracterización de los principales factores climáticos, (temperatura, precipitación, humedad relativa y vientos). Merece atención especial el análisis de los eventos climáticos de mayor relevancia en el área de estudio, la definición de la estacionalidad climática (la cual muestra una amplia variación de las condiciones de lluvia entre meses veraniegos muy lluviosos y meses invernales de lluvias escasas), así como los resultados del balance hídrico que manifiesta la cantidad de humedad disponible anualmente en el suelo para el sostenimiento de la cobertura vegetal. Veamos un poco sobre los factores meteorológicos que se estudian:

2.4.1.1 Precipitaciones

Las precipitaciones en la región se producen por la disponibilidad de energía solar. La energía que llega a la superficie es devuelta a la atmósfera en forma de calor sensible y latente (evapotranspiración), así el balance de energía y humedad interactúan, y la

radiación neta se divide en términos de calor sensible y/o latente dependiendo de las condiciones ambientales.[Gonzales et al., 2007]

Esto produce mecanismos de convección (ascensión de masas de aire que implica la formación de nubes cumulonimbos) y complementariamente precipitaciones estratiformes (formación de nubes estratos). En ambos casos el suministro de humedad es endógeno y exógeno, es decir, procede de los enormes volúmenes de evapotranspiración producto de la densa cubierta vegetal y del ingreso de humedad mediante los factores atmosféricos que interactúan en la región. [Gonzales et al., 2007]

El periodo de intensas precipitaciones o fuerte actividad convectiva está comprendido entre los meses de noviembre y marzo, presentando una disminución de éstas o menor actividad convectiva entre los meses de mayo a septiembre. Los meses de abril y octubre son meses de transición entre un régimen y otro. En la Fig.4 podemos observar el promedio de lluvia anual es de 600 mm. Las lluvias se concentran de manera estacional desde diciembre hasta abril

Fig.4 Precipitación en promedio en un año

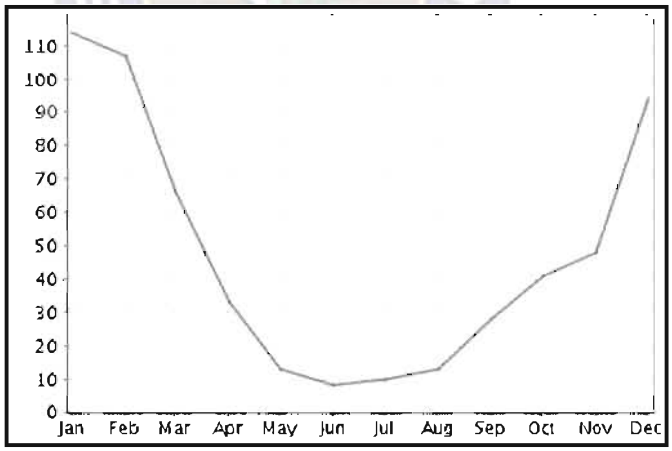

Fuente: [Gonzales et al., 2007]

2.4.1.2 Temperatura

La temperatura en el sector del altiplano se presenta menos estable con relación a las temperaturas del oriente, dado que los factores que lo determinan no son constantes a lo largo del año.

En verano (Noviembre a Abril) el clima puede ser impredecible: Ya que las impredecibles lluvias en las tardes o en la mañana hace que la topografía de la ciudad de

La Paz se convierta a menudo en torrentes ríos de agua. En invierno (Mayo a Octubre) los días pueden ser algo fríos, con temperaturas que alcanzan 18-20°C (64-68°F). En la noche es a menudo bajo al punto de congelamiento. El clima es de montaña con condiciones extremas durante todo el año. El promedio anual es de 6 - 10°C., en la Fig. 5 se muestra las temperaturas promedio. [Gonzales et al., 2007]

Fig.5 Temperatura promedio en un año

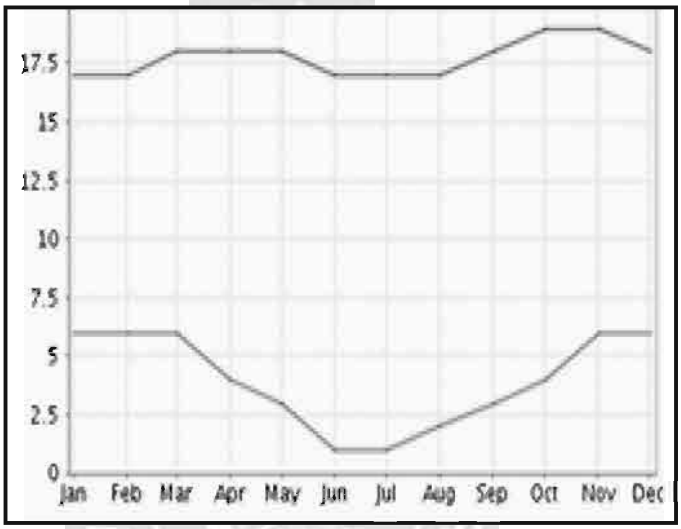

Fuente: [Gonzales et al., 2007]

2.4.1.3 Humedad relativa

La humedad atmosférica es la cantidad de vapor de agua existente en el aire. Depende de la temperatura, de forma que resulta mucho más elevada en las masas de aire caliente que en las de aire frío. Se mide mediante un aparato denominado higrómetro, y se expresa mediante los conceptos de humedad absoluta, específica, o relativa del aire.

La humedad relativa del aire es la relación porcentual entre la cantidad de vapor de agua real que existe en la atmósfera y la máxima que podría contener a idéntica temperatura. La fuente principal de la humedad del aire es la superficie de los océanos, de donde se evapora el agua de forma constante. Pero también contribuyen a su formación los lagos, glaciares, ríos, superficies nevadas, la evapotranspiración del suelo, las plantas y los animales. [Gonzales et al., 2007]

La humedad relativa es el contenido de humedad en el aire (humedad absoluta) relativo a la humedad máxima que puede tener el aire a la temperatura dada.

La humedad relativa (HR) presenta una relación inversa a la temperatura. Esto es así porque al aumentar la temperatura se incrementa la presión de saturación, con lo que la humedad relativa disminuye. Si la temperatura desciende, disminuye también la presión de saturación, reflejando un incremento de la humedad relativa. En consecuencia, los valores máximos de la humedad relativa suelen alcanzarse durante las primeras horas del día, momento en que se registra la temperatura mínima.[[Walhs, 2010]

La humedad relativa en La Paz es de 50% y en el Alto es de 53% según los datos de la INE entre los años 2002 a 2008.

2.4.1.4 Vientos

El sistema de vientos que actúa sobre el área de estudio responde básicamente a la dinámica atmosférica de alcance regional, y en menor proporción, a la dinámica de factores locales.

Debido a la altitud del altiplano, el viento en superficie está referido al nivel de 4 km (~ 620 hPa). En general, los vientos son del oeste. Sin embargo, el relieve modifica el flujo superficial y en el altiplano sur los vientos son básicamente del O y NO, en su sector norte (Salinas G-M y R. Mulatos), del NO y NE en su sector medio, y del N y NE, un poco más hacia el sur. Los vientos N, NO y O alcanzan velocidades de 4 a 12 m s-1 (14,4 a 43,2 km h-1) y son frecuentes en los meses de enero a abril.

Desde el punto de vista agrícola, los vientos más perjudiciales son los de septiembre-octubre, ya que producen el enterrado de las plántulas germinadas de quinua, y los vientos de abril que producen daños a las cosechas. [Gonzales et al., 2007]

Por encima de 5.000 msnm (metros sobre el nivel del mar), los vientos tienden a variar estacionalmente entre el NO y el NE y ya por encima de los 7.000 msnm (atmósfera libre), el flujo se regulariza como del O y NO en primavera, del E y SE en verano y del O y NO en otoño e invierno.[Gonzales et al., 2007]Lo anterior hace suponer que el nivel de 7.000 msnm representa el tope de la capa de fricción sobre el altiplano. El cambio de dirección del viento, en verano, en todos los niveles está asociado con la advección de aire amazónico, que favorece las precipitaciones en esta temporada.

En conclusión se tiene que en verano los vientos soplan de Este con Dirección Oeste, con vientos tibios con velocidades entre 7 y 77 Km./hr., y en Invierno los vientos van de Sudoeste a Este, vientos fríos. [Gonzales et al., 2007]

2.4.1.5 Anomalías Climáticas

En el mundo el 68% de agua de los ríos proviene de los glaciares, la nieve y el hielo que se acumulan en la altura de las montañas, el 20% de los glaciares de América Latina se encuentran en Bolivia, ciertas ciudades de los Andes centrales dependen de un 80% del suministro de agua originaria por las montañas. El impacto que causo el calentamiento global a nivel mundial ya se puede ver en los nevados de Bolivia del Mururata, Chacaltaya, Illampu, HuaynaPotosi y TuniCondoriri. Los nevados son glaciares y están considerados como represas naturales pero, debido al calentamiento global, se están derritiendo y eso hace que exista menor disponibilidad de agua. [Lemuz, 2011]
Con el calentamiento global ya existente, las estaciones de tiempo como verano, otoño, invierno, primavera, no tienen el mismo impacto ya que en verano podemos tener descensos de temperatura como si fuera invierno o precipitaciones pluviales como en temporada de primavera.

2.4.2 POBLACION

El concepto de «población» se utiliza para señalar la agrupación humana pero como elemento componente indeterminado del Estado, ya que se refiere a todos sus habitantes, tengan el carácter o la condición que tuvieren, nacionales, extranjeros, residentes, transeúntes, particulares, funcionarios, etc.,
El crecimiento demográfico en las poblaciones, se debe a los siguientes factores: La tasa de natalidad, la tasa de mortalidad y las migraciones. Las dos primeras, constituyen el crecimiento vegetativo. Es muy raro encontrar estos factores sobretodo en poblaciones rurales, en caso de utilizar los mismos el método desarrollado se conoce con el nombre de crecimiento poblacional por método de las componentes.

El crecimiento poblacional, está íntimamente ligado al tamaño del proyecto y por tanto, al periodo de diseño que se analice. Debido a factores imprevisibles, una población no puede ser extrapolada con seguridad a más de 20 años, pues durante periodos más largos, podrían ocurrir fenómenos de crecimiento que distorsionen en alto grado la magnitud del proyecto que se vaya a adoptar. [UMSS, 2009]

Crecimiento por componentes:

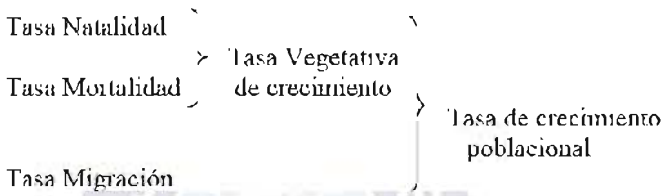

La *Tasa de Crecimiento poblacional*es el aumento (o disminución) de la población por año en un determinado período debido al aumento natural y a la migración neta, expresado como porcentaje de la población del año inicial o base.

La *Tasa Vegetativa de crecimiento*es simplemente los nacimientos menos las defunciones. Si hay más defunciones que nacimientos obtendremos un número negativo, o dicho de otro modo, en lugar de ganar población se pierde.

La *Tasa de Natalidad*es número de niños nacidos vivos en un año, expresado como porcentaje de la población o por cada 1.000 personas; y la tasa bruta de natalidad es el cociente entre el número de nacimientos ocurridos durante un periodo determinado (generalmente un año calendario) y la población media del mismo periodo.

La *Tasa de Mortalidad*es número de defunciones ocurridas en un año, como porcentaje de la población o por cada 1.000 personas; y la tasa bruta de mortalidad es el cociente entre el número de defunciones de todas las edades ocurridas en un periodo determinado (generalmente un año calendario) y la población estimada a mitad del mismo periodo.

La *Tasa de Migración* es el cociente entre el saldo neto migratorio de un periodo (inmigrantes menos emigrantes) y la población estimada a mitad del mismo periodo.

Para proyectar la población, la elección final del método depende, de la experiencia del diseñista y del conocimiento que se tenga acerca de las condiciones Socio-Económicas y características de salud de la población, de esta manera se puede tomar una tasa de crecimiento con diferentes hipótesis, las cuales pueden ser altas, medias y bajas según los datos que se tengan ya sea de la INE, u otra entidad. [UMSS, 2009]

Una estimación Población estimada en la ciudad del 2010 es 2.350.466 con 790.353 habitantes en la ciudad de La Paz y 694.749 habitantes El Alto, con un crecimiento del 1%.[Blondel, 2010]

2.4.3 PRECIO DEL AGUA

Las tarifas del agua son esenciales en la gestión de los abastecimientos y saneamientos urbanos a la hora de sostener elequilibrio económico financiero del servicio, repartir los costes de este servicio entre los consumidores equitativamente y como medio paratransmitir la necesidad de un uso racional y eficiente del agua.

La tarifa del agua urbana, tradicionalmente, se le ha denominado como un precio "político", es decir, un precio subvencionado. [AAPS, 2010]

En la tabla 4 se observa los diferentes tarifas en el consumo de agua según el nivel social y e industrial.

Tabla 5. Estructura de tarifas 2009 – 2010

	categoría					
	valor	domestica			comercial	industrial
nivel	Bs./m3	inicio m3	final m3	inicio m3	final m3	inicio m3
alta	12,9	301		21		1
media	6,9	151	300	1	20	
baja	4,55	31	150			
domestico	2,27	1	30			
vejez	1,82	1	15			
solidaria 110/2007	1,79	1	15			

Fuente: AAPS (Autoridad de Agua Potable y Saneamiento), EPSAS S.A. La Paz 2010

2.4.4 DEMANDA DE AGUA

La demanda de agua, en un sentido convencional, hacereferencia a la necesidad de agua para uno o varios usos, y es, por tanto, la que se manifiesta a los niveles de precio actuales.

En la ciudad de La Paz, la demanda de agua por red de cañería hasta la edificación es de 91.7%; por pileta pública 4.4% y por río, vertiente o acequia 1.4%, veamos la tabla 5, que especifica más en detalle:

Tabla 6. Fuentes de procedencia de agua

DESCRPICCION	LA PAZ
Procedencia del agua	100%
Por cañería hasta la edificación	91,7
Pileta publica	4,4
Pozo o noria privado	0,3
Pozo o noria publico	0,3
Rio, vertiente o acequia	1,4
Carro repartidor	0,3
Agua de lluvia	0,1
Otros	1,5

Fuente:INE (Instituto Nacional de Estadisticas)

El consumo de agua viene dado por:

Consumo doméstico: la demanda suele ser bastante inelástica para subidas no muy considerables del precio. Puede reducirse considerablemente si se dan alzas considerables del precio (también si se adoptan medidas drásticas en épocas de gran escasez) sin que se produzcan graves quiebras del bienestar.

Consumo industrial: la demanda es más elástica, ante aumentos del precio del agua y del coste de depuración, se reduce el consumo industrial a favor del reciclaje.

Consumo agrícola: la demanda es muy elástica. Se ha comprobado que un aumento del precio del 50% reduce el consumo agrícola del agua hasta en un 75%. En la tabla 6 se muestra la poblacion total que cuenta con conexciones a domicilio, tanto domestico y o industrial, y el consumo total de agua que hay entre ambas.

Tabla 7. consumo facturado anual 1998-2010(m3 año) la paz - Bolivia

AÑO	CONSUMO	CONEXIONES ACTIVAS
1998	28,475,487	82,787
1999	31,527,741	90,042
2000	31,623,147	93,221
2001	30,391,432	96,401
2002	30,980,698	99,467
2003	30,498,793	101,653
2004	29,859,773	103,179
2005	28,221,654	105,699
2006	30,614,066	108,418
2007	29,589,422	112,103
2008	30,427,405	114,666
2009	30,141,620	117,051
2010	30,308,983	119,019

Fuente: EPSAS (Empresa Pública, Social de Agua y Saneamiento S.A)

2.4.5 DISPONIBILIDAD DE AGUA

Las poblaciones de La Paz y El Alto cuentan con agua potable merced a un sistema que capta y procesa agua de un conjunto de ríos que drenan los principales nevados de la cordillera oriental ubicados al norte y este de ambas ciudades. Cinco represas almacenan 46.427.000 m3 de agua y 32 pozos de agua subterránea (con capacidad de 262 millones de m3/año), los que sirven para abastecer la demanda de sus casi 10 millones de habitantes (Figura 6). [Lemuz, 2011]

Actualmente las zonas de Caiconi, Villa Fátima, Miraflores Alto, Miraflores Bajo y la Zona Sur de la ciudad de La Paz reciben agua gracias al servicio de las represas de Incachaca, AjuanKhota y Hampaturi, que tienen una capacidad total de almacenaje de 10.853.483 m3 de agua, que es el 23% del total de la capacidad de almacenaje del

sistema, el cual se usa para abastecer la demanda de poco más de 300.000 habitantes (algo más del 30 % de la población de la Ciudad de La Paz). [Lemuz, 2011]

Fig.6 Esquema de captación y distribución de agua potable en la ciudad de La Paz

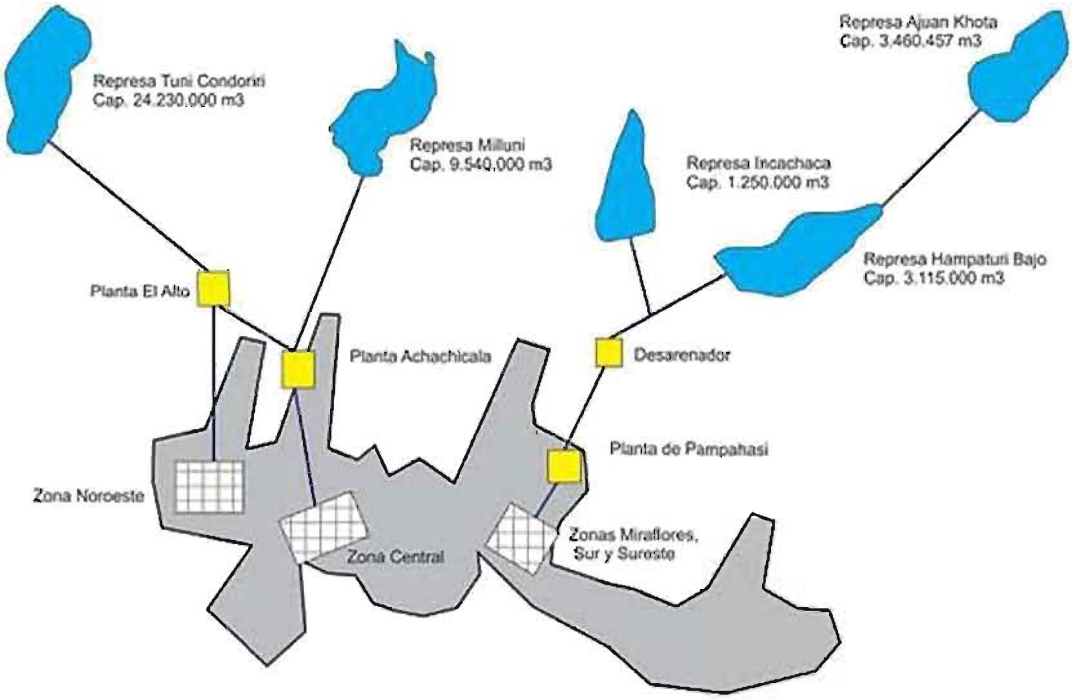

Fuente: [Lemuz, 2011]

Veamos en la siguiente tabla 7, las capacidades y aportes que realizan a la ciudad de La Paz las represas.

Tabla 8. Capacidad en fuentes

Cuenca		Aporte Hm^3/año		Caudal l/s		Ciudad
	Capacidad m3	Año Seco	Año Húmedo	Año Seco	Año Húmedo	
Milluni	9.540.000	11,87	26,71	376	847	La Paz
Incachaca	1.250.000	5,98	13,45	189	426	La Paz
AjuanKhota	3.460.457	8,13	18,3	258	580	La Paz
Hampaturi Bajo	3.115.000	6,26	14,07	198	446	La Paz

Fuente: EPSAS (Empresa Pública, Social de Agua y Saneamiento S.A)

2.5 REDES NEURONALES ARTIFICIAL

2.5.1 DEFINICION

Existen diferentes formas de definir lo que son las redes neuronales, por ejemplo:

"… un sistema de computación hecho por un gran número de elementos simples, elementos de proceso muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas".[Basogai, 2008]

Una red neuronal, según FremanySkapura, es un sistema de procesadores paralelos conectados entre sí en forma de grafo dirigido. 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 ANN (*Artificial Neural Networks*) es su útil comportamiento al aprender, reconocer y aplicar relaciones entre objetos y tramas de objetos propios del mundo real. En este sentido, se utilizan las ANN como unas herramientas que podrá utilizarse para resolver problemas difíciles. [Freeman, 1993]

Las Redes Neuronales Artificiales, ANN están inspiradas en las redes neuronales biológicas del cerebro humano. Están constituidas por elementos que se comportan de forma similar a la neurona biológica en sus funciones más comunes. Estos elementos están organizados de una forma parecida a la que presenta el cerebro humano. [Basogai, 2008]

2.5.2 CARACTERISTICAS DE LAS REDES NEURONALES ARTIFICIALES

Las ANN (*Artificial Neural Networks*) al margen de "parecerse" al cerebro presentan una serie de características propias del cerebro. Por ejemplo las ANN aprenden de la experiencia, generalizan de ejemplos previos a ejemplos nuevos y abstraen las características principales de una serie de datos.

Aprender: adquirir el conocimiento de una cosa por medio del estudio, ejercicio o experiencia. Las ANN pueden cambiar su comportamiento en función del entorno. Se les muestra un conjunto de entradas y ellas mismas se ajustan para producir unas salidas consistentes.

Generaliza: extender o ampliar una cosa. Las ANN generalizan automáticamente debido a su propia estructura y naturaleza. Estas redes pueden ofrecer, dentro de un margen, respuestas correctas a entradas que presentan pequeñas variaciones debido a los efectos de ruido o distorsión.

Abstraer: aislar mentalmente o considerar por separado las cualidades de un objeto. Algunas ANN son capaces de abstraer la esencia de un conjunto de entradas que aparentemente no presentan aspectos comunes o relativos.

2.5.3 REDES NEURONALES BIOLOGICAS

La neurona es la unidad fundamental del sistema nervioso y en particular del cerebro. Cada neurona es una simple unidad procesadora que recibe y combina señales desde y hacia otras neuronas. Si la combinación de entradas es suficientemente fuerte la salida de la neurona se activa. La Figura se muestra las partes que constituyen una neurona. [Basogain, 2008]

El cerebro consiste en uno o varios billones de neuronas densamente interconectadas. Veamos la Fig. 7, donde el axón (salida) de la neurona se ramifica y está conectada a las dendritas (entradas) de otras neuronas a través de uniones llamadas sinapsis. La eficacia de la sinapsis es modificable durante el proceso de aprendizaje de la red.

Fig.7 Red Neuronal Biológica

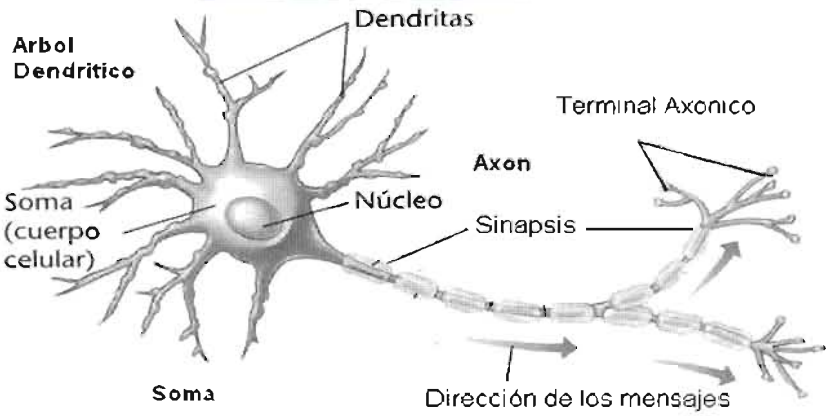

Fuente: [Morgan &Scofield, 1991]

2.5.4 RED NEURONAL ARTIFICIAL

El modelo de una neurona artificial es una imitación del proceso de una neurona biológica, puede también asemejarse a un sumador hecho con un amplificador operacional.

Existen varias formas de nombrar una neurona artificial, es conocida como nodo, neuronodo, celda, unidad o elemento de procesamiento (PE). En la figura 8 se observa una red neuronal artificial en forma general y su similitud con una neurona biológica. [Morgan &Scofield, 1991]

Fig.8 Comparación de una neurona Biológica y Artificial

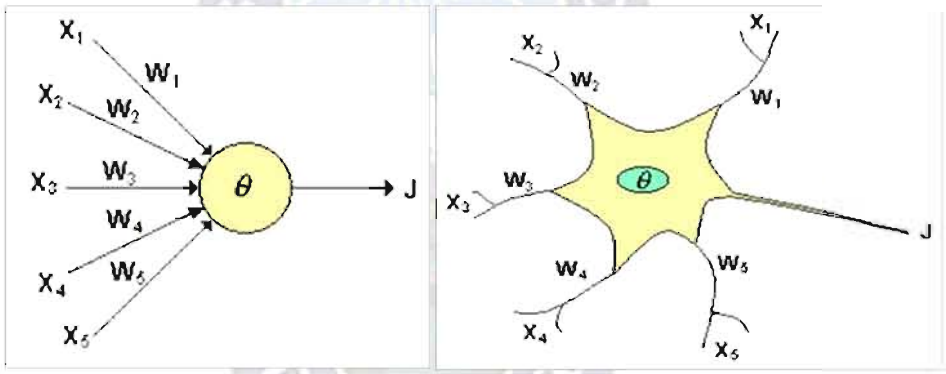

Fuente: [Morgan &Scofield, 1991]

De la observación detallada del proceso biológico se han hallado los siguientes análogos con el sistema artificial:

· Las entradas *Xi* representan las señales que provienen de otras neuronas y que son capturadas por las dendritas.

· Los pesos *Wi*son la intensidad de la sinapsis que conecta dos neuronas; tanto *Xi* como *Wi*son valores reales.

· $\boldsymbol{\theta}$ es la función umbral que la neurona debe sobrepasar para activarse; este proceso ocurre biológicamente en el cuerpo de la célula.

Las señales de entrada a una neurona artificial $\boldsymbol{x_1, x_2, \ldots, x_n}$son variables continuas en lugar de pulsos discretos, como se presentan en una neurona biológica. Cada señal de entrada pasa a través de una ganancia o peso, llamado peso sináptico o fortaleza de la

conexión cuya función es análoga a la de la función sináptica de la neurona biológica. Los pesos pueden ser positivos (excitatorios), o negativos (inhibitorios), el nodo sumatorio acumula todas las señales de entradas multiplicadas por los pesos o ponderadas y las pasa a la salida a través de una función umbral o función de transferencia. La entrada neta a cada unidad puede escribirse de la siguiente manera. [Torres, 2008]

$$h_i(t) = \sum_j w_{ij} x_j$$

El modelo anterior es muy general, por lo que de manera práctica se emplea un modelo estándar más sencillo.

Además, en algunas ocasiones se agrega al conjunto de pesos de la neurona un parámetro adicional θ_i en las unidades de i, llamado umbral quedando el argumento de la función de la siguiente manera:

$$\sum_j w_{ij} x_j - \theta$$

Lo anterior implica agregar un grado de libertad a la neurona. Para el caso de las neuronas el parámetro θ representará el nivel mínimo o umbral que debe alcanzar el potencial pos sináptico para que la neurona se active.

De esta forma, el modelo de la neurona queda:

$$y_i(t) = f\left(\sum_{i=1}^{n} w_{ij} x_j - \theta_i\right)$$

Dónde:

$\boldsymbol{x_j(t)}$ es el conjunto de entradas

$\boldsymbol{w_{ij}}$ son los pesos sinápticos,

$\boldsymbol{h_i(t) = \sum w_{ij} x_j}$ es la regla de propagación

$\boldsymbol{y_i(t) = f_i(h_i(t))}$ es la función de activación que representa tanto la salida de la neurona como su estado de activación.

Con el modelo de la neurona establecido solo es necesario especificar la forma de la función de activación para caracterizarla por completo.

2.5.4.1 Estado de Activación

Una neurona biológica puede estar activa (excitada) o inactiva (no excitada); es decir, que tiene un "*estado de activación*". Las neuronas artificiales también tienen diferentes estados de activación; algunas de ellas solamente dos, al igual que las biológicas, pero otras pueden tomar cualquier valor dentro de un conjunto determinado.

Cada neurona i-ésima, en cualquier instante, está caracterizada por un estado de activación $\boldsymbol{a_i(t)}$, que podemos especificar por un vector de N números reales A (t), que representa el estado de activación del conjunto de neuronas. Por lo tanto, para activación de la unidad $\boldsymbol{U_i}$ en el tiempo *t* se tiene:

$$\boldsymbol{A(t) = (a_1(t), a_2(t), \dots, a_i(t), \dots, a_N(t))}$$

La *función activación* calcula el estado de actividad de una neurona; transformando la entrada global (menos el umbral, $\boldsymbol{\theta_i}$) en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (–1 a 1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o –1) o activa (1).

2.5.4.2 Función de Salida o Transferencia

Esta función determina el estado de activación actual $a_i(t)$ a partir del potencial pos sináptico $h_i(t)$ y del estado de activación anterior $a_i(t\text{-}1)$

$$\boldsymbol{a_i(t) = f_i(a_i(t-1), h_i(t))}$$

Aunque en muchos modelos sólo se considera su estado actual, la función se expresa como sigue:

$$\boldsymbol{a_i(t) = f_i(h_i(t))}$$

Entre las neuronas que componen la red, existen conexiones que las unen. Cada una envía una señal de respuesta mediante una función de salida$\boldsymbol{f_i(a_i(t))}$, y es enviada a través de canales de comunicación a otras unidades de la red, que transforman el estado actual de activación $\boldsymbol{a_i(t)}$, en una señal de salida $\boldsymbol{y_i(t)}$, es decir:

$$\boldsymbol{y_i(t) = f_i(a_i(t))}$$

La tabla 9 muestra las funciones de transferencia típicas que suelen utilizarse son:

Tabla 9. Funciones de transferencia

	FUNCION	RANGO	GRAFICA
Identidad	$y = x$	$[-\infty, +\infty]$	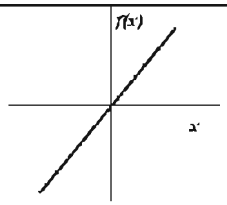
Escalón	$y = sing\ (x)$ $y = H(x)$	$[-1, +1]$ $[0, +1]$	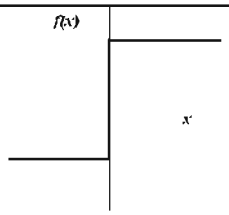
Lineal a Tramos	$y = \begin{cases} -1, si\ x < -1 \\ x, si + 1 \leq x \leq -1 \\ +1, si\ x > +1 \end{cases}$	$[-1, +1]$	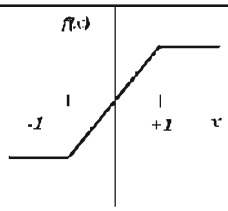
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = tgh(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}}$	$[0, +1]$ $[-1, +1]$	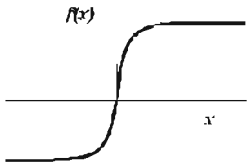
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	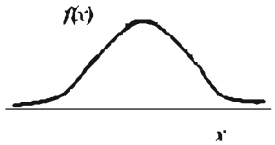
Sinusoideal	$y = Asen(wx + \varphi)$	$[-1, +1]$	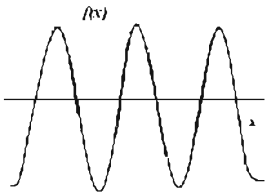

Fuente: [Hilera & Martínez, 1995]

2.5.5 TOPOLOGIA DE LAS REDES NEURONALES

La topología o arquitectura de una red neuronal consiste en la organización y disposición de las neuronas en la misma, formando capas o agrupaciones de neuronas más o menos alejadas de la entrada y salida de dicha red. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas. [Matich, 2001]

Se distinguen tres tipos de capas: de entrada, de salida y ocultas. Una capa de entrada, también denominada sensorial, está compuesta por neuronas que reciben datos o señales procedentes del entorno. Una capa de salida se compone de neuronas que proporcionan la respuesta de la red neuronal. Una capa oculta no tiene una conexión directa con el entorno, es decir, no se conecta directamente ni a órganos sensores ni a efectores. Este tipo de capa oculta proporciona grados de libertad a la red neuronal gracias a los cuales es capaz de representar más fehacientemente determinadas características del entorno que trata de modelar. [Larrañaga et al, 2002]

Fig.9 Redes neuronales

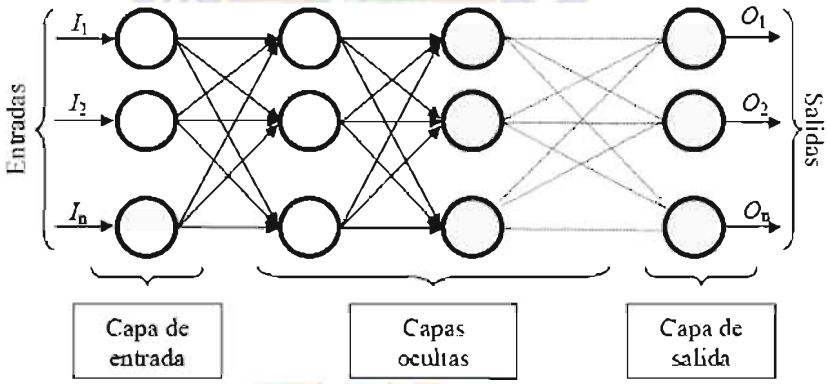

Fuente: [Larrañaga et al, 2002]

Teniendo en cuenta diversos conceptos se pueden establecer diferentes tipos de arquitecturas neuronales. Así considerando su estructura podemos hablar de:

2.5.5.1 Redes Mono Capa

En las redes mono capa, se establecen conexiones entre las neuronas que pertenecen a la única capa que constituye la red. Las redes mono capas se utilizan generalmente en

tareas relacionadas, con lo que se conoce como auto asociación (regenerar información de entrada que se presenta a la red de forma incompleta o distorsionada).

La red más simple es un grupo de neuronas ordenadas en una capa como se muestra en la Figura 10. Los nodos circulares sólo son distribuidores de las entradas y no se consideran constituyentes de una capa.

Fig.10 Redes neuronales mono capa

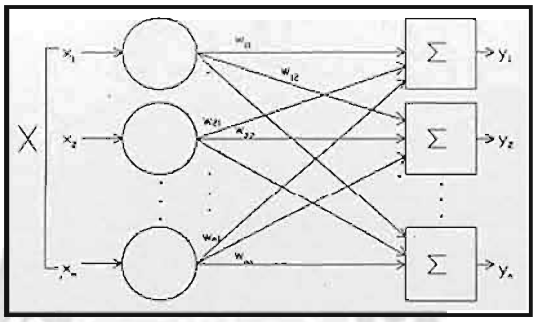

Fuente: [Larrañaga et al, 2002]

Cada una de las entradas está conectada a través de su peso correspondiente a cada neurona artificial. En la práctica existen conexiones eliminadas e incluso conexiones entre las salidas y entradas de las neuronas de una capa. No obstante la figura muestra una conectividad total por razones de generalización.

2.5.5.2 Redes Multicapa

Las redes multicapa se forman con un grupo de capas simples en cascada. La salida de una capa es la entrada de la siguiente capa. Se ha demostrado que las redes multicapa presentan cualidades y aspectos por encima de las redes de una capa simple. La Figura 11 muestra una red de dos capas.

Fig.11 Redes Multicapa

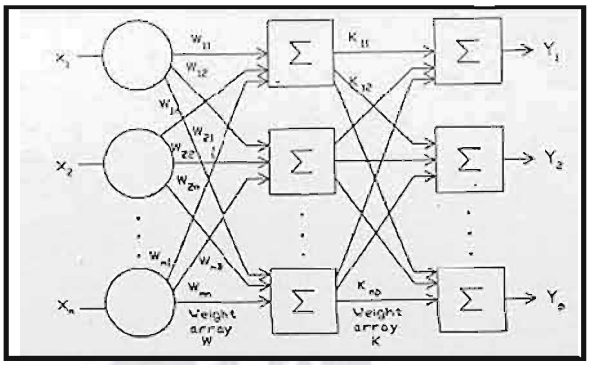

Fuente: [Larrañaga et al, 2002]

Las redes multicapas son aquellas que disponen de un conjunto de neuronas agrupadas en varios (2, 3, etc.) 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.

2.5.6 CONEXIÓN DE REDES

2.5.6.1 Redes con conexión hacia adelante

Normalmente, todas las neuronas de una capa reciben señales de entrada desde otra capa anterior (la cual está más cerca a la entrada de la red), y envían señales de salida a una capa posterior (que está más cerca a la salida de la red). A estas conexiones se las denomina *conexiones hacia adelante o feedforward.*

En las redes con conexión hacia adelante, todas las señales neuronales se propagan hacia adelante a través de las capas de red. No existen conexiones hacia atrás y normalmente tampoco autor recurrentes, ni laterales, excepto en el caso de los modelos de red propuestos por Kohonen. [Hilera & Martínez, 1995]

2.5.6.2 Redes con conexión hacia atrás

En un gran número de las redes también existe la posibilidad de conectar la salida de las neuronas de capas posteriores a la entrada de capas anteriores; a estas conexiones se las denomina *conexiones hacia atrás o feedback.*

2.5.6.3 Redes con conexión hacia adelante y atrás

En este tipo de redes la información circula tanto hacia adelante como hacia atrás durante el funcionamiento de la red. Para que esto sea posible, existen conexiones tanto hacia adelante como hacia atrás entre las neuronas [Hilera & Martínez, 1995]

2.5.7 MECANISMO DE APRENDISAJE

Las NNA están concebidas para presentar características análogas a las del funcionamiento del cerebro humano. La capacidad de aprender es una de las características de la red neuronal que la diferencian de la programación tradicional y que imita, de forma semejante y en pequeña escala, el funcionamiento del cerebro. Son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. [Daza, 2008]

En el proceso de aprendizaje de las NNA, se ajustan los parámetros libres de la red a partir de un proceso de interacción con el entorno que rodea la red, es de carácter secuencial y adaptativo, de tal manera, que la red adquiere conocimiento continuamente, como resultado de la acumulación de experiencias ocurridas, similar al proceso de aprendizaje del cerebro humano en lo que se refiere a considerar los errores pasados. [Daza, 2008]

El objetivo del entrenamiento de una ANN es conseguir que una aplicación determinada, para un conjunto de entradas produzca el conjunto de salidas deseadas o mínimamente consistentes. El proceso de entrenamiento consiste en la aplicación secuencial de diferentes conjuntos o vectores de entrada para que se ajusten los pesos de las interconexiones según un procedimiento predeterminado. Durante la sesión de entrenamiento los pesos convergen gradualmente hacia los valores que hacen que cada entrada produzca el vector de salida deseado.

Los algoritmos de entrenamiento o los procedimientos de ajuste de los valores de las conexiones de las ANN se pueden clasificar en dos grupos: Supervisado y No Supervisado.

2.5.7.1 APRENDIZAJE SUPERVISADO

En este caso, los patrones para el aprendizaje están formados por parejas, que constan de un vector de variables de entrada, junto con las salidas correspondientes. Por tanto cada valor de salida es la respuesta deseada a las señales de entrada. En este caso, los pesos se obtienen minimizando alguna función de error que mide la diferencia entre los valores de salida deseados y los calculados por la red neuronal. En este tipo de aprendizaje se debe tener en cuenta el problema de la convergencia del error. En general, la función de error resultante puede contener múltiples mínimos locales y, por lo tanto, el proceso de aprendizaje puede no converger al mínimo global óptimo. [Basogain, 2008]

El aprendizaje supervisado se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) 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. [Matich, 2001]

En este tipo de aprendizaje se suelen considerar, a su vez, tres formas de llevarlo a cabo, que dan lugar a los siguientes aprendizajes supervisados:

2.5.7.1.1 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.

2.5.7.1.2 Aprendizaje por refuerzo.

Se trata de un aprendizaje supervisado, más lento que el anterior, que se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada.

2.5.7.1.3 Aprendizaje estocástico.

Consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

2.5.7.2 APRENDIZAJE NO SUPERVISADO

Aprendizaje no supervisado: En este caso, los datos se presentan a la red sin información externa, y la red tiene que descubrir por sí misma patrones o categorías. Este tipo de aprendizaje se encuadra dentro de las técnicas auto organizativas, o técnicas automáticas para descubrir la estructura de datos. Algunos métodos de aprendizaje no supervisado son:

2.5.7.2.1 Aprendizaje Hebbiano

Consiste en modificar los pesos de acuerdo con algún criterio de correlación entre las actividades neuronales,

2.5.7.2.2 Aprendizaje competitivo

Neuronas diferentes se conectan con pesos negativos (inhibitorios) que fuerzan una competición para ganar la actividad neuronal, y.

2.5.7.2.3Representación de características

Que concierne a la ordenación geométrica de los vectores peso de las unidades competitivas.

Los datos del aprendizaje no supervisado pueden contener valores de entrada y valores de salida pero, en contraposición al aprendizaje supervisado, no hay información acerca de que salidas corresponden a cada una de las entradas de los datos. [López, 2003]

2.5.8 PERCEPTRON SIMPLE

El perceptron simple o perceptron es el de tipo red neuronal más sencillo que se puede implementar. Este tipo de red solo sirve para clasificar los elementos pertenecientes a dos clases linealmente separables.

El perceptron simple fue introducido por Rosenblatt (1962) y es un modelo unidireccional compuesto por dos capas de neuronas, una de entrada y otra de salida. La operación en un perceptron simple que consta de n neuronas de entrada y m neuronas de salida se puede expresar como:

$$y_i = f(\sum_{j=1}^{n} w_{ij} x_j - \theta_i)$$

Con $i = 1, \ldots, m$.

Las neuronas de entrada son discretas y la función de activación de las neuronas de la capa de salida es de tipo escalón.

2.5.9 PERCEPTRON MULTI CAPA

Además de una capa de entrada y una de salida, un perceptrónmulti-capa tiene capas intermedias ocultas. Los nodos de la capa de entrada alimentan la red distribuyendo hacia delante las señales de entrada. Cada nodo en las capas ocultas y de salida recibe una entrada de los nodos de las capas previas y calcula un valor de salida para la siguiente capa.

La adición de capas ocultas proporciona a este tipo de arquitectura suficiente flexibilidad para resolver muchos problemas en los que los perceptrones simples fallan.

El perceptron multicapa está compuesto por varias capas de neuronas entre la entrada y salida de la red. En general, el número de capas deberá ser lo suficiente grande como para que se forme una región compleja para la solución del problema, Esta arquitectura suele entrenarse mediante el algoritmo denominado retro propagación de errores a la cual denominaremos red de retro propagación.

2.5.10 REDES DE PROPAGACION HACIA ATRAS (BACKPROPAGATION).

El concepto básico de Backpropagation fue presentado en 1974 por Paul Werbos e independientemente reinventado por David Parker en 1982, y también presentado en 1986 por Rumelhart, Hinton y Willians. La duplicidad de esfuerzos y trabajos es frecuente en cualquier disciplina, y más en el mundo de las ANN debido a su naturaleza interdisciplinaria. [Basogain, 2008]

El nombre de backpropagation resulta de la forma en que el error es propagado hacia atrás a través de la red neuronal, en otras palabras el error se propaga hacia atrás desde la capa de salida. Esto permite que los pesos sobre las conexiones de las neuronas ubicadas en las capas ocultas cambien durante el entrenamiento.

El cambio de los pesos en las conexiones de las neuronas además de influir sobre la entrada global, influye en la activación y por consiguiente en la salida de una neurona. Por lo tanto, es de gran utilidad considerar las variaciones de la función activación al

modificarse el valor de los pesos. Esto se llama *sensibilidad* de la función activación, de acuerdo al cambio en los pesos.

2.5.11 ALGORITMO DE ENTRENAMIENTO

Las redes Backpropagation tienen un método de entrenamiento supervisado. A la red se le presenta parejas de patrones, un patrón de entrada emparejado con un patrón de salida deseada. Por cada presentación los pesos son ajustados de forma que disminuya el error entre la salida deseada y la respuesta de la red.

El algoritmo de aprendizaje backpropagation conlleva una fase de propagación hacia adelante y otra fase de propagación hacia atrás. Ambas fases se realizan por cada patrón presentado en la sesión de entrenamiento.

El algoritmo consiste de dos fases, llamadas: 1) pasó hacia delante, y 2) pasó hacia atrás.

Bajo el algoritmo de aprendizaje, se proponen *k* ejemplos de la población para entrenar a la red. Cada ejemplo propuesto de la población puede ser definido exactamente por un vector de entrada $[X_i^l = (x_{i1}, x_2, \dots, x_{im}), 1 \leq i \leq k, 1 \leq l \leq m]$y por un vector de salida actual o deseada $[Z_i^l = (z_{i1}, z_2, \dots, z_{in}), 1 \leq i \leq k, 1 \leq l \leq n]$. En este caso, *m* representa el número de entradas que explican el *k*-ésimo ejemplo.

2.5.11.1 Propagación hacia adelante

Bajo la propagación hacia delante (paso 1), el vector de entrada alimenta la capa de entrada para producir un vector de salida llamado $[Y_i^l = (y_{i1}, y_2, \dots, y_{im}), \forall \omega_{ij}, 1 \leq i \leq k, 1 \leq l \leq n]$. Las funciones de salida estimada y actual se comparan para calcular el error cuadrático para cada unidad de salida en el sistema, por ejemplo,

$[e_i^l = (y_{i1} - z_{ij})^2, \forall \omega_{ij}, 1 \leq i \leq k, 1 \leq l \leq n]$.

Sumando las diferencias de las salidas individuales, se genera una función *E* de error, descrita de la siguiente manera:

$$E = \sum_{i=1}^{k} \sum_{j=1}^{n} e_{ij}^2 = \frac{1}{2} \sum_{i=1}^{k} \sum_{j=1}^{n} (y_{ij} - z_{ij})^2$$

El objetivo es entonces minimizar la función de error *E*, cambiando apropiadamente y a través de ejemplos los pesos, de manera que todos los vectores de entrada estén correctamente mapeados con su correspondiente vector de salida. Por lo tanto, la función objetivo se define como:

$$Minimizar\{E\} \in W_i^j, \forall X_i^l, Y_i^j$$

2.5.11.2 Propagación hacia Atrás

En el paso 2 (propagación hacia atrás), la dirección y magnitud del cambio de los pesos se calcula para localizar la solución óptima. En otras palabras, el error cuadrático total del paso 1 se calcula y se propaga hacia atrás, capa por capa, de las unidades de salida a las unidades de entrada para lograr la convergencia de la función de error E. La dirección y magnitud del cambio en los pesos se calcula como:

$$\Delta\omega_{ij} = \frac{\partial E}{\partial \omega_{ij}}\varepsilon, 0 < \varepsilon < 1$$

Donde, ε representa la convergencia del algoritmo bajo iteraciones sucesivas (capas). El término ε es la tasa de aprendizaje que determina el tamaño del paso que es utilizado para moverse hacia el mínimo de E. Valores de ε demasiado grandes conducen a oscilaciones alrededor del mínimo, mientras que valores demasiado pequeños pueden conducir a una lenta convergencia de la red.

Los ajustes en los pesos se determinan por la forma en que ocurre la propagación en cada nivel. Para todas las funciones continuas y diferenciables I_i, O_iy E, el valor del cambio en los pesos $[\frac{\partial E}{\partial \omega_{ij}}]$ en cada nivel se calcula como:

$$\Delta\omega_{ij} = \frac{\partial E}{\partial \omega_{ij}} = \left(\frac{\partial E}{\partial O_i}\right)\left(\frac{\partial O_i}{\partial I_i}\right)\left(\frac{\partial I_i}{\partial \omega_{ij}}\right)$$

En este proceso, el peso del vector W, se actualiza para cada par entrada-salida $[X_i, Z_i]$ para cada ejemplo, o se acumula el cambio de los pesos $[\omega_{ij}]$ para todos los ejemplos y se actualizan al final de cada iteración. Estos dos pasos se ejecutan en iteraciones sucesivas del algoritmo de propagación hacia atrás hasta que la función de error E, converge al nivel deseado, produciendo en consecuencia la solución óptima.

Hilera y Martínez presentan de manera sucinta los pasos y las formulas necesarias para aplicar el algoritmo de entrenamiento de una red neuronal, veamos los pasos a seguir en las figura 12 que se presentan:

Fig. 12 Pasos y fórmulas para aplicar el algoritmo de aprendizaje

Proponer la arquitectura de la red: # de neuronas de entrada, # capas ocultas y neuronas en cada capa, # de salidas

↓

Inicializar los pesos de la red con valores pequeños aleatorios

↓

Presentar los vectores (matrices) de entrada y de salida

Entrada: $E_1, E_2, E_3, \ldots\ldots E_n$
Salida: $S_1, S_2, S_3, \ldots\ldots S_n$

↓

Se calcula la salida actual de la red. Para lo cual se presentan las entradas a la red y se va calculando la salida que presenta la neurona en cada capa hasta llegar a la salida.

1. Se calculan las entradas netas para las neuronas ocultas procedentes de las neuronas de entrada:

Para una neurona *j* oculta: $net_{pj}^{h} = \sum_{i=1}^{h} w_{ji}^{h} x_{pi} + \theta_j^h$, donde h se refiere a la capa oculta, *p* al p-ésimo vector de entrenamiento y *j* a la *j*-ésima neurona oculta. El término θ es opcional (bias)

2. Se calculan las salidas de las neuronas ocultas: $y_{pj} = f_j^h(net_{pj}^h)$
3. Se realizan los mismos cálculos para obtener las salidas de las neuronas de salida

$$net_{pk}^{o} = \sum_{i=1}^{L} w_{kj}^{o} x_{pj} + \theta_k^o$$

$$y_{pk} = f_k^o(net_{pk}^o)$$

↓

Se calculan los términos de error para todas las neuronas. Si la neurona *k* es una neurona de salida, el valor del error será: $\delta^{o}_{pk} = (S_{pk} - y_{pk}) f'^{o}_{k}(net^{o}_{pk})$

La función *f*, debe cumplir el requisito de ser derivable (lineal, tangencial, sigmoidal), la sigmoidal por ejemplo se representa por la expresión:

$$f_k(net_{jk}) = \frac{1}{1 + e^{-net_{jk}}}$$

Si la neurona j no es de salida, entonces la derivada parcial del error no puede ser evaluada directamente. Por tanto, se obtiene a partir de valores conocidos y otros que pueden ser evaluados: $\delta^{h}_{pj} = f'^{h}_{j}(net^{h}_{pj}) \sum_{k} \delta^{o}_{pk} w^{o}_{kj}$

Para actualizar los pesos se usa un algoritmo recursivo, comenzando por las neuronas de salida y trabajando hacia atrás hasta llegar a la entrada, ajustando los pesos de la siguiente forma:

$$w^{o}_{kj}(t+1) = w^{o}_{kj}(t) + \Delta w^{o}_{kj}(t+1)$$

$$\Delta w^{o}_{kj}(t+1) = \alpha \delta^{o}_{pk} y_{pj}$$

Para las neuronas de la capa oculta:

$$w^{h}_{ji}(t+1) = w^{h}_{ji}(t) + \Delta w^{h}_{ji}(t+1)$$

$$\Delta w^{h}_{ji}(t+1) = \alpha \delta^{h}_{pj} y_{pi}$$

Para acelerar el proceso de aprendizaje, se puede añadir un término momento

El error en las capas ocultas depende de todos los términos de error de las capas de salida. De ahí el término back-propagation.

El proceso se repite hasta que el error esta por debajo o es menor que un valor previamente definido

Fuente: [Lizarrazo, 2006]

2.5.12 APLICACIONES DE LAS REDES NEURONALES ARTIFICIALES

Las características especiales de los sistemas de computación neuronal permiten que sea utilizada esta nueva técnica de cálculo en una extensa variedad de aplicaciones.

La computación neuronal provee un acercamiento mayor al reconocimiento y percepción humana que los métodos tradicionales de cálculo. Las redes neuronales artificiales presentan resultados razonables en aplicaciones donde las entradas presentan ruido o las entradas están incompletas. Algunas de las áreas de aplicación de las RNA son las siguientes:

Compresión de Imágenes: la compresión de imágenes es la transformación de los datos de una imagen a una representación diferente que requiera menos memoria o que se pueda reconstruir una imagen imperceptible. Cottrel, Munro y Zisper de la Universidad de San Diego y Pisttburgh han diseñado un sistema de compresión de imágenes utilizando una red neuronal con un factor de compresión de [8-1].

Reconocimiento de Caracteres: es el proceso de interpretación visual y de clasificación de símbolos. Los investigadores de Néstor, Inc. han desarrollado un sistema de computación neuronal que tras el entrenamiento con un conjunto de tipos de caracteres de letras, es capaz de interpretar un tipo de carácter o letra que no haya visto con anterioridad.

Reconocimiento de Patrones en Imágenes: una aplicación típica es la clasificación de objetivos detectados por un sonar. Existen varias ANN basadas en la popular Backpropagation cuyo comportamiento es comparable con el de los operadores humanos. Otra aplicación normal es la inspección industrial.

Predicción: en el mundo real existen muchos fenómenos de los que conocemos su comportamiento a través de una serie temporal de datos o valores. Lapedes y Farber del Laboratorio de Investigación de los Álamos, han demostrado que la red backpropagation supera en un orden de magnitud a los métodos de predicción polinómicos y lineales convencionales para las series temporales caóticas.

Predicción: en el mundo real existen muchos fenómenos de los que conocemos su comportamiento a través de una serie temporal de datos o valores. Lapedes y Farber del Laboratorio de Investigación de los Álamos, han demostrado que la red

backpropagationsupera en un orden de magnitud a los métodos de predicción polinómicos y lineales convencionales para las series temporales caóticas.

2.5.13 REDES NEURONALES UTILIZADAS EN LA PREDICCION

A diferencia de los enfoques tradicionales de análisis de series temporales y las previsiones, las redes neuronales artificiales necesitan una cantidad reducida de la información para pronosticar el futuro de los datos de series de tiempo. En base de los datos disponibles de la serie de tiempo, los parámetros de la red internamente son sintonizados usando un algoritmo de ajuste apropiado. Puede ser necesario incluir también la modificación de la arquitectura de red elegida inicialmente para adecuarse mejor a la arquitectura requerida por el problema planteado. [Daza, 2008]

2.5.14 METODOLOGIA PARA LA PREDICCION CON REDES NEURONALES

La metodología para la predicción es generalmente entendida como un conjunto de enfoques, métodos y herramientas para recopilación de datos de series de tiempo que se utilizan para la previsión o predicción de los futuros valores de las series de tiempo, en base a los valores pasados. La metodología para la previsión incluye las siguientes etapas según Palit y Popovic:

a) **Preparación de los datos**

Para el pronóstico, es decir la adquisición, estructuración, normalización y la división de los datos pasos que se detallan a continuación:

Estructuración de los datos. Se debe obtener el par (entrada, salida deseada), es decir se obtendrá la siguiente ecuación:

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

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 será numero de patrones de la muestra, Δ será el intervalo entre los valores de la serie de tiempo y $x(t)$ será el valor de la serie de tiempo en un instante t.

Normalización de los datos. La preparación de los datos incluye limpiar y transformar los datos. El objetivo es quitar el ruido, las inconsistencias de la resolución, y acentuar las relaciones importantes en las variables de la 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 demasiados pequeños, Los valores pequeños tienen una contribución baja a la varianza general; y estos predisponen a otros patrones con valores más altos. La normalización de los datos es necesaria ya que los datos suelen ser ruidosos e incompletos, lo que le impide a la red neuronal artificial enfocar la información importante y de esta manera obtener los patrones normalizados, con media igual a cero y una desviación estándar igual a 1, esto mediante la ecuación:

$$\overline{x}_i = \frac{1}{N}\sum_{n=1}^{N} X_i^n = 0$$

$$\sigma_i^2 = \frac{1}{N-1}\sum_{n=1}^{N} (x_i^n - \overline{x}_i)^2 = 1$$

$$\tilde{x}_i^n = \frac{x_i^n - \overline{x}_i}{\sigma_i}$$

También se puede hacer uso de la siguiente del método de máximos y mínimos que está dado por:

$$X_j = \frac{X_i - X_{min}}{X_{max} - X_{min}}$$

Dónde:

X_j ***dato normalizado***

X_i ***dato original***

X_{max} ***es el dato mas grade de la serie***

X_{min} ***es el dato mas pequeño de la serie***

División de los datos. En la práctica es común dividir la serie de tiempo en tres distintos conjuntos: entrenamiento, prueba y validación (fuera de la muestra). El conjunto de entrenamiento es la más grande y se usa para que la red neuronal pueda aprender el modelo que presentan los datos. 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 entrenada. El conjunto de validación debe consistir en las más recientes observaciones contiguas. Se debe tener el cuidado para no usar el conjunto de validaciones como conjunto de prueba.

b) Determinación de la arquitectura de la red

Es decir, la selección del tipo de red que se utiliza para predicción, la determinación del número de nodos de entrada y salida de la red, numero de capas, el número de neuronas dentro de las capas, determinación de las intersecciones entre las neuronas, la selección de la función de activación de las neuronas, entre otras.

En un modelo neuronal estándar para realizar la predicción de una serie de tiempo se debe usar un juego de d-tuplas como entradas y un solo valor designado a la salida de la red. La estructura a nivel macro del modelo predictivo es ilustrado en la fig.13, en el cual se observa un conjunto de d-tuplas como variables predictivas $[x(t-d),...x(t-1),x(t)]$ y una salida $[x(t+1)]$, como variable predicha. [Larrañaga et al, 2002]

Fig.13 modelo macro

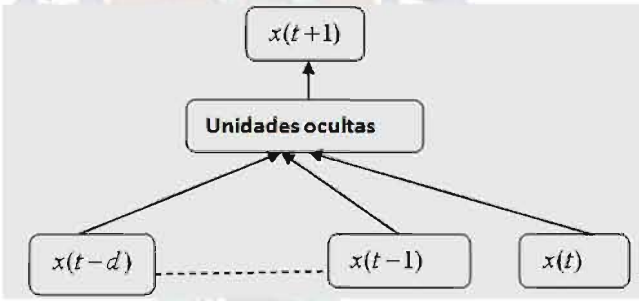

Fuente: [Larrañaga et al, 2002]

c) Diseño de la estrategia de aprendizaje o entrenamiento de la red

Es decir, la selección del algoritmo de aprendizaje, el índice de rendimiento, la capacitación y la supervisión. El entrenamiento de la red neuronal es un proceso en 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 mismos durante el entrenamiento de la red, haciendo que la red pueda lograr la generalización más alta.

d) Evaluación global

De los resultados de la predicción mediante la utilización de nuevos conjuntos de datos de observación.

El entrenamiento de la red puede requerir de repetidos ensayos de entrenamiento con varios valores de peso iníciales. Después de cada corrida de entrenamiento los resultados de la misma tienen que ser evaluados y comparados con los resultados logrados en las corridas anteriores, en orden para seleccionar la mejor corrida.

2.5.15 COMBINACION DE LAS REDES NEURONALES Y LOGICA DIFUSA

La razón más importante para combinar los sistemas difusos con las redes neuronales es la capacidad de aprendizaje pues tales combinaciones son capaces de aprender reglas lingüísticas y/o funciones de pertenencia, o de optimizar las ya existentes. Aprender, en este caso significa crear una base de reglas o funciones de pertenencia de improvisaciones basadas en el entrenamiento de datos presentados como un problema de aprendizaje fijo o libre.

Combinar la lógica difusa y las redes neuronales puede aliviar los problemas asociados con cada uno de estos paradigmas. Un análisis revela que las desventajas de disco paradigmas parecen complementarias y por lo tanto, es natural considerar construir un sistema combinando ambos enfoques. Mientras que las capacidades de aprendizaje es una ventaja desde el punto de vista del sistema difuso, la formación automática de reglas lingüísticas será la ventaja desde el punto de vista de la red neuronal. [Baron, 1998]

2.6CONJUNTOSDIFUSOS

Preferencia, similitud, vaguedad, incertidumbre, imprecisión o posibilidad son algunos de los términos que caracterizan el conocer y razonar humano, y que resultan determinantes en aquellas situaciones en las que la información disponible es incompleta. La progresiva automatización de tareas que incorporan información procedente de la descripción realizada por un ser humano, habitualmente mediante el lenguaje, nos demandan modelar algunas de las características indicadas.

El punto de partida en la lógica clásica o difusa tiene su origen en las proposiciones elementales que están dentro de la *lógica proposicional,* cada proposición elemental corresponde a una frase simple del lenguaje natural, como ser "el teléfono móvil de Carla es de última tecnología", "la planificación es punto inicial en cualquier proyecto", "el diseño de la interfaz gráfica tiene una duración de 10 días", son oraciones declarativas que son verdaderas o falsas en el contexto de la lógica clásica sin embargo la lógica difusa trata de evaluar el valor de veracidad de estas proposiciones entre lo verdadero y el falso, tomando como ejemplo la última proposición, existe la posibilidad que la duración de una actividad sufra variaciones a lo planificado, entonces ésta situación conlleva a la redefinición de la proposición de la forma: "el diseño de la interfaz gráfica tiene una duración de más o menos 10 días", ante este tipo de proposiciones la lógica clásica como la lógica n-valuada quedan cortas en su tratamiento.

Analizando algunos aspectos relevantes entre la lógica clásica y difusa se tiene lo siguiente:

Sea p una proposición, en la lógica clásica el valor de verdad de p es cero o uno, es decir $v(p) \in \{0,1\}$.

Sea p una proposición, en la lógica difusa el valor de verdad de p están entre el cero y el uno, es decir $v(p) \in [0,1]$.

Los valores de verdad de p que tienden a uno indican que la proposición p es más verdadera en la lógica difusa.

En la lógica de predicados dado un conjunto no vacío X denominado conjunto universal o universo del discurso, cada predicado unitario P se define como una función que asigna a cada elemento x una propiedad, atributo o relación entre elementos de X dado por la proposición de la forma $P(x)$="x es p", por ejemplo sea el conjunto universo X, conjunto de colores de ojos de personas y sea el predicado P ="ojos azules", entonces el predicado al asignar a un elemento (persona) llámese "Carla" genera la proposición "Carla es de ojos azules", prestando atención a este singular proceder el predicado P ha generado implícitamente un conjunto A de personas de ojos azules. Indicar que un predicado preciso P es aquel que origina proposiciones $P(x)$ precisas, en tanto que un predicado impreciso generará proposiciones imprecisas.

Del análisis de la exposición anterior se llega a las siguientes conclusiones:

- Los conjuntos difusos son originados por predicados difusos, también indicar que todo predicado induce un subconjunto y todo subconjunto induce un predicado, estos conjuntos son estructurados con una visión particular a alcanzar.
- Los predicados precisos dan lugar a conjuntos clásicos, en los que un elemento o pertenece completamente al conjunto o no pertenece en absoluto, mientras que los predicados imprecisos dan lugar a conjuntos difusos, en los que el grado de veracidad de un elemento varia dentro del intervalo [0,1].

Para dar más claridad a este asunto veamos el siguiente ejemplo. Sea $X_{[0,10]}$ un conjunto de números reales entre el 0 y 10 universo de discurso y el predicado P ="intervalo 5 y 8" que a su vez define al conjunto A subconjunto de X con aquellos números enteros entre 5 y 8 representados en la figura 14.

Fig. 14 Conjunto clásico, $X = [0,10], A = [5,8]$ donde $A \subseteq X$

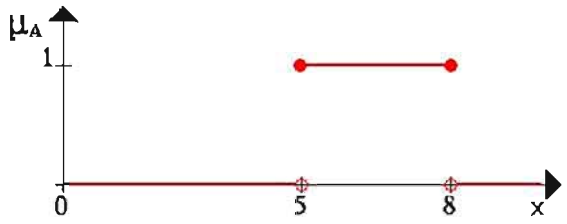

Fuente: [Bonissone, 1980]

La correspondiente interpretación del gráfico es que se asigna el valor de *uno* a aquellos elementos que están en el conjunto A o *cero* para los que no están, es decir se restringe en valores absolutos; empero en los conjunto difusos los elementos son evaluados de la pertenencia o no pertenencia a un conjunto de acuerdo a grados.

Para una mejor interpretación de los conjuntos difusos se la puede representar mediante gráficos como la función triangular, función gamma, función S, función gaussiana, función trapezoidal, eligiendo de éstas la función que mejor represente la incertidumbre para un concepto dado. De acuerdo a la línea investigativa del trabajo en la aplicación de conjuntos difusos se utilizará la función triangular, para el tratamiento de la incertidumbre en valores de tiempos, así la función triangular es representada por la figura 15.

Fig.15 Función triangular $A(x;a,m,b)$

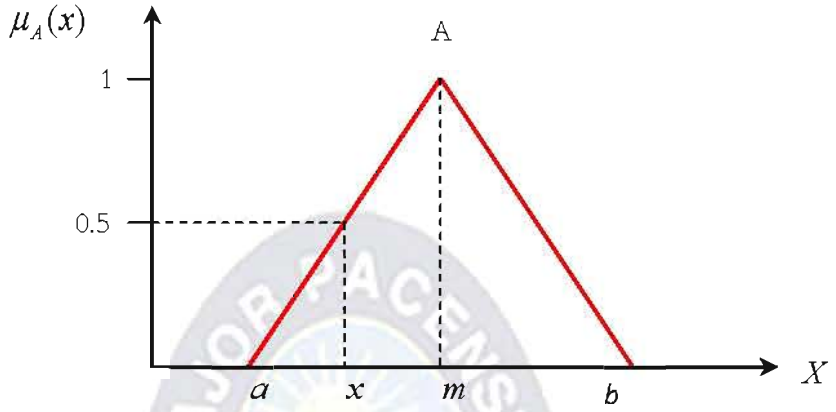

Fuente: [Choque, 2002]

La función triangular está compuesta por tres números como es (a,m,b), en la cuál m es el valor exacto a alcanzar por los dos extremos denotado por a y b, significa que m presenta una variación en el intervalo $[a,b]$, ésta función triangular es seleccionado por que se ajusta adecuadamente para el tratamiento de la variabilidad de las duraciones de tiempo en las actividades.

2.6.1 FUNCIÓN CARACTERÍSTICA

La función característica es una forma de especificar un conjunto en términos de funciones algebraicas. La función característica de un conjunto nítido se la desarrolla de la siguiente manera: sea una función $\mu : X \to \{0,1\}$, algunos elementos de X tomarán el valor 1 mientras que otros tomarán el valor 0. Los primeros forman un subconjunto A definido como $A = \{x \in X \mid \mu(x) = 1\}$, recíprocamente todo subconjunto nítido A define una función $\mu_A : X \to \{0,1\}$, denominada función característica, que toma el valor 1 para los elementos que pertenecen a A y 0 para los que no pertenecen, descritas formalmente por:

$$\mu_A(x) = \begin{cases} 1 & si\, x \in A \\ 0 & si\, x \notin A \end{cases}$$

Es decir $\mu_A(x) = v(x \in A)$. El valor $\mu_A(x)$ se denomina función de pertenencia del elemento x al conjunto A.

La función característica de un conjunto difuso permite la construcción de un marco formal en la cual pueda efectuarse el tratamiento y manipulación de la incertidumbre. En un conjunto difuso su frontera no está precisamente definida, y la prueba de pertenencia regresa un valor entre el cero y el uno [0,1], valor que esta definido en los números reales $\mathbb{R}$, es decir existen números difusos que expresan cantidades aproximadas dentro del intervalo [0,1], para este fin se introdujo el concepto del *grado de pertenencia* denotada por μ el cual es subjetivo y dependiente del dominio.

Sea X conjunto no vacío y el conjunto difuso $A \subset X$, A está caracterizado por su función de pertenencia $\mu_A : X \to [0,1]$, donde cada elemento de A toma un valor en el intervalo [0,1] de números reales, y μ indica en qué medida cada elemento de X pertenece a A, esto es $v(x \in A) = \mu(x)$. La función característica para el conjunto difuso de la figura 15 es la siguiente:

$$\mu_A(x) = \begin{cases} 0 & si \quad x \le a \\ (x-a)/(m-a) & si \quad a < x < m \\ (b-x)/(b-m) & si \quad m < x < b \\ 0 & si \quad x \ge b \end{cases}$$

Como ejemplo, situándonos en el contexto de este trabajo se define el conjunto universo como el consumo total agua potable por definida como $\boldsymbol{X_{2.450.230} = \{x \in Z | 0 \le x \le 2.450.230\}}$ donde x representa el consumo de agua en un periodo del año, sea el predicado P ="consumo de agua normal es de más o menos 2.321.456 por mes" que define el conjunto A de consumo de agua de $\boldsymbol{\pm 2.321.456}$ por mes, esta situación está descrita por la función triangular de la figura 16.

Fig. 16 Conjunto difuso consumo normal

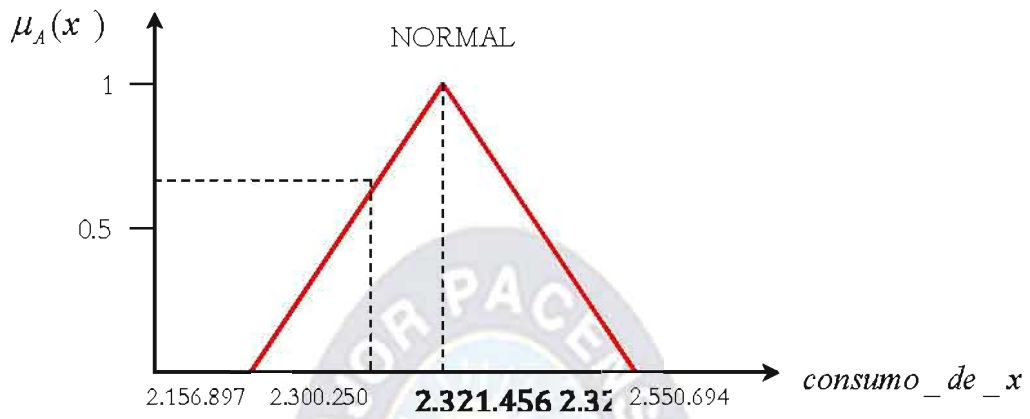

Fuente: [Bonissone, 1980]

Para determinar el valor de pertenencia o no pertenencia de un elemento a un conjunto difuso se recurre a su función característica. Para un conjunto de duraciones $x = \{8, 8.5, 9\}$ en el intervalo $a < x < m$ se tiene los siguientes grados de pertenencia.

Tabla 10. Grados de pertenencia

x	$(x-a)/(m-a)$	$\mu_A(x)$
2.300.250	**(2.300.250-2.156.3897)/(2.321.456-2.300.250)**	0.67

Fuente: Elaboración Propia

$v_1(\text{"}el_consumo_de_agua \pm 2.321.456_mes(2.300.250)\text{"})$ =0.67 significa que la actividad pertenece al conjunto A en un grado de 0.67 de veracidad. Por tanto, una forma posible de definir un conjunto difuso es dar su función característica, especialmente cuando X es un conjunto numérico y $\mu_A(x)$ puede representarse mediante una función algebraica.

2.6.2 CORTE DE NIVEL ALFA

Sea X un conjunto difuso, si A es un subconjunto difuso de X se denota que el corte de nivel alfa $corte-\alpha$ de A es A_α, entonces para cualquier numero $\alpha \in [0,1]$ el corte de nivel alfa se define por $A_\alpha = \{x | \mu_A(x) \geq \alpha, x \in X\}$, denominado nivel de nitidez del conjunto difuso A. Para $\alpha \leq \mu_A(x) \leq 1$.

Fig. 17 Corte de nivel alfa para el conjunto difuso

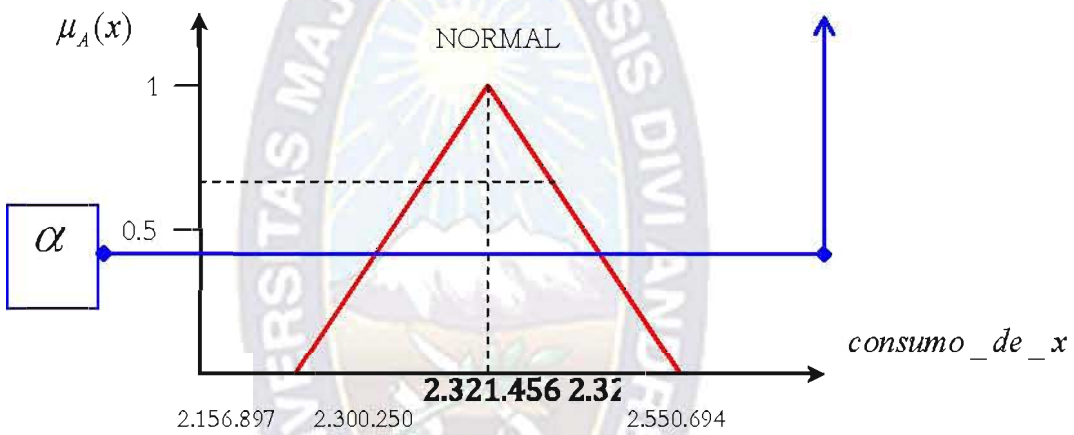

Fuente: Elaboración propia

Al aplicar el corte de nivel alfa a un conjunto difuso, éste se reduce a un conjunto mas pequeño con elementos de un alto grado de pertenencia limitado por α.

Tomando en cuenta los grados de pertenencia de los resultados de la tabla 8, el establecer un corte de nivel $\alpha = 0.5$, significa la reducción del conjunto, compuesto por aquellas de consumo de agua con grados de pertenencia mayores o iguales a 0.5, implica que de la tabla serán tomadas en cuenta los valores de tiempo 0.67 y será descartada los valores inferiores por tener un menor grado de pertenencia al conjunto A de consumo de agua.

2.6.3 VARIABLES LINGÜÍSTICAS

Una variable lingüística es una variable que describe el estado de un fenómeno como ser temperatura, aprendizaje, limpieza, sabiduría, duración de actividad, etc., cuyos valores son palabras o sentencias enmarcadas en un lenguaje predeterminado. Cada una de estas palabras o términos se conoce como etiquetas lingüística y se presenta por medio de un conjunto borroso definido sobre el universo de discurso de la variable a la vez a éstos conjuntos es aplicable los *modificadores lingüísticos* que son las que acentúan una etiqueta lingüística como ejemplo *muy, más o menos, mucho, ligeramente, altamente, bastante*, etc., los cuáles hacen como un *operador* que actúa sobre un conjunto difuso asociado al significado de su operando. Tomando el ejemplo del conjunto difuso de la figura 2.10 se identifican los siguientes atributos:

- Variable lingüística = duración de actividades
- Valor de la variable lingüística = normal, es una etiqueta lingüística y el nombre del conjunto difuso.
- Modificador lingüístico = más o menos, aplicable a la etiqueta lingüística.

La utilidad de las variables lingüísticas es descrita a continuación:

- Es una forma de comprimir información llamada granulación.
- Ayuda a caracterizar fenómenos que están mal definidos o son complejos de definir.
- Es un medio de trasladar conceptos o descripciones lingüísticas a descripciones numéricas que pueden ser tratadas automáticamente: relaciona o traduce el proceso simbólico a proceso numérico.

2.6.4 OPERACIONES LÓGICAS

A diferencia de los resultados bivalentes que se generan por las operaciones con la lógica clásica, los valores de verdad de las proposiciones en la lógica difusa son grados de pertenencia.

Sea $A(x)$, $B(x)$ son conjuntos difusos en el universo X, con estos conjuntos se realizan las siguientes operaciones:

- Unión: $(A \cup B)(x) = A(x) \vee B(x) = \max\{A(x), B(x)\}$
- Intersección: $(A \cap B)(x) = A(x) \wedge B(x) = \min\{A(x), B(x)\}$
- Negación (complemento a uno): $\neg A(x) = 1 - A(x)$
- Implicación: $p \rightarrow q = Min\{1, 1 - p + q\}$
- Equivalencia: $p \leftrightarrow q = 1 - |p - q|$

A continuación se muestra las operaciones entre las diferentes conectivas lógicas.

Tabla 11. Valores de verdad resultado de operaciones lógicas

μ_A	μ_B	$\neg\mu_A$	$\mu_A \wedge \mu_B$	$\mu_A \vee \mu_B$	$\mu_A \rightarrow \mu_B$	$\mu_A \leftrightarrow \mu_B$
0	0.7	1.0	0.0	0.7	1.0	0.3
0.6	0.3	0.4	0.3	0.6	0.7	0.7
1	0.2	0.0	0.2	1.0	0.2	0.2
0.9	0.1	0.1	0.1	0.9	0.2	0.2

Fuente: [Díez, 2005]

2.7 SERIES DE TIEMPO

Una serie de tiempo es una secuencia cronológica de observaciones de una variable en particular.

En términos formales, una serie de tiempo se define como una secuencia de vectores, dependientes del tiempo transcurrido t:

$$\bar{\boldsymbol{X}}(t)$$

donde $t = 0, 1, 2, \ldots$

Teóricamente, x se puede ver como una función continua de la variable de tiempo t. Sin embargo, para cuestiones prácticas, el tiempo generalmente se ve en términos de pasos de tiempo discretos, conduciendo a una instancia de x en cada punto de un intervalo de tiempo, generalmente de tamaño fijo. [Bowerman&O'Connel, 1993]

De acuerdo a Chatfield (1978), son varios los objetivos por los cuales se desea analizar una serie de tiempo:

Descripción: Al tener una serie de tiempo, el primer paso en el análisis es graficar los datos y obtener medidas descriptivas simples de las propiedades principales de la serie.

Explicación: Cuando las observaciones son tomadas sobre dos o más variables, es posible usar la variación en una serie para explicar la variación en las otras series.

Predicción: Dada una serie de tiempo se intenta predecir los valores futuros de la serie. Este es el objetivo más frecuente en el análisis de series de tiempo.

Control: Si una serie de tiempo se genera por mediciones de calidad de un proceso, el objetivo del análisis puede ser el control del proceso.

Una serie de tiempo generalmente se examina con la intención de descubrir patrones históricos que puedan ser útiles en la predicción. Para identificar esos patrones es conveniente pensar que una serie de tiempo consiste de varios componentes:

Tendencia. Una serie de tiempo tiene tendencia cuando por largos periodos los valores crecen o disminuyen consistentemente. También puede definirse como cambios en la media.

Ciclos. Se refiere a movimientos hacia arriba o hacia abajo alrededor del nivel de la tendencia. Estas fluctuaciones, medidas de pico a pico, pueden tener una duración larga.

Variaciones estacionales. Son patrones históricos que ocurren y se repiten cada determinado tiempo, por ejemplo, anualmente. Estas variaciones son causadas típicamente por factores como el clima y las costumbres.

Fluctuaciones irregulares. Son movimientos irregulares en una serie de tiempo que no siguen un patrón regular, ni reconocible. Tales movimientos representan "lo que queda" en una serie de tiempo después de que la tendencia, ciclos y variaciones estacionales han sido explicados.

Pueden obtenerse valores futuros de una serie de tiempo observada mediante una gran cantidad de métodos de predicción. Estos métodos pueden clasificarse fundamentalmente en tres grupos:

Subjetivos. Las predicciones se hacen sobre bases subjetivas usando el criterio, la intuición, el conocimiento en el área y otra información relevante. Entre estos métodos

se encuentran: Ajuste de una curva subjetiva, el método Delphi1 y comparaciones tecnológicas en tiempo independiente.

Univariados. Con este tipo de método se obtienen valores futuros de la serie basándose en el análisis de sus valores pasados, se intenta conseguir un patrón en estos datos, se asume que este patrón continuará en el futuro y se extrapola para conseguir predicciones. Son muchos los métodos que encajan en esta categoría, entre estos se encuentran: Extrapolación de curvas de tendencia, suavización exponencial, método de Holt-Winters2 y método de Box-Jenkins (ARIMA). Este último es un método ampliamente utilizado.

Causales o multivariados. Involucra la identificación de otras variables que están relacionadas con la variable a predecir. Una vez que esas variables han sido identificadas, se desarrolla un modelo estadístico que describe la relación entre esas variables y la variable a pronosticar.

3

Diseño y Desarrollo

Introducción

En este capítulo se trataran tres temas muy importantes: La selección de variables que intervendrán en el aprendizaje de la red, el diseño del modelo de red neuronal predictiva y finalmente la preparación de los datos de entrenamiento.

3.1 MODELO GENERAL

En el modelo general se observa la fuente de datos como elemento fundamental de entrada al modelo predictivo. Conformado por los datos relacionados con el consumo de agua, las redes neuronales y la lógica difusa constituyen herramientas de apoyo para la generación de resultados basados en los datos de consumo de agua y otras variables (Ver Fig. 18).

Fig. 18 Modelo General

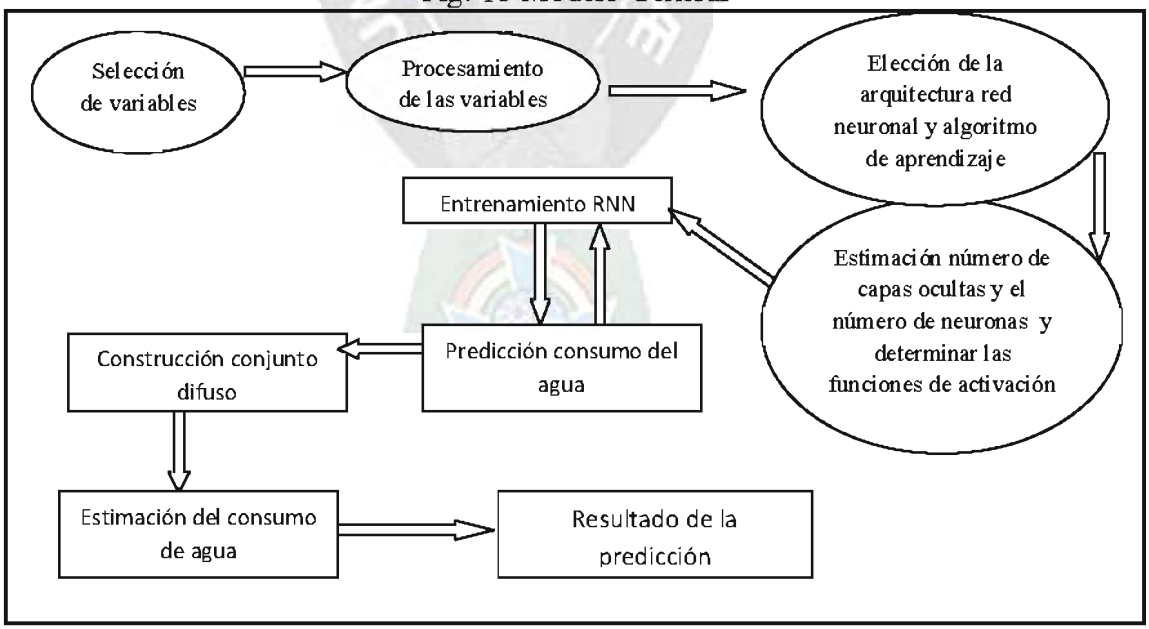

Fuente: Elaboración Propia

3.2 PREPARACION DE LOS DATOS

3.2.1 Selección de variables para el entrenamiento de la red

La elección de las variables es muy importante ya que con estos datos alimentaremos a la red neuronal,con estas variables realizaremos el entrenamiento de la red neuronal par que al final obtengamos una red neuronal que pueda predecir la demanda de agua potable para ello se tiene las siguientes variables:

Temperatura

En algunos trabajos señalan esta variable como principal determinante de la demanda de consumo de agua, puesto que en días de calor el uso del agua incrementa como por ejemplo, en lavar la ropa, el aseo personal, tomar agua para perder el calor, riego de jardines, lavado de vehículos, y otras actividades, y cuando hace frio el uso del agua se ve en decrecimiento o en un estado normal de uso del agua. Para este estudio tomaremos las temperaturas máximas ya que es de gran influencia en el consumo de agua.

Población

La población es el total de personas que hacen uso del agua, diaria, semanal, mensual y anual, hace que esta variables tenga mucha influencia en el consumo de agua total, ya que las cantidades de personas que hacen uso del agua van en aumento de acuerdo a sus necesidades, es por ello que se toma en cuenta esta variable,

Nro. De conexiones activas

Son el total de la población Paceña conectada al servicio de agua potable, de los cuales comprenden: Viviendas, Empresas, locales, puntos de riegos y más.

Calendario.

Se comprueba que la demanda de agua es muy variable en cada mes del año, en cada semana, día, incluso más en horas. Para esta variable de calendario escogeremos la variable MES, ya que existen datos disponibles del consumo de agua por mes. Los datos del consumo de agua por semana, día, hora, son muy difíciles de realizar su cálculo.

Si bien las variables como la información económica y los factores no predecibles pueden incidir significativamente en la demanda de consumo de agua, se ha optado por no seleccionarlas para el entrenamiento del modelo de red neuronal, esto debido a que sus efectos son de poca relevancia.

3.2.2Estructuración de los datos

Se realiza la codificación de las variables de entrada, que entrenaran al modelo,que se han resumido en la siguiente tabla 10:

Tabla 12. Variables que intervienen en el aprendizaje de la red

VARIABLES	UNIDADES	TIPO
Temperatura	Grados centígrados	Numérica Representado por su valor actual
Población	-	Numérica Representado por su valor actual
Nro._conexiones	-	Numérica Representado por su valor actual
Mes	-	Codificada Enero=0, Febrero=1, …, Diciembre=11
Consumo de Agua	m^3(metros cúbicos)	Numérica Representado por su valor actual

Fuente: Elaboración Propia

Debido a que el sistema de distribución de agua potable entre las ciudades del Alto y la ciudad de La Paz, son muy grandes, solo se tomaron en cuenta datos de la ciudad de La Paz, datos que se obtuvieron de la Empresa Pública Social de Agua y Saneamiento (EPSAS), puesto que esta empresa está encargada de la realización de informes de datos históricos o estadísticos del consumo de agua mensual y anualmente tanto de la ciudad de La Paz como del Alto. En cuanto a la variable temperatura, los datos se obtuvieron de la institución de Servicio Nacional de Hidrología y Meteorología (SENAMI), quienes están encargados de preparar información del cambio de clima: Temperatura, precipitaciones fluviales, humedad, etc. En la siguiente tabla 11, se tiene una muestra de

los datos obtenidos y clasificados para el entrenamiento de la red más preciso del año 1999.

Tabla 13. Datos para el entrenamiento de la red

Tiempo año	Mes	Población	Nro._conexiones	Temperatura	Consumo de agua (m3)
1999	0	597.854	90.042	19,5	2.635.991
1999	1	597.854	90.042	18,5	2.554.366
1999	2	597.854	90.042	17,6	2.563.856
1999	3	597.854	90.042	18,5	2.596.834
1999	4	597.854	90.042	19,1	2.669.544
1999	5	597.854	90.042	18,8	2.666.963
1999	6	597.854	90.042	17,8	2.758.945
1999	7	597.854	90.042	19,3	2.593.989
1999	8	597.854	90.042	19,3	2.583.964
1999	9	597.854	90.042	19,0	2.658.987
1999	10	597.854	90.042	20,8	2.677.538
1999	11	597.854	90.042	20,9	2.566.768

Fuente: Elaboración propia con datos de EPSAS Y SENAMI

3.2.3Preparación de la información de entrada

Uno de los aspectos más relevantes en el éxito de cualquier red neuronal es el conjunto de datos empleados en su entrenamiento, incluso el más simple de los modelos puede ofrecer buenos resultados si es alimentado con datos que, tras ser procesados adecuadamente, revelan de forma clara y precisa la información relevante. Asímismo, el mejor de los modelos fracasara si es entrenado con datos de baja calidad.

Es por tanto necesario llevar a cabo un procesamiento de la información muestral para este modo aumentar la capacidad de aprendizaje de la red. El procesamiento constara de las siguientes operaciones:

Filtrado: Consiste en verificar si la series de datos contienen valores perdidos, para reemplazar estos datos perdidos se introducen datos con valores de una media aritmética de valores anteriores y posteriores al periodo.

Codificación: La codificación se realiza como se explico en el tabla 10.

Normalización: La técnica utilizada es la llamada número máximo y mínimo. La elección de esta técnica viene a que se puede limitar las series en el rango de [0,1], además de un fácil y velos calculo. Este procedimiento consiste simplemente en modificar la escala de las variables ateniendo a su valor mínimo y máximo. Como resultado obtendremos nuevas series de datos más homogéneas.

Para normalizar los datos se utilizo la siguiente ecuación descrita en el capítulo 2:

$$X_j = \frac{X_i - X_{min}}{X_{max} - X_{min}}$$

Donde:

X_j ***dato normalizado***

X_i ***dato original***

X_{max} ***es el dato mas grade de la serie***

X_{min} ***es el dato mas pequeño de la serie***

Ejemplo para el cálculo de la normalización para la variable mes

$X_{max} = 11$
$X_{min} = 0$

$$X_i = 0$$

Tenemos:

$$X_j = \frac{0 - 0}{11 - 0} = 0.000$$

$X_{max} = 11$
$X_{min} = 0$

$$X_i = 1$$

Tenemos:

$$X_j = \frac{1 - 0}{11 - 0} = 0.909$$

Se normaliza de la misma manera para todas las variables (ver tabla 12)

Tabla 14: Datos de entrada normalizados en escala [0-1].

Tiempo año	Mes	Población	Nro._conexiones	Temperatura	Consumo de agua (m3)
1999	0	0,003	0.0000	0,5	0,8048
1999	0,0909	0,003	0.0000	0,3571	0,6753
1999	0,1818	0,003	0.0000	0,2286	0,6903
1999	0,2727	0,003	0.0000	0,3571	0,7427
1999	0,3636	0,003	0.0000	0,4429	0,8581
1999	0,4545	0,003	0.0000	0,4	0,854
1999	0,5455	0,003	0.0000	0,2571	1
1999	0,6364	0,003	0.0000	0,4714	0,7382
1999	0,7273	0,003	0.0000	0,4714	0,7223
1999	0,8182	0,003	0.0000	0,4286	0,8413
1999	0,9091	0,003	0.0000	0,6857	0,8708
1999	1	0,003	0.0000	0,7	0,695

Fuente: Elaboración propia

Y para la des normalización se usa lo siguiente:

$$x_i = x_j * (x_{max} - x_{min}) + x_{min}$$

x_i ***dato original a encontrar***

x_j ***es el dato normalizado***

X_{max} ***es el dato mas grade de la serie***

X_{min} ***es el dato mas pequeño de la serie***

Ejemplo para el variable mes

$$X_{max} = 11$$

$$X_{min} = 0$$

$$x_j = 0.2727 \ldots$$

$$x_4 = 0{,}2727 \ldots * (11 - 0) + 0 = 3$$

3.2.4División de los datos

Para realizar un estudio sobre la predicción del consumo de agua en la ciudad de La Paz, expresado en metros cúbicos, se recurre a la serie temporal de consumo agua referente al periodo comprendido entre Enero de 1999 y Diciembre de 2009, el resto de valores históricos, hasta diciembre de 2010, no se dan a conocer a la red, aunque si se consideran para validar las predicciones y conocer mejor la serie temporal (Ver tabla 13).

Tabla 15.División de la Muestra

Total de observaciones	144
Observaciones para el entrenamiento	132
Observaciones para la predicción	12

Fuente: Elaboración propia

3.3DETERMINACIÓN DE LA ARQUITECTURA DEL MODELO DE RED NEURONAL

Las Redes Neuronales Artificiales (RNN) están siendo utilizadas, en los últimos años, en múltiples campos, uno de ellos es la predicción de series temporales. En este apartado se utilizan las RNN para obtener predicciones de la serie temporal "Demanda de agua", en base a datos históricos.

3.3.1Estructura de la red neuronal

La red neuronal está basada en la estructura de la red retropropagación del error (*Backpropagation o BP)*, con una capa de entrada, una o más capas ocultas y una de salida. En lo referente a las capas de entrada los datos de ingreso serán las variables que afectan significativamente en el aprendizaje de la red, descritas anteriormente. La capa de salida contara con una unidad, el cual indicara el valor del consumo de agua por mes asociado a cada vector de entradas presentadas a la red. Finalmente las capas ocultas contaran con un número variable de neuronas (Ver Figura 19).

No existe una fórmula mágica para seleccionar el número óptimo de nodos para la capa oculta, tampoco el número de capas ocultas, se recomienda que se deba comenzar con una o dos capas ocultas, pero esto será respondido una vez realizado el entrenamiento de la red.

Fig. 19 Estructura del modelo red neuronal *Backpropagation*

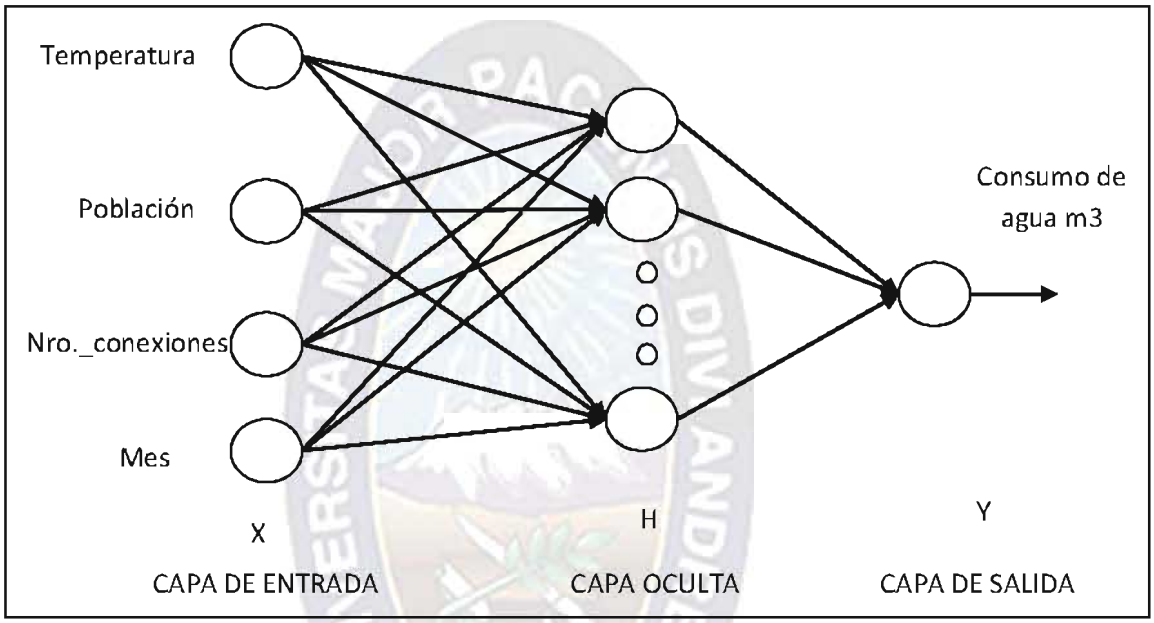

Fuente: Elaboración Propia

3.3.2Numero de neuronas en la capa oculta

El numero optimo de neuronas en la capa oculta está en función del mínimo error admisible, en todo caso, el objetivo es dotar a la red neuronal de n números adecuados de neuronas en la(s) capa(s) oculta(s) para que sea capaz de aprender las características de las relaciones existentes entre los datos de la muestra.

Realizando experimentaciones con diferentes capas ocultas se obtuvo que para el entrenamiento de la red neuronal predictiva para el consumo de agua es de 4-8-8-1, donde las 4 primeras son las variables de entrada, las siguientes ochos son capas ocultas de entradas de las variables, las siguientes 8 es la capa oculta para la salida, y la ultima es el resultado del entrenamiento.

3.3.3Descripción formal

La definición de la red neuronal artificial para la predicción del consumo de agua es la siguiente:

Definición 3.1

La red neuronal artificial RN para la predicción de la demanda de agua potable hacia la ciudad de La Paz, está dada por la dupla:

RN=(X, H, Y)

Donde:

X: conjunto de entradas para la red

H: conjunto de neuronas para la capa oculta

Y: Salida de la red

También la salida de la red se define como la función:

$$Y = f(X, H)$$

Definición 3.2

Se define el vector $X \in RN$, como la entrada a la red neuronal artificial para la predicción del consumo de agua potable en la ciudad de La Paz, como un vector de la forma:

$$X = (x_1, x_2, x_3, x_4)$$

Donde;

x_1: $Temperatura$

x_2: $Poblacion$

x_3: $Nro._coexiones$

x_4: Mes

Definición 3.3

La salida de la red neuronal RN, está dada por el vector Y que tiene la siguiente forma:

$$Y = (y_i)$$

Donde:

y_i: *es el consumo de agua potable* (m^3)

Definición 3.4

La función de activación (salida) de la red neuronal artificial RN está dada por la función sigmoidea, debido a que ofrece salidas de valores entre los intervalos de [0,1], esta función responde a la siguiente ecuación:

$$Y_j(t+1) = \frac{1}{1+e^{-Net_j}}$$

Con

$$Net_j = \sum_{1}^{N} w_{ij} y_i$$

3.4 DISEÑO TEORICO DEL MODELO DE RED NEURONAL PARA EL ENTRENAMIENTO

Para la entrada de la red neuronal se tiene una matriz de tamaño *n*, que contempla todas las variables para el entrenamiento, de forma:

	Mes	Población	Nro._conexiones	Temperatura
A_{i-n}				
…				
A_{i-2}				
A_{i-1}				

A la cual llamaremos *p*.

Para la matriz de la capa oculta, tiene los pesos iníciales W_{jt}, por definición, se toman con valores aleatorias que oscilan entre -1 y 1, el tamaño de la matriz será de 8x4.

W=

0,18	0,11	0,19	0,56
0,83	0,18	0,90	0,77
0,77	0,10	0,10	0,31
0,93	0,49	0,04	0,18
0.39	0.58	0.69	0.98
0.57	0.24	0.54	0.21
0.93	0.39	0.18	0.58
0.78	0.64	0.45	0.87

La matriz de datos objetivos se tiene uno de la forma:

A_l=

Consumo de agua
Dat. 1
Dat. 2
Dat. 3
…
Dat. n

Que llevara el nombre de*t*.

En cada caso, A_l representa el consumo total por mes, que se toman como datos para realizar las predicciones.

Es necesario matrices de pesos para la unión de la capa oculta con la de salida, la cual está dada por la siguiente matriz LW.

LW=

0.3	0.5	0.90	0.87	0.45	0.60	0.41	0.7

Umbral de la capa oculta que esta dado por la matriz siguiente.

$$B = \begin{bmatrix} 0{,}18 \\ 0{,}83 \\ 0{,}77 \\ 0{,}93 \\ 0.39 \\ 0.57 \\ 0.93 \\ 0.78 \end{bmatrix}$$

El umbral de capa de salida es:

$$LB = \begin{bmatrix} 0{,}58 \end{bmatrix}$$

Las matrices W, LW, B y LB presentan datos de manera aleatoria, puesto que es necesario para inicialización de pesos de estos valores, es imposible conocer de manera adelantada los puntos mínimos de error, se acostumbra tomar valores que estén cercanos a 0 y 1, de esta manera se procede al entrenamiento de la red.

Así como es necesaria una regla que combine las entradas a una neurona con los pesos de las conexiones, también se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación, las funciones que se utilizan entre la capa de entrada y la capa oculta es la función sigmoidea definida por:

$$y = \frac{1}{1 + e^{-x}}$$

Visto en el capítulo 2, entre la capa oculta y de salida también se utiliza la función sigmoidea

3.5 REGLA DE APRENDIZAJE

El aprendizaje de la red neuronal se realiza mediante el algoritmo de entrenamiento Backpropgation, en particular, aquel llamado LevenbergMarquardt, debido a su rapidez de convergencia.

Tomando en cuenta estos pasos, se presenta el modelo teórico sobre el entrenamiento de la red neuronal artificial para el proceso de predicción del consumo de agua se puede observar en la Figura 20.

Fig.20 Modelo teórico del entrenamiento

Ingresar *p* y *t*

Se calcula los valores de entradas para la capa oculta

$$In = \sum w_{jt} * p_{tk} + B$$

Se calcula las salidas de la capa oculta

$$i = f(In)$$

Se pasa a la capa de salida y se calcula los valores de las entradas

$$Im = \sum LW_{ik} * i + LB$$

Se calculan las salidas

$$o = g(Im)$$

Se obtienen los términos de error para las unidades ocultas

$$k = (y - o) * g(In)$$

Términos de error para la capa de salida

$$\delta = f(In) * \sum k * w$$

Se actualizan los pesos

$$w(t+1) = w(t) + \delta * p$$

El error esta dado por

$$E = \frac{1}{2}\sum \delta^2$$

El proceso se repite hasta que se llegue a la matriz objetivo y se estabilice el error

Fuente: Elaboración propia

Para comparar resultados sobre predicciones y los datos reales, se toma en cuenta el error absoluto individual, que está dado por:

$$\varepsilon_i = x_i - \mu$$

También se toma en cuenta el error porcentual, que viene como:

$$\varepsilon_p = \frac{(x_t - \mu)}{\mu} * 100$$

Donde; x_i es el dato a observar y μ es el dato real.

3.6 APLICACIÓN DE LA LOGICA DIFUSA A LOS DATOS DE LA PREDICCION DE LA RED NEURONAL

Luego de obtener los resultados de la red neuronal, se diseña el modelo de Lógica Difusa.

Para una mejor interpretación de los conjuntos difusos del resultado de la red neuronal predictiva. De acuerdo a la línea investigativa del trabajo en la aplicación de conjuntos difusos se utilizará la función triangular, para el tratamiento de la incertidumbre en valores de consumo de agua en un periodo futuro, así la función triangular es representada por la figura 21.

Fig. 21 Función triangular

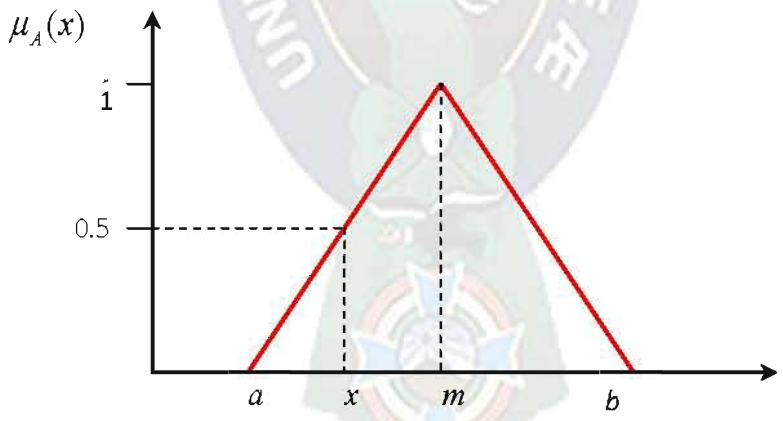

Fuente: Elaboracion propia

Donde X viene siendo cantidad de consumo de agua en un periodo *t*, *a* y *b* son los extremos de *m* que es el consumo total de agua en año predicho por la red neuronal.

La función característica para el conjunto difuso es la siguiente:

$$\mu_A(x) = \begin{cases} 0 & si & x \leq a \\ (x-a)/(m-a) & si & a < x < m \\ (b-x)/(b-m) & si & m < x < b \\ 0 & si & x \geq b \end{cases}$$

Para hallar los extremos a y b procederemos de la siguiente manera:

Definición 3.5

Para hallar los valores a y b tenemos que tener un valor que incremente y decrezca el valor predicho por la red neuronal, que en este caso es m, la variable que incremente y decrezca solo puede conocerse a través de la experiencia del experto o por algún cálculo estadístico o matemático por lo que se tiene:

ec =experiencia o calculo estadístico

pr= promedio de crecimiento del consumo de agua

$$\boldsymbol{ec = m * pr}$$

Ahora se tiene

$\boldsymbol{a = m - e}$c *extremo inferior*

$\boldsymbol{b = m + ec}$*extremo superior*

Ahora bien para obtener resultados que nos den un intervalo de consumo de agua se tiene que despejar la ecuación de la función característica del modelo triangular dado por:

$$\frac{\boldsymbol{x - a}}{\boldsymbol{m - a}} = \boldsymbol{h}$$

Donde $h$es el valor de confianza con el que se quiere obtener un valor de proximidad de probabilidad confiable.

Despejando se tiene:

$$x_l = h(m - a) + a \quad \textit{valor inferior}$$

Despejando se tiene

$$x_s = b - h(b - m) \quad \textit{valor superior}$$

Así obtenemos un intervalo de confianza dado por $[x_l, x_s]$

Con los datos del intervalo se puede realizar conclusiones que ayuden al experto de cuanto de consumo de agua se puede tener en un fututo próximo con una confianza o probabilidad de *h*, por ejemplo:

Si h=0.60, el consumo de agua para un periodo t =2013 predicho es de entre [47.456.367-50.654.897] expresado en m3/año.

Con estos valores un experto tendrá un criterio de decisión.

4

Experimentación

Introducción

En este capítulo se explica cómo se realiza el entrenamiento y los resultados que se obtienen, como también se aplica la lógica difusa a los resultados de la predicción. A demás se presenta la estructura final de la red neuronal para realizar predicciones.

4.1ENTRENAMIENTO DE LA RED

4.1.1 SOPORTE INFORMATICO PARA EL MODELO

Existe en la actualidad una infinidad de herramientas informáticas para la manipulación de las redes neuronales artificiales, para este trabajo se optó por utilizar el programa Matlab y sus Neural Network Toolbox debito a que posee un motor de cálculo muy potente, también nos permite modificar parámetros de entrenamiento como la tasa de aprendizaje, el momento, el número de iteraciones, el error cuadrático medio mínimo aceptable, etc.

En la figura 21 se muestra el código para el entrenamiento de la red:

Fig.22 Código para el entrenamiento

```
Cargamos los datos de la matriz
todosp=variables de entrada para el entrenamiento
todost=datos objetivos  consumo real
%dividimos la matriz de datos en tres grupos
%datos para el entrenamiento
%datos para validar
%datos para el test
trp=todosp; %conjunto de datos entrenar
vp=todosp; %conjunto de tatos para validar
tsp=todosp;%conjunto de datos para la test(prueba)
trt=todost;  %conjunto de datos de objetivos
vt=todost ;  %conjunto de objetivos para validar
tst=todost; %conjunto de objetivos para test(prueba)
todospn=todosp';
%[todospn,mintodosp,maxtodosp]=premnmx(todosp);
% se utiliza lo anterior para normalizar los datos no normalizados
trpn=trp';
trt=trt';
vpn=vp';
vt=vt';
v.P=vpn;
v.T=vt;
net=newff([-1 1;-1 1;-1 1;-1 1],[8
1],{'logsig','logsig'},'trainlm');
%función de transferencia logsig y algoritmo de entrenamiento
LevenbergMarquardt
net=init(net);   %iniciamos la red con valores aleatorios
net.trainParam.show=100;  %muestra numero de ciclos en pantalla
net.trainParam.epochs=500; %numero de ciclos de entrenamiento
net.trainParam.goal=1e-10; %error que debe alcanzar el
entrenamiento
[net,tr]=train(net,trpn,trt,[],[],v); %realiza el entrenamiento
tspn=tsp';
rdo=sim(net,tspn);
tst=tst';
[m,b,r]=postreg(rdo,tst)
W=net.IW{1,1};%matriz de pesos entre entrada y oculta
LW=net.LW{2,1};%matriz de pesos entre oculta y salida
B=net.b{1}; %umbrales de la capa
LB=net.b{2}; %matriz de salida
```

Fuente: Elaboración propia

De donde obtenemos como resultado la matriz:

W representa la matriz de los pesos que une la capa de entrada y la capa oculta

W=

-11,4804013	4,15260081	-14,3291649	17,9412804
-8,62048765	8,79300557	16,9183907	31,1454317
-13,4955459	-2,20121621	-0,05746414	-4,27663607
-11,073366	-1,79389846	-1,17095152	-4,28480995
-0,39865174	-32,6307186	-12,3784016	0,92896033
-3,32204892	-1,44496198	-5,58030653	7,16446169
0,44485098	45,1192737	32,0552695	-0,97166948
-5,66364128	1,9215377	7,97621057	-1,12844805

LW representa la matriz de los pesos que une la capa oculta con la capa de salida.

LW=

2,07108593	1,8172065	-18,024639	19,2044356	-20,1153159	-1,49683213	-19,6871573	-1,66177993

B representa la matriz de umbrales de la capa oculta

B=

-8,13658985
-34,1706221
6,65090954
6,04758339
22,6143318
-3,37042079
-34,8902969
3,41036225

LB representa la matriz de los umbrales de la capa de salida

LB=

21,5541175

Con estas W LW B LB son matrices ya entrenadas, con las cuales ya se pueden realizar predicciones.

4.1.2 PREDICCION

Con estos datos se presenta los pasos generales para la realización de predicciones: Las variables normalizadas elegidas, son multiplicadas por la matriz de los pesos sinápticos, que une la capa de entrada con la capa oculta. A la matriz resultante se le aplica una función soigmoidea, ya que los datos esta normalizados entre [0,1]. Esta se multiplica por la matriz de pesos que une la capa oculta con la capa de salida y de la suma el umbral de salida, nuevamente aplicamos la función sigmoidea para que los datos estén entre el rango de [0,1]. El dato obtenido debe ser des normalizado, y nos muestra las predicciones realizado por la red neuronal para un tiempo t, en la siguiente figura 22, se muestra el código para realizar la predicciones.

Fig.23 Código para la predicción

```
Loadprueba91netWLWBLB
T=[0.000 0.0030 0.000 0.500]; el dato viene dado por este
vector
Q=T';
D=W*Q;
H=D+B;
k=logsig(H);
I=LW*k;
Z=I+LB;
R=logsig(Z);
V(i)=R;   %trasladamos la respuesta a un vector luego des
normalizamos ese dato y obtenemos el resultado que se estima
```

Fuente: Elaboración propia

En primer lugar se realizara un contraste de lo bien que ha aprendido la red, es decir, en qué medida es capaz de repetir la serie original al presentarle los mismos datos nuevamente de entrenamiento. En segundo lugar se probara la capacidad de generalización de la red, y por tanto validar su capacidad como instrumento de predicción, con datos no entrenados.

4.1.3 PREDICCION CON DATOS CONOCIDOS POR EL MODELO RED NEURONAL

Los valores predichos de consumo de agua mediante la red neuronal, son comparados con los datos reales para el año 2009 en particular, que se observa en la tabla 14.

Tabla 16. Consumo real y predicciones red neuronal

Mes	CONSUMO REAL	RED NEURONAL	Error porcentual
Enero	2.510.138	2.544.739	1,3784
Febrero	2.466.045	2.443.726	-0,9050
Marzo	2.321.319	2.371.744	2,1722
Abril	2.520.571	2.478.075	-1,6860
Mayo	2.536.419	2.517.455	-0,7477
Junio	2.517.440	2.512.486	-0,1968
Julio	2.540.043	2.509.268	-1,2116
Agosto	2.518.145	2.485.804	-1,2843
Septiembre	2.595.560	2.504.024	-3,5266
Octubre	2.687.358	2.675.112	-0,4557
Noviembre	2.720.538	2.687.333	-1,2205
Diciembre	2.317.734	2.490.402	7,4498
TOTAL	30.251.310	30.220.166	P=-0,0195

Fuente: Elaboración Propia

Aquí observamos gráficamente el consumo de agua real y red neuronal en la figura 23

Fig.24 Consumo real y predicciones red neuronal

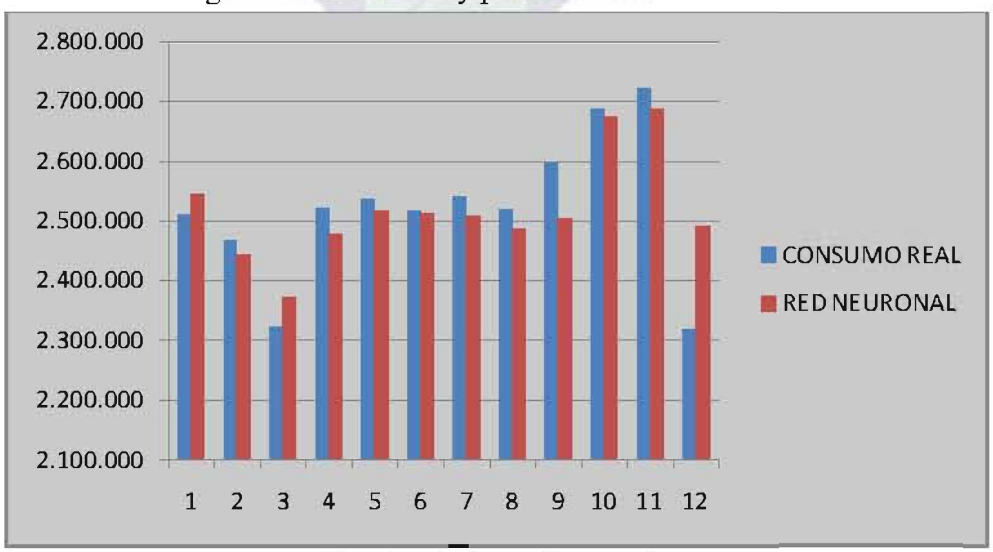

Fuente: Elaboración propia

En la figura 23 observamos como los datos reales y los de la red neuronal contrastan, a primera vista se puede apreciar un aceptable similitud entre ambas.

4.1.4 PREDICCION CON LOS DATOS NO CONOCIDOS POR ELMODELO RED NEURONAL

A continuación presentaremos al modelo el conjunto de datos que se habían reservado con anterioridad (ver tabla 13). El modelo procesara esta nueva información teniendo en cuenta las relaciones aprendidas en el entrenamiento y que guarda en forma de matriz de pesos sinápticos. La salida del modelo no será mas que la predicción, comparando esta con los valores reales del consumo de agua real del año a predecir, en este caso para el año 2010 (Ver tabla 15).

Tabla 17. Predicción con datos no entrenados

Mes	CONSUMO REAL	RED NEURONAL	Error porcentual
Enero	2.439.848	2.308.652	-5,3772
Febrero	2.297.436	2.185.744	-4,8616
Marzo	2.400.488	2.438.163	1,5695
Abril	2.485.305	2.647.397	6,5220
Mayo	2.563.221	2.656.861	3,6532
Junio	2.512.072	2.677.128	6,5705
Julio	3.211.519	2.634.874	-17,9555
Agosto	2.577.617	2.685.524	4,1863
Septiembre	2.576.575	2.685.138	4,2135
Octubre	2.617.026	2.678.002	2,3300
Noviembre	2.608.775	2.685.303	2,9335
Diciembre	2.703.904	2.682.911	-0,7764
TOTAL	30.993.785	30.965.698	P=0,2506

Fuente: Elaboración propia

En la figura 25 se puede observar mucho mejor la predicción vs el consumo real.

Fig. 25 Predicción con datos no entrenados

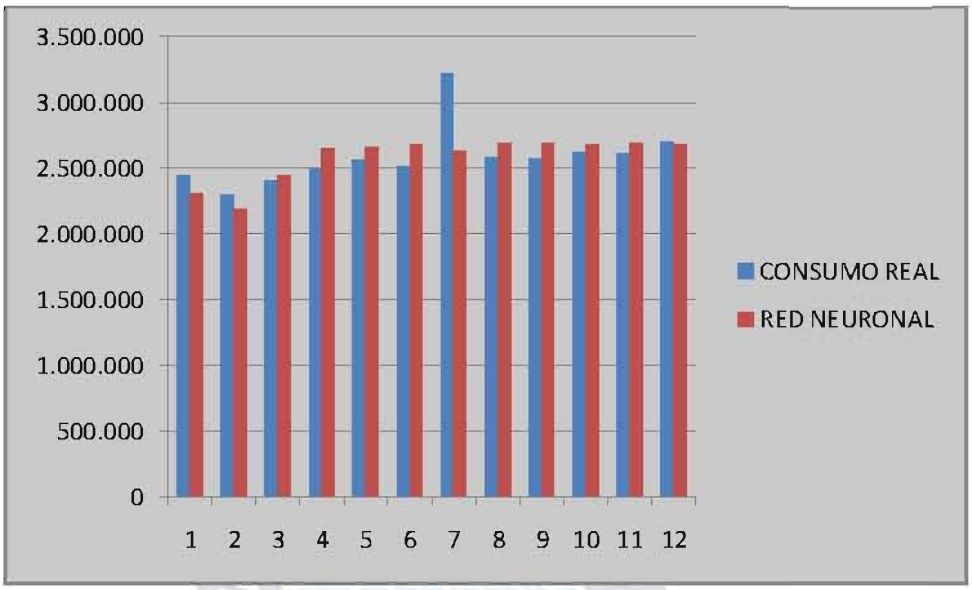

Fuente: Elaboración Propia

Observando el grafico se puede afirmar con seriedad que la red neuronal realiza predicciones muy buenas.

4.1.5 ANALISIS POST-ENTRENAMIENTO

El rendimiento de un modelo de red neuronal (capacidad de predicción), una ves entrenado puede ser medido realizando un análisis de regresión entre la respuesta del modelo y la correspondiente salida original (consumo de agua real). El siguiente comando ilustra cómo se puede realizar un análisis de regresión sobre el modelo.

```
[m,b,r]=postreg(rdo,tst)
```

Se realiza un comparación entre la curva de consumo generada por el modelo de red neuronal rdo y la correspondiente curva de consumo real tst. El comando postreg arroja tres resultados las cuales son: m, b, r, de donde las dos primeras corresponde a la pendiente y la intersección en el eje Y de la mejor regresión lineal relacionando el consumo de agua real con el consumo de agua de la red neuronal.

Si se tiene un ajuste perfecto la pendiente m deberá ser 1, y la intersección en Y dado por b debería ser 0. La tercera variable r, es el coeficiente de correlación entre el

consumo real de agua y el consumo predicho por la red. Si r es igual a 1, entonces hay una correlación perfecta entre el consumo real y de la predicción, entonces tenemos que:

$$\boldsymbol{m = 0.8407}$$

$$\boldsymbol{b = 0.0902}$$

$$\boldsymbol{r = 0.9178}$$

En la siguiente figura 26 muestra el análisis de regresión en el modelo neuronal.

Observando en la figura 26, vemos que el mejor ajuste lineal (roja), es muy parecido al ajuste perfecto. También se advierte que el R=0.9178, que está muy próxima a la unidad, esto es suficiente para afirmar que la predicción realizada con el modelo de red neuronal es bastante bueno.

Fig.26 Análisis de regresión del modelo de red neuronal

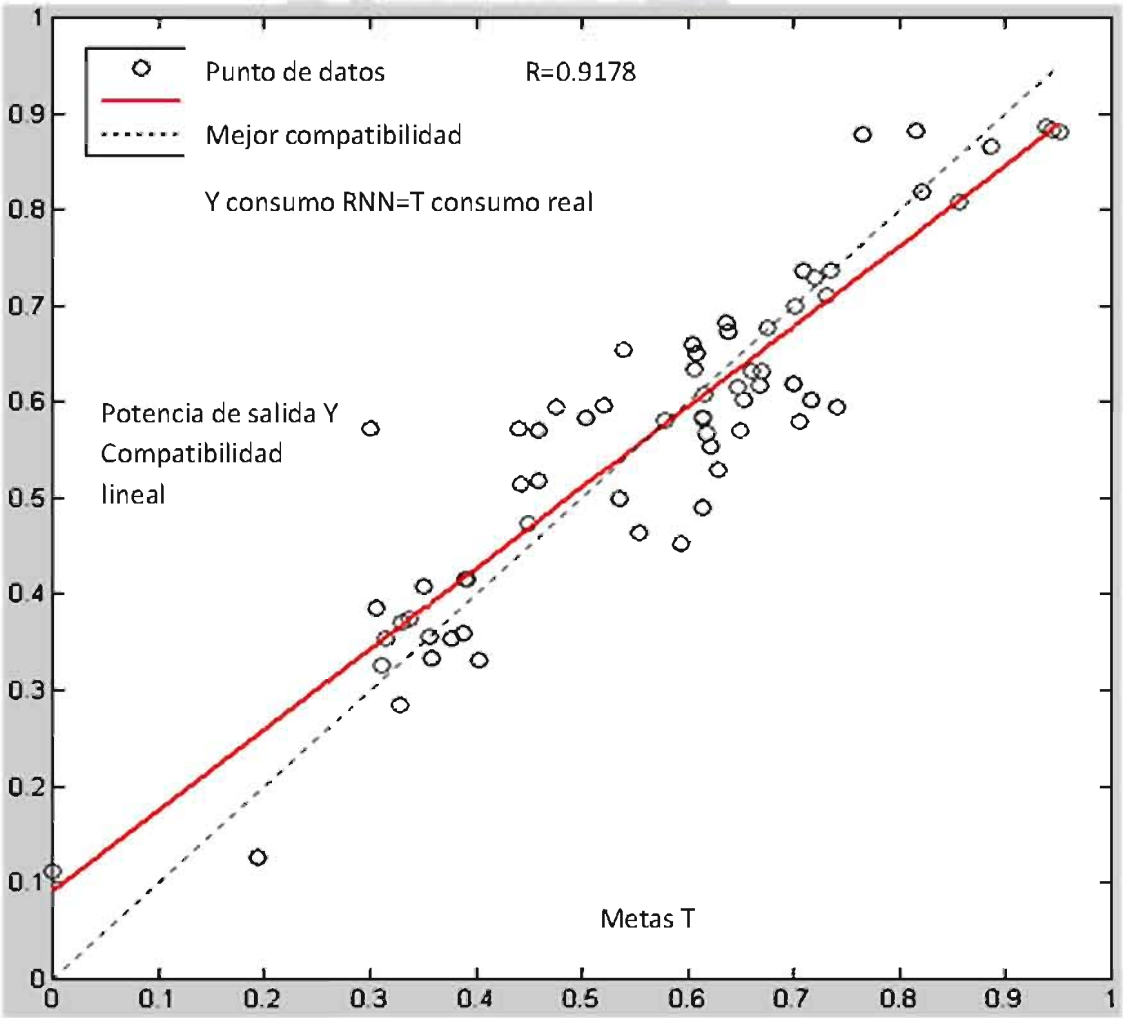

Fuente: Elaboración propia

Además estudiando los errores relativos dado por la formula

$$\varepsilon_p = \frac{(x_t - \mu)}{\mu} * 100$$

El promedio de error porcentual es del 10%, este valor indica que el modelo de red neuronal tiene una efectividad del 90%, observando la figura 27 del consumo real vs consumo predicho por la red, con todos los datos, se tiene:

Fig. 27 consumo real vs consumo predicho red neuronal (todos los datos)

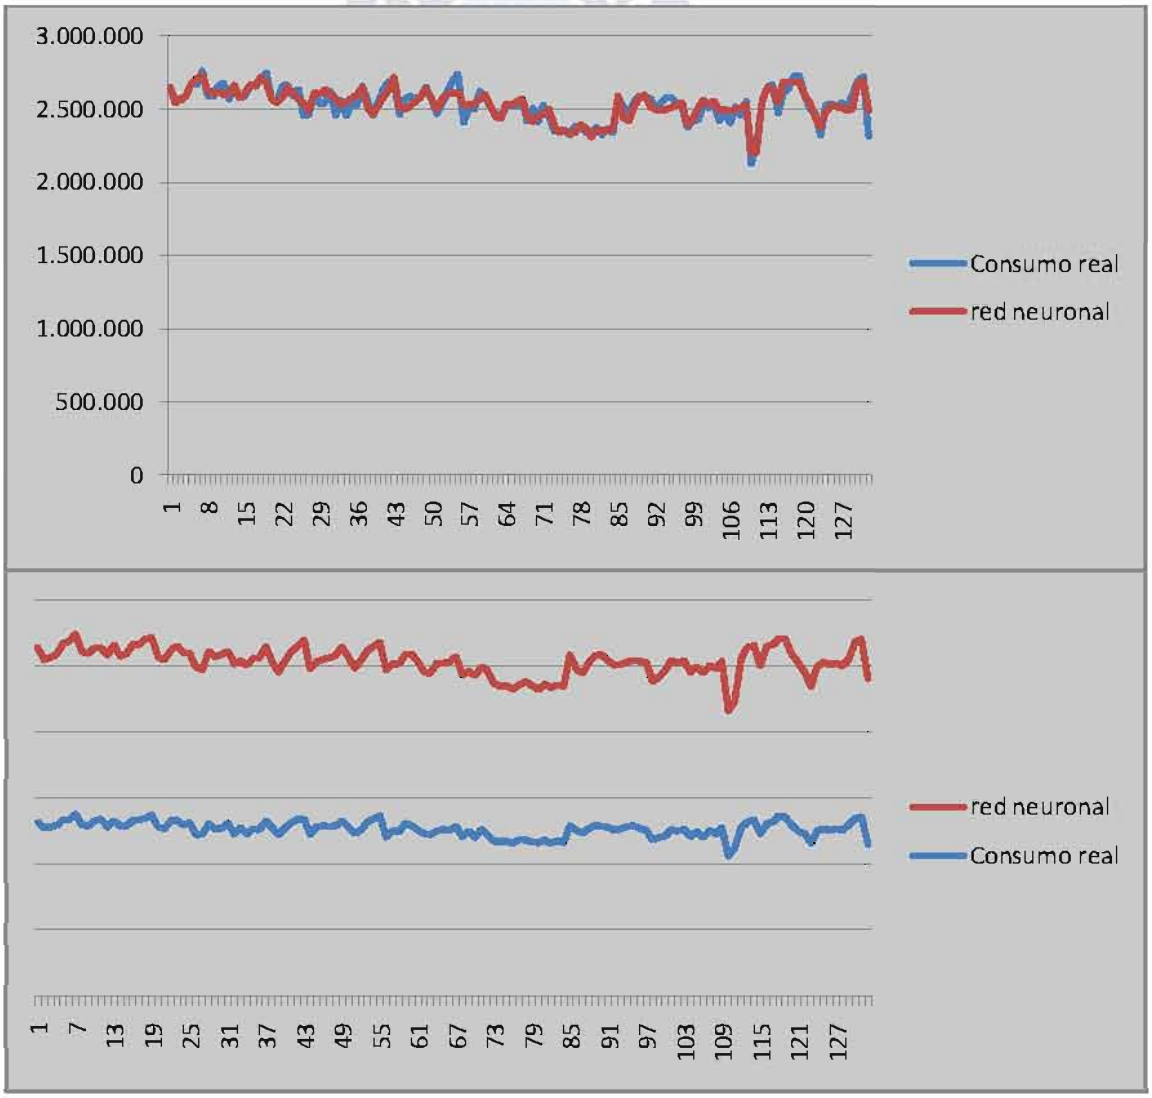

Fuente: Elaboración propia

4.1.6 APLICACIÓN DE LA FUNCION TRIANGULAR DE LA LOGICA DIFUSA A LA PREDICCION DE LA RED NEURONAL.

La aplicación de la lógica difusa al conjunto de datos predichos por la red neuronal nos dará a un mas, confiabilidad puesto que la lógica difusa nos permitirá generar dos valores de consuno de agua, donde el dato predicho por la red estará inmerso en ella, para ello utilizaremos la función triangular.

Primeramente tenemos que encontrar el valor de:

ec=experiencia o calculo estadístico

Para ello utilizaremos la definición 3,5 descrita en el capítulo 3.

Encontrar este valor nos permitirá hallar los extremos de la función triangular, con los cuales podremos calcular los intervalos de consumo de agua con una veracidad "*h*".

Primeramente encontremos el valor *pr*queno es más que el promedio de incremento del consumo de agua de todos los datos observados para el entrenamiento, en la tabla 16 se muestra todos los promedios de 1999 al 2009:

pr=promedio porcentual de incremento de agua

Tabla 18. Promedio de incremento de consumo de agua por mes y año

Años/mes	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009
Enero	8,4	8,4	8,7	8,6	8,6	8,5	8,3	8,4	8,5	8,3	8,3
Febrero	8,1	8,1	8,1	8,2	8,3	8,3	8,3	8,2	8	7	8,2
Marzo	8,1	8,2	8,1	7,9	8	8,3	8,3	8,1	8,2	7,4	7,7
Abril	8,2	8,4	8,6	8,2	8,2	8,5	8,2	8,3	8,2	8,4	8,3
Mayo	8,5	8,5	8,3	8,5	8,5	8,5	8,4	8,5	8,5	8,7	8,4
Junio	8,5	8,5	8,4	8,7	8,7	8,5	8,4	8,4	8,5	8,7	8,3
Julio	8,8	8,7	8,6	8,7	8,9	8,7	8,3	8,4	8,6	8,1	8,4
Agosto	8,2	8,1	8,1	7,9	7,8	8,2	8,3	8,2	8,2	8,5	8,3
Septiembre	8,2	8,1	8,4	8,3	8,1	8,5	8,4	8,3	8,4	8,6	8,6
Octubre	8,4	8,4	8,1	8,4	8,1	8,1	8,2	8,4	8,1	8,9	8,9
Noviembre	8,5	8,4	8,4	8,3	8,5	8,5	8,4	8,4	8,5	8,9	9
Diciembre	8,1	8,2	8,3	8,3	8,4	8,3	8,3	8,3	8,3	8,5	7,7
promedio de consumo	8,3	8,3	8,3	8,3	8,3	8,4	8,3	8,3	8,3	8,3	8,3

Fuente: Elaboración propia

Una vez obtenidos los promedios *pr* se trabaja con ellos para encontrar los valores inferiores y extremos, ejemplo.

Ahora calculamos el*ec* para la hallar los valores laterales.

$$\boldsymbol{ec = m * pr}$$

e c= 2.544.739*0.85 = 2163028

De la tabla 15 tomamos el valor del mes de enero predicho por la red

$\boldsymbol{a = m - e}$c *extremo inferior* =2.544.739-2.163.028=381711

$\boldsymbol{b = m + ec}$*extremo superior* =2.544.739+2.163.028=4.707.767

De la tabla 15

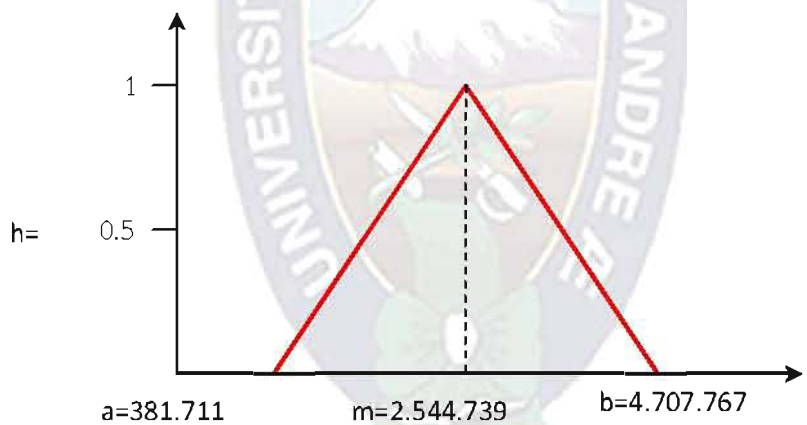

$$\boldsymbol{x_i = h(m - a) + a \quad valor\ inferior}$$

$$\boldsymbol{x_s = b - h(b - m) \quad valor\ superior}$$

Con un *h=0.5 se tiene:*

$$\boldsymbol{x_i = 0.50(2.544.739 - 381.711) + 381.711 = \quad 1.463.225}$$

$$\boldsymbol{x_s = 4.707.767 - 0.50(4.707.767 - 2.544.739) = \quad 3.626.258}$$

Como *h=0.5 no es muy bueno probamos con h=0.80*

$$x_i = 0.80(2.544.739 - 381.711) + 381.711 = \quad 2.112.133$$

$$x_s = 4.707.767 - 0.80(4.707.767 - 2.544.739) = \quad 2.977.353$$

Aquí podemos aprecia mucho mejor un intervalo de consumo con una probabilidad del 80%, el intervalo de consumo de agua seria de:

$$[2.112.113 - 2.977.353]$$

Donde el valor m=**2.544.739** esta dentro del rango, para mas claridad observemos la tabla 17 donde nos muestra el intervalo de consumo para todo un año, en particular para el año 2009.

Tabla 19. Intervalo de consumo con nivel de confianza del 80%

Confianza 80%	inferior	RED NEURONAL	superior
Enero	2.112.133	2.544.739	2.977.343
Febrero	2.031.323	2.443.726	2.896.532
Marzo	1.973.737	2.371.744	2.838.947
Abril	2.058.802	2.478.075	2.924.011
Mayo	2.090.306	2.517.455	2.955.515
Junio	2.086.331	2.512.486	2.951.540
Julio	2.083.757	2.509.268	2.948.966
Agosto	2.064.985	2.485.804	2.930.195
Septiembre	2.079.561	2.504.024	2.944.771
Octubre	2.216.432	2.675.112	3.081.641
Noviembre	2.226.209	2.687.333	3.091.418
Diciembre	2.068.664	2.490.402	2.933.873
Total	25.092.241	30.220.168	35.474.751

Fuente: Elaboración propia

Así de esta manera podemos dar valores confiables en vez de dar un valor que tiene cierto grado de incertidumbre, podemos decir entonces ahora que el modelo de red neuronal y lógica difusa muestra valores confiables.

4.1.7 PROTOTIPO

Fig.28 Ventana de inicio

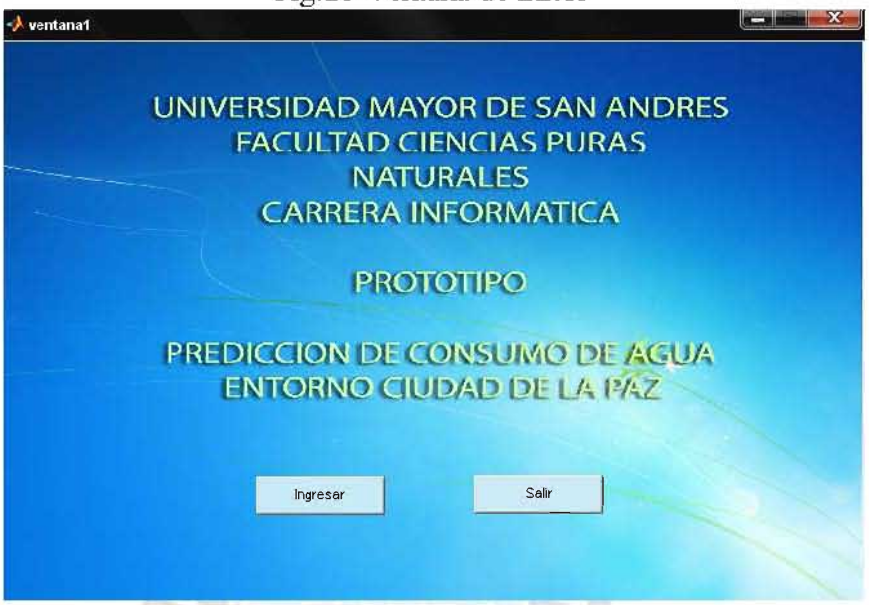

Fuente: Elaboración propia

Fig. 29 Ventana de cálculos

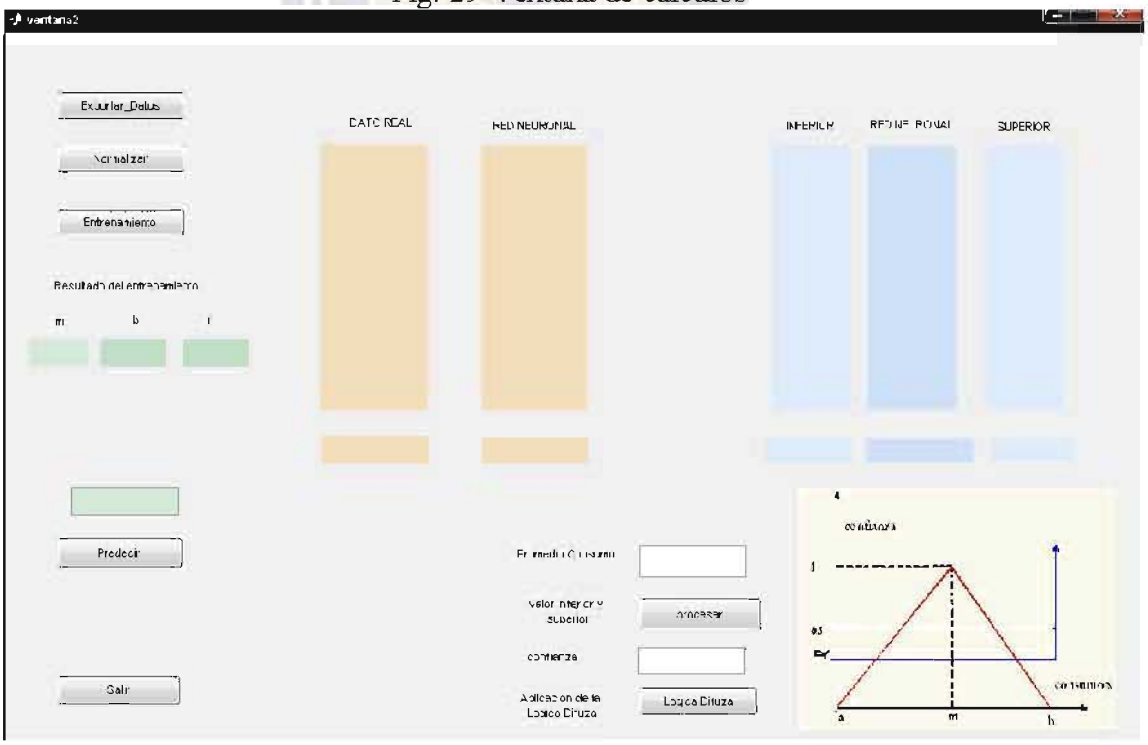

Fuente: Elaboración propia

Fig. 30 Inicialización de datos

Fuente: Elaboración propia

Fig. 31 Resultados de redes neuronales y lógica difusa

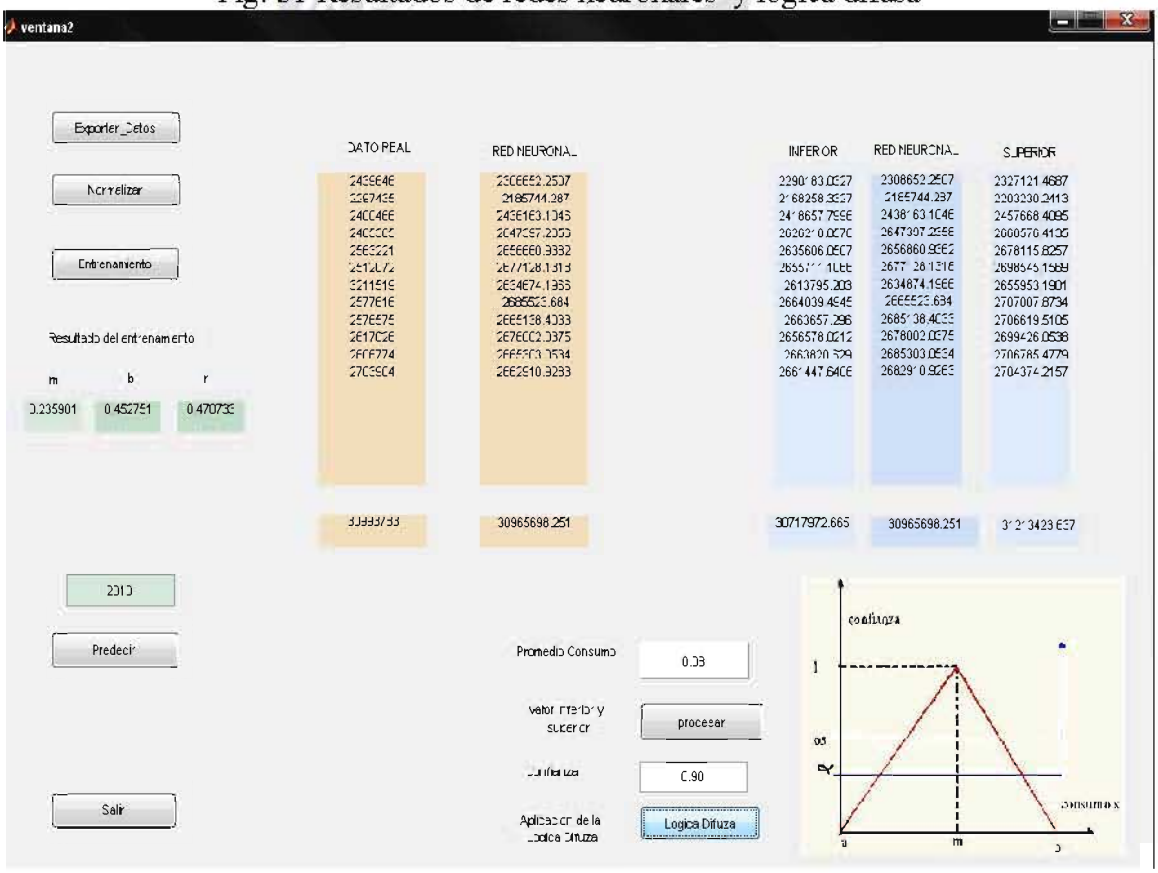

Fuente: Elaboración Propia

5

Conclusiones y Recomendaciones

5.1 CONCLUSIONES

El modelo neuronal con una estructura de 4 entradas y una capa oculta de 8 y una salida, ha sido capaz de predecir el consumo de agua potable con una precisión del 90%,con un error del 10%, además efectuando el análisis de la regresión del modelo, esta arroja un resultado bastante satisfactorio con un R=0.9178, lo que significa que los resultados obtenidos por el modelo de red neuronal propuesto se acercan en gran medida a los resultados reales, y con la incorporación de la lógica difusa al 90% de veracidad del la predicción de consumo de agua se convierte en un modelo eficaz en la predicción del consumo de agua potable.

Se cumplió con el objetivo general y específicos, ya que con el modelo propuesto se puede realizar predicciones en un tiempo t, como también se incorporó al estudio las variables descritas en el objetivos específicos, también se realizó un prototipo de predicción del consumo de agua.

El estudio realizado ofrece una información confiable del consumo de agua, solucionando así el problema de falta de información del consumo de agua en un tiempo t futuro, y además también de esta manera cumplimos con nuestros objetivos planteados.

5.2 ESTADO DE LA HIPOTESIS

La hipótesis de investigación planteada indica: *"La aplicación de redes neuronales y lógica difusa al consumo de agua potable, permitirá predecir la demanda del agua en los siguientes años, con una efectividad del 60%."*.

Con las conclusiones anteriores podemos afirmar que efectivamente se realizó la aplicación de la red neuronal y la lógica difusa, primeramente utilizando un modelo de red neuronal, que alimentada por variables que afectan en el consumo de agua, se

predijo el consumo de agua para un tiempo t, con una efectividad del 90%, y con la incorporación de la lógica difusa al consumo de agua los resultado de veracidad superaron en gran media, entonces la combinación de la red neuronal y lógica difusa tiene una efectividad de unos 98%, sobrepasando la efectividad planteada en la hipótesis.

En conclusión el modelo de red neuronal y lógica difusa superó las expectativas de efectividad, podemos decir entonces que el trabajo realizado tiene un gran nivel informativo que es lo que se quería resolver en el problema planteado.

5.3 RECOMENDACIONES

En cuanto a las series de datos, se recomienda que estas sean obtenidas de una fuente fidedigna, porque si los datos no reflejan la veracidad de nuestro campo de aplicación de ninguna o poca ayuda será para el modelo propuesto.

Este trabajo considera información de la ciudad de La Paz, también se puede tomar en cuenta los datos de la ciudad del Alto, ya que tiene un similar comportamiento en el consumo de agua potable.

Tomar una cantidad mayor de información (datos históricos de años pasados), para analizar el comportamiento del modelo

5.4 TRABAJOS FUTUROS

Para trabajos futuros se recomienda utilizar otras variables como: consumo de agua doméstico, consumo de agua industrial, días de consumo alto o bajo.

Resultaría sumamente interesante aplicar otro método de la inteligencia artificial para la resolución de este problema, como las redes neurodifuso, aplicada a variables de incertidumbre o algoritmos genéticos.

Realizar una comparación de un modelo estadístico, con las redes neurodifusos, o el modelo de red neuronal.

Combinar (Hibridación) de las redes neuronales con otro modelo como el ARIMA, u otro modelo de predicción, para comparar resultados con el presente trabajo.

Para trabajos futuros realizar predicciones, con variables que afecten al consumo de agua, para predecir el consumo de agua para toda Bolivia, mostrando resultados de consumo por departamento y el total consumido de agua potable en Bolivia.

UNIVERSITAS MAJOR PACENSIS DIVI ANDRE Æ

6. BIBLIOGRAFIA

PUBLICACIONES, TRABAJOS Y TESIS

[PND, 2005] PLAN NACIONAL DE DESARROLLO, 2005, AGUA PARA LA GENTE - SANEAMIENTO BÁSICO, Ministerio de agua y medio ambiente, Bolivia

[Foster, 2006] David Foster Hales, 2006, La población del mundo que aumenta a razón de unos 90 millones de personas por año / Fuente: David Foster Hales, vice administrador adjunto del CentroMundial para el Medio Ambiente de la Agencia de Estados Unidos para el Desarrollo Internacional (USAID).

[Gonzales et al., 2007] Javier Gonzales Iwanciw, Jorge Cusicanqui Giles, Marilyn Aparicio Effen, 2007, MINISTERIO DE PLANIFICACIÓN DEL DESARROLLO, Programa Nacional de Cambios Climáticos, BOLIVIA

[Bonissone, 1980] Bonissone, Piero P., 1980, A Fuzzy Sets Based Linguistic Approach: Theory and Applications. pags. 99-109. General Electric CompanyCorporateResearch and Development.

[Barón, 1998] María del Pilar Barón Duarte, 1998, Sistema de Control Integrado Neurofuzzy, Universidad Distrital Francisco José de caldas, facultad de ingeniería, Santafé de Bogotá d.c.

[Morgan &Scofield, 1991] D.P.Morgan, C.L. Scofield, 1991, "Neural Networks and Speech Processing", Kluwer Academic Publishers 1991.

[Blondel, 2010] AlvaroBlondelRossetti, COORDINACIÓN Y SUPERVISIÓN GENERAL, 2010, Compendio de Estadísticas Ambientales del Municipio de La Paz, 2000-2010, Oficial Mayor de Planificación para el Desarrollo, La Paz - Bolivia.

[Marin& Alonso, 2003] Gonzalo Marín - Ingeniería sin fronteras y Colaboración de José A. Alonso- ICEI, 2003, EL AGUA Y EL DESARROLLO HUMANO SOSTENIBLE PRINCIPALES PROBLEMAS Y DESAFÍOS

[UMSS, 2009] UMSS, 2009, Abastecimiento de agua potable, Universidad Mayor de San Simón - facultad de ciencias y tecnología, Bolivia

[AAPS, 2010] AAPS, 2010, AUTORIDAD DE AGUA POTABLE Y SANEAMIENTO, Av. Mariscal Santa Cruz, Edif. Cámara de Comercio, Piso 16, La Paz-Bolivia

[Freeman, 1993] Freeman James y SKAPURA David, 1993, "Redes Neuronales: Algoritmos, aplicaciones y técnicas de programación". Delaware E.U.A. Addison Wesley Iberoamericana S.A.

[Basogain, 2008] Xabier BasogainOlabe, 2008, Redes Neuronales y sus Aplicaciones, Escuela superior de Bilbao

[Hilera & Martínez, 1995] Hilera Jose R, MartinezVictor J., 1995, Redes Neuronales Artificiales, Fundamentos, modelos y aplicaciones, Estados Unidos: Addison-Wesley Iberoamericana, serie paradigma, ISBM-201-87895-X

[Matich, 2001] Damián Jorge Matich, 2001, Redes Neuronales: Conceptos Básicos y Aplicaciones, Universidad Tecnológica Nacional – Facultad Regional Rosario

[Larrañaga et al, 2002] Pedro Larrañaga, Iñaki Inza, AbdelmalikMoujahid, 2002, Redes Neuronales, Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad del País Vasco.

[Daza, 2008] Dr. Francisca Daza Sánchez, 2008, DEMANDA DE AGUA EN ZONAS URBANAS EN ANDALUCÍA, Universidad de Córdoba, DEPARTAMENTO DE ESTADÍSTICA, ECONOMETRÍA, I.O. Y ORGANIZACIÓN DE EMPRESAS

[Choque, 2002] Choque Guillermo A., 2002: Inteligencia Artificial-Perspectivas y realizaciones, Disponible: http://academic.umsanet.edu.bo/docentes/gchoque

[Bowerman&O´Conell, 1993] Bowerman B. O´Conell R., 1993, Fore casting an time sereies: an applied approach (3ra Ed.). California, USA: DuxburyPress.

[Díez, 2005] Díez, F. J., 2005, Introducción al Razonamiento Aproximado, Dpto. Inteligencia Artificial UNED, 1ª Edición Octubre 1998, Revisión Noviembre 2005.

[Lizarrazo, 2006] Juan Manuel LizarrazoMarriaga, 2006, Desarrollo de un Modelo de redes neuronales para predecir la resistencia a la compresión y la resistividad eléctrica del concreto, Universidad Nacional de Colombia - Facultad de Ingeniería.

[Morgan, 1991] D.P.Morgan, C.L. Scofield, "Neural Networks and Speech Processing", 1991, Kluwer Academic Publishers 1991.

[Williams & Wilkin, 2003] Rhoades RA, Tanner GA. Medical Physiology, 2003, 2nd ed. editions, Baltimore: Lippincott Williams & Wilkins, OCLC 50554808. ISBN 0781719364.

[Utz, 2003] Jeffrey Utz, M.D., 2003,¿Qué porcentaje del cuerpo es agua?, TheMadSci Network

[Crespo, 2006] El país que no tiene agua o que tiene dificultades con el agua está condenado al subdesarrollo, salvo que tenga petróleo o algún otro recurso en cantidades ingentes, Alberto Crespo, 2006, en "La crisis del agua refleja otras crisis".

[Shiklomanov, 1999] Estudio de Igor A. Shiklomanov, 1999, Tendencias en el consumo humano e industrial de agua, y su relación el ritmo de la evaporación de las reservas, Instituto Hidrológico Estatal (SHI, San Petersburgo) y Unesco, París, 1999.

[Gleick, 2006] Gleick, Peter H., 2006,The World's Water: The Biennial Report on Freshwater Resources, Washington: Island Press. (10 de November de 2006).

[UNESCO, 2006] Water a shared responsibility, UNESCO, 2006, The United Nations World Water Development Report 2.

[Walhs, 2010] EIA Proyecto de Desarrollo del Área Sur,Walsh, 2010.

[Gispert, 2000] Cristina de GispertBrosa, 2000: *Tributos ambientales sobre el agua y el comportamiento del sector industrial*. Tesis de grado. Barcelona.

[Larman, 1999] Larman C. (1999). UML y Patrones, Introducción al análisis y diseño orientado a objetos. Mexico: Pretince Hall.

[Jacobson et al, 2000] Jacob I. Booch G., Runbaugh I. (2000). *El proceso Unificado de Desarrollo de Software*. Madrid: Addison Wesly.

[Bowerman&O´Conell, 1993] Bowerman B. O´Conell R. (1993) *Fore casting an time sereies: an applied approach (3ra Ed.)*. California, USA: DuxburyPress.

[Pressman, 2003] Pressman, Roger S., 2003: *Ingeniería del software en un enfoque práctico,* 601. Quinta edición. McGRawHill. Editorial Concepción Fernández. Madrid España.

[Matich, 2001] *Damián Jorge Matich, Redes Neuronales: Conceptos Básicos y Aplicaciones, 2001,* Universidad Tecnológica Nacional – Facultad Regional Rosario.

[Rivas &Marelo, 2005] V. M. Rivas, M.G. Arenas & J. Merelo, A. Prieto, *Predicción de consumo de agua mediante redes neuronales de funciones base radiales evolutivas, 2005,* Departamento de Informática Universidad de Jaén EPS de Jaén &Depto. De Arquitectura y Tecnología de Computadores Universidad de Granada ETS Ingeniería Informática.

[Barlow, 2001] MaudeBarlow Presidenta nacional del Council of Canadians (Consejo de los Canadienses), Presidenta del Comité sobre mundialización del agua del IFG, *EL ORO AZUL La crisis mundial del agua y la reificación de los recursos hídricos del planeta*, 20001, El Ceibo T.B

[Aude, 2007] W.H. Aude, *El Agua Nuestro Bien Común,* 2007, México, Centroamérica y el Caribe.

[Grosse et al., 2006] Grosse, R.; Santos, C.; Taks, J. &Thimmel, S., Las Canillas Abiertas de América Latina II, Edición: Casa Bertolt Brecht., 2006, Montevideo, Uruguay.

[Rico, 2007] Antonio M. Rico Amorós, *Tipologías de consumo de agua en abastecimientos urbano-turísticos de la comunidad de Valencia*, Instituto Universitario de Geografía, 2007, Universidad de Alicante.

[Sepúlveda, 2007] Karina Sepúlveda Pino, *Modelo Matemático para Predecir el Comportamiento del Silicio en el Proceso de Obtención del Arrabio en el Departamento de Altos Hornos en la Compañía Siderúrgica Huachipato S.A.*, 2007, Universidad BioBio, Concepción.

[UNC, 2008] Facultad de Ciencias Exactas, *Investigación Operativa I*, 2008, Universidad Nacional del Centro (UNC).

[Bustos, 2007] M. En C. Eduardo Bustos Farías, *Modelo de Pronostico,* 2007, Instituto Politécnico Nacional, Escuela Superior de Cómputo.

[Oliveros, 2006] Lic. Esp. Miguel Oliveros, *Pronósticos*, 2006, Universidad de los Andes, Facultad de Ciencias Económicas y Sociales, Escuela de Administración y Contaduría Pública, Departamento de Ciencias Administrativas, Administración de la Producción y las Operaciones I.

[Encarta, 2008] Enciclopedia Encarta 2008 en Español.

[Quiroz, 2009] *Franz Quiroz*, 2009, El apoyo a comités de agua potable: Historia y experiencias para lograr su sostenibilidad.

REFERENCIA ELECTRONICAS

[Ali, 2000] El Agua, Ismael Ali Gago, 2000, Disponible: http://platea.pntic.mec.es/iali/personal/agua/index.htm

[ANC, 2008] El agua portable es segura es esencial, Academia Nacional de Ciencias, 2008, Disponible: http://drinking-water.org/html/es/index.html

[IAMA, 2000] El agua, ingeniería ambiental y medio ambiente, 2000, Disponible: http://agua2.html

[Lemuz, 2011] Carlos Lémuz, 2011, Proyectada ampliación de la represa de Hampaturi podría poner en riesgo importante patrimonio natural y arqueológico del municipio de la paz, Sociedad de Arqueología de La Paz, Bolivia,

Disponible: http://www.ahorabolivia.com/2011/07/22/proyectada-ampliacion-de-la-represa-de-hampaturi-podria-poner-en-riesgo-importante-patrimonio-natural-y-arqueologico-del-municipio-de-la-paz/

[ONU, 2006] ONU, *El agua, una responsabilidad compartida 2° Informe de las Naciones Unidas sobre el Desarrollo de los Recursos Hídricos en el Mundo*, 2006, Disponible: www.unesco.org/water/wwap/index_es.shtml

[INE, 2008] INE, *Estadísticas e indicadores del agua, 2008,* Disponible: www.ine.es

[Choque, 2002] Choque Guillermo A., 2002: *Inteligencia Artificial-Perspectivas y realizaciones,* Disponible: http://academic.umsanet.edu.bo/docentes/gchoque

[Heinrich, 2006] Fundación Heinrich Böll, Oficina Regional para C.A., México y Cuba, *La gota de la vida: Hacia una gestión sustentable y democrática del agua*, Impreso en México por: Frente & Vuelta, 2006, Disponible: www.boell-latinoamerica.org.

[Jiménez, 2000] Joel N. Jiménez Lozano, *El agua,* Disponible: http://ciencias.jornada.com.mx/ciencias/investigacion/ciencias-de-la-tierra/investigacion/el-agua

[RAE, 2008] Diccionario, Real Academia Española, Consumo, 2008-2010, Disponible: www.realacademiaespañola.com

[DefABC, 2008] Definición ABC, Consumo, 2008 – 2010, Disponible: www.definiconABC.com

[DEF, 2007] Definiciones, Definición de CONSUMO, 2007, Disponible: www.definiciones.com.mx

ANEXOS

ARBOL DE PROBLEMA

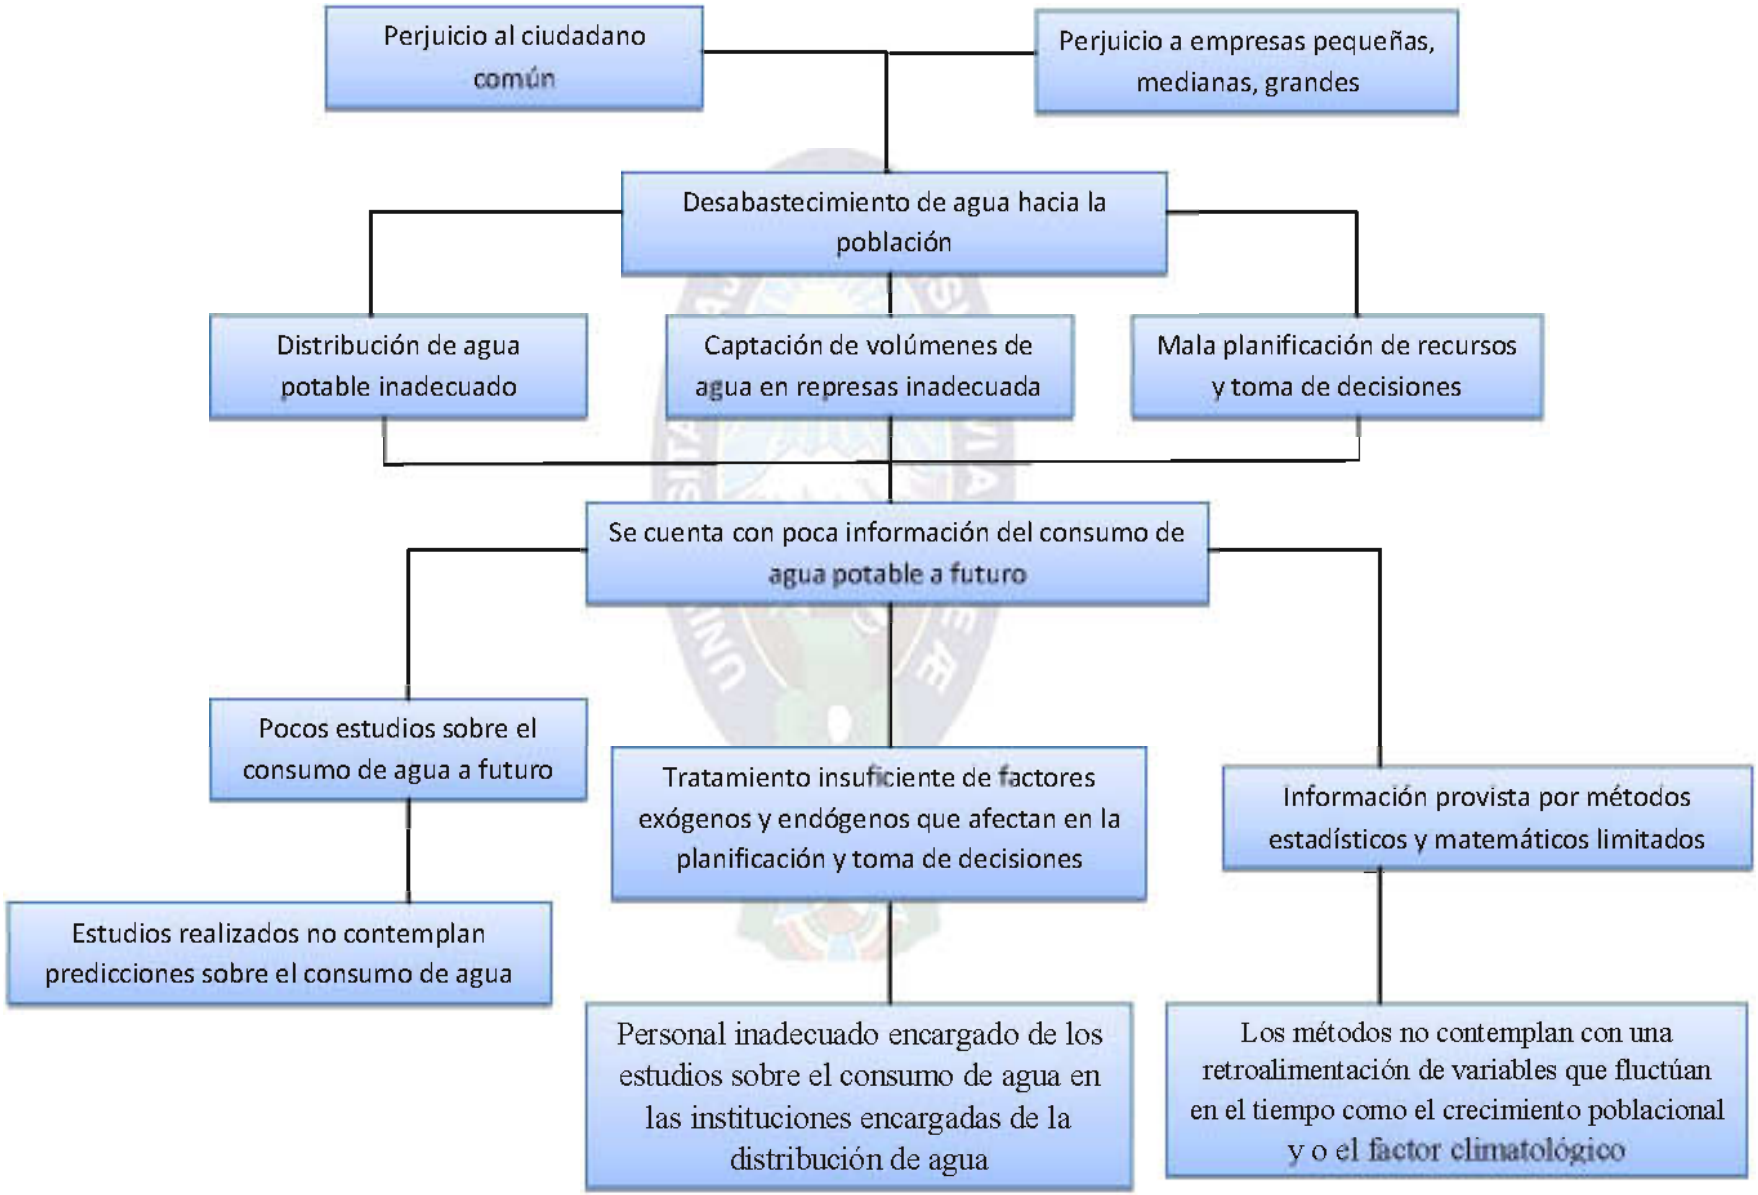

ANEXO A

Datos de: Consumo de agua por mes y año
Fuente: EPSAS

M/año	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
Enero	2.635.991	2.659.669	2.632.522	2.652.522	2.649.680	2.520.238	2.350.232	2.582.782	2.512.238	2.550.711	2.510.138	2.439.848
Febrero	2.554.366	2.574.554	2.452.431	2.552.437	2.564.254	2.464.144	2.354.374	2.515.264	2.374.134	2.128.930	2.466.045	2.297.436
Marzo	2.563.856	2.587.756	2.462.805	2.452.805	2.467.805	2.452.325	2.352.683	2.477.645	2.412.325	2.250.766	2.321.319	2.400.488
Abril	2.596.834	2.659.732	2.611.223	2.551.653	2.529.623	2.508.572	2.325.368	2.549.573	2.428.553	2.554.466	2.520.571	2.485.305
Mayo	2.669.544	2.672.435	2.535.551	2.635.552	2.629.551	2.526.438	2.382.459	2.589.552	2.529.438	2.646.688	2.536.419	2.563.221
Junio	2.666.963	2.698.455	2.541.232	2.684.232	2.694.283	2.515.349	2.375.334	2.576.387	2.511.349	2.668.666	2.517.440	2.512.072
Julio	2.758.945	2.745.978	2.623.648	2.683.678	2.735.668	2.571.647	2.341.561	2.569.768	2.531.647	2.468.767	2.540.043	3.211.519
Agosto	2.593.989	2.565.832	2.458.324	2.459.326	2.409.866	2.418.145	2.335.454	2.515.376	2.418.145	2.611.103	2.518.145	2.577.617
Septiembre	2.583.964	2.546.556	2.556.532	2.566.551	2.506.550	2.503.265	2.373.775	2.537.782	2.493.265	2.642.425	2.595.560	2.576.575
Octubre	2.658.987	2.657.454	2.454.401	2.588.491	2.498.401	2.407.378	2.327.569	2.573.451	2.406.358	2.728.645	2.687.358	2.617.026
Noviembre	2.677.538	2.661.859	2.540.453	2.570.632	2.620.699	2.525.538	2.365.889	2.580.689	2.515.436	2.724.580	2.720.538	2.608.775
Diciembre	2.566.768	2.592.867	2.522.310	2.582.819	2.587.819	2.446.734	2.336.956	2.545.797	2.456.534	2.592.111	2.317.734	2.703.904
Total año	31.527.745	31.623.147	30.391.432	30.980.698	30.894.199	29.859.773	28.221.654	30.614.066	29.589.422	30.567.858	30.251.310	30.993.785

ANEXO B

DATOS DE : TEMPERATURA MÁXIMA MEDIA (ºC)

Fuente: SENAMI

AÑO	ENE	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC
1990	17,2	18,3	18,8	18,4	17,4	14,8	15,6	17,6	19,0	18,9	18,9	19,1
1991	18,6	19,6	19,0	19,5	19,2	16,6	16,2	16,5	16,7	18,5	18,8	20,2
1992	18,0	19,0	20,4	20,0	20,0	17,2	16,4	16,2	18,7	18,5	19,1	19,0
1993	16,8	18,7	17,5	18,1	18,7	18,4	17,5	16,8	18,9	19,0	20,2	19,5
1994	18,6	18,5	18,8	18,5	19,4	17,8	17,0	18,8	19,7	20,2	20,4	20,2
1995	19,4	20,1	18,6	20,2	19,8	18,7	18,9	20,2	19,1	21,7	20,7	19,2
1996	17,8	18,9	20,2	19,5	19,2	17,6	17,2	18,2	19,7	20,9	19,7	18,2
1997	18,6	17,2	16,8	18,2	18,7	18,7	19,4	17,9	19,4	21,4	21,0	22,9
1998	21,8	21,2	21,5	21,1	20,7	17,9	18,8	19,8	21,2	20,7	20,6	21,5
1999	19,5	18,5	17,6	18,5	19,1	18,8	17,8	19,3	19,3	19,0	20,8	20,9
2000	20,2	19,2	20,2	21,2	20,7	17,5	17,6	19,0	21,4	19,5	23,2	20,6
2001	17,2	18,0	19,1	20,6	19,6	18,8	18,5	17,8	20,0	20,3	22,6	20,2
2002	20,4	18,6	19,0	18,7	19,3	18,4	15,8	18,9	20,1	19,1	21,1	20,6
2003	19,5	20,0	18,9	20,3	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	18,3	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	18,3	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	17,3	19,5	17,5	20,8	20,3	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
SUMA	395,5	401,9	404,9	412,8	407,1	382,2	372,4	393,1	409,5	424,4	439,0	427,5
MEDIA	18,8	19,1	19,3	19,7	19,4	18,2	17,7	18,7	19,5	20,2	20,9	20,4

ANEXO C

Datos de: Conexiones de agua mas población consumidora de agua
Fuente: EPSAS

AÑO	CONEXIONES ACTIVAS	Población servida Agua Potable
1999	90.042	597.854
2000	93.221	662.988
2001	96.401	675.054
2002	99.467	687.120
2003	101.653	720.468
2004	103.179	747.474
2005	105.699	761.836
2006	108.418	785.523
2007	112.103	815.593
2008	114.666	830.341
2009	117.050	844.115
2010	119.019	854.996

ANEXO D

Estructuración de datos e resultados de la Predicción
(Elaboración en base a los datos EPSAS y SENAMI)

Tiempo año	Mes	Población	Nro._conexiones	Temperatura	Consumo de agua (m3)	RNN	Erro Ab.
1999	0	597.854	90.042	19,5	2.635.991	2.642.781	6.790
1999	1	597.854	90.042	18,5	2.554.366	2.541.235	-13.131
1999	2	597.854	90.042	17,6	2.563.856	2.568.325	4.469
1999	3	597.854	90.042	18,5	2.596.834	2.588.666	-8.168
1999	4	597.854	90.042	19,1	2.669.544	2.674.583	5.039
1999	5	597.854	90.042	18,8	2.666.963	2.709.232	42.269
1999	6	597.854	90.042	17,8	2.758.945	2.723.460	-35.485
1999	7	597.854	90.042	19,3	2.593.989	2.622.698	28.709
1999	8	597.854	90.042	19,3	2.583.964	2.610.502	26.538
1999	9	597.854	90.042	19,0	2.658.987	2.616.025	-42.962
1999	10	597.854	90.042	20,8	2.677.538	2.596.240	-81.298
1999	11	597.854	90.042	20,9	2.566.768	2.605.705	38.937
2000	0	662.988	93.221	20,2	2.659.669	2.660.652	983
2000	1	662.988	93.221	19,2	2.574.554	2.573.865	-689
2000	2	662.988	93.221	20,2	2.587.756	2.603.320	15.564
2000	3	662.988	93.221	21,2	2.659.732	2.666.093	6.361
2000	4	662.988	93.221	20,7	2.672.435	2.651.502	-20.933
2000	5	662.988	93.221	17,5	2.698.455	2.716.590	18.135
2000	6	662.988	93.221	17,6	2.745.978	2.681.439	-64.539
2000	7	662.988	93.221	19,0	2.565.832	2.567.030	1.198
2000	8	662.988	93.221	21,4	2.546.556	2.543.643	-2.913
2000	9	662.988	93.221	19,5	2.657.454	2.579.318	-78.136
2000	10	662.988	93.221	23,2	2.661.859	2.644.003	-17.856
2000	11	662.988	93.221	20,6	2.592.867	2.607.870	15.003
2001	0	675.054	96.401	17,2	2.632.522	2.567.999	-64.523
2001	1	675.054	96.401	18,0	2.452.431	2.539.793	87.362
2001	2	675.054	96.401	19,1	2.462.805	2.488.227	25.422
2001	3	675.054	96.401	20,6	2.611.223	2.609.374	-1.849
2001	4	675.054	96.401	19,6	2.535.551	2.603.156	67.605
2001	5	675.054	96.401	18,8	2.541.232	2.630.937	89.705
2001	6	675.054	96.401	18,5	2.623.648	2.592.356	-31.292
2001	7	675.054	96.401	17,8	2.458.324	2.573.204	114.880
2001	8	675.054	96.401	20,0	2.556.532	2.524.994	-31.538
2001	9	675.054	96.401	20,3	2.454.401	2.550.691	96.290
2001	10	675.054	96.401	22,6	2.540.453	2.568.750	28.297
2001	11	675.054	96.401	20,2	2.522.310	2.597.934	75.624

2002	0	687.120	99.467	20,4	2.652.522	2.643.983	-8.539
2002	1	687.120	99.467	18,6	2.552.437	2.510.009	-42.428
2002	2	687.120	99.467	19,0	2.452.805	2.459.382	6.577
2002	3	687.120	99.467	18,7	2.551.653	2.528.859	-22.794
2002	4	687.120	99.467	19,3	2.635.552	2.585.349	-50.203
2002	5	687.120	99.467	18,4	2.684.232	2.625.141	-59.091
2002	6	687.120	99.467	15,8	2.683.678	2.715.838	32.160
2002	7	687.120	99.467	18,9	2.459.326	2.503.041	43.715
2002	8	687.120	99.467	20,1	2.566.551	2.494.773	-71.778
2002	9	687.120	99.467	19,1	2.588.491	2.519.960	-68.531
2002	10	687.120	99.467	21,1	2.570.632	2.552.388	-18.244
2002	11	687.120	99.467	20,6	2.582.819	2.580.082	-2.737
2003	0	720.468	101.653	19,5	2.649.680	2.635.682	-13.998
2003	1	720.468	101.653	20,0	2.564.254	2.564.320	66
2003	2	720.468	101.653	18,9	2.467.805	2.496.706	28.901
2003	3	720.468	101.653	20,3	2.529.623	2.564.124	34.501
2003	4	720.468	101.653	19,4	2.629.551	2.600.503	-29.048
2003	5	720.468	101.653	18,9	2.694.283	2.603.810	-90.473
2003	6	720.468	101.653	17,8	2.735.668	2.615.897	-119.771
2003	7	720.468	101.653	19,1	2.409.866	2.526.198	116.332
2003	8	720.468	101.653	19,1	2.506.550	2.527.814	21.264
2003	9	720.468	101.653	21,2	2.498.401	2.535.082	36.681
2003	10	720.468	101.653	21,6	2.620.699	2.564.632	-56.067
2003	11	720.468	101.653	20,8	2.587.819	2.597.785	9.966
2004	0	747.474	103.179	17,8	2.520.238	2.530.606	10.368
2004	1	747.474	103.179	18,9	2.464.144	2.447.736	-16.408
2004	2	747.474	103.179	20,0	2.452.325	2.434.329	-17.996
2004	3	747.474	103.179	20,5	2.508.572	2.534.372	25.800
2004	4	747.474	103.179	19,4	2.526.438	2.520.241	-6.197
2004	5	747.474	103.179	18,3	2.515.349	2.547.294	31.945
2004	6	747.474	103.179	16,9	2.571.647	2.569.647	-2.000
2004	7	747.474	103.179	17,5	2.418.145	2.455.787	37.642
2004	8	747.474	103.179	19,7	2.503.265	2.414.416	-88.849
2004	9	747.474	103.179	22,2	2.407.378	2.453.312	45.934
2004	10	747.474	103.179	21,5	2.525.538	2.463.031	-62.507
2004	11	747.474	103.179	21,8	2.446.734	2.496.372	49.638
2005	0	761.836	105.699	19,2	2.350.232	2.386.064	35.832
2005	1	761.836	105.699	18,4	2.354.374	2.339.281	-15.093
2005	2	761.836	105.699	20,9	2.352.683	2.353.119	436
2005	3	761.836	105.699	19,6	2.325.368	2.334.350	8.982
2005	4	761.836	105.699	20,5	2.382.459	2.338.247	-44.212

2005	5	761.836	105.699	19,0	2.375.334	2.390.872	15.538
2005	6	761.836	105.699	18,8	2.341.561	2.364.788	23.227
2005	7	761.836	105.699	20,1	2.335.454	2.308.501	-26.953
2005	8	761.836	105.699	18,3	2.373.775	2.356.101	-17.674
2005	9	761.836	105.699	19,0	2.327.569	2.352.010	24.441
2005	10	761.836	105.699	20,4	2.365.889	2.351.981	-13.908
2005	11	761.836	105.699	21,7	2.336.956	2.362.853	25.897
2006	0	785.523	108.418	17,6	2.582.782	2.588.986	6.204
2006	1	785.523	108.418	19,7	2.515.264	2.438.188	-77.076
2006	2	785.523	108.418	19,8	2.477.645	2.421.683	-55.962
2006	3	785.523	108.418	19,5	2.549.573	2.518.508	-31.065
2006	4	785.523	108.418	18,9	2.589.552	2.577.012	-12.540
2006	5	785.523	108.418	18,0	2.576.387	2.593.772	17.385
2006	6	785.523	108.418	18,8	2.569.768	2.518.770	-50.998
2006	7	785.523	108.418	18,9	2.515.376	2.496.625	-18.751
2006	8	785.523	108.418	19,6	2.537.782	2.488.372	-49.410
2006	9	785.523	108.418	20,9	2.573.451	2.494.644	-78.807
2006	10	785.523	108.418	20,4	2.580.689	2.508.588	-72.101
2006	11	785.523	108.418	20,2	2.545.797	2.527.487	-18.310
2007	0	815.593	112.103	19,7	2.512.238	2.538.963	26.725
2007	1	815.593	112.103	19,2	2.374.134	2.391.046	16.912
2007	2	815.593	112.103	18,4	2.412.325	2.427.864	15.539
2007	3	815.593	112.103	19,4	2.428.553	2.503.475	74.922
2007	4	815.593	112.103	18,8	2.529.438	2.559.620	30.182
2007	5	815.593	112.103	19,1	2.511.349	2.529.193	17.844
2007	6	815.593	112.103	17,3	2.531.647	2.553.224	21.577
2007	7	815.593	112.103	19,5	2.418.145	2.488.784	70.639
2007	8	815.593	112.103	17,5	2.493.265	2.494.352	1.087
2007	9	815.593	112.103	20,8	2.406.358	2.489.535	83.177
2007	10	815.593	112.103	20,3	2.515.436	2.495.256	-20.180
2007	11	815.593	112.103	19,8	2.456.534	2.504.814	48.280
2008	0	830.341	144.666	18,0	2.550.711	2.527.861	-22.851
2008	1	830.341	144.666	19,7	2.128.931	2.198.804	69.874
2008	2	830.341	144.666	18,6	2.250.767	2.208.423	-42.344
2008	3	830.341	144.666	19,9	2.554.467	2.555.230	763
2008	4	830.341	144.666	19,4	2.646.688	2.645.557	-1.131
2008	5	830.341	144.666	19,1	2.668.667	2.637.960	-30.707
2008	6	830.341	144.666	18,8	2.468.768	2.542.238	73.471
2008	7	830.341	144.666	20,1	2.611.104	2.683.270	72.167
2008	8	830.341	144.666	20,8	2.642.426	2.685.248	42.822
2008	9	830.341	144.666	20,6	2.728.645	2.684.118	-44.527

2008	10	830.341	144.666	22,7	2.724.581	2.685.279	-39.302
2008	11	830.341	144.666	19,9	2.592.111	2.593.017	906
2009	0	844.115	117.050	19,8	2.510.138	2.544.739	34.601
2009	1	844.115	117.050	20,1	2.466.045	2.443.726	-22.319
2009	2	844.115	117.050	19,7	2.321.319	2.371.744	50.425
2009	3	844.115	117.050	19,5	2.520.571	2.478.075	-42.496
2009	4	844.115	117.050	19,4	2.536.419	2.517.455	-18.964
2009	5	844.115	117.050	19,1	2.517.440	2.512.486	-4.954
2009	6	844.115	117.050	18,2	2.540.043	2.509.268	-30.775
2009	7	844.115	117.050	20,1	2.518.145	2.485.804	-32.341
2009	8	844.115	117.050	20,7	2.595.560	2.504.024	-91.536
2009	9	844.115	117.050	21,9	2.687.358	2.675.112	-12.246
2009	10	844.115	117.050	22,5	2.720.538	2.687.333	-33.205
2009	11	844.115	117.050	20,5	2.317.734	2.490.402	172.668
2010	0	854.996	119.019	19,8	2.439.848	2.308.652	-131.196
2010	1	854.996	119.019	20,1	2.297.436	2.185.744	-111.691
2010	2	854.996	119.019	21,1	2.400.488	2.438.163	37.675
2010	3	854.996	119.019	21,6	2.485.305	2.647.397	162.092
2010	4	854.996	119.019	19,5	2.563.221	2.656.861	93.640
2010	5	854.996	119.019	19,5	2.512.072	2.677.128	165.056
2010	6	854.996	119.019	19,1	3.211.519	2.634.874	-576.645
2010	7	854.996	119.019	20,8	2.577.617	2.685.524	107.907
2010	8	854.996	119.019	20,6	2.576.575	2.685.138	108.563
2010	9	854.996	119.019	20,1	2.617.026	2.678.002	60.976
2010	10	854.996	119.019	22,5	2.608.775	2.685.303	76.529
2010	11	854.996	119.019	20,7	2.703.904	2.682.911	-20.993