

# **ESCUELA POLITÉCNICA NACIONAL**

**FACULTAD DE INGENIERÍA CIVIL Y AMBIENTAL**

**REDES NEURONALES ARTIFICIALES APLICADAS A LA  
MODELACIÓN PRECIPITACIÓN – ESCURRIMIENTO DE LA  
CUENCA DE HUMBOLDT EN EL VOLCAN ANTISANA**

**TESIS PREVIA A LA OBTENCIÓN DEL GRADO DE MASTER (MSc) EN  
RECURSOS HÍDRICOS**

**ALEXIS GABRIEL AGUILAR ALEGRÍA**

alexis\_aga@hotmail.com

**DIRECTOR: MSc - MBA – ING. CARLOS OSWALDO PROAÑO SANTOS**

coproanos@yahoo.com

**CODIRECTOR: MSc-ING. PATRICIO RUBEN ORTEGA LARA**

patricio.ortega@epn.edu.ec

**Quito, Abril 2019**

## DECLARACIÓN

Yo, Alexis Gabriel Aguilar Alegría, declaro que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

La Escuela Politécnica Nacional, puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y por la normatividad institucional vigente.

---

**Alexis Gabriel Aguilar Alegría**

## **CERTIFICACIÓN**

Certifico que el presente trabajo fue desarrollado por Alexis Gabriel Aguilar Alegría, bajo mi supervisión.

---

**MSc. MBA .Ing. Carlos Oswaldo Proaño  
Santos**

**DIRECTOR DE PROYECTO**

## AGRADECIMIENTOS

A Jesús, que eres capaz de darme fuerza en mis momentos de flaqueza y permitirme creer que existe algo más grande para mí allá afuera.

A mis padres y hermanos por ser la inspiración y fortaleza en este camino a la culminación de mi carrera.

A mi tío Eddie y mi tía Mary, por creer en mí siempre y estar prestos con sus consejos.

A ti Daniela, por ser mi alegría y mi bálsamo en los momentos difíciles.

Gracias a mis tutor y amigo Oswaldo por ser mi guía durante todo este camino de conocimientos y aprendizaje.

A mi templo del saber cómo es la Escuela Politécnica Nacional por prestarme todas las facilidades para obtener información en sus bibliotecas y profesores.

A la empresa ICA Consultores, por mostrarte su apoyo y comprensión al momento de necesitar su ayuda para cumplir con la Maestría.

A todos, que de una u otra manera me apoyaron y fueron parte de este proyecto de titulación.

GRACIAS.

Alexis Gabriel Aguilar Alegría

## DEDICATORIA

A mi mamita Narcisa y a mi papito Rubén.

Les dedico mi tesis con todo mi amor.

*Alexis Gabriel Aguilar Alegría*

# CONTENIDO

## INDICE GENERAL

<b>DECLARACIÓN</b> .....	<b>i</b>
<b>CERTIFICACIÓN</b> .....	<b>ii</b>
<b>AGRADECIMIENTOS</b> .....	<b>iii</b>
<b>DEDICATORIA</b> .....	<b>iv</b>
<b>CONTENIDO</b> .....	<b>v</b>
<b>INDICE GENERAL</b> .....	<b>v</b>
<b>RESUMEN</b> .....	<b>xii</b>
<b>ABSTRACT</b> .....	<b>xiii</b>
<b>PRESENTACIÓN</b> .....	<b>xiv</b>
<b>CAPITULO 1   DEFINICIONES BASICAS DE REDES NEURONALES ARTIFICIALES</b> .....	<b>1</b>
1.1    INTRODUCCIÓN.....	1
1.2    EVOLUCIÓN EN EL TIEMPO DE LAS REDES NEURONALES ARTIFICIALES .....	1
1.3    DEFINICIÓN DE RED NEURONAL ARTIFICIAL (RNA) .....	3
1.4    APLICACIONES DE RNA .....	4
1.5    NEURONA BIOLÓGICA Y NEURONA ARTIFICIAL.....	5
1.6    FUNCIONES DE TRANSFERENCIA.....	7
1.6.1    FUNCIÓN ESCALÓN O LIMITADOR FUERTE .....	7
1.6.2    FUNCIÓN TRANSFERENCIA SEMI-LINEAL .....	8
1.6.3    FUNCIÓN TRANSFERENCIA SIGMOIDE.....	9
1.6.4    FUNCION DE TRANSFERECIA DE BASE RADIAL .....	10
1.7    ENTRENAMIENTO DE RNA.....	11
1.7.1    ENTRENAMIENTO NO SUPERVISADO .....	11
1.7.2    ENTRENAMIENTO SUPERVISADO .....	12
1.8    TOPOLOGÍA DE LAS REDES NEURONALES .....	16
1.8.1    ESTRUCTURA DE NEURONAS .....	16
1.8.2    ESTRUCTURA DE INTERCONEXIÓN.....	17
1.8.3    REDES NEURONALES AUTO-REGRESIVAS (RNAR).....	20
1.9    CLASIFICACIÓN DE REDES NEURONALES ARTIFICIALES (RNA) .....	20

<b>CAPITULO 2</b>	<b>REDES NEURONALES ARTIFICIALES APLICADAS A MODELOS</b>	
<b>PRECIPITACION-ESCURRIMIENTO.....</b>		<b>23</b>
2.1	DEFINICIONES HIDROLOGICAS .....	23
2.1.1	CICLO HIDROLÓGICO .....	23
2.1.2	MODELOS PRECIPITACION – ESCURRIMIENTO (P-E).....	24
2.1.3	ESCURRIMIENTO .....	25
2.1.4	FLUJO SUPERFICIAL DE SATURACIÓN.....	26
2.2	RNA PARA MODELOS P-E .....	27
2.2.1	BREVE RESEÑA HISTÓRICA DE RNA APLICADA A RELACION P-E .....	27
2.2.2	BENEFICIOS DE LAS RNAs APLICADA A LA RELACION P-E .....	30
2.3	CARACTERISTICAS DE LOS DATOS DE ENTRADAS Y SALIDAS DENTRO DE UNA RNA APLICADO A FENOMENOS DE P-E .....	32
2.3.1	VARIABLES DE ENTRADA PARA EL MODELO PRECIPITACIÓN- ESCURRIMIENTO.....	32
2.3.2	COMBINACIÓN DE LAS VARIABLES DE ENTRADA .....	33
2.3.3	PREPARACIÓN DE DATOS.....	33
2.3.4	PRE-PROCESAMIENTO DE DATOS.....	35
2.4	TIPOS DE ARQUITECTURAS DE RNAs APLICADA A LA RELACION P-E .....	37
2.4.1	CRITERIOS PARA DETERMINAR LA ARQUITECTURA ÓPTIMA DE RNA.....	39
2.4.2	INICIALIZACIÓN DE PESOS SINÁPTICOS DE LA RNA.....	40
2.5	EVALUACIÓN DE RNA.....	40
<b>CAPITULO 3</b>	<b>DESCRIPCIÓN DE LA PLATAFORMA UTILIZADA PARA RNA</b>	
<b>APLICADA A LA RELACION P-E.....</b>		<b>44</b>
3.1	HERRAMIENTA NN-TOOLBOX .....	44
3.2	PROCESO DE CREACION DE LA RNA UTILIZANDO NN-TOOLBOX.....	46
3.2.1	DATOS DE ENTRADA DE LA RNA.....	46
3.2.2	ARQUITECTURA DE LA RNA .....	47
3.2.3	ETAPA DE ENTRENAMIENTO .....	49
3.2.4	ETAPA DE VALIDACIÓN .....	50
<b>CAPITULO 4</b>	<b>ANALISIS DEL AREA DE ESTUDIO E INFORMACION BASE.....</b>	<b>51</b>
4.1	DESCRIPCION GENERAL DEL AREA DE ESTUDIO .....	51
4.2	CUENCA HUMBOLDT .....	52
4.3	DESCRIPCION CLIMATICA DE LA ZONA DE ESTUDIO.....	55
4.3.1	DATOS METEOROLÓGICOS.....	57
4.4	PRECIPITACION.....	60
4.5	HIDROLOGIA .....	61

4.5.1	ESTACIÓN LOS CRESPOS (MS28) .....	61
4.5.2	ESTACIÓN HUMBOLDT (MS21) .....	62
<b>CAPITULO 5 APLICACIÓN DE LAS RNA AL MODELO PRECIPITACION- ESCORRENTIA DE LA CUENCA HUMBOLDT .....</b>		<b>64</b>
5.1	PROCESO PARA EL DESARROLLO DE UN ESQUEMA DE RNAs APLICADO A MODELOS PRECIPITACION-ESCURRIMIENTO .....	64
5.2	SELECCIÓN DE DATOS .....	67
5.2.1	DETERMINACIÓN DEL INTERVALO DE TIEMPO DE LA SERIE DE DATOS .....	67
5.2.2	PREPARACIÓN DE PRECIPITACIONES DIARIAS .....	67
5.2.3	PREPARACIÓN DE CAUDALES DIARIOS .....	69
5.3	PREPROCESAMIENTO DE DATOS PARA RNA .....	69
5.4	SELECCIÓN DE VARIABLES DE MODELACION .....	77
5.4.1	IDENTIFICACIÓN DE DATOS PREDICTORES .....	77
5.5	SERIE DE DATOS PREPARADOS .....	78
5.6	ESTANDARIZACIÓN O NORMALIZACIÓN DE DATOS .....	78
5.7	CONJUNTO DE DATOS .....	79
5.8	ETAPA DE ENTRENAMIENTO DE LA RNA .....	79
5.8.1	SELECCIÓN DE NUMERO DE NEURONAS EN LA CAPA OCULTA .....	80
5.8.2	SELECCIÓN DE LOS DATOS DE ENTRADA PARA ENTRENAMIENTO DE LA RNA .....	81
5.8.3	SELECCIÓN DEL ALGORITMO DE ENTRENAMIENTO .....	85
5.8.4	SELECCIÓN DE LA FUNCIÓN DE TRANSFERENCIA .....	87
5.8.5	SELECCIÓN DEL NUMERO DE CAPAS OCULTAS .....	88
5.8.6	TEMPERATURA COMO VARIABLE DE ENTRADA .....	89
5.8.7	PREDICCIONES .....	90
5.9	ETAPA DE VALIDACION .....	92
5.10	ARQUITECTURA ÓPTIMA DE LA RNA APLICADA A LA RELACION P-E EN LA CUENCA DE HUMBOLDT .....	93
<b>CAPITULO 6 CONCLUSIONES Y RECOMENDACIONES .....</b>		<b>95</b>
6.1	CONCLUSIONES .....	95
6.2	RECOMENDACIONES .....	97
<b>REFERENCIAS BIBLIOGRAFICAS .....</b>		<b>99</b>
<b>ANEXO A .....</b>		<b>103</b>
<b>ALGORITMO LEVENBERG MARQUARDT .....</b>		<b>103</b>
<b>ANEXO B .....</b>		<b>107</b>



<b>ALGORITMO DE RETROPROPAGACION .....</b>	<b>107</b>
<b>ANEXO C .....</b>	<b>109</b>
<b>SCRIPT PARA MODELACION DE LA RNA PARA P-R .....</b>	<b>109</b>
<b>ANEXO D .....</b>	<b>110</b>
<b>RESUMEN DE PRUEBAS ENTRENADAS APLICANDO RNA PARA LA RELACION P-E EN LA CUENCA HUMBOLDT.....</b>	<b>110</b>

## INDICE DE TABLAS

<b>Tabla 1.1.</b> Aplicación de RNA .....	4
<b>Tabla 2.1.</b> Resumen de estudios previos en las RNA que se han empleado para P-E .....	38
<b>Tabla 3.1.</b> Formas de división de datos .....	47
<b>Tabla 3.2.</b> Funciones de transferencia NN-Toolbox .....	48
<b>Tabla 3.3.</b> Algoritmo de Entrenamiento .....	49
<b>Tabla 3.4.</b> Parámetros de Parada de entrenamiento de la red .....	50
<b>Tabla 4.1.</b> Resumen de las estaciones pluviométricas y pluviográficas.....	56
<b>Tabla 4.2.</b> Promedio mensual de la temperatura del aire, Estación ORE .....	57
<b>Tabla 4.3.</b> Humedad Relativa promedio mensual, Estación ORE .....	58
<b>Tabla 4.4.</b> Promedios mensuales de radiación incidente de onda corta - ORE .....	59
<b>Tabla 4.5.</b> Promedios mensuales de la velocidad del viento-ORE.....	59
<b>Tabla 5.1.</b> Disponibilidad de Precipitaciones diarias .....	68
<b>Tabla 5.2.</b> Disponibilidad de Caudales diarios.....	69
<b>Tabla 5.3.</b> Rangos de datos validos de la cuenca Humboldt .....	78
<b>Tabla 5.4.</b> Comparación de pruebas de entrenamiento variando el número de neuronas en capa oculta .....	80
<b>Tabla 5.5.</b> Comparación de pruebas con datos de entrada de precipitaciones .....	82
<b>Tabla 5.6.</b> Comparación de pruebas con datos de entrada de P-Q .....	84
<b>Tabla 5.7.</b> Resultados de pruebas comparativas con variación del Algoritmo de Entrenamiento .....	86
<b>Tabla 5.8.</b> Resultados de las pruebas comparativas de la función de transferencia. ....	87
<b>Tabla 5.9.</b> Resultados comparativos de Pruebas variando el Número de Capas Ocultas.....	88
<b>Tabla 5.10.</b> Resultados de pruebas con datos de entrada P-Q-T .....	89
<b>Tabla 5.11.</b> Resultados para Predicción QMS21→QMS21.....	91
<b>Tabla 5.12.</b> Resultados para Predicción QMS28-MS21→QMS21 .....	91
<b>Tabla 5.13.</b> Resultados de la Etapa de Validación .....	93

## INDICE DE FIGURAS

<b>Figura 1.1.</b> Representación de las características básicas de una neurona biológica .....	5
<b>Figura 1.2.</b> Esquema de la similitud de una neurona artificial con la neurona biológica .....	6
<b>Figura 1.3.</b> Función de transferencia de limitador fuerte.....	8
<b>Figura 1.4.</b> Función de transferencia semi-lineal .....	8
<b>Figura 1.5.</b> Función transferencia sigmoide .....	9
<b>Figura 1.6.</b> Función tangente hiperbólica .....	10
<b>Figura 1.7.</b> Función de base radial.....	10
<b>Figura 1.8.</b> Ejemplo de red hacia adelante de capa singular .....	17
<b>Figura 1.9.</b> Ejemplo de Red hacia adelante Multicapas .....	18
<b>Figura 1.10.</b> Ejemplo de Red Recurrente o Retroalimentación.....	19
<b>Figura 1.11.</b> Ejemplo de una red neuronal auto-regresiva .....	20
<b>Figura 1.12.</b> Clasificación de RNA.....	21
<b>Figura 1.13.</b> Clasificación de RNA en base a las entradas .....	22
<b>Figura 2.1</b> Representación esquemática del ciclo hidrológico .....	24
<b>Figura 2.2</b> Componentes de un hidrograma en un cauce .....	25
<b>Figura 2.3</b> Hidrogramas de cuatros modelos hipotéticos .....	43
<b>Figura 4.1</b> Ubicación general de la zona de estudio .....	51
<b>Figura 4.2</b> Ubicación Cuenca Humboldt.....	52
<b>Figura 4.3</b> Cobertura del Suelo de la Cuenca Humboldt.....	54
<b>Figura 4.4</b> Ubicación de estaciones Pluviográficas y Limnimétricas en la cuenca Humboldt .....	56
<b>Figura 4.5</b> Ubicación de Pluviógrafos y pluviómetros en el volcán Antisana .....	60
<b>Figura 5.1.</b> Esquema del desarrollo de procesos para RNA .....	66
<b>Figura 5.2.</b> Serie de datos (P-Q) del periodo 2005.....	70
<b>Figura 5.3.</b> Serie de datos depurados (P-Q) del periodo 2005 .....	71
<b>Figura 5.4.</b> Serie de datos (P-Q) del periodo 2006.....	71

<b>Figura 5.5.</b>	Serie de datos depurados (P-Q) del periodo 2006 .....	72
<b>Figura 5.6.</b>	Serie de datos (P-Q) del periodo 2007.....	73
<b>Figura 5.7.</b>	Serie de datos depurados (P-Q) del periodo 2007 .....	73
<b>Figura 5.8.</b>	Serie de datos (P-Q) del periodo 2008.....	74
<b>Figura 5.9.</b>	Serie de datos depurados (P-Q) del periodo 2008 .....	74
<b>Figura 5.10.</b>	Serie de datos (P-Q) del periodo 2009.....	75
<b>Figura 5.11.</b>	Serie de datos depurados (P-Q) del periodo 2009 .....	75
<b>Figura 5.12.</b>	Serie de datos (P-Q) del periodo 2010.....	76
<b>Figura 5.13.</b>	Serie de datos depurados (P-Q) del periodo 2010 .....	76
<b>Figura 5.14.</b>	Comparación de PR31 vs MS21 .....	83
<b>Figura 5.15.</b>	Comparación PR15 vs MS21 .....	85

## RESUMEN

El comportamiento hidrológico de la cuenca de Humboldt en el volcán Antisana permite conocer la cantidad existente del caudal, siendo de gran utilidad como ejemplo el proyecto La Mica Quito-Sur que abastece de agua potable a la parte sur de la ciudad de Quito. Por ello, para determinar el escurrimiento superficial de la cuenca Humboldt se utilizó la relación Precipitación-Escurrimiento aplicando la metodología de Redes Neuronales Artificiales (RNA), la cual es un proceso sin conocimiento previo de las características fisiográficas e hidrológicas de la cuenca, únicamente usa datos de entrada representativos y por medio de la densa interconexión de simples elementos computacionales conocidos como “neuronas” en combinación con los algoritmos y funciones de entrenamiento permiten que la red trabaje como un modelo que resuelve problemas no lineales y complejos. Para aplicar RNA se utilizó la herramienta NN-Toolbox de la plataforma Matlab, la cual entrega una amplia variedad de alternativas en la etapa de entrenamiento y validación de la red. Los datos de entrada utilizados son: precipitaciones (P5-P7-P8-P9), caudales Los Crespos (MS28) y temperatura (Estación ORE); mientras los datos objetivos son los caudales Humboldt (MS21) en el punto de cierre de la cuenca Humboldt. Finalmente, el intervalo de tiempo para la modelación de la RNA está dado en días.

La investigación presentada se fundamenta en demostrar que la RNA es apta para realizar la relación precipitación-escurrimiento en la cuenca de Humboldt, considerando la generación de una arquitectura optima después de realizar varias pruebas en la cual se cambió los datos de entrada, los algoritmos de entrenamiento, las funciones de transferencia, el número de capas ocultas y el número de neuronas en la capa oculta.

## ABSTRACT

The hydrological behavior of the Humboldt basin in the Antisana volcano allows to know the existing amount of the flow, being very useful for the project La Mica Quito-Sur that supplies potable water to the southern part of the city of Quito. Therefore, to determine the surface runoff of the Humboldt basin, the Precipitation-Runoff relationship was applied applying the Artificial Neural Networks (ANN) methodology, which is a process without previous knowledge of the physiographic and hydrological characteristics of the basin, only uses representative input data and through the dense interconnection of simple computational elements known as "neurons" in combination with training algorithms and functions allow the network to work as a model that solves nonlinear and complex problems. To implement ANN, the NN-Toolbox of the Matlab platform was used, which provides a wide variety of alternatives in the training and validation of the network. The input data used are: rainfall (P5-P7-P8-P9) flows Crespos (MS28) and temperature (Station ORE); While the objective data are the Humboldt flows (MS21) at the point of closure of the Humboldt basin. Finally, the time interval for ANN modeling is given in days.

The research presented is based on demonstrating that ANN is appropriate for performing the precipitation-runoff relationship in the Humboldt basin, considering the generation of an optimal architecture after performing several tests in which the input data were changed, the algorithms Training, transfer functions, the number of hidden layers and the number of neurons in the hidden layer.

## PRESENTACIÓN

La disponibilidad de agua en las cuencas hidrológicas del país a lo largo de los años se ha convertido en uno de los principales objetivos por parte de los hidrólogos para la planificación y manejo del recurso hídrico. Además, debido a la limitada información en lo que respecta a estaciones hidrométricas en las cuencas hidrográficas del país ha sido necesario acudir a modelos empíricos, y entre los más comunes se encuentran los modelos Precipitación-Escorrentamiento (P-E), considerado como un modelo altamente no lineal por la dificultad que presenta en la obtención de resultados. Para lo cual se vio la oportunidad de aplicar la técnica de RNA, por ser un modelo tipo “caja negra”, en el que se introduce una serie de datos de entrada (Precipitación-Temperatura-Caudal) para generar una serie de datos de salida (Caudales de escurrimiento) y sin la necesidad de conocer las características fisiográficas de la cuenca. Para lograr los resultados deseados es necesario primero realizar la etapa de entrenamiento de la red neuronal, en la cual se ejecuta una serie de combinaciones con los datos de entrada, asignado una función de transferencia, variando las neuronas de las capas oculta y comparando con los datos medidos obtener un error permisible. Adicionalmente, es importante que la red neuronal se considere como un modelo generalizado y no presente muestras de sobre-entrenamiento, lo cual sería perjudicial para los resultados modelados.

La importancia de la RNA en la modelización y predicción de los caudales diarios, y mensuales durante las últimas décadas y sobre todo por el número de estudios existentes, permite proponer como un modelo sintético de gran alcance que manejará de una manera eficiente la limitada información existente y tengan una gran adaptabilidad a la variabilidad de las características físicas que poseen cada una de las cuencas hidrográficas.

Uno de los principales desafíos de la hidrología es aplicar modelos computacionales que sean capaces de generar resultados con una alta confiabilidad en comparación con los métodos tradicionales. Además, el método de RNA aplicado a las variables climáticas en una cuenca sea capaz de simular y pronosticar caudales.

## **OBJETIVO GENERAL**

El proyecto tiene como objetivo generar caudales en la cuenca Humboldt ubicada al suroeste del volcán Antisana aplicando el modelo de Redes Neuronales Artificiales (RNA), el cual permita determinar la mejor arquitectura de la Red para la relación Precipitación- Escurrimiento (P-E).

## **OBJETIVOS ESPECÍFICOS**

- a) Describir los modelos de Redes Neuronales Artificiales más utilizados en la investigación del fenómeno Precipitación – Escurrimiento, sus ventajas y desventajas.
- b) Determinar la mejor arquitectura de un modelo de RNA que defina la relación Precipitación-Escurrimiento a través de indicadores de medida de error en el proceso.
- c) Indicar la influencia del glaciar en la cuenca de Humboldt e indicar como sería representado numéricamente en el desarrollo de la modelación.



# **CAPITULO 1**

## **DEFINICIONES BASICAS DE REDES NEURONALES ARTIFICIALES**

### **1.1 INTRODUCCIÓN**

En este capítulo se presentan las definiciones y conceptos básicos que se refieren a los diferentes componentes de un modelo basado en Redes Neuronales Artificiales (RNA), los mismos que permitirán tener un mejor entendimiento del modelo computacional aplicado al fenómeno Precipitación – Esguerrimiento (P-E) en la cuenca de Humboldt.

### **1.2 EVOLUCIÓN EN EL TIEMPO DE LAS REDES NEURONALES ARTIFICIALES**

El estudio del cerebro humano viene desde hace mucho tiempo atrás, pero específicamente sobre redes neuronales artificiales aparecen de la mano del neurólogo Warren McCulloch en 1943, quien junto al matemático Walter Pitts realizaron la publicación del libro “A Logical Calculus of the Ideas Immanent in Nervous Activity” y modelaron una red neuronal simple en base a circuitos eléctricos.

En 1949 Donal Hebb desarrolló sus ideas sobre el aprendizaje neuronal en su libro “The Organization of Behaviour”, en la cual establece una relación entre la fisiología y la psicología.

En 1957, Frank Rosenblatt inicio el desarrollo del Perceptrón, el cual es el modelo más antiguo de la red neuronal y se utiliza hasta la actualidad como un detector de patrones. Sin embargo, presentaba una serie de limitaciones, debido a que no era capaz de clasificar variedades no separables linealmente.

En 1959, Bernard Widrow y su más notable estudiante de posgrado Marcian Hoff desarrollaron el modelo ADALINE (Adaptive Linear Elements), el cual fue la primera red neuronal aplicada a un problema real.

Desde los años 60 hasta la actualidad, quien generó una gran influencia en lo concerniente al tema de RNA es Stephen Grossberg, quien a lo largo de los años ha escrito una gran cantidad de libros y ha desarrollado una gran cantidad de modelos de redes neuronales. Además, Grossberg estudió los mecanismos de la percepción y la memoria.

Después de 1969 se presentaron muchas críticas a las redes neuronales artificiales, por lo cual este tipo de tecnología permaneció sin mayor desarrollo en la década de los setenta. A inicios de 1982 se retoma con fuerza el tema, debido a los esfuerzos de Hopfield en la auto-asociación de las redes neurales. Este crecimiento también se produce debido a la intervención de Rumelhart, Hinton y Williams (1986) con el desarrollo del algoritmo de Retro-propagación. En el mismo año, Rumelhart y McClelland publicaron el libro "Parallel Distributed Processing", siendo este libro de gran influencia para la aplicación generalizada del algoritmo Retro-propagación.

En 1985 el Instituto Americano de Física empezó lo que se ha convertido en una reunión anual denominada "Neural Networks for Computing". Mientras, en 1987 se realiza la primera conferencia internacional sobre redes neuronales del Instituto de Ingeniería Eléctrica y Electrónica (IEEE), la cual atrajo a más de 1800 asistentes.

En 1990 el programa de investigación e innovación del departamento de defensa de los Estados Unidos nombró 16 temas que apuntaban específicamente a las redes neuronales con 13 temas adicionales dirigidos al posible uso de redes neuronales.

En la actualidad, muchas discusiones se han planteado sobre el tema de redes neuronales, y muchos concluyen que su desarrollo parece muy brillante con el avance de las nuevas computadoras existentes, cuya capacidad para el uso de RNA es idóneo.

### **1.3 DEFINICIÓN DE RED NEURONAL ARTIFICIAL (RNA)**

Existen múltiples definiciones de RNA, entre las que se destaca las siguientes:

“Redes Neuronales Artificiales son redes interconectadas masivamente en paralelo de elementos simples y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real, del mismo modo que lo hace el sistema nervioso biológico.” (Kohonen, 1988)

“La RNA es un tratamiento del sistema de información paralelamente-distribuido de forma masiva, que tiene ciertas características de desempeño que lo asemeja a redes neuronales biológicas del cerebro humano”. (Haykin, 1994)

“La particular habilidad del cerebro de aprender de experiencias sin un conocimiento previo de las más importantes relaciones físicas, haciéndolas enormemente flexibles y un potente dispositivo de cálculo que los investigadores de la Inteligencia Artificial han tratado de imitarla.” (Minns, 1998)

“Las Redes Neuronales Artificiales pueden ser entendidas como una clase de modelo matemático útil para emular los procesos que ocurren en el interior del cerebro humano” (Proaño, 1998)

De las definiciones anteriores se entiende que las Redes Neuronales Artificiales son modelos matemáticos que tratan de imitar los procesos del cerebro humano en base a datos de entrada y por medio de un proceso de caja negra generar datos de salida.

Los sistemas computacionales tradicionales leen y ejecutan instrucciones en la memoria del computador (desarrollado por Von Neuman), y por ello se lo denomina como proceso secuencial. Mientras las RNAs no ejecutan instrucciones, sino que responde en forma paralela a los datos de entrada que se presenta, y por ello es conocido como un proceso paralelo-distribuido. Ofreciendo una alternativa a la computación clásica, para aquellos problemas en los cuales los métodos tradicionales no han entregado resultados convincentes, o fiables. Es por ello, que las RNAs son un conjunto alternativo y complementario de técnicas a los modelos tradicionales. Además que puede considerarse como procedimientos de búsqueda

de patrones computacionales que permiten modelar, simular y pronosticar sin tener en cuenta el funcionamiento interno de la red (Tipo Caja Negra), cuyo interés es su interacción con el medio que le rodea pero sin considerar como lo hace. Por lo tanto, la RNA debe estar bien definida los datos de entrada y salida pero sin la necesidad de conocer a detalle el funcionamiento interno de la red.

## 1.4 APLICACIONES DE RNA

Sería imposible cubrir la gama total de aplicaciones para las que las redes neuronales han proporcionado soluciones destacadas. A continuación se menciona algunas de las aplicaciones de las RNAs en función de ajuste, reconocimiento de patrones, agrupamiento de datos, y análisis de series temporales. En la Tabla 1.1 se presenta una idea de la diversidad de aplicaciones para las cuales las redes neuronales artificiales proporcionan soluciones comprobadas.

**Tabla 1.1.** Aplicación de RNA

Área:	Aplicación:
Aeroespacial	Piloto automático para aeronaves de alto rendimiento, simulación de rutas de vuelo, sistemas de control de aeronaves, simulación de componentes de avión y detección de fallas.
Automotor	Sistema automático de guía de automóvil
Seguridad	Control de armas, reconocimiento facial, nuevos tipos de sensores, radares y procesamiento de señales de imagen, extracción de características y supresión de ruido
Electrónica	Predicción de secuencia de código, disposición de chips de circuitos integrados, control de procesos, análisis de fallos de chips, visión de máquina, y síntesis de voz
Entretenimiento	Animación, efectos especiales, pronóstico de mercado
Financiero	Evaluación de bienes raíces, asesoría de préstamos, selección de hipotecas, calificación de bonos corporativos, análisis de uso de líneas de crédito, seguimiento de actividades de tarjetas de crédito, programa de operaciones de cartera, análisis financiero corporativo y predicción de precios de divisas
Industria	Predicción de procesos industriales, tales como la salida de gases de los hornos
Fabricación	Control de proceso de fabricación, diseño y análisis de productos, diagnóstico de procesos y máquinas, sistemas de inspección visual de calidad, pruebas de cerveza, análisis de calidad de soldadura, predicción de calidad de papel, análisis de calidad de chips de computadora, planificación y gestión, y modelado dinámico del sistema de proceso químico
Medicina	Análisis de células de cáncer de mama, análisis de electroencefalografía y electrocardiogramas, diseño de prótesis, optimización de tiempos de trasplante, mejoramiento de la calidad hospitalaria y asesoramiento en sala de emergencias
Voz	Reconocimiento de voz, comprensión de voz, síntesis de texto a voz.
Telecomunicaciones	Comprensión de imagen y datos, servicio automatizado de información, traducción de idioma en tiempo real.
Transporte	Sistemas de diagnóstico de frenos de camiones, planificación de vehículos y sistemas de ruta.
Hidrología	Predicción de clima, modelación diaria de P-E, predicción y pronóstico de variables de recursos hídricos, y la modelación del manejo hídrico en cuencas hidrológicas


**Fuente:** (Beale, Hagan, & Demuth, 2015)

## 1.5 NEURONA BIOLÓGICA Y NEURONA ARTIFICIAL

La neurona es la unidad básica del cerebro humano y una unidad de procesamiento lógico independiente. La operación de la neurona es un proceso complicado y de difícil entendimiento a nivel de detalle, aunque las referencias básicas son relativamente claras. Es por ello que las neuronas aceptan varias entradas, las cuales si son suficientemente activas, la neurona se activara, caso contrario, la neurona permanecerá en estado inactivo (Beale & Jackson, 1997)

La parte principal de una neurona biológica se llama Soma. Unido al soma están las dendritas, que son filamentos de forma irregular que actúan como las conexiones a las cuales todas las entradas de la neurona arriban. Otro tipo de nervio unido al soma es el Axón, este se activa eléctricamente, y son diferentes a las dendritas porque sirven como el canal de salida de la neurona. El axón es una especie de dispositivo limite no lineal que produce un impulso de voltaje llamado acción potencial (Beale & Jackson, 1997). El axón termina en un contacto especial llamado sinapsis, que une el axón con la dendrita de otra célula, y además libera sustancias químicas llamadas neurotransmisoras cuando el potencial de la sinapsis ha sido elevado por la acción del axón. Es por ello que la sinapsis estimula a las dendritas que afectan, mientras a otras las inhibe. Una sola neurona tendría varias entradas sinápticas en las dendritas y varias salidas sinápticas conectadas a otras células. En la Figura 1.1 se presenta un esquema básico de neurona biológica.

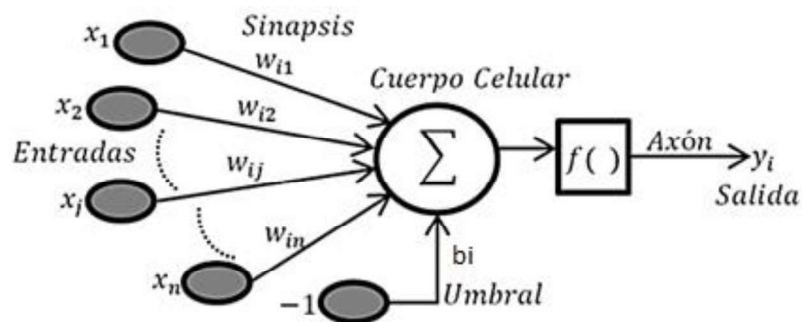
**Figura 1.1.** Representación de las características básicas de una neurona biológica



**Fuente:** (Flores H. , 2015)

Por otro lado, la neurona modelo calcula la suma ponderada de las señales entrantes y produce una salida de 1 o 0, dependiendo de si esta suma está por encima o por debajo de un valor umbral ( $b$ ) dado. Una descripción simplificada de la operación de la neurona biológica representada en la Figura 1.2, la cual constituye la base de la neurona modelo, en la cual se aprecia la similitud del modelo neuronal con la neurona biológica (Minns, 1998).

**Figura 1.2.** Esquema de la similitud de una neurona artificial con la neurona biológica



**Fuente:** (Huerta, Quispe, Ramos, Fernández, & Molina, 2012)

La neurona artificial se puede representar como una ecuación matemática que permite calcular un valor de salida en base a valores de entrada dados. La siguiente ecuación representa de forma matemática el esquema de la Figura 1.2.

$$y_i = f(\sum_{i=1}^n x_i * w_i - b_i) \quad (\text{Ec 1.1})$$

Donde:

f: Función de transferencia (función de activación)

$x_i$ : Elemento de entrada

$y_i$ : Elemento de salida

$w_i$ : Peso asociado con elemento de entrada.

$b_i$ : Valor umbral conocido también como bias, tiene el efecto de rebajar la entrada de la red dentro de la función de activación.

Generalmente cada conexión es definida por un peso ( $w_i$ ), los pesos son vectores que determinan el efecto activador o inhibitor. Cuando la activación de la neurona  $x_i$  multiplicada por los pesos  $w_i$  es positiva, entonces la unidad sirve para activar, pero si la multiplicación de la neurona  $x_i$  por los pesos  $w_i$  es negativa, entonces la unidad sirve como inhibidor.

## 1.6 FUNCIONES DE TRANSFERENCIA

La función de transferencia determina la respuesta de un nodo a la señal de entrada total que recibe. Existen varias funciones que pueden ser usadas como funciones de activación, ya que el rendimiento de la RNA depende de la función de transferencia que vaya a ser utilizada.

Las funciones de transferencia más comunes son:

- Función de transferencia Escalón o limitador fuerte.(hardlim)
- Función de transferencia lineal (purelin)
- Función mixta (escalón-lineal)
- Función de transferencia Log-Sigmoidal (logsig)
- Función de activación de la Sigmoid tangencial hiperbólica (tansig)
- Función Gaussiana


### 1.6.1 FUNCIÓN ESCALÓN O LIMITADOR FUERTE

Conocida como la función binaria, la activación es 1 si la entrada sumada excede el umbral de la neurona, y -1 en caso inverso. La función de transferencia limitador fuerte restringe el espacio de salida a valores entre 1 y -1. Esta función se usaría para perceptrones, pero a menudo son muy limitados en sus capacidades de aprendizaje y rendimiento (Proaño, 1998). La grafica derecha de la Figura 1.3 muestra la función limitador fuerte bajo las siguientes condiciones:

$$x < 0 \rightarrow y = -1$$

$$x > 0 \rightarrow y = 1$$

**Figura 1.3.** Función de transferencia de limitador fuerte



**Fuente:** (Proaño, 1998)

### 1.6.2 FUNCIÓN TRANSFERENCIA SEMI-LINEAL


La función semi-lineal puede ser considerada como una función lineal con valores límites superior e inferior, las salidas puede tomar cualquier valor entre -1 y 1. Por ser una función discontinua, el aprendizaje es limitado a diferencia de la función lineal. En la Figura 1.4 se presenta la función lineal bajo las siguientes condiciones:

$$x < -1 \rightarrow y = -1$$

$$-1 < x < 1 \rightarrow y = x$$

$$x > 1 \rightarrow y = 1$$

**Figura 1.4.** Función de transferencia semi-lineal




**Fuente:** (Proaño, 1998)



### 1.6.3 FUNCIÓN TRANSFERENCIA SIGMOIDE

La función de transferencia sigmoide puede tener cualquier valor positivo entre 0 y 1. Además, la función sigmoide se utiliza comúnmente en las redes multicapas, como retro-propagación (backpropagation), en parte porque es continua y diferenciable.

**Figura 1.5.** Función transferencia sigmoide



**Elaborado:** Alexis Aguilar

La función sigmoide tiene la siguiente ecuación:

$$f(z)_j = \frac{1}{1+e^{-z_j}} \quad (\text{Ec 1.2})$$

Donde:


$f(z)_j$ : Es la activación de la salida de la neurona  $j$

$Z$ : Es la entrada total a la neurona,  $Z_j = \sum_{j=1}^n x_j * w_{ij}$

Algunos investigadores también emplean la tangente hiperbólica como función de activación, la cual se transforma de la función sigmoidea. En la Figura 1.6 se representa la función tangente hiperbólica cuya ecuación es:

$$f(Z_j) = \tanh(Z_j) = \frac{e^{z_j} - e^{-z_j}}{e^{z_j} + e^{-z_j}} \quad (\text{Ec 1.3})$$

**Figura 1.6.** Función tangente hiperbólica




**Elaborado:** Alexis Aguilar

#### 1.6.4 FUNCION DE TRANSFERENCIA DE BASE RADIAL

Las funciones de base radial utiliza la función gaussiana. Esta función produce su valor máximo sólo para entradas muy cercanas a su centro y es casi cero para todas las demás entradas. Las RNAs construidas usando funciones de base radial son mucho más rápidas que otros tipos de funciones durante la etapa de entrenamiento de la red, aunque es para un número limitado de entradas. (Proaño, 1998). En la Figura 1.7 se representa la función de base radial.

**Figura 1.7.** Función de base radial



**Fuente:** (Proaño, 1998)

La función Gaussiana tiene la siguiente ecuación:

$$f(x) = e^{-\frac{1}{2\sigma_j^2} \sum_{i=1}^n (x_{ij} - c_i^j)^2} \quad (\text{Ec 1.4})$$

Donde:

$f(x)$ : Es la activación de la salida en la neurona  $j$

$x_{ij}$ : Es la entrada del nodo  $i$  a  $j$

$c_i^j$ : Es el centro de la función de transferencia del nodo  $j$  para la entrada  $i$ .

$J^2$ : Es la propagación de la función de transferencia del nodo  $j$ .

## 1.7 ENTRENAMIENTO DE RNA

La RNA necesita de una etapa de entrenamiento para que sepa cómo comportarse dependiendo del estímulo que se le presente. El entrenamiento se representa por medio del algoritmo que la red neuronal va a utilizar para modificar los pesos sinápticos y los bias (valor umbral) de tal manera que para cierto patrón o datos de entrada se tenga una salida específica como respuesta. Por tal motivo, existen dos tipos de entrenamiento para la Red Neuronal Artificial:

- Entrenamiento Supervisado
- Entrenamiento No Supervisado.

### 1.7.1 ENTRENAMIENTO NO SUPERVISADO

La red con entrenamiento No Supervisado aprende en base a asociación de patrones o generación de categorías que ella crea por si sola. No se produce error debido a que no se generan valores de salida para cada valor de entrada. El entrenamiento no supervisado se utiliza principalmente en aplicaciones que entran dentro del dominio de los problemas de estimación tales como: modelado estadístico, la compresión, el filtrado, la separación de fuentes ciegas y la agrupación. Otra aplicación de entrenamiento No Supervisado es la clasificación de los datos en diferentes grupos por similitud. Los mapas de auto-organización

utilizan algoritmos de entrenamiento No Supervisado. Las clases o técnicas para el entrenamiento No Supervisado son:

- Kohonen learning
- Adaptive Resonance Theory (ART)

## **1.7.2 ENTRENAMIENTO SUPERVISADO**

El entrenamiento supervisado es una técnica de aprendizaje automático que establece los parámetros de una red neuronal artificial a partir de datos de entrada. La tarea de la red neuronal artificial en la etapa de entrenamiento supervisado es establecer el valor de sus parámetros para cualquier valor de entrada válido, después de haber visto el valor de salida. Además, durante este tipo de entrenamiento, el error que se genere entre los datos salida (output) y los datos medidos permite la corrección de los pesos sinápticos ( $w$ ) y los bias ( $b$ ) de la red neuronal hasta que alcance el resultado deseado con un error admisible.

El entrenamiento supervisado puede ser dividido en diferentes reglas:

- Regla de aprendizaje de Retro-propagación
- Método basados en la optimización del algoritmo
  - Algoritmo Gradiente conjugado
  - Algoritmo Cuasi-Newton's
  - Algoritmo Levenberg-Marquardt
- Perceptrón

### **1.7.2.1 Regla de aprendizaje de Retro-propagación**

La regla de aprendizaje de Retro-propagación o regla delta, se trata del ajuste de los pesos sinápticos para obtener una respuesta de salidas muy cercana a los datos medidos o datos objetivo. La diferencia que resulta entre el valor de la respuesta y el valor objetivo se le conoce como error. Una vez calculado el error, la regla delta vuelve a propagar este error de una capa a la anterior. Luego, la propagación

siguiente de estos errores a través de la red, que permite a los pesos sinápticos se ajusten correctamente. De esta manera se reduce la función de error y se dice que la RNA aprende. (Proaño, 1998)

Durante la primera fase, los datos de entrada ingresan al sistema y se propaga hacia delante (forwards) a través de la red hasta la capa de salida. En ese instante se comparan entre sí los valores objetivos y los valores salidas calculadas, y la señal de error se calcula en los correspondientes ajustes de pesos sinápticos. En la segunda fase, esta señal de error se propaga hacia atrás (backwards) a través de la red a cada capa intermedia. (Minns, 1998). Finalmente, todo el proceso se repite hasta que el error total para todo el conjunto de datos sea despreciable y ya no sea necesario realizar ajustes de pesos sinápticos. La función error utilizada en la RNA de múltiples capas puede escribirse como:

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2 \quad (\text{Ec. 1.5})$$

Donde:

$E_p$ : Función error para el patrón p

$t_{pj}$ : Salida objetivo para el patrón p en el nodo j

$o_{pj}$ : Salida calculada en el nodo j

La fracción 1/2 hace las matemáticas un poco más simple, y trae la función error en línea con otras medidas similares.

### 1.7.2.2 Algoritmo de Gradiente Conjugado

El algoritmo de gradiente conjugado es útil para resolver varios problemas de optimización. El método del gradiente conjugado, a diferencia de la retro-propagación estándar, no procede a lo largo de la dirección del gradiente de error, sino en una dirección ortogonal a la del paso anterior. Esto evita que los pasos futuros influyan en la minimización lograda durante la etapa actual. Además, está comprobado que cualquier método de minimización desarrollado por el algoritmo de gradiente conjugado es cuadráticamente convergente. (De Vos, 2003)

Los pasos a seguir para el desarrollo del algoritmo son:

- i. Iniciar los pesos sinápticos de la red a valores aleatorios pequeños.
- ii. Propagar el q-ésimo patrón de entrenamiento a través de la red, calculando la salida de cada neurona.
- iii. Calcular el error local en cada neurona de la red.
- iv. Calcular el valor de salida deseado para cada una de las combinaciones lineales estimadas.
- v. Actualizar la estimación de la matriz de covarianza en cada capa y la estimación del vector de correlación cruzada para cada neurona.
- vi. Actualizar el vector de peso sináptico para cada neurona en la red.
- vii. Hasta que la red alcance un nivel de precisión predeterminado, vuelva al literal ii.

### 1.7.2.3 Algoritmo Cuasi-Newton

Según el método de Newton, el conjunto de pesos óptimos que minimiza la función de error se puede encontrar aplicando la matriz de Hessian. El método de Newton teóricamente puede converger más rápido que el método del gradiente conjugado, lamentablemente, la complejidad de la matriz de Hessian hace que sea un recurso intenso para su cálculo.

Los métodos cuasi-Newton ofrecen una solución a este problema con menos requisitos computacionales: actualizan una matriz aproximada de Hessian en cada iteración del algoritmo, acelerando así los cálculos durante el proceso de entrenamiento. (De Vos, 2003)

El conjunto de pesos óptimos que minimiza la función de error se puede encontrar aplicando la siguiente ecuación:

$$w(k + 1) = w(k) - H_k^{-1} * g_k \quad (\text{Ec. 1.6})$$

Donde:

$H_k^{-1}$ : Matriz Hessian del índice de desempeño a los valores actuales de los pesos sinápticos y bias:

gk: Representa el gradiente de la función error

#### 1.7.2.4 Algoritmo Levenberg-Marquardt (L-M)

El algoritmo de Levenberg-Marquardt (L-M) fue diseñado para acercarse a la velocidad de entrenamiento de segundo orden sin tener que calcular la matriz Hessian. (De Vos, 2003). Si la función de rendimiento tiene la forma de una suma de cuadrados, entonces la matriz Hessian puede ser aproximada como:

$$H = J^T J \quad (\text{Ec. 1.7})$$

Y el gradiente se puede calcular como:

$$g = J^T e \quad (\text{Ec. 1.8})$$

Donde:

H: matriz Hessian

J: matriz Jacobiana

e: vector de errores de red

g: gradiente

$$J = \begin{bmatrix} \frac{\delta_{e1}}{\delta_{w1}} & \frac{\delta_{e1}}{\delta_{w2}} & \dots & \frac{\delta_{e1}}{\delta_{wn}} \\ \frac{\delta_{e2}}{\delta_{w1}} & \frac{\delta_{e2}}{\delta_{w2}} & \dots & \frac{\delta_{e2}}{\delta_{wn}} \\ \dots & \dots & \dots & \dots \\ \frac{\delta_{ep}}{\delta_{w1}} & \frac{\delta_{ep}}{\delta_{w2}} & \dots & \frac{\delta_{ep}}{\delta_{wn}} \end{bmatrix} \quad (\text{Ec. 1.9})$$

La matriz Jacobiana es menos compleja de resolver en comparación de la matriz Hessian. Un problema con este método es que requiere el inverso de la matriz H. Aunque este problema se puede resolver fácilmente mediante la siguiente modificación:

$$H = J^T J + \mu * I \quad (\text{Ec. 1.10})$$

Donde  $\mu$  es un número pequeño y I es la matriz idéntica.

Es necesario calcular los elementos de la matriz Jacobiana asociados con cada par de entradas y salidas. Para el cálculo de las derivadas en la función Jacobiana se utiliza la ecuación siguiente:

$$J_{i,j} \approx \frac{\Delta e_i}{\Delta w_j} \quad (\text{Ec. 1.11})$$

Donde  $\Delta e_i$  representa el cambio en el error de salida debido a pequeñas perturbaciones del peso  $\Delta w_j$ .

## 1.8 TOPOLOGÍA DE LAS REDES NEURONALES

La topología de las redes neuronales representa la forma en que las neuronas están conectadas a la red. En otras palabras, puede ser vista con la relación entre las neuronas por medio de sus conexiones. Otra definición más precisa indica que la topología de las redes neuronales consiste de su conformación o de la estructura de las neuronas, junto con su estructura de interconexión o conectividad. La topología de una red neuronal juega un rol fundamental en su funcionalidad y desarrollo.

### 1.8.1 ESTRUCTURA DE NEURONAS

Las redes neuronales artificiales tienen una topología de capas, donde la estructura de una red puede ser descrita por el número de capas neuronales, y el número de neuronas en cada una de las capas, descrita como  $N_L$ , donde  $L$  indica el número de capas.

En las redes neuronales multicapas y en la mayoría de redes neuronales, las capas neuronales esta ordenadas y pueden ser numeradas. Sabiendo de sobremanera que el índice  $L$  para la capa de entrada es 1, para la capa oculta el índice será 2 y para la capa de salida el índice es 3. El índice de la capa de salida variara en función del número de capas ocultas que presente la red.



## 1.8.2 ESTRUCTURA DE INTERCONEXIÓN

La estructura de interconexión de la red neuronal determina la forma en que las neuronas son enlazadas. Basado en la estructura de capas, existen conexiones de neuronas en capas adyacentes, conexiones de neuronas en la misma capa, conexiones en la misma neurona, y conexión de neuronas en capas que no son adyacentes.


Considerando la disposición de las neuronas, la dirección, la forma en que están conectadas y como se componen sus capas, las RNA se pueden dividir en:

- Red hacia adelante (feedforward) de una capa
- Red hacia adelante (feedforward) multicapas
- Red recurrente o retroalimentación (feedback)

### 1.8.2.1 Red hacia adelante de una capa

La red hacia adelante (feedforward) de una capa, tiene una sola capa singular o capa de salida en una sola dirección, es decir, es una red unidireccional, que va desde la capa de entrada a la capa de salida. Esta red es especialmente usada en clasificación de patrones y problemas de filtrado lineal. En la Figura 1.8 se presenta de manera gráfica la red hacia adelante de una capa.

**Figura 1.8.** Ejemplo de red hacia adelante de capa singular



**Elaborado:** Alexis Aguilar

**Fuente:** Springer, 2017


### 1.8.2.2 Red hacia adelante Multicapas

La red hacia adelante (feedforward) multicapas está compuesta de una o más capas ocultas. Son empleadas en la solución de diversos problemas, tales como patrones de clasificación, identificación de sistemas, control de procesos, robótica, etc.

En la Figura 1.9 muestra un red hacia adelante (feedforward) con múltiples capas: una capa de entrada con  $n$  señales, dos capas neuronales ocultas que consisten en neuronas  $n_1$  y  $n_2$  respectivamente, y definitivamente, una capa neuronal de salida compuesta de  $m$  neuronas representando los respectivos valores de salida.

Entre las principales redes que utilizan la red hacia adelante (feedforward) de capas múltiples son: Multicapas Perceptron (MLP siglas en ingles) y Función de base Radial (FBR), cuyos algoritmos de entrenamiento utilizados en sus procesos se basan respectivamente en la regla delta, mencionada en la sección 1.7.2.1.

**Figura 1.9.** Ejemplo de Red hacia adelante Multicapas



**Elaborado:** Alexis Aguilar


**Fuente:** Springer, 2017

### 1.8.2.3 Red recurrente o retroalimentación (feedback)

En este tipo de redes, las neuronas de la capa de salida se utilizan como entradas de retroalimentación para generar nuevas neuronas en la capa de salida. Las funciones de retroalimentación denominan a estas redes como procesamiento dinámico de información. Es decir, que puede emplearse en sistemas de variación de tiempo, tales como la predicción de series de tiempo, sistemas de identificación y optimización, control de procesos, etc.

Entre las principales redes de retroalimentación están el Hopfield y Perceptrons con retroalimentación, el principal de los algoritmos de entrenamientos usados en sus procesos de entrenamiento se encuentra la regla delta. En la Figura 1.10 se muestra un ejemplo de red de retroalimentación, donde una de las señales de la salida retroalimenta a la capa intermedia. Por lo tanto, usando estos procesos de retroalimentación, las redes con esta arquitectura producen valores de salida presentes tomando en cuenta los valores de salida anteriores.

**Figura 1.10.** Ejemplo de Red Recurrente o Retroalimentación




**Elaborado:** Alexis Aguilar

**Fuente:** Springer, 2017

### 1.8.3 REDES NEURONALES AUTO-REGRESIVAS (RNAR)

Las redes neuronales Auto-Regresivas (RNAR) son redes neuronales donde las salidas calculadas están afectando las entradas del sistema desde la segunda etapa de tiempo. En este sentido, es necesario tener las condiciones iniciales para la primera etapa de tiempo. En otras palabras, las salidas calculadas en una etapa de tiempo se convierten en componentes del vector de entrada para las siguientes etapas de tiempo. Una de las ventajas de una RNAR es que gran parte de la información histórica sobre la dinámica del sistema se encapsula en la salida de cada etapa de tiempo (Proaño, 1998). Esto se debe al hecho de que la salida que contiene dicha información invaluable está sujeta a ser utilizada como entrada en el futuro.

**Figura 1.11.** Ejemplo de una red neuronal auto-regresiva

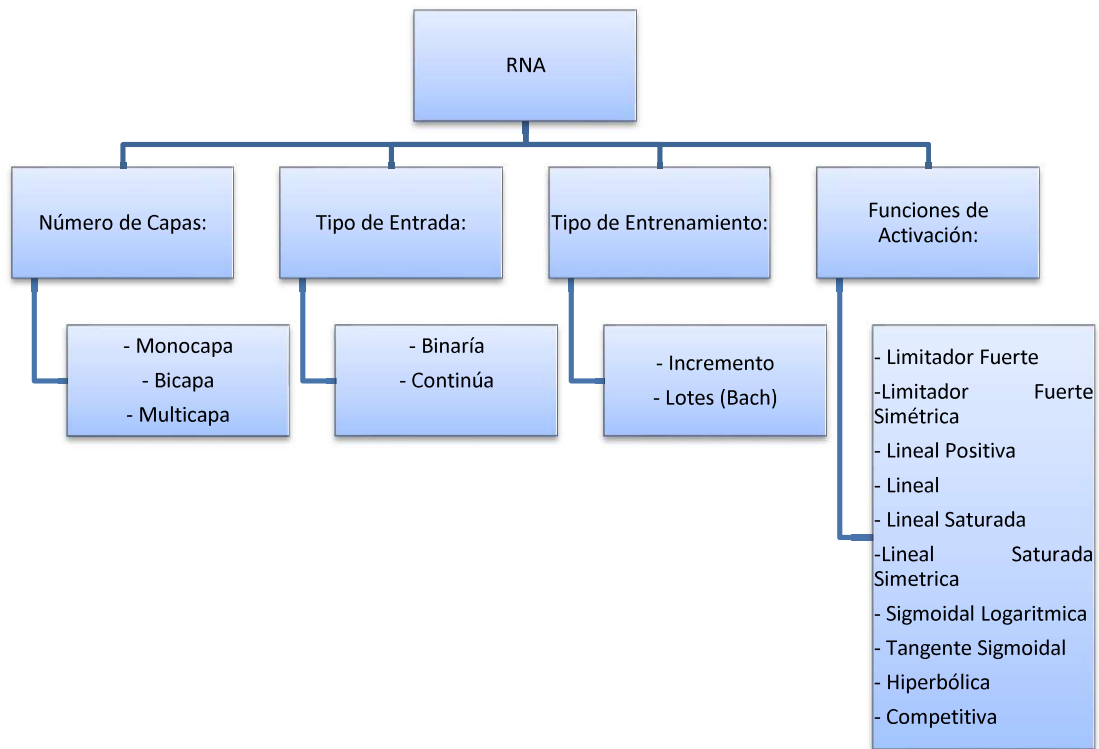


**Fuente:** (Proaño, 1998)

## 1.9 CLASIFICACIÓN DE REDES NEURONALES ARTIFICIALES (RNA)

La clasificación de RNA se puede realizar tomando en consideración varios criterios, tales como el número de capas, la dirección de información de flujo, el tipo de entrenamiento, y por las funciones de transferencia. En la Figura 1.12 se muestra la clasificación de las RNAs en base a los criterios mencionados.

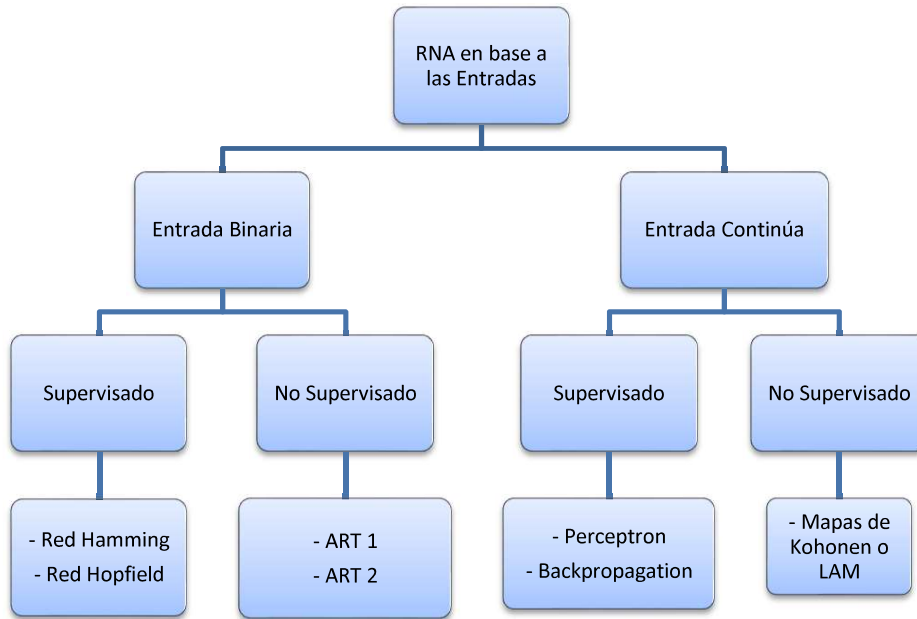
**Figura 1.12.** Clasificación de RNA



**Elaborado:** Alexis Aguilar

Además, las RNAs se pueden dividir considerando los valores de entradas (binarias o continuas), la cual se basa por el tipo de entrenamiento que posee la red. En la Figura 1.13 se muestra la clasificación de RNA en base a las entradas.

**Figura 1.13.** Clasificación de RNA en base a las entradas



**Elaborado:** Alexis Aguilar

## **CAPITULO 2**

### **REDES NEURONALES ARTIFICIALES APLICADAS A MODELOS PRECIPITACION-ESCURRIMIENTO**

Este capítulo describe la utilización de las Redes Neuronales Artificiales (RNA) para los modelos Precipitación-Escorrimento (P-E). Las RNAs han encontrado un creciente uso en diversas disciplinas que están más enfocadas a las diversas ramas de la ingeniería y la ciencia. Los investigadores en hidrología han mostrado un serio interés en este tema debido a que han presentado una gran sofisticación en el desarrollo de algoritmos y por la aparición de poderosas herramientas computacionales, la cual deja de ser el principal limitante conocido hace tres décadas atrás. Por ello, las Redes Neuronales Artificiales (RNA) han sido usadas con éxito en las áreas relacionadas con Hidrología, tales como: la modelación de la relación Precipitación – Escorrimento (P-E), Predicción de Tramos de Flujo, Modelación de Aguas Subterráneas, Calidad del agua, Predicción de precipitaciones, Predicción de caudales, Series hidrológicas y Operación de Reservorios, etc.


#### **2.1 DEFINICIONES HIDROLOGICAS**

##### **2.1.1 CICLO HIDROLÓGICO**

Una buena forma de entendimiento de los procesos involucrados en la transformación de la precipitación en escurrencia es el ciclo hidrológico, cuya fuerza generadora del ciclo hidrológico es la radiación solar, tal como se aprecia en la Figura 2.1. El ciclo hidrológico no tiene principio ni fin, y su descripción puede empezar en cualquier punto. El agua que se encuentra en la superficie terrestre o muy cerca de ella se evapora bajo efecto de la radiación solar y el viento. El vapor de agua que se forma, se eleva y se transporta a la atmosfera en forma de nubes hasta que se condensa y cae a la tierra en forma de precipitación. En el trayecto a la superficie de la tierra, el agua puede evaporarse nuevamente o ser interceptada por las plantas, luego fluye

por la superficie hasta las corrientes o se infiltra. De la precipitación que llega a las corrientes, una parte se infiltra y otra llega a los océanos y grandes cuerpos de agua. De la parte que se infiltra, una es tomada por las plantas y otra va hacia zonas profundas del suelo para ser almacenada como agua subterránea. (Aparicio Mijares, 1992)

**Figura 2.1** Representación esquemática del ciclo hidrológico



**Fuente:** (Aparicio Mijares, 1992)

### 2.1.2 MODELOS PRECIPITACION – ESCURRIMIENTO (P-E)

La determinación de los modelos P-E para una cuenca ha sido uno de los problemas que más ha sido investigado por los hidrólogos, ya que esta relación es altamente no lineal y compleja. El estado hidrológico de una cuenca comienza con un evento de precipitación, el cual representa la intensidad de la precipitación, la duración de la tormenta y la distribución de la precipitación sobre la cuenca.


Por otro lado, el escurrimiento depende de varios factores como son: la humedad inicial del suelo; el uso del suelo; la geomorfología de la cuenca; la evaporación; la infiltración; la duración de la precipitación, etc.



Aunque muchas cuencas se han monitoreado para proporcionar registros continuos de flujo del cauce, los hidrólogos a menudo se enfrentan con situaciones en las que hay poca o ninguna información. En tales casos, la utilización cada vez más creciente de los modelos P-E han sido considerados para generar series de datos de crecidas sintéticas.

La forma de representar un escurrimiento en una cuenca es por medio de un hidrograma, en la Figura 2.2 se presenta la variación del caudal en el tiempo. La curva de un hidrograma puede ser dividido en dos partes: las parte inferior es el caudal base, cuyo caudal no fue generado por la precipitación y representa el proceso de flujos retardados en la sub-superficie de la cuenca (aguas subterráneas). Por otro lado, la parte superior sería el caudal generado por el evento tormenta que cae sobre la cuenca. Este flujo es el que contribuye al escurrimiento de la cuenca.

**Figura 2.2** Componentes de un hidrograma en un cauce



**Fuente:** (Chow, 1994)

### 2.1.3 ESCURRIMIENTO

Los componentes del escurrimiento pueden ser expuestos como: escurrimiento superficial, escurrimiento subsuperficial y escurrimiento subterráneo.

### **2.1.3.1 ESCURRIMIENTO SUPERFICIAL**

El escurrimiento superficial es aquella parte de la lluvia que no es absorbida por el suelo mediante infiltración, por lo que se considera un escurrimiento directo. El efecto sobre el escurrimiento total es inmediato, y existirá durante la tormenta e inmediatamente después de que esta termine. (Villon, 2002)

### **2.1.3.2 ESCURRIMIENTO SUBSUPERFICIAL**

Es aquel que proviene de la precipitación infiltrada, por lo que el efecto sobre el escurrimiento total puede ser inmediato o retardado. Si es inmediato se le considera como parte del escurrimiento superficial, caso contrario como escurrimiento subterráneo. El flujo subsuperficial se convierte en el mecanismo primordial del transporte de agua lluvias hacia las corrientes (Chow, 1994).

### **2.1.3.3 ESCURRIMIENTO SUBTERRÁNEO**

Es aquél que, debido a una profunda percolación del agua infiltrada en el suelo, se lleva a cabo en los mantos subterráneos y que, posteriormente, por lo general, descarga a las corrientes fluviales. El escurrimiento subterráneo y la parte retardada del escurrimiento subsuperficial constituyen el escurrimiento base de los ríos.

### **2.1.4 FLUJO SUPERFICIAL DE SATURACIÓN**

Es aquel que se produce cuando el flujo subsuperficial satura el suelo cerca a la parte inferior de la pendiente. El flujo superficial de saturación satura el suelo desde abajo por el flujo subsuperficial, y este ocurre con mayor frecuencia en la parte inferior de las pendientes de colinas cerca a las bancas de la corriente. (Chow, 1994)

Los diferentes tipos de escurrimientos son muy útiles para la relación P- E pero dentro del proceso del flujo de la cuenca es difícil considerarlos por separado en especial en el caso de flujos subterráneos rápidos o retardados.

## **2.2 RNA PARA MODELOS P-E**

La relación P-E es denominado un modelo empírico, ya que a la cuenca se la considera como una "caja negra", sin ninguna referencia a los procesos internos que controlan la precipitación y su transformación a escurrimiento. El fenómeno P-E es tratado como un problema complejo por las dificultades que presenta y por la mala comprensión que se tiene en el mundo real.

Las RNA son ejemplos típicos de modelos empíricos por tener la capacidad de extraer relaciones entre las entradas y las salidas de un proceso, sin necesidad de conocer las características propias del sistema. Además, se adapta bien a la relación P-E, ya que es un problema altamente no lineal.

### **2.2.1 BREVE RESEÑA HISTÓRICA DE RNA APLICADA A RELACION P-E**

Un gran interés se ha presentado en las últimas dos décadas sobre la utilización de RNA para modelos P-E en cuencas en base a registros de precipitaciones, caudales superficiales, caudales subterráneos, variables climáticas con variación de tiempo diaria y mensual. A continuación se presentan algunos ejemplos de su utilización alrededor del mundo:

El estudio preliminar de Halff (1993) donde se diseñó una RNA hacia adelante (Feedforward) de tres capas ocultas, utilizando los hietogramas de precipitación observados como datos de entrada e hidrogramas registrados por el Servicio Geológico de Estados Unidos (USGS) en Bellvue-Washington como datos de salida deseados. Se utilizó cinco neuronas en la capa oculta. Aunque se consideró un total de cinco eventos de tormentas, los datos de cuatro tormentas se utilizaron para el entrenamiento de la red, mientras que los datos de la quinta tormenta se utilizaron para las pruebas de rendimiento de la red. Finalmente, la serie de 25 datos de precipitaciones normalizados en intervalo de 5 min se aplicó como datos de entrada para predecir el escurrimiento. Por tanto, dicho estudio abre varias posibilidades para la aplicación de precipitación-escurrimiento mediante redes neuronales artificiales.

En 1993, Hjelmfelt y Wang desarrollaron una RNA basada en la teoría del hidrograma unitario. El uso de la superposición lineal en un hidrograma de escurrimiento compuesto para una cuenca fue desarrollado por la suma apropiada de las ordenadas del hidrograma unitario y los excesos del escurrimiento. Para implementar esto en un marco de red neuronal, el número de unidades en la capa de entrada y de la capa oculta se mantuvo igual. Los nodos en la capa oculta fueron totalmente conectados con el nodo de salida único que representa el escurrimiento. Los datos de precipitación y escorrentía de 24 tormentas grandes fueron seleccionados de la cuenca del arroyo Goodwater Creek (área de 12.2 km<sup>2</sup>) en el centro de Missouri para entrenar y probar la RNA.

En una aplicación que usa dos redes neuronales, Zhu (1994) predijo los límites superior e inferior en el hidrograma de crecida en la cuenca Butter Creek de Nueva York. Las predicciones fuera del rango de datos de entrenamiento fueron hechas cuando no había datos actuales de inundaciones disponibles y había que basarse solo en estimaciones de datos de precipitación. Las predicciones dentro del rango de datos de entrenamiento se basaron tanto en las precipitaciones como en los datos de inundaciones anteriores. Los datos para RNA aplicado en pruebas y validación fueron generados a partir de un modelo no lineal de almacenamiento. Los autores encontraron que, mientras que la RNA estuvo bien durante la interpolación, las predicciones hechas por fuera del rango de los datos de entrenamiento no fueron alentadores.

Hjelmfelt y Wang (1996) compararon el método aplicado en el estudio de 1993, con una RNA de tres capas con Retro-propagación (Backpropagation). Los autores concluyeron que una red regular no podía reproducir el hidrograma unitario muy bien y era más susceptible al ruido que una red cuya arquitectura era más adecuada para los cálculos del hidrograma unitario.

En 1997, Shamseldin comparó la RNA con un modelo lineal simple conocido como el modelo de perturbación lineal, el cual es basado en la temporada y con un modelo de perturbación lineal más cercano. Para este estudio se recolectaron valores promedio diarios de precipitación y escurrimiento de seis cuencas hidrográficas diferentes en

todo el mundo. Una red neuronal de tres capas fue adoptada por el autor, y el método de gradiente conjugado se utilizó para el entrenamiento.

En un esfuerzo por relacionar el escurrimiento, la precipitación, la nieve, la temperatura, y los flujos previos, Tokar y Markus (1997) usaron RNA para predecir flujos mensuales en el río Fraser cerca de Granby-Colorado y flujos diarios en la cuenca Raccoon cerca de Bayard-Iowa. Los modelos WATBAL y SAC-SMA fueron utilizados como herramientas alternativas para la comparación en las dos cuencas hidrográficas, respectivamente. Ellos crearon una RNA de tres capas para predecir el escurrimiento mensual y diario de dos cuencas pequeñas. Para la cuenca del río Fraser, la RNA presentó mayor precisión en las predicciones mensuales que las obtenidas con el modelo conceptual. Mientras, para el río Raccoon, la RNA mostro una precisión razonable en el entrenamiento al compararlo con el modelo conceptual.

Tokar y Johnson (1999) informaron que los modelos de RNA proporcionan una mayor capacitación y precisión de las pruebas en comparación con la regresión y modelos conceptuales simples. Su objetivo era predecir el escurrimiento diario para el río Little Patuxent-Maryland, con precipitaciones diarias, temperatura y equivalentes de deshielo que sirven como insumos. Se encontró que la selección de datos de entrenamiento tiene un gran impacto en la precisión de la predicción. Los autores formaron y analizaron las RNAs con datos de humedad, sequía y promedio anual, respectivamente, así como combinaciones de éstos, con el fin de ilustrar el impacto de la serie de entrenamiento sobre el desempeño de la red. Además, la RNA que fue entrenada con datos húmedos y secos tenía la mayor exactitud de predicción. La duración del registro de entrenamiento tuvo un impacto mucho menor en el rendimiento de la red en los tipos de datos de entrenamiento.

En 1998, Dawson y Wilby usaron una red de retroalimentación de tres capas para determinar las escorrentías sobre las cuencas de los ríos Amber y Mole. Los datos de entrada de la red fueron caudales y el promedio de las precipitaciones anteriores. Los datos de salida consistían de la predicción de caudales futuros. Cuando se comparó con los caudales actuales, la RNA sobrestimo la aparición de caudales bajos para el río Mole. La RNA mostro que para la predicción del sistema requirió más información.

Rajurkar, Chaube, Kothyari, (2002) presentaron la aplicación de la metodología de RNA para modelar los flujos diarios durante los eventos de inundación de monzones para una cuenca de gran tamaño del río Narmada en Madhya Pradesh (India). La variación espacial de la precipitación se explica por la subdivisión de la cuenca y el tratamiento de la precipitación media de cada subcuenca como una entrada paralela y separada en el modelo. Se muestra que un modelo lineal de entrada múltiple y de una sola salida (MISO siglas en inglés) acoplado con la RNA proporciona una mejor representación de la relación precipitación-escorrentía en cuencas de gran tamaño comparadas con modelos MISO lineales y no lineales.

En el 2003, De Vos aplicó las RNAs en la relación precipitación-escorrentía para la cuenca Alzette-Pfaffenthal (Luxemburgo). El desarrollo del modelo de RNA se realizó en la plataforma de Matlab, la cual posee una herramienta (NN-Tool) que fue modificada para ajustarse a las demandas de la investigación de De Vos. El tipo de red utilizada es RNA-feedforward multicapa estática. Además, se usó el algoritmo Cascade-Correlation, que fue programado e incorporado en esta herramienta por De Vos. El objetivo de este algoritmo es aliviar el proceso prueba-error y de esa forma encontrar la red óptima. Los datos diarios de entrada considerados fueron caudales subterráneos, precipitaciones y valores de evapotranspiración, mientras los datos de salida fueron caudales de escorrentía diario.

Muchas pruebas se han realizado en los últimos años aplicando RNA al modelo precipitación-escorrentía, lo cual permite demostrar cada vez más que la precisión de los resultados obtenidos para modelos no-lineales se ajustan de manera óptima con RNA, permitiendo considerarla como una técnica fiable para la determinación de escorrentías en cuencas hidrológicas.

### **2.2.2 BENEFICIOS DE LAS RNAs APLICADA A LA RELACION P-E**

Los hidrólogos encontraron muchos problemas al momento de resolver en base a la relación P-E la determinación de caudales para una cuenca hidrográfica. Como resultado de estas dificultades y de una mala comprensión en los modelos

conceptuales, las RNAs pueden desempeñar un papel importante en el modelado de la relación P-E.

La precisión de los datos de salida en la relación P-E aplicando RNA permite proveer información útil para diseños de obras de infraestructura, permite generar planes de emergencia ante condiciones extremas de inundación o sequía, se puede diseñar obras que permitan el control de las inundaciones y permite aprovechar para la generación de centrales hidroeléctricas y para el abastecimiento de agua potable de las poblaciones cercanas.

Muchos investigadores han manifestado que la relación precipitación-escorrentía es uno de los fenómenos hidrológicos más complejos de entender debido a la gran cantidad de variables físicas, la no linealidad de los procesos físicos, las escalas espaciales y temporales de la cuenca y la incertidumbre en la estimación de los parámetros. Por ello, por las dificultades mencionadas y por el pobre entendimiento de los procesos de la naturaleza, la RNA puede ser de mucha ayuda en los modelos de P-E de cuencas hidrológicas.

Las RNAs son típicos modelos empíricos, por tanto el fenómeno P-E pueden llevarse a cabo en un marco puramente analítico, y la cuenca puede ser tratado como una caja negra, sin ninguna referencia a los procesos internos que controlan la transformación de la precipitación a escorrentía. Además, la RNA se adapta bien a un problema altamente no lineal y complejo.

Actualmente todavía se subestima el desarrollo de RNA aplicados a los modelos de P-E en comparación con los métodos tradicionales probabilísticos y sintéticos. En los capítulos posteriores se indicara que pasos se debe considerar para obtener una arquitectura óptima de la RNA aplicado a la relación P-E.

## **2.3 CARACTERISTICAS DE LOS DATOS DE ENTRADAS Y SALIDAS DENTRO DE UNA RNA APLICADO A FENOMENOS DE P-E**

Las RNAs son modelos de caja negra, la cual proviene de un proceso interno de los datos que se ingresan al sistema. Por ello, es importante determinar qué datos de entrada y que datos de salida se deben presentar a la RNA.

Las variables consideradas para la determinación del escurrimiento de la cuenca hidrológica deben tener una relación causal con la misma, tales como la precipitación, temperatura, caudales, niveles de agua, evaporación, etc. En cambio, los datos de salida deseados son valores de escurrimiento de la cuenca medidos.

La selección de una variable de entrada adecuada permite que la RNA logre con éxito el vector de salida deseado. Por ello, es de vital importancia investigar que variables tienen influencia en el sistema hidrológico que va a ser entrenado. Un conocimiento claro del sistema hidrológico es primordial, pues así se evitara la perdida de información útil y que se ingrese información innecesaria en el modelo, y ello origine una disminución del rendimiento de la red.

### **2.3.1 VARIABLES DE ENTRADA PARA EL MODELO PRECIPITACIÓN-ESCURRIMIENTO**

Las variables que determinan el escurrimiento superficial en una cuenca son:

- Precipitación
- Intensidad de lluvia
- Evaporación
- Velocidad del viento
- Temperatura

Además de la precipitación, el glaciar existente en la cuenca interviene en la generación del escurrimiento superficial, cuya influencia puede ser representada en las siguientes variables climáticas:



- Altura de la nieve
- Caudal del glaciar
- Temperatura media en el periodo de invierno.

Otras variables importantes a considerar en la investigación que presenta relación con la cantidad de agua que se encuentra en la cuenca hidrológica son:

- Niveles de agua subterránea
- Valores de caudales anteriores y actuales medidos aguas arriba del punto de interés de la cuenca hidrológica investigada.

### **2.3.2 COMBINACIÓN DE LAS VARIABLES DE ENTRADA**

Las variables de entrada deben ser elegidas en función de los procesos de escurrimiento que rige a la cuenca hidrológica, es decir, para nuestra cuenca de estudio se considera el predominio del escurrimiento superficial.

Además, la dificultad de seleccionar las variables de entrada idóneas no se basa solo en tomar un conjunto de variables específicas, sino en escoger variables que no se superpongan sino que se complementen entre sí. Por lo cual, manejar variables que se superpongan entre sí forma redes más complejas y generan el sobre-entrenamiento del modelo, lo cual conlleva a limitar las opciones de los algoritmos de entrenamiento y perjudica el ajuste de los pesos sinápticos de la RNA.

### **2.3.3 PREPARACIÓN DE DATOS**

Un aspecto de gran importancia en los modelos empíricos, y en especial en las RNAs es la calidad y cantidad de datos de entrada que se manipula. Es decir, mientras mayor sea la cantidad de datos de entrada considerados para el modelo, permite tener un mejor ajuste de los pesos sinápticos y que evita el sobre-entrenamiento de la RNA.

Los datos de entrada y salida, que se utilizan para lograr que la RNA aprenda durante la etapa de entrenamiento, deben ser seleccionados de la manera adecuada de tal forma que la Red sea capaz de extraer información útil al momento de comparar los datos modelados de la red con los datos medidos en campo. (De Vos, 2003). A continuación se presentan los criterios más importantes a tener en cuenta sobre los datos de entrada y datos de salida dentro de un modelo de RNAs:

#### **2.3.3.1 Calidad de datos**

La calidad de los datos que se manipula debe tener un tratamiento previo, en el cual se consideren varios aspectos, tales como:

- Tener muy claro la procedencia de los datos que se está manipulando, de esta manera se tendrá certeza que representan las características de la cuenca hidrológica en estudio.
- No presencia de valores negativos en series generalmente con valores positivos.
- En una serie de datos, la continuidad debe ser prioritario ante todo.
- Las pruebas estadísticas en caso de ser datos sin procesamiento, son muy útiles para indicar la fiabilidad de los datos y con ello eliminar valores atípicos (cuando se desconoce la presencia de un temporal extraordinario en el clima de la cuenca hidrológica). (De Vos, 2003)

#### **2.3.3.2 Cantidad de datos**

El número de pares de datos de entradas y salidas deseados para la modelación de la RNA es difícil de estimar de antemano. Hay algunas consideraciones, pero la más importante debería ser que la cantidad de datos recolectados sean capaces de cubrir varias series de datos anuales, tanto históricos como actuales. Las RNAs son malos extrapoladores, ya que si el modelo desea predecir con precisión los escurrimientos de una cuenca, cuya serie de datos de entrada no se asemeja al periodo de las series anuales usadas para el entrenamiento, la red no obtendría los datos deseados.

El número de variables existentes en la cuenca hidrológica son un limitante al momento de realizar la combinación de variables como datos de entrada de la RNA, ya que si no se dispone esto se reflejaran en los resultados del escurrimiento de la cuenca.

Es importante también que al momento de manejar una serie de datos temporales, se deba llevarlos de una manera cronológica, lo cual permite manejar la información de una forma estacional (verano o invierno), sin necesidad de realizar una filtración previa u ordenamiento de datos.

### **2.3.4 PRE-PROCESAMIENTO DE DATOS**

La preparación de datos implica una serie de procesos, como la limpieza de datos, la identificación de las variables apropiadas, la estandarización o normalización de los datos de entrada y, finalmente, la división de los datos en conjuntos de datos de entrenamiento, validación y simulación. (Abrahart, Kneale, & See, 2004)

Normalmente los datos que forman parte de la RNA son datos hidrológicos pre-procesados, es decir, aquellos que se obtienen de mediciones en campo y luego procesados en gabinete.

#### **2.3.4.1 Estandarización o normalización de datos**

La estandarización de datos de entrada utiliza la función de transferencia tal como la función sigmoide, (ver 1.6.3), cuyos límites de saturación son 0 y 1 y si los datos de entrenamiento presentan valores extremos comparado con estos límites, la red no podría estar entrenando. La estandarización de los datos tiene como objeto suavizar el modelo y los efectos de ruido de los datos.

Todas las variables deben ser estandarizadas para asegurar que reciben el mismo peso sináptico durante el proceso de entrenamiento. Sin estandarización, las variables de entrada dominarán el entrenamiento en mayor o menor medida porque los pesos sináptico iniciales dentro de una red se asignan al azar.

La escala de amplitud es una forma de escalar los datos entre máximo y mínimos para un rango de valores deseado, como por ejemplo 0 y 1 o -1 y 1. Por ello, investigadores han indicado que la amplitud de escala a un rango más pequeño como por ejemplo 0.05 a 0.95 o 0.1 a 0.9 o 0.2 a 0.8 evita problemas de saturación de señal de los datos de salida en la aplicación de RNA.

La ecuación de escalamiento puede ser escrita como:

$$X_n = FMIN + \frac{(X_u - factmin)}{factmax - factmin} (FMAX - FMIN) \quad (Ec 2.1)$$

Donde  $X_u$  es valor real,  $X_n$  es el valor estandarizado, FMIN-FMAX son los valores máximo y mínimo del rango escalado y factmax-factmin son los valores máximo y mínimo de los valores reales.

Una forma común de amplitud de escalamiento aplicada a la hidrología, es escalamiento logarítmico. (De Vos, 2003)

$$X_n = \ln(X_u) \quad (Ec2.2)$$

Otra manera de determinar la amplitud de escalamiento es:

- Los valores son estandarizados con respecto al rango de todos los valores

$$N_i = \frac{R_i - Min_i}{Max_i - Min_i} \quad (Ec 2.3)$$

- Los valores son estandarizados con respecto a la suma de cuadrados de todos los valores.

$$N_i = \frac{R_i}{\sqrt{SS_i}} \quad (Ec2.4)$$

Donde  $R_i$  es el valor real  $i$ ,  $N_i$  es el valor obtenido de la estandarización;  $Min$  es el mínimo valor y  $Max$  es el máximo valor de todos los valores aplicado, y  $SS_i$  es la suma cuadrada de todos los valores aplicados. (Dawson & Wilby, 1998)

## **2.4 TIPOS DE ARQUITECTURAS DE RNAs APLICADA A LA RELACION P-E**

En una RNA cada problema tiene su solución singular. Es decir, para diferentes problemas existen diferentes tipos de RNAs. Por ello, modelos diferentes pueden dar buenos ajustes, lo cual hace difícil la selección de un tipo de RNA con respecto a otro.

Los tipos de RNA comúnmente utilizados en la relación P-E se detallan en la siguiente lista (Ver Tabla 2.1) propuesta por Dawson y Wilby (2001), en la cual se presenta la utilización de MLP en la mayoría de trabajos realizados y el algoritmo más utilizado es el error de retro-propagación de Redes Neuronales (BPNN). Sin embargo una selección adecuada del tipo de RNA debe ser basada en las características de las variables de entrada y en la capacidad de haber solucionado problemas similares investigados por otros hidrólogos.

**Tabla 2.1.** Resumen de estudios previos en las RNA que se han empleado para P-E

Referencia	año	Tiempo unitario	Cuenca	Area (km2)	Arquitectura
Abrahart and Kneale	1997	hora	Wye, UK	11	MLP/BPNN
Campolo et al	1999	hora	Tagliamento, Italy	2480	MLP/BPNN
Carriere et al.	1996	30 seg	Laboratory catchment	2.1m2	MLP/BPNN
Dawson and Wilby	1998	15 min	Amber, UK	139	MLP/BPNN
	1998	15 min	Mole, UK	142	MLP/BPNN
Fernando and Jayawardena	1998	10 min	Kamihonsha, Japan	3.12	RBF/OLS; MLP/BPNN
Hall and Minns	1993	5 seg	Laboratory catchment	26.8m2	MLP/BPNN
	1993	1 min	Doncaster, UK	5.14 ha	MLP/BPNN
Hsu et al.	1995	dia	Leaf River, USA	1949	MLP/LLSSIM
Jayawardena and Fernando	1998	hora	Kamihonsha, Japan	3.12	RBF/OLS; MLP/BPNN
Lange	1998	hora	Zeller Bach, Germany	20	MLP/BPNN
	1998	hora	Windach, Germany	344.7	MLP/BPNN
Lorrai and Sechi	1995	mes	Araxisi, Italy	121	MLP/BPNN
Minns and Hall	1997	30 min	Dollis Brook, UK	24	MLP/BPNN
	1997	30 min	Silk Stream, UK	31.25	MLP/BPNN
Poff et al.	1996	dia	Independence, USA	230	MLP/BPNN
	1996	dia	Little Patuxent, USA	97	MLP/BPNN
See and Openshaw	1998	hora	Ouse, UK	3286	MLP/BPNN with KN
Shamseldin	1997	dia	Sunkosi, Nepal	18000	MLP/CG
	1997	dia	Shiquan, China	3092	MLP/CG
	1997	dia	Yanbain, China	2350	MLP/CG
	1997	dia	Bird Creek, USA	2344	MLP/CG
	1997	dia	Wolombi Creek, Australia	1580	MLP/CG
Teegavarapu	1998	10 dia	Malaprabha, India	-	MLP/BPNN; RBF/OLS
Zealand et al.	1999	1/4 mes	Namakan	19270	MLP/BPNN
N. J. de Vos y T. H. M. Rientjes	2005	dia-hora	The Geer river	494	ML-BPA

**Elaborado:** Alexis Aguilar

**Fuente:** (Abrahart, Kneale, & See, 2004)

Notación:

MLP: Multi-Capa Perceptrón;

BPNN: Retro-propagación de Redes Neuronales;

RBF: Función base radial;

OLS: Mínimos cuadrados ordinarios;

LLSSIM: Mínimos cuadrados lineales con simplex de arranque múltiple operación;

CG: Gradiente conjugado;

KN: Red Kohonen

#### **2.4.1 CRITERIOS PARA DETERMINAR LA ARQUITECTURA ÓPTIMA DE RNA**

No solo el tipo de red, sino la arquitectura realizada a la red determinan su rendimiento en términos de calidad de los datos de salida obtenidos. La arquitectura óptima de la red da un buen rendimiento en lo que respecta a minimización de errores entre los datos de salida y los datos deseados o medidos, además da la capacidad de conservar una estructura simple y general.

Para encontrar la arquitectura óptima de la RNA se puede iniciar con la red de alimentación hacia adelante (feedforward), de las cuales las más utilizadas son las redes Perceptrón Multi-capas (MLP) y la función Radial Básica (RBF). Mientras la función de transferencia depende del tipo de red y del algoritmo de entrenamiento que se vaya a emplear. Además, los modeladores deben especificar el número de capas ocultas y el número de neuronas en cada capa oculta. Pues, si se selecciona muy pocas neuronas en las capas ocultas, la red puede ser incapaz de describir la función subyacente porque tiene parámetros insuficientes (o 'grados de libertad') para asignar a todos los puntos en los datos de entrenamiento. Por el contrario, si hay demasiadas neuronas, la red tiene demasiados parámetros libres y puede superponer los datos, perdiendo la capacidad de generalización de la red. Es por ello que muchos investigadores siguen buscando como determinar el número óptimo de neuronas ocultas en las capas ocultas, pero hasta ahora el método más utilizado es el de prueba y error.

La cantidad y calidad de datos de entrada y datos deseados de salida dependen de la información existente, pero el número de neuronas ocultas y el número de capas ocultas son elegibles por el modelador. Los parámetros de error útiles para la validación de la RNA se mencionan ampliamente en la sección 2.5.

#### **2.4.2 INICIALIZACIÓN DE PESOS SINÁPTICOS DE LA RNA**

Al iniciar el entrenamiento de la RNA se genera de una manera aleatoria la matriz de pesos sinápticos y bias, luego del entrenamiento de la red, la acción aleatoria posibilita encontrar un mínimo global de error cada vez que sea entrenada la red nuevamente.

Es importante mencionar que si se puede generar una matriz aleatoriamente, y que los pesos sinápticos sean pequeños. Una técnica aplicada para el tema de inicialización de pesos sinápticos es la presentada por Nguyen-Widrow. (Beale, Hagan, & Demuth, 2015)

El método de inicialización Nguyen y Widrow muestra que una red sigmoide / lineal de dos capas puede ser vista como la realización de una aproximación lineal por partes de cualquier función aprendida. Además, se muestra que los pesos sinápticos y bias generados con ciertas restricciones resultan en una red inicial mejor capacitada para formar una función de aproximación arbitraria. El uso de las condiciones iniciales de Nguyen-Widrow (en lugar de puramente aleatorias) a menudo acorta el tiempo de entrenamiento en más de un orden de magnitud. (Beale, Hagan, & Demuth, 2015)

### **2.5 EVALUACIÓN DE RNA**

En la actualidad existe una gran cantidad de criterios para evaluar las RNAs aplicada a la relación P-E, esto se debe a que no existe una sola medida de error estándar (solo existen medidas de error más utilizadas que otras). Otro motivo para la falta de generalidad de los criterios de evaluación es la particularidad que presenta cada una de las cuencas estudiadas (debido a la morfología de la cuenca, clima, etc). Además, otro motivo a considerar es la variación del tiempo de la serie de datos de entrada, ya que la serie puede variar desde segundos hasta meses.

Cuando las RNAs son entrenadas usando algoritmos tales como retro-propagación, generalmente se optimizan de tal manera que minimiza su error global que se genera entre los datos deseados y datos de salida del modelo. (Dawson & Wilby, 2001)



En muchos algoritmos de entrenamiento se usa el error cuadrático medio, el cual proporciona una medida general del rendimiento del modelo, pero según lo que manifiesta (Dawson & Wilby, 2001) “No identifica regiones específicas donde un modelo es deficiente”. Por lo cual se deben usar otras medidas de error para cuantificar las deficiencias de la red.

Las medidas de error más comúnmente empleadas son:

- Error cuadrático medio (MSE);
- Error relativo cuadrático medio (RMSE);
- Coeficiente de eficiencia (CE)
- Coeficiente de determinación ( $R^2$ )
- Coeficiente de correlación ( $r$ )

$$MSE = \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{n} \quad (\text{Ec 2.5})$$

$$RMSE = \frac{\sum_{i=1}^n \frac{(Q_i - \hat{Q}_i)^2}{Q_i^2}}{n} \quad (\text{Ec 2.6})$$

$$CE = 1 - \frac{\sum_{i=1}^n (Q_i - \hat{Q}_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (\text{Ec 2.7})$$

$$R^2 = \left[ \frac{\sum_{i=1}^n (Q_i - \bar{Q})(\hat{Q}_i - \bar{Q})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2 \sum_{i=1}^n (\hat{Q}_i - \bar{Q})^2}} \right]^2 \quad (\text{Ec 2.8})$$

$$r = \frac{\sum_{i=1}^n (Q_i - \bar{Q})(\hat{Q}_i - \bar{Q})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2 \sum_{i=1}^n (\hat{Q}_i - \bar{Q})^2}} \quad (\text{Ec 2.9})$$

Donde:

$\hat{Q}_i$  es el caudal modelado;  $Q_i$  es el caudal observado;  $\bar{Q}$  es el caudal medio modelado;  $\bar{Q}$  es el caudal medio observado.

Según (Dawson & Wilby, 2001), los errores MSE son una buena medida para la calibración de caudales altos, mientras que los errores RMSE son una buena medida para caudales moderados. CE,  $r$  y  $R^2$  proporcionan comparaciones útiles entre

estudios, ya que las medidas estandarizadas son independientes de la escala de los datos utilizados. Además, son correlaciones estadísticas que evalúan la bondad de ajuste de los datos modelados con respecto a los datos observados. CE va desde  $-\infty$  en el peor de los casos a +1 para una correlación perfecta, un CE de 0,9 o superior es muy satisfactorio, 0,8 a 0,9 representa un modelo bastante bueno, y por debajo de 0,8 se considera insatisfactorio. Por otro lado,  $R^2$  oscila entre -1 (correlación negativa perfecta), a través de 0 (sin correlación) a +1 (correlación positiva perfecta).

El coeficiente de correlación varía entre -1 a 1, para fines prácticos se admite como aceptable para aquellas series que presentan su coeficiente de correlación  $r > 0.7$ , para el periodo común de datos, puesto que dicho coeficiente significa que la dispersión en los datos respecto a la media de una estación se justifica a través de la dispersión de los correspondientes valores de la otra variable respecto a su propio valor medio. (Almeida Roman, 2010)

Otra medida de error que se ha utilizado en la calibración de la red es el error absoluto medio (MAE), que calcula todas las desviaciones de los datos originales independientemente del signo y donde no se pone en consideración para los eventos de alto flujo.

$$MAE = \frac{\sum_{i=1}^n |Q_i - \hat{Q}_i|}{n} \quad (\text{Ec 2.10})$$

Dadas las múltiples medidas de rendimiento, el problema se direcciona a cuál de todas ellas es la más idónea. En el ejemplo presentado por (Dawson & Wilby, 2001) en la Figura 2.3 se presentan cuatro modelos hipotéticos de escurrimiento:

Modelo A: predice el caudal pico desfasado y superior al hidrograma observado;

Modelo B: predice los caudales bajos con más precisión;


Modelo C: simula el caudal bien, pero contiene mucho ruido;

Modelo D: reproduce bien el evento de crecida, pero tiene un mal desempeño en los caudales bajos.

De la Figura 2.3 se puede indicar que el modelo C supera a todos los demás modelos pero es menos preciso que el modelo B en los caudales bajos y menos precisos que el modelo D en los caudales de crecida. El modelo A pareciera el más débil de todos

pero si se aplica  $R^2$  se comporta mejor que los otros tres modelos anteriormente descritos.

**Figura 2.3** Hidrogramas de cuatros modelos hipotéticos



**Fuente:** (Dawson & Wilby, 2001)

Es importante el no confiar en medidas de error individuales para evaluar el desempeño del modelo. Por lo tanto, las medidas de error de bondad de ajuste (por ejemplo, CE,  $r$ , y  $R^2$ ) y medidas de error absoluto (RMSE y MAE) se deben utilizar de manera combinada (Dawson & Wilby, 2001). Para la evaluación de los modelos P-E aplicando RNA se utilizara la medida de error RMSE y  $r$ .

## **CAPITULO 3**

### **DESCRIPCIÓN DE LA PLATAFORMA UTILIZADA PARA RNA APLICADA A LA RELACION P-E**

En este capítulo se realiza una breve introducción del emulador NN-Toolbox utilizado para modelar RNA. El NN-Toolbox es una herramienta que forma parte del programa Matlab, la cual a través del proceso de diseño de la red neuronal permite resolver problemas en varias áreas, como por ejemplo la relación P-E.

#### **3.1 HERRAMIENTA NN-TOOLBOX**

Las RNAs han sido entrenadas para resolver problemas complejos en varios campos y que son difíciles de resolver por métodos conceptuales. El fenómeno P-E es un problema que puede ser emulado aplicando RNA. Para lo cual, existen varios emuladores que se diferencian por la topología de la red, por el número de neuronas, por el número de capas ocultas, por los tipos de algoritmo de entrenamiento, etc.

El emulador NN-Toolbox permite resolver una diversidad de problemas aplicando RNAs debido a que el emulador maneja una plataforma flexible, de fácil configuración al momento de cambiar las características de la red neuronal y posee varias maneras de revisar el error que presenta los datos de salida con respecto a los datos deseados.

La presentación grafica tanto de la arquitectura como de los resultados y del error que se genera con cada una de las funciones de entrenamiento es útil para analizar y comentar los productos generados con la herramienta. Los resultados son fáciles de importar para usarlos en otras plataformas para realizar nuevas aplicaciones o análisis de los resultados.

La herramienta NN-Toolbox presenta cuatro formas de utilizarla para resolver los problemas en base a RNAs. La primera forma de utilizar la herramienta es a través de la interfaz gráfica de usuario, el cual provee una forma rápida de acceder a la poderosa herramienta para las siguientes tareas:

- a. Función de Ajuste (Function Fitting)

- b. Reconocimiento de patrones (Patterns Recognition)
- c. Agrupamiento de datos (Data Clustering)
- d. Análisis de series de tiempos (Time series)

La tarea función de ajuste crea una red de dos capas de alimentación hacia adelante con la aplicación de la función sigmoide en la capa oculta, y la función lineal en la capa de salida.

La tarea de reconocimiento de patrones es el proceso de entrenamiento en una red neural para asignar la correcta clase deseada para un conjunto patrones de entrada. La red está compuesta de dos capas, en la capa oculta se aplica la función lineal, y en la capa de salida se aplica la función exponencial normalizada.

La tarea de agrupamiento es un proceso de entrenamiento en una red neuronal en patrones, de modo que la red aparezca con su propia clasificación para patrones semejantes y relativamente arreglados. Además este tipo de red, se la considera como un mapeo de auto-organización, la cual consiste en una capa competitiva que puede clasificar un conjunto de datos con cualquier número de dimensiones en tantas clases como la capa tiene neuronas. Las neuronas están arregladas en una topología de dos dimensiones.

La tarea análisis de series de tiempo es un proceso de entrenamiento que resuelve problemas no lineales de series de tiempo con una red neuronal dinámica. Las redes neuronales dinámicas se utiliza para el filtrado no lineal y la predicción de valores futuros en base a valores pasados de series de tiempo. Las redes neuronales dinámicas pueden resolver problema no lineal, problema auto-regresivos no lineal, y problema auto-regresivos no lineal con entradas externas.

La segunda forma de uso de la herramienta es a través de operaciones básicas de línea de comandos. Las funciones de líneas de comando utilizan listas de argumentos simples con ajustes inteligentes predeterminados para los parámetros de funciones.

La tercera forma de uso es la personalización de la herramienta, Esta capacidad avanzada le permite crear sus propias redes neuronales personalizadas, aunque se mantiene el acceso a la funcionalidad completa de la herramienta.

El cuarto uso a la herramienta es la capacidad de modificar cualquiera de los archivos de código contenidos en la herramienta NN-Toolbox. Cada componente computacional está escrito en código MATLAB y es totalmente accesible.

## **3.2 PROCESO DE CREACION DE LA RNA UTILIZANDO NN-TOOLBOX**

A continuación se describe brevemente el proceso de utilización de la herramienta NN-Toolbox para RNA. Los pasos comunes son: Ingreso de los datos de entrada y salidas; creación de la arquitectura de la red neuronal; entrenamiento y validación de la RNA.

### **3.2.1 DATOS DE ENTRADA DE LA RNA**

El usuario de la herramienta NN-Toolbox puede seleccionar las variables de entrada y/o salidas de una RNA. El número de entradas o salidas pueden ser seleccionadas libremente sin ser esto una limitación al momento de realizar el entrenamiento de la RNA. Las entradas y salidas pueden usarlas de forma de valor real o en forma de valor estandarizado/normalizado, el usuario determinara cuál de las dos formas de ingreso de las variables le convenga más en la etapa de entrenamiento.

#### **3.2.1.1 División de Datos**

Para el entrenamiento RNA, los datos de entrada se pueden dividir en tres subconjuntos. El primer subconjunto es de entrenamiento, que se utiliza para calcular el gradiente y actualizar la red de pesos sinápticos y bias. El segundo subconjunto es de calibración, donde se controla el error durante el proceso de entrenamiento, y al momento de obtener el mínimo error, la etapa de entrenamiento se detiene y los pesos sinápticos y bias ya poseen una distribución adecuada para la red. El tercer subconjunto es conocido como prueba, el cual es usado para comparar los diferentes modelos pero no es obligatorio su utilización en la etapa de entrenamiento de la red.

Cuando se utilice el subconjunto de prueba, y el error de prueba alcanza un mínimo en un número de iteración significativamente diferente que el error de validación establecido, esto podría indicar una distribución errónea de los porcentajes de los subconjuntos en la serie de datos.

Para distribuir los subconjuntos de datos de entrada existen cuatro formas de realizarlas en la herramienta NN-Toolbox. En la Tabla 3.1 se presenta las formas de división de datos para el entrenamiento de la red.

**Tabla 3.1.** Formas de división de datos

FUNCION	DEFINICIÓN
dividerand	Divide los datos aleatoriamente
divideblock	Divide los datos dentro bloques continuos
divideint	Divide los datos usando una selección intercalada
divideind	Divide los datos por el índice

**Elaboración:** Alexis Aguilar

**Fuente:** (Beale, Hagan, & Demuth, 2015)










### 3.2.2 ARQUITECTURA DE LA RNA

Al momento de crear la arquitectura de la RNA, se debe asumir el número de capas ocultas, la versión 2011 de la herramienta NN-Toolbox no presenta un limitante en la determinación del número de capas ocultas. Otra característica de la arquitectura de la red neuronal es el número de neuronas en las capas ocultas, este ítem es de mucha importancia al momento de obtener la mejor arquitectura de entrenamiento de la red, por practica se recomienda iniciar el entrenamiento con 10 neuronas en las capas ocultas seleccionadas. De la misma forma, la herramienta no presenta una limitante el número de neuronas en la capa oculta.

La herramienta NN-Toolbox presenta una variedad en el tipo de función de transferencia para cada una de las capas de la RNA. La función de transferencia lineal

(purelin), sigmoide (logsig), y tangente hiperbólica (tansig) son las más comunes al momento de configurar la arquitectura de la red neuronal. A continuación en la Tabla 3.2 se presenta un resumen de las funciones existentes en la herramienta NN-Toolbox:

**Tabla 3.2.** Funciones de transferencia NN-Toolbox

Name	Input/Output Relation	Icon	MATLAB Function
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		hardlim
Symmetrical Hard Limit	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		hardlims
Linear	$a = n$		purelin
Saturating Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		satlin
Symmetric Saturating Linear	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$		satlins
Log-Sigmoid	$a = \frac{1}{1 + e^{-n}}$		logsig
Hyperbolic Tangent Sigmoid	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		tansig
Positive Linear	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		poslin
Competitive	$a = 1$ neuron with max $n$ $a = 0$ all other neurons		compet

**Fuente:** (Beale, Hagan, & Demuth, 2015)



### 3.2.3 ETAPA DE ENTRENAMIENTO

Para realizar la etapa de entrenamiento de la RNA, la herramienta NN-Toolbox (Ver Tabla 3.3) presenta una variedad de los algoritmos de entrenamiento:

**Tabla 3.3.** Algoritmo de Entrenamiento

FUNCIÓN	DESCRIPCIÓN
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traingcb	Conjugate Gradient with Powell/Beale Restarts
traingcf	Fletcher-Powell Conjugate Gradient
traingcp	Polak-Ribière Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

**Fuente:** (Beale, Hagan, & Demuth, 2015)

El algoritmo de entrenamiento más rápido es trainlm, por tal motivo aparece en la plataforma por defecto. El algoritmo trainbfg es también rápida. Pero estos métodos son menos eficientes para redes largas con miles de pesos sinápticos. El algoritmo trainlm se desarrollan mejor en problemas de funciones de ajuste (regresión no lineal).

Ya seleccionado el algoritmo de entrenamiento, el siguiente paso es elegir los criterios de parada del entrenamiento de la red neuronal. Los criterios usados para la detención del entrenamiento se presentan en la Tabla 3.4.

**Tabla 3.4.** Parámetros de Parada de entrenamiento de la red

PARAMETROS	CRITERIOS DE PARADA
min_grad	Magnitud mínima de gradiente
max_fail	Número máximo de incremento de validación
time	Tiempo máximo de entrenamiento
goal	Valor mínimo de rendimiento
epochs	Número máximo de iteraciones de entrenamiento

**Fuente:** (Beale, Hagan, & Demuth, 2015)

### 3.2.4 ETAPA DE VALIDACIÓN

Con el objetivo de verificar la capacidad de generalización de la red es conveniente disponer de un grupo de los datos independientes de las variables de entrada que no se hayan utilizados en la etapa de entrenamiento, y una vez que se obtenga la arquitectura optima de la red neuronal, se debe ingresar el conjunto de datos para verificar la calidad de los resultados utilizando el coeficiente de correlación lineal entre los datos de salida de la red neuronal y los datos medidos en campo. En el caso que la correlación  $r < 0.7$ , se debe revisar si la red perdió su generalización. Es recomendable que la serie de datos de entrada para la etapa de validación de la RNA se representativa.

## CAPITULO 4


### ANALISIS DEL AREA DE ESTUDIO E INFORMACION BASE

#### 4.1 DESCRIPCION GENERAL DEL AREA DE ESTUDIO

La cuenca Humboldt forma parte de las cuencas hidrográficas del volcán Antisana, de manera general está ubicado al Sur-Oeste del volcán, rodeado al norte por el río Papallacta, al sur por la laguna La Mica, al este por el río Quijos y al oeste por la ciudad de Quito. Geográficamente está ubicada a  $0,488^{\circ}$  S;  $78,141^{\circ}$  W. La cumbre de la cuenca de Humboldt se encuentra a 5670 msnm, mientras el sitio de cierre de la cuenca se encuentra en la cota 4010 msnm. (Mena Correa, 2010)

En la **¡Error! No se encuentra el origen de la referencia.** se presenta la ubicación general de la cuenca Humboldt.

**Figura 4.1** Ubicación general de la zona de estudio



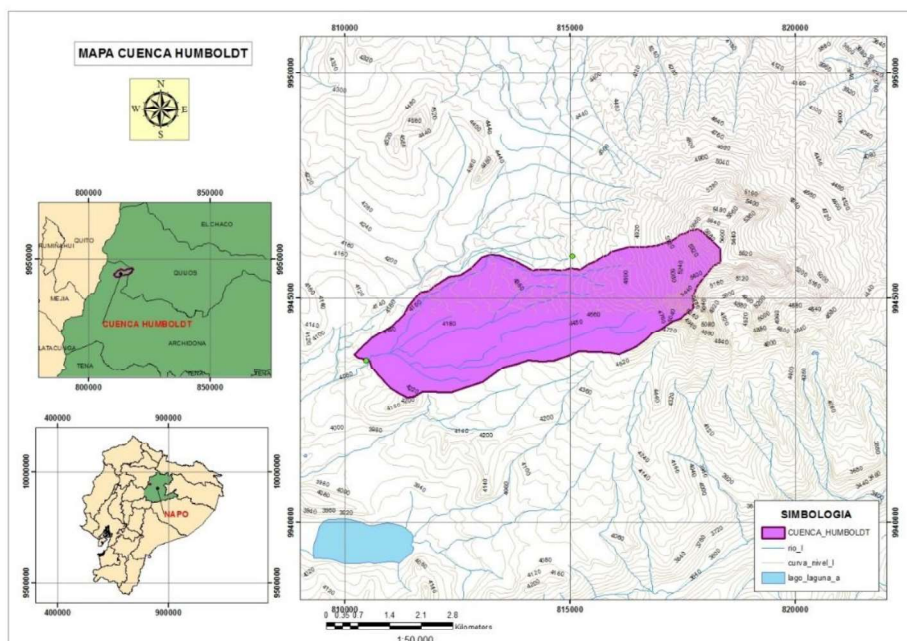
**Elaboración:** Alexis Aguilar

Para la presente investigación se seleccionó a la cuenca de Humboldt por tener la mayor área de las tres cuencas existentes en la zona y por la influencia que genera sobre el proyecto La Mica. Las principales características hidromorfológicas de esta cuenca se presentan a continuación.

## 4.2 CUENCA HUMBOLDT

La cuenca de Humboldt tiene características típicas de un páramo andino, en la cual se presenta valles formados por glaciaciones, planicies con lagos, humedales, pastizales, matorrales, y bosques de baja altura. La cuenca presenta un bajo porcentaje de superficie glaciaria, su régimen hidrológico es pluvio-nival, mientras que dentro de la misma hacia aguas arriba se encuentra la cuenca Los Crespos, la cual tiene un régimen glacio-nival. (Mena Correa, 2010) La superficie de la cuenca Humboldt es igual a 14,2 km<sup>2</sup> desarrollándose desde la cota 5670 msnm hasta 4010msnm.

**Figura 4.2** Ubicación Cuenca Humboldt



Elaborado: Alexis Aguilar

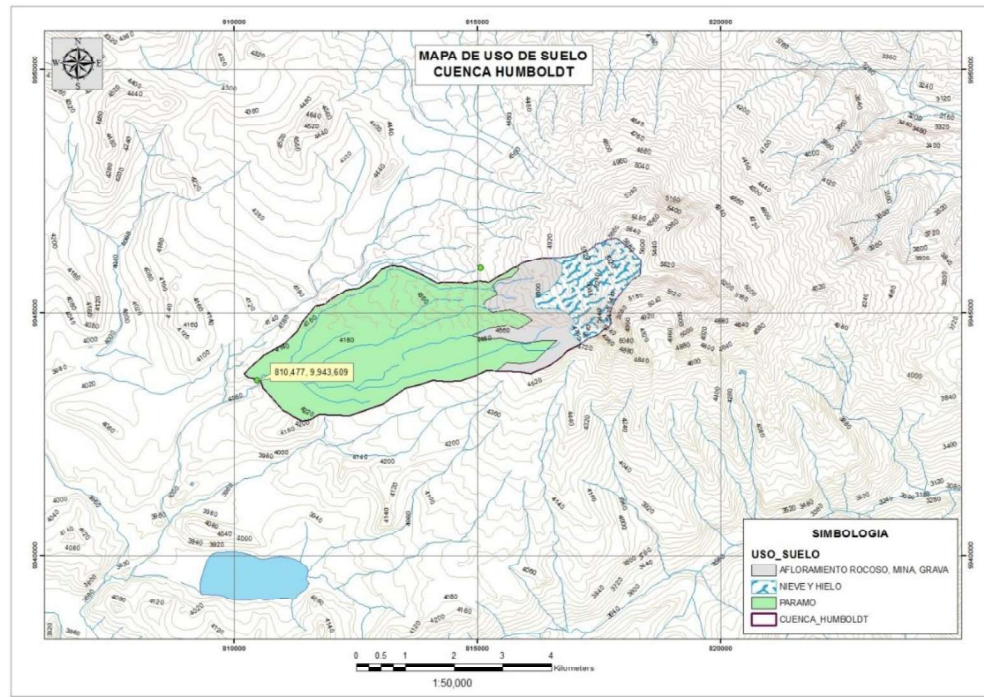
Dentro de la cuenca Humboldt aguas arriba se ubica la estación limnimétrica la cual es el punto de cierre de la cuenca Los Crespos, su superficie tiene cobertura glaciar en su totalidad. Por su localización la cuenca es perceptiva a los cambios de temperatura superficial del Pacífico (fenómeno El Niño y La Niña) y por el aire húmedo proveniente de la cuenca del Amazonas, sin embargo el Océano Atlántico, aunque en menor medida también es fuente de humedad (RUIZ, 2015)- (Mena Correa, 2010). La cuenca Los Crespos tiene un área de 1.7 km<sup>2</sup> y se encuentra entre las cotas 5670 msnm hasta 4730 msnm.

El escurrimiento desde el glaciar Los Crespos constituye la aportación más importante de origen glaciar hacia la cuenca Humboldt y adicionalmente al sur hay un área glaciar adicional de 0.34 km<sup>2</sup> que contribuye también a la cuenca Humboldt. (Caceres, et al., Glaciares del Ecuador Antisana 15 Y 12, Carihuayraso, 2011)

Por su ubicación geográfica es una zona rica en recursos hídricos. Parte de sus aguas drenan hacia la laguna La Mica, la cual abastecen de agua a gran parte del Distrito Metropolitano de Quito. (RUIZ, 2015)

La superficie glaciar que forma parte de la cuenca cubre el 14% de la cuenca drenada, la parte no glaciar de la cuenca esta principalmente cubierta por vegetación propia de los páramos y una pequeña cantidad de morrena que recubren la parte media de la cuenca (ver Figura 4.3). (Caceres, et al., Glaciares del Ecuador Antisana 15 Y 12, Carihuayraso, 2011). Las morrenas están constituidas de material heterogéneo, que incluye arena y piedras de ahí que el suelo es bastante permeable.

**Figura 4.3** Cobertura del Suelo de la Cuenca Humboldt



Elaborado: Alexis Aguilar

La cuenca Humboldt representa una de las más estudiadas en el área Hidrometeorológica del volcán Antisana, en el cierre de la cuenca se encuentra la estación limnimétrica Humboldt (MS21) que fue construida en 1999 en el marco de cooperación del proyecto GREATICE por las tres instituciones INAMHI-EMAAP-Q e IRD y empezó su funcionamiento en noviembre del mismo año. Por poseer información confiable la estación MS21, se consideró los valores diarios para el análisis del fenómeno precipitación-escorrentía aplicando Redes Neuronales Artificiales con la ayuda de la plataforma NN-Toolbox.

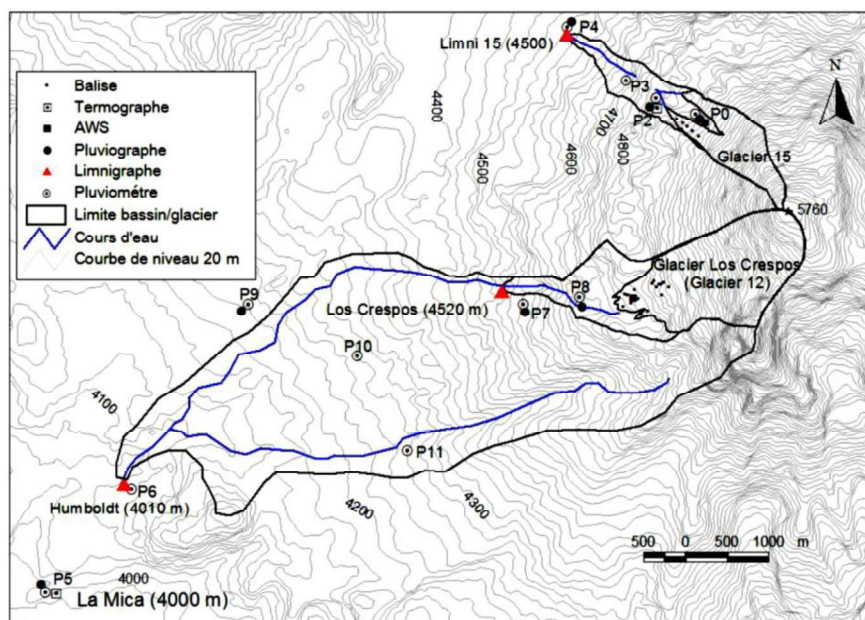
### 4.3 DESCRIPCION CLIMATICA DE LA ZONA DE ESTUDIO

Las variaciones climáticas dependen de la fisiografía local y de las corrientes que vienen del Pacífico y de la Amazonía. Los factores determinantes de los regímenes climáticos son:

- Latitud, define las condiciones de circulación atmosférica a nivel planetario entre la línea Ecuatorial y los Polos. El Ecuador está regido por las reglas de circulación de zona de baja latitud (es una región donde la presión atmosférica es más baja que la del aire circundante). Las zonas ecuatoriales y tropicales reciben mayor cantidad de energía respecto a los polos. (Mena Correa, 2010)
- El relieve, la altitud, y el efecto de la cordillera de los Andes divide al Ecuador en tres zonas climáticas (Costa, Sierra y Oriente). Por ser una barrera modificada, las precipitaciones son alimentadas por el aire húmedo proveniente tanto de la cuenca amazónica como del Golfo de Panamá.
- La influencia de corrientes oceánicas del Pacífico, donde se generan masas de aire que se ven perturbadas por la influencia de corrientes oceánicas. El Ecuador está sometido a la influencia permanente de la corriente fría de Humboldt ( $15\text{ }^{\circ}\text{C} < T < 19\text{ }^{\circ}\text{C}$ ), la cual desplaza desde el sur y toma luego una dirección noreste para finalmente calentarse y mezclarse con la corriente cálida Ecuatorial Sur ( $T > 25\text{ }^{\circ}\text{C}$ )

Las variables meteorológicas en el volcán Antisana son medidas por la estación meteorológica automática ORE, la cual está instalada sobre la morrena lateral del glaciar 15 $\alpha$  a 4850 msnm. La estación ORE mide los principales parámetros meteorológicos que intervienen en el cálculo del balance hídrico. Mientras existe una red de cinco estaciones pluviográficas (cuyo código son: P5, P7, P8, P9), las cuales almacenan la precipitación instantánea que presenta influencia sobre la cuenca Los Crespos y cuenca Humboldt. Adicionalmente las mediciones de niveles de agua son registradas por las estaciones limnigráficas Crespos y Humboldt. Las estaciones pluviográficas y limnigráficas se presentan en la Figura 4.4.

**Figura 4.4** Ubicación de estaciones Pluviográficas y Limnimétricas en la cuenca Humboldt



Fuente: (Villacis M. , 2008).

A continuación se muestra las estaciones pluviométricas y pluviográficas presentadas en la Tabla 4.1:

**Tabla 4.1.** Resumen de las estaciones pluviométricas y pluviográficas

ESTACION	ARTEFACTOS	X (m)	Y(m)	ALTURA	INSTALACION	EJE
P5-MICA	PLUVIOMETRO Y PLUVIOGRAFO	809054	9942411	3930	1994	MICA-GLACIAR LOS CRESPOS
P7-CRESPOS	PLUVIOMETRO Y PLUVIOGRAFO	815067	9945705	4450	2002	MICA-GLACIAR LOS CRESPOS
P8-CRESPOS MORRENA	PLUVIOMETRO Y PLUVIOGRAFO	815834	9945610	4730	2006	MICA-GLACIAR LOS CRESPOS
P9-PARAMO	PLUVIOMETRO Y PLUVIOGRAFO	812350	9946318	4269	2005	HORIZONTAL 4264 msnm

**Elaborado:** Alexis Aguilar

**Fuente:** (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)



### 4.3.1 DATOS METEOROLÓGICOS

Los datos meteorológicos son registrados por la estación ORE (4850 msnm), que inicia su funcionamiento el 21 de diciembre del 2004, y es una estación automática. A pesar de que fue localizada fuera de la cuenca Los Crespos en la morrena del glaciar 15α del Antisana, su situación es favorable ya que tiene menos influencia del glaciar (Villacis M. , 2008).

Las variables climáticas registradas en la estación ORE son: Temperatura del aire, Humedad Relativa, Velocidad del viento, Dirección del viento, radiación incidente de onda corta, radiación incidente de onda larga y Precipitación.

Las variables climáticas se basaron de los promedios mensuales de los periodos 2005, 2006, 2007, 2008 y 2009, la cual presenta un comportamiento similar en todos los periodos.

#### 4.3.1.1 Temperatura del Aire

La máxima temperatura mensual se presentó en el año 2005 en el mes de febrero con 2.11°C y la mínima temperatura se presentó en julio del 2008 con 0.27°C. En la Tabla 4.2 se presenta los valores de temperatura media mensual para el periodo 2005 hasta el periodo 2009.

**Tabla 4.2.** Promedio mensual de la temperatura del aire, Estación ORE

MES \ AÑO	TEMPERATURA (°C)				
	2005	2006	2007	2008	2009
ENERO	1.75	0.63	1.88	1.14	0.67
FEBRERO	2.11	1.45	1.52	0.47	0.66
MARZO	1.29	1.04	1.15	0.28	
ABRIL	1.72	1.11	1.07	1.93	1.50
MAYO		1.79	1.60	1.49	1.26
JUNIO	1.50	1.08	0.32	1.07	1.18
JULIO	0.98		1.26	0.27	0.71
AGOSTO	1.07	0.93	0.55		1.10
SEPTIEMBRE	1.38	0.54		0.74	1.58
OCTUBRE	1.11	1.47	0.49	0.49	1.49
NOVIEMBRE	1.28	0.83	1.06	0.99	2.00
DICIEMBRE	0.53	1.10	0.37	0.91	1.85

**Elaborado:** Alexis Aguilar

**Fuente:** (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

#### 4.3.1.2 Humedad Relativa

De acuerdo a promedios mensuales registrados durante el periodo del 2005-2009 en la estación ORE, en el año 2007 y en el 2009 existen variaciones significativas a lo largo de los meses. Por ejemplo, la máxima se dio en el mes de abril 2007 con 98.92% y la mínima se presenta en abril del 2009 con 65.85%. El año 2008 el valor máximo se presenta en el mes de marzo con 89.14%. Además se puede ver que sigue la lógica inversa de la temperatura, es decir si la temperatura sube la humedad relativa baja y viceversa. En la Tabla 4.3 se presenta los valores medios mensuales de la humedad relativa.

**Tabla 4.3.** Humedad Relativa promedio mensual, Estación ORE

AÑO MES	HUMEDAD RELATIVA (%)				
	2005	2006	2007	2008	2009
ENERO	76.48	83.77	77.33	83.68	88.45
FEBRERO	79.66	82.32	71.23	88.39	87.67
MARZO	85.68	85.38	87.30	89.14	
ABRIL	85.60	86.76	98.92	88.51	65.85
MAYO		75.42	82.82	87.64	81.84
JUNIO	77.55	77.47	85.88	82.93	82.05
JULIO	68.66		68.24	80.73	77.25
AGOSTO	70.54	76.68	76.86		76.15
SEPTIEMBRE	69.26	75.38		81.43	68.83
OCTUBRE	83.11	74.25	84.80	87.61	79.59
NOVIEMBRE	71.18	86.80	82.96	85.28	73.43
DICIEMBRE	83.86	84.79	85.70	83.85	79.77

**Elaborado:** Alexis Aguilar

**Fuente:** (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

#### 4.3.1.3 Radiación incidente de onda corta (SWinc en W/m<sup>2</sup>)

La radiación máxima se midió en el mes de septiembre del 2009 con 310.99 W/m<sup>2</sup>, y la radiación mínima es 151.45 W/m<sup>2</sup> en abril del 2007. La radiación promedio es igual 202.25 W/m<sup>2</sup>. Los valores más altos se presentan en los meses de junio hasta octubre los cuales se muestran en Tabla 4.4.

**Tabla 4.4.** Promedios mensuales de radiación incidente de onda corta - ORE

MES \ AÑO	RADIACION INCIDENTE (W/m <sup>2</sup> )		
	2007	2008	2009
ENERO	191.91	185.61	174.70
FEBRERO	200.30	182.30	178.83
MARZO	173.85	171.67	
ABRIL	151.45	186.39	184.93
MAYO	179.40	188.46	212.87
JUNIO	201.42	221.97	224.91
JULIO	235.84	228.93	259.53
AGOSTO	249.08		287.33
SEPTIEMBRE		207.35	310.99
OCTUBRE	167.11	185.11	222.51
NOVIEMBRE	201.63	151.95	218.88
DICIEMBRE	162.85	164.46	209.79

**Elaborado:** Alexis Aguilar

**Fuente:** (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

#### 4.3.1.4 Velocidad del Viento

La velocidad máxima registrada en el año 2009 es igual a 9,22 m/s, el valor mínimo registrado en el 2009 es de 2,25 m/s y un valor promedio de 5,36 m/s. En la Tabla 4.5 se presenta los valores mensuales de la velocidad del viento medidos por la estación ORE.

**Tabla 4.5.** Promedios mensuales de la velocidad del viento-ORE

MES \ AÑO	VELOCIDAD VIENTO (m/s)		
	2007	2008	2009
ENERO	4.47	3.39	2.25
FEBRERO	5.74	2.88	3.44
MARZO	3.75	2.35	
ABRIL	2.55	3.42	7.58
MAYO	3.71	3.12	3.81
JUNIO	6.03	4.48	5.83
JULIO	4.58	6.36	8.93
AGOSTO	6.60		7.64
SEPTIEMBRE		3.49	9.22
OCTUBRE	1.88	2.83	4.64
NOVIEMBRE	4.13	1.85	2.73
DICIEMBRE	3.15	2.64	2.89

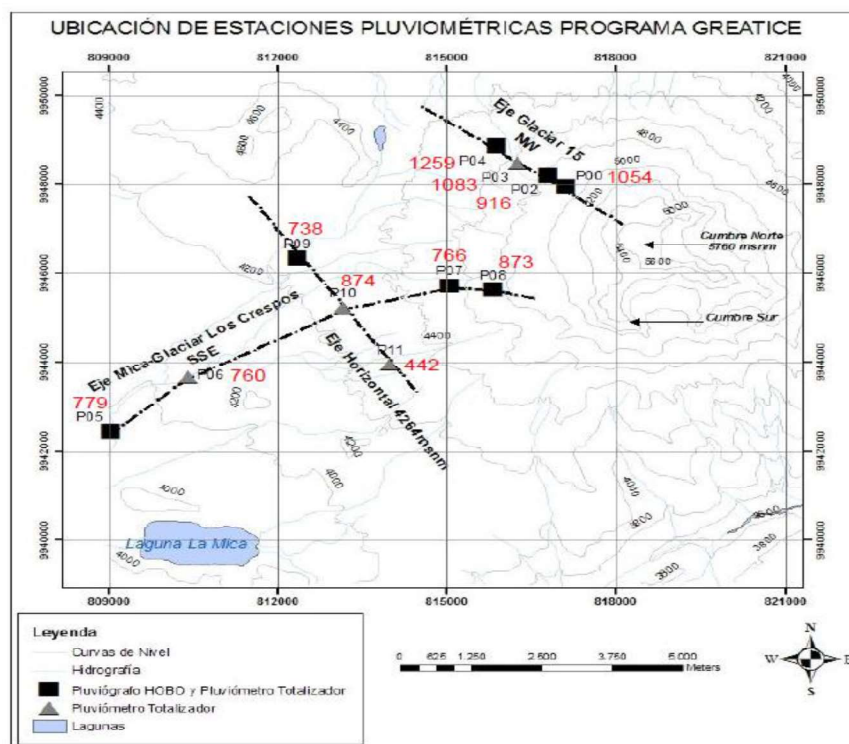
**Elaborado:** Alexis Aguilar

**Fuente:** (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

#### 4.4 PRECIPITACION

En la cuenca de Humboldt existe una red de pluviógrafos y pluviómetros que permiten conocer la variación en la pluviometría en el lado occidental y noroccidental del volcán Antisana entre los 4000 y 4900 msnm. En la Figura 4.5 se aprecia que sobre la cuenca de Humboldt se forman dos ejes pluviométricos (Eje la Mica-Glaciár Los Crespos y eje Horizontal 4264 msnm) cuyo objetivo fue el estudio de la variabilidad espacial de las precipitaciones. En el eje Mica-Glaciár Los Crespos se encuentra las estaciones P8-P7-P10-P6-P5, mientras el eje Horizontal 4264 msnm se encuentran las estaciones P11-P10-P9 que va de noreste a suroeste.

**Figura 4.5** Ubicación de Pluviógrafos y pluviómetros en el volcán Antisana



**Fuente:** (Cáceres, Manciatì, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

Para realizar el análisis se consideró las precipitaciones medida en los pluviómetros por presentar los datos de forma diaria en los informes “Glaciares del Ecuador-Antisana 15” (Cáceres, Manciat, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

Por la ubicación y la influencia en el análisis del fenómeno precipitación- escurrimiento de la cuenca Humboldt en el volcán Antisana se consideraron los datos de los pluviómetros P5, P7, P8, P9. Las precipitaciones serán aprovechadas tanto para proceso de entrenamiento y validación de la RNA aplicada a la relación P-E.

## **4.5 HIDROLOGIA**

A fin de realizar la modelación del fenómeno precipitación - escurrimiento aplicando redes neuronales artificiales se consideraron las estaciones hidrológicas Los Crespos (MS28) y Humboldt (MS21) ubicados en la cuenca Humboldt. Estas estaciones permiten determinar el comportamiento hidrológico y miden la producción del recurso hídrico con la presencia del glaciar en la cuenca Los Crespos, la cual forma parte de la cuenca Humboldt. Estas estaciones fueron construidas bajo el marco de cooperación entre el IRD, el INAMHI, la EMAAP-Q y la Escuela Politécnica Nacional (EPN) en el Proyecto GREATICE.

### **4.5.1 ESTACIÓN LOS CRESPOS (MS28)**

La estación hidrológica Los Crespos tiene una superficie total de 2,40 km<sup>2</sup> y una superficie glaciar de 1,69 km<sup>2</sup>, la cual representa el 70,4% de la superficie total. Se encuentra a una altitud de 4521 msnm. Se ubica en la parte alta del río Antisana y las coordenadas UTM (PSAD56-Zona 17S) son 815.058E y 9'945.918N. La ubicación de la estación se debió por la aportación de glaciar a la cuenca y la estabilidad de la zona para realizar las mediciones. Además, a esta estación llega una gran parte de los escurrimientos de origen glaciar que posteriormente llegan a la estación hidrológica Humboldt. La estación Los Crespos está constituida por un vertedero trapezoidal inclinado a 45°, su base inferior de 0,42m y su base superior de 2,0m. Para las

mediciones se utiliza un limnógrafo de inyección de burbujas de aire ORPHIMEDES de marca OTT, el error de medida es  $\pm 1$ cm. Para esta estación con los datos obtenidos en el campo se ha definido la Curva de calibración, la cual genera el caudal del vertedero de sección trapezoidal construido. La estación se encuentra en funcionamiento desde el 2003 hasta la actualidad. (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

Para el análisis se revisaron los caudales diarios desde periodo 2005 hasta el periodo 2010, a pesar que la estación tiene registros desde el 2003. Sin embargo, por la poca continuidad de los datos de los años 2003 y 2004, estos no fueron utilizados.

Una de las dificultades que se presentaba en la estación Los Crespos fue por motivo de encontrarse con presencia de sedimentos en la sección de control y cerca de los limnógrafos. Otro problema es la congelación del caudal, dificultando a los sensores el registro de los niveles de agua.

#### **4.5.2 ESTACIÓN HUMBOLDT (MS21)**

La estación hidrológica Humboldt se encuentra a una altitud de 4010 msnm, se ubica en la parte baja del río Antisana y las coordenadas UTM (PSAD56-Zona 17S) son 810.477E y 9'943.609N. Esta estación se localiza a corta distancia del campamento de la EMAAP-Q en la laguna de la Mica en donde inicia el Proyecto La Mica Quito Sur. Lo que le confiere una gran utilidad para determinar el comportamiento hidrológico de la cuenca de origen glaciar que contribuye a este importante proyecto de abastecimiento de agua potable para Quito. (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

La estación está constituida por un canal rectangular con un ancho de 1.28m y una longitud de 6.0m, los muros laterales son de hormigón ciclópeo con una altura de 1,60 metros que encausan las aguas del río Antisana. La estación Humboldt fue construida en 1999 en el marco de cooperación del proyecto GREATICE por las tres instituciones INAMHI-EMAAP-Q e IRD.

La estación Humboldt retiene en su totalidad el caudal de la estación Los Crespos, la cual es la mayor aportación de origen glaciar. Para las mediciones se ha utilizado

desde limnógrafos manuales hasta sensores electrónicos, el error de medida es  $\pm 1$ cm. La recopilación de datos de cotas de esta estación hidrológica ha procedido principalmente de dos fuentes: los registros de los sensores electrónicos y los rollos limnográficos, estos últimos han sido digitalizados.

El transporte de sedimentos representa un problema importante en la sección de control del vertedero, por tal motivo las acumulaciones son limpiadas durante las visitas regulares de control de la estación. (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012)

Los caudales considerados para el análisis fueron del periodo 2005 hasta el 2010, no se consideró los periodos anteriores al año 2005 por no haber interacción con las estaciones pluviográficas consideradas para la modelación del fenómeno precipitación-escorrimento y para estar dentro del mismo rango de análisis de la estación hidrológica Los Crespos.

## **CAPITULO 5**

### **APLICACIÓN DE LAS RNA AL MODELO PRECIPITACION-ESCORRENTIA DE LA CUENCA HUMBOLDT**

Para iniciar el desarrollo de la relación precipitación-escorrimento (P-E) aplicando la RNA, es importante tener claro el proceso a realizar en base a una serie de pasos que permitirá realizar de una manera adecuada el entrenamiento y validación del modelo P-E.

Cuando se utilizan RNAs para modelar la relación P-E, se deben tomar varias decisiones por parte del modelador. Por ejemplo, seleccionar la mejor arquitectura de la RNA, elegir el mejor algoritmo de entrenamiento, procesar los datos de entrada, seleccionar el número de capa ocultas, seleccionar los indicadores de error en la etapa para el entrenamiento y validación de la red, selección de las variables como datos de entrada y de salida, o bien, como decidir la estandarización o normalización de los datos, entre otros aspectos a ser considerados.

Este capítulo tiene por objeto describir las etapas necesarias para la aplicación de RNA a la modelación precipitación-escorrimento de la cuenca de Humboldt.

#### **5.1 PROCESO PARA EL DESARROLLO DE UN ESQUEMA DE RNAs APLICADO A MODELOS PRECIPITACION-ESCORRIMIENTO**

Según (Dawson & Wilby, 2001) para desarrollar los modelos de RNA aplicados a la hidrología se ha sintetizado en siete pasos:

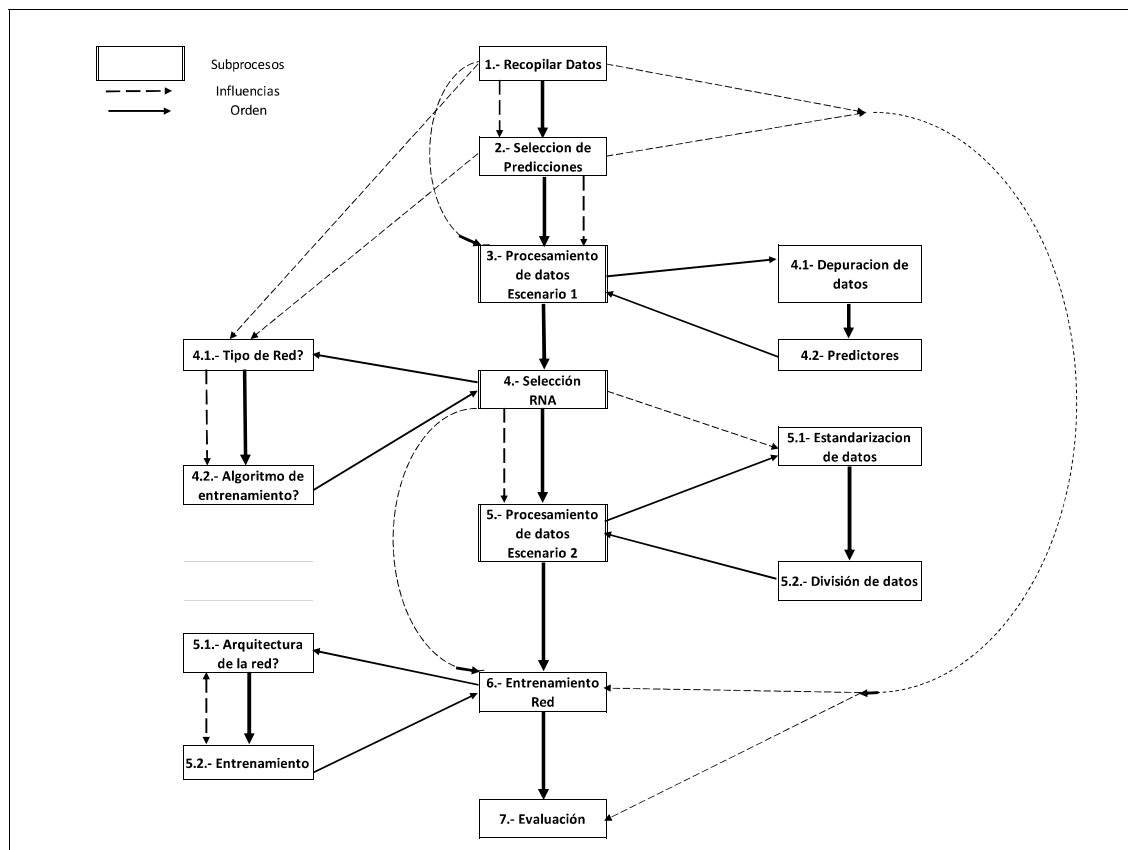
- I. Selección de datos.
- II. Selección de una predicción apropiada.
- III. Pre-procesamiento de los datos:
  - Depuración de datos, los cuales no sean adecuados para el modelo.
  - Predictores más significativos para la modelación.



- Normalización o estandarización de datos y selección de datos para entrenamiento, validación y prueba.
- IV. Selección de RNA
- Tipo de red apropiada, como punto de inicio es apropiado el uso de MLP.
  - Selección de algoritmo de entrenamiento, y determine la arquitectura.
- V. Pre-procesamiento de datos:
- Estandarización y normalización de datos.
  - Conjunto de datos, crear conjunto de datos de entrenamiento, validación y prueba.
- VI. Entrenamiento de la red:
- Definir el número de neuronas y el número de capas ocultas.
  - Entrenar un número de redes usando la calibración de datos, terminando el proceso de entrenamiento al momento que exista sobreajuste.
- VII. Evaluación: seleccionar la medida de error (ver sección 2.5), el cual indique que modelo es el apropiado.

A continuación, se presenta un esquema (ver Figura 5.1), en el cual las líneas solidas muestran el flujo del proceso, y las líneas punteadas muestran la influencia de cada etapa sobre la otra. Los subprocesos se muestran con rectángulos de línea doble a los lados.

**Figura 5.1.** Esquema del desarrollo de procesos para RNA



**Elaborado:** Alexis Aguilar

**Fuente:** (Dawson & Wilby, 2001)

La importancia de cada una de las etapas del proceso es la misma, ya que cada una de las etapas obliga a cumplirla de una manera óptima y, con ello, evitar la reproducción de modelos inadecuados y poco fiables.

Queda a criterio del modelador considerar los pasos más adecuados para el desarrollo del modelo precipitación-escorrentía pues, algunos pasos pueden estar intrínsecamente realizados en pasos anteriores.

## **5.2 SELECCIÓN DE DATOS**

Las variables hidrometereológicas a considerar para la modelación de la relación Precipitación-Escurrimiento en la cuenca Humboldt aplicando RNAs deben escogerse en base a la información existente y a la influencia sobre la cuenca de cada una de ellas. La cuenca de Humboldt tiene influencia del Glaciar, la cual se refleja en los caudales medidos en la estación Los Crespos (MS28), la cual también se considera como dato de entrada para el modelo de RNAs.

A continuación, se indica la determinación del intervalo de tiempo de la serie de datos considerados en el proceso del entrenamiento, de la misma forma las variables consideradas como datos de entrada y como validación de la red.

### **5.2.1 DETERMINACIÓN DEL INTERVALO DE TIEMPO DE LA SERIE DE DATOS**

Las variables hidrometereológicas en la cuenca de Humboldt son medidas a distintos intervalos de tiempo. La estación ORE registra las variables meteorológicas cada 30 minutos, las estaciones limnigráficas registran alturas del nivel de agua cada 15 minutos, mientras que los pluviógrafos registran únicamente cuando se presenta un evento de precipitación. Por lo tanto, como la respuesta hidrológica de la cuenca de Humboldt varía de 2 a 3 horas (Villacis M. , 2008). Para el diseño de la RNA, las series de las variables hidrometereológicas se modificaron a intervalo de tiempo igual a 1 día. Por lo tanto, los datos de precipitación y los caudales y variables climáticas se transformaron a datos diarios.

### **5.2.2 PREPARACIÓN DE PRECIPITACIONES DIARIAS**

Las estaciones pluviográficas consideradas para el análisis de la cuenca de Humboldt son P5, P7, P8 y P9, y debido a que cada una de ellas se encuentra dentro y en los alrededores de la cuenca, los eventos medidos en las estaciones tienen influencia directa en el escurrimiento que se genere sobre la cuenca de Humboldt.

La información fue recopilada de los informes “Glaciares del Ecuador Antisana 15” generados por las instituciones (IRD-INAMHI-EMMAPQ-EPN) a cargo de las estaciones existentes para los años 2005, 2006, 2007, 2008, y 2009. Estas instituciones se han encargado del procesamiento y validación de los datos obtenidos de los equipos de medición instalados. Mientras que los datos diarios de precipitaciones y caudales del año 2010 se obtuvieron del trabajo de investigación “Simulación de la hidrología de la cuenca de Humboldt del volcán Antisana”(RUIZ, 2015) realizado en la Escuela Politécnica Nacional. Debido a este antecedente se puede indicar que los datos utilizados son fiables, lo cual garantiza cualquier análisis a posterior.

Para el entrenamiento del modelo se consideraron la mayoría de datos de la serie histórica, por ello, se seleccionó como valores de entrada la serie de datos de precipitación y caudales de los años 2005, 2007, 2008, 2009 y 2010 y para validarlo se seleccionaron los datos del año 2006.

La información de las estaciones pluviográficas P5, P7, P8 y P9 y de las estaciones Limnigraficas MS21 y MS28 fueron utilizadas como variables de entrada del modelo de RNAs.

La disponibilidad de los datos de precipitación de las estaciones pluviográficas en los años seleccionados se indica en la Tabla 5.1, donde se aprecia que el año 2010 presenta el menor número de valores disponibles.

**Tabla 5.1.** Disponibilidad de Precipitaciones diarias

ESTACIONES PLUVIOGRAFICAS	DISPONIBILIDAD DE DATOS (%)					
	2005	2006	2007	2008	2009	2010
P5-MICA	100	100	100	100	100	30.4
P7-CRESPOS	100	100	100	100	100	30.4
P8-CRESPOS MORRENA	100	100	100	100	100	30.4
P9-PARAMO	100	100	100	100	100	30.4

**Elaborado:** Alexis Aguilar

### 5.2.3 PREPARACIÓN DE CAUDALES DIARIOS

Las estaciones hidrológicas utilizadas que forman parte de la cuenca de Humboldt son MS21 (Humboldt) y MS28 (Los Crespos). Los años seleccionados para el entrenamiento son 2005, 2007, 2008, 2009 y 2010 y se encuentran en el mismo periodo de las estaciones pluviográficas.

En la serie de datos disponibles de la estación hidrológica Humboldt (MS21), se determinaron que la mayor disponibilidad de caudales diarios se presenta en el año 2007 y 2009, mientras en el año 2010 presenta la menor disponibilidad de caudales diarios. La estación hidrológica Los Crespos (MS28) presenta el año 2005, 2007, 2008 y 2009 con más del 90% de disponibilidad de caudales diarios y al año 2010 con el menor número de caudales diarios medidos. En la Tabla 5.2 se presenta la disponibilidad de caudales diarios en la estación Humboldt y Los Crespos.

**Tabla 5.2.** Disponibilidad de Caudales diarios

ESTACIONES HIDROLOGICAS	DISPONIBILIDAD DE DATOS (%)					
	2005	2006	2007	2008	2009	2010
MS21-HUMBOLDT	68.5	73.7	100.0	96.4	99.7	30.4
MS28-LOS CRESPOS	98.9	78.4	95.1	92.9	99.7	30.4

**Elaborado:** Alexis Aguilar

### 5.3 PREPROCESAMIENTO DE DATOS PARA RNA

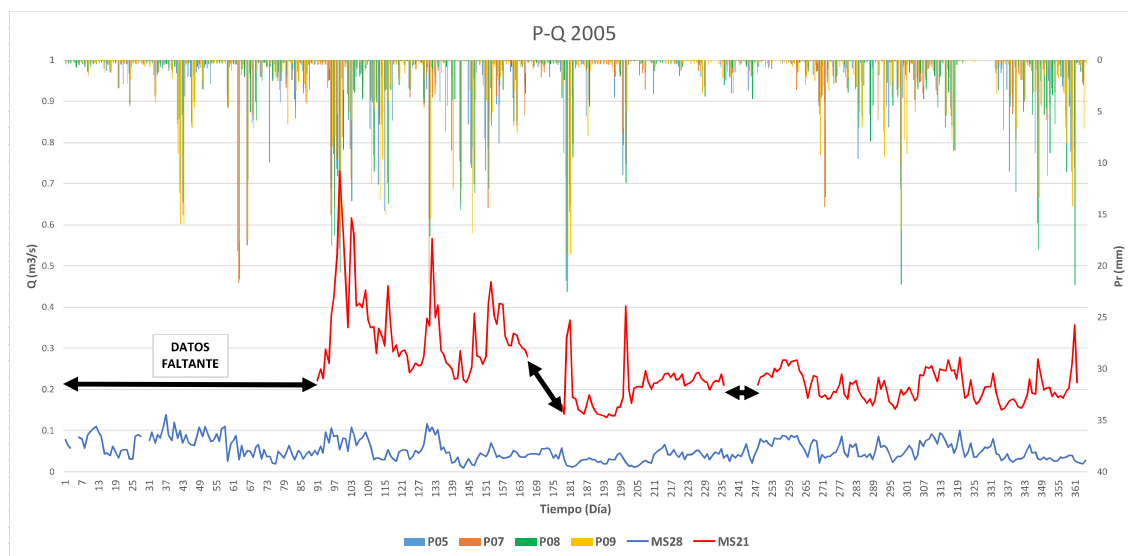
La cuenca Humboldt es un área pequeña, pero por motivo del manejo de la información recopilada en los informes de (Cáceres, Manciatí, Maisincho, Loyo, Cuenca, Arias, Villacís, Francou, Cadier, 2012), se ha considerado el intervalo diario de los datos de entrada, tanto para las precipitaciones y caudales.

Como proceso de depuración de la serie de datos se eliminó los rangos en los que se presente datos faltantes tanto en la serie de precipitaciones diarias, como en la serie de caudales diarios de cada una de las estaciones consideradas para el

entrenamiento de la RNA. Además, se eliminaron los valores que no presenten relación directa entre las precipitaciones diarias y los caudales diarios para cada uno de los periodos desde el año 2005 hasta el 2010.

En la Figura 5.2 se muestra la serie de precipitaciones y caudales del periodo 2005, aquí se presenta falta de datos de caudales en los meses de enero, febrero, marzo, mayo, agosto en la estación hidrológica Humboldt (MS21), mientras que los caudales faltantes en la estación hidrológica Los Crespos (MS28) se corresponden al mes de enero. Además se puede apreciar que los picos de los caudales tienen relación directa con los picos de las precipitaciones de las estaciones pluviográficas pero, en los días que no se presenta la relación serán eliminados.


**Figura 5.2.** Serie de datos (P-Q) del periodo 2005



**Elaborado:** Alexis Aguilar

En la Figura 5.3 se presenta la serie de datos depurada para el periodo 2005, tanto para los caudales diarios de las estaciones MS21, MS28, y las precipitaciones diarias de las estaciones P5, P7, P8, y P9. Esta serie será la considerada para el proceso de entrenamiento de la RNA.


**Figura 5.3.** Serie de datos depurados (P-Q) del periodo 2005



**Elaborado:** Alexis Aguilar

En la Figura 5.4 se presenta la serie de datos del periodo 2006, en la cual se muestran los caudales faltantes en la estación MS21 en los meses enero, febrero, abril, septiembre, octubre, noviembre y diciembre, mientras que los caudales faltantes de la estación MS28 corresponden a los meses de junio, agosto y septiembre.

**Figura 5.4.** Serie de datos (P-Q) del periodo 2006



**Elaborado:** Alexis Aguilar

Considerando las incongruencias de correspondencia entre precipitaciones y caudales y los datos faltantes en la serie histórica, se realiza una depuración de eventos diarios. En la Figura 5.5 se presentan los eventos diarios considerados para la etapa de validación de la RNA en la cuenca Humboldt.

**Figura 5.5.** Serie de datos depurados (P-Q) del periodo 2006




**Elaborado:** Alexis Aguilar

La serie de datos del periodo 2007 es una de las más completas dentro de los periodos seleccionados. En la Figura 5.6 se indica los rangos de datos faltantes en la estación MS28 en los meses de octubre y noviembre. Por tanto esta fue la única depuración que se realizó en toda la serie de datos, tanto en lo correspondiente a precipitaciones como a caudales considerados.




**Figura 5.6.** Serie de datos (P-Q) del periodo 2007



**Elaborado:** Alexis Aguilar

En la Figura 5.7 se presenta la serie de datos depurada del periodo 2007, la cual será considerada para el entrenamiento de la red.


**Figura 5.7.** Serie de datos depurados (P-Q) del periodo 2007



**Elaborado:** Alexis Aguilar

En la serie de datos del periodo del 2008 (ver Figura 5.8), los caudales faltantes corresponden a los meses de febrero y abril de la estación MS28, mientras que para la estación MS21 corresponden al mes de abril.


**Figura 5.8.** Serie de datos (P-Q) del periodo 2008



**Elaborado:** Alexis Aguilar

En la Figura 5.9 se presenta la serie de datos depurada, tanto para precipitaciones diarias como para los caudales diarios del periodo 2008, que se utilizarán para el entrenamiento de la RNA aplicada al modelo P-E.


**Figura 5.9.** Serie de datos depurados (P-Q) del periodo 2008



**Elaborado:** Alexis Aguilar

La serie de datos del periodo del 2009 (ver Figura 5.10) no se identificó vacíos en la serie, la depuración se basó en la falta de relación directa entre los picos de los caudales con respecto a las precipitaciones.


**Figura 5.10.** Serie de datos (P-Q) del periodo 2009



**Elaborado:** Alexis Aguilar

En la Figura 5.11 se presenta la serie depurada de datos del periodo 2009 que se utilizaron para el entrenamiento de la RNA aplicada al modelo P-E.


**Figura 5.11.** Serie de datos depurados (P-Q) del periodo 2009



**Elaborado:** Alexis Aguilar

La serie de datos del periodo 2010 presenta la menor cantidad de valores disponibles de todos los periodos anteriores. En la Figura 5.12 se presenta la serie histórica con los valores existentes tanto de precipitaciones diarias, como caudales diarios en la cual se observa valores en la estación P8 que no presentan relación directa con los caudales MS21 y MS28.


**Figura 5.12.** Serie de datos (P-Q) del periodo 2010



**Elaborado:** Alexis Aguilar

En la Figura 5.13 se presenta los datos depurados en el periodo del 2010 que se utilizaron para el entrenamiento de la RNA aplicada al modelo P-E.

**Figura 5.13.** Serie de datos depurados (P-Q) del periodo 2010



**Elaborado:** Alexis Aguilar

## 5.4 SELECCIÓN DE VARIABLES DE MODELACION

Es fundamental tener claro la variable que se desean modelar en la cuenca y el tiempo de entrega de los resultados. Para la cuenca de Humboldt la modelación se basa en la relación precipitación-escorrentía con el objetivo de conocer el caudal que se genera debido a la precipitación que cae sobre ella.

### 5.4.1 IDENTIFICACIÓN DE DATOS PREDICTORES

Para obtener un mejor rendimiento del modelo es útil identificar los predictores más importantes. La mayoría de estudios se enfoca en predecir el flujo en la cuenca en función de las condiciones climáticas e hidrológicas. En el caso de la cuenca de Humboldt, la RNA realiza la modelación en función de las precipitaciones, variables climáticas y caudales antecedentes que influyen sobre la cuenca. Para representar la variable modelada y las variables de entrada a la RNA se resume en la siguiente ecuación:

$$Q_{t+x} = f(Q_{t-r}, P_{t-r}) \quad (\text{Ec 5.1})$$

Donde:

$Q_{t+x}$  es el flujo futuro, "x" es el tiempo seleccionado en el futuro, para la cuenca de Humboldt el caudal es diario.

$Q_{t-r}$  es el flujo antecedente, donde "r" es el tiempo seleccionado en el pasado, para la cuenca de Humboldt es el caudal Los Crespos pues, la cual representa el efecto del glaciar en la cuenca.

$P_{t-r}$  es la precipitación antecedente, donde "r" es el tiempo seleccionado en el pasado, para la cuenca de Humboldt, cuyas precipitaciones antecedentes son aquellas registradas en P5, P7, P8 y P9.

## 5.5 SERIE DE DATOS PREPARADOS

Los datos de entrada (P5, P7, P8, P9, MS28) que fueron considerados como datos disponibles del pre-procesamiento realizado serán utilizados para la etapa de entrenamiento de la RNA en la cuenca Humboldt, cuyo modelo tratara de generar caudales similares a los medidos en la estación MS21. La serie de datos determinado para la etapa de entrenamiento de la red son los años 2005, 2007, 2008, 2009, y 2010 mientras la serie de datos seleccionados para la etapa de validación del modelo entrenado son el año 2006. En la Tabla 5.3 se presenta el resumen de los datos disponibles para modelación de la RNA aplicada a la relación P-E en la cuenca de Humboldt.

**Tabla 5.3.** Rangos de datos validos de la cuenca Humboldt

ESTACIONES	RANGO DE DATOS					
	2005	2006	2007	2008	2009	2010
P5-MICA	01/ABR-15/JUN 27/JUN-24/AGO	01/JUN-14/JUN 05/NOV-19/NOV	04/MAY-14/SEP 31/OCT-25/NOV 30/NOV-31/DIC	27/ABR-28/MAY 30/MAY-27/NOV 29/NOV-31/DIC	22/ENE-30/ENE 10/ABR-27/JUL	01/JUN-12/JUN 01/JUL-12/JUL 01/AGO-12/AGO 01/OCT-12/OCT 01/NOV-12/NOV
P7-CRESPOS						
P8-CRESPOS MORRENA						
P9-PARAMO						
MS28-LOS CRESPOS						
MS21-HUMBOLDT						

**Elaborado:** Alexis Aguilar

## 5.6 ESTANDARIZACIÓN O NORMALIZACIÓN DE DATOS

Es importante que las variables deban ser estandarizadas para asegurar que reciben igual atención durante el proceso de entrenamiento. Para la estandarización se aplicaran las formulas propuestas en la sección 2.3.4.1. De esta manera se evita el ruido en los hidrogramas modelados. El intervalo recomendado por (Dawson & Wilby, 2001) es  $[0.1; 0.9]$ , la cual se representa en la ecuación Ec 2.1. Los datos de entrada previamente estandarizados serán utilizados en la herramienta NN-Toolbox para realizar el proceso de entrenamiento.

## 5.7 CONJUNTO DE DATOS

Es importante para el desarrollo de la red dividir el conjunto de datos en tres partes o subconjuntos: subconjunto de entrenamiento, subconjunto de entrenamiento cruzado (conocido en NN-Toolbox como subconjunto de parada) y subconjunto de prueba. El subconjunto de entrenamiento realiza el ajuste de los pesos sinápticos y bias de la RNA. El subconjunto de parada determina cuándo parar el entrenamiento (para evitar el sobre-entrenamiento) en base al mínimo error generado entre los datos de salida del modelo y los datos deseados medidos en la estación Humboldt.

Para realizar el proceso de entrenamiento de la RNA aplicada al modelo P-E en la cuenca Humboldt se dividió inicialmente los datos de entrenamiento en dos subconjuntos:

- 80% para entrenamiento del modelo;
- 20% para parada del modelo;

No se consideró el subconjunto de prueba, debido a que no es necesario para el proceso de entrenamiento, ya que no influye en el ajuste de pesos y bias generada en la RNA.

## 5.8 ETAPA DE ENTRENAMIENTO DE LA RNA

A continuación se presentan las diversas pruebas realizadas aplicando la RNA. El objetivo es encontrar la mejor arquitectura de la RNA aplicada a la relación P-E en función de los datos de entrada seleccionados. Primeramente, se determina el número de neuronas en la capa oculta de la red, selección de las variables climáticas e hidrológicas como datos de entrada de la RNA. En segundo lugar, se realizan varias pruebas y análisis de sensibilidad para determinar buenas opciones de parámetros de diseño de RNA, tales como: el algoritmo de entrenamiento, los parámetros del algoritmo de entrenamiento, el tipo de red, el tipo de función de transferencia y el número de capas ocultas. A continuación se presenta las pruebas realizadas en la etapa de entrenamiento para determinar la mejor arquitectura de la RNA del modelo P-E aplicado a la cuenca Humboldt.

### 5.8.1 SELECCIÓN DE NUMERO DE NEURONAS EN LA CAPA OCULTA

Las primeras pruebas realizadas fue determinar el número de neuronas en la capa oculta de la red neuronal. Se consideró realizar modelos en la etapa de entrenamiento utilizando 5 neuronas, 10 neuronas, 15 neuronas, 20 neuronas, 25 neuronas y 30 neuronas en la capa oculta de la RNA. El algoritmo de entrenamiento utilizado es Levenberg-Marquardt (LM) y la función de entrenamiento es Tansig. Además, los datos entrada para entrenamiento de la RNA fueron divididos en 2 subconjuntos: subconjunto entrenamiento que asumirá el 80% del total de datos de entrada y el subconjunto de parada de la red tendrá el 20% del total de datos de entrada. La agrupación de ambos subconjuntos será de forma aleatoria, la cual es una de las opciones que permite utilizar el programa NN-Toolbox.

En la Tabla 5.4 se presenta la comparación de los resultados obtenidos en los modelos P-E entrenados aplicando RNA variando el número de neuronas en la capa oculta. Para la comparación de los resultados se consideraron el coeficiente de correlación “r” y el RMSE.

**Tabla 5.4.** Comparación de pruebas de entrenamiento variando el número de neuronas en capa oculta

		P5-P7-P8-P9-MS28→MS21		
Nº	PRUEBAS		LM	Neuronas en Capa Oculta
1	PR1	r	0.64	5
		RMSE	0.14	
2	PR2	r	0.68	10
		RMSE	0.08	
3	PR3	r	0.68	15
		RMSE	0.13	
4	PR4	r	0.69	20
		RMSE	0.14	
5	PR5	r	0.69	25
		RMSE	0.12	
6	PR19	r	0.68	30
		RMSE	0.12	

**Elaborado:** Alexis Aguilar



Analizando los resultados obtenidos se puede mencionar que el aumento en el número de neuronas en la capa oculta presenta variación en los parámetros de medida de error ( $r$ , RMSE). Es importante indicar que el aumento desmedido de número de neuronas en la capa ocultas no necesariamente mejora el rendimiento de la RNA, por lo contrario genera un fenómeno conocido como Sobre-entrenamiento, el cual debe ser evitado por el modelador en la etapa de determinación de la arquitectura óptima de la RNA. Finalmente de los resultados se concluyó utilizar 25 neuronas en la capa oculta para los modelos de RNAs posteriores.

## **5.8.2 SELECCIÓN DE LOS DATOS DE ENTRADA PARA ENTRENAMIENTO DE LA RNA**

Los resultados de la RNA se fundamentan en los datos de entrada considerados. Para la modelación de la cuenca Humboldt se disponen de valores de precipitaciones diarias en las estaciones P5, P7, P8 y P9, variables climáticas y caudales diarios en la estación Los Crespos (MS28). Para comprobar la influencia del glaciar sobre la cuenca de Humboldt se realizaron pruebas de entrenamiento utilizando como datos de entrada solo las precipitaciones diarias (P5, P7, P8 y P9), y pruebas de entrenamiento combinando las precipitaciones diarias y los caudales diarios de la estación Los Crespos (MS28) como datos de entrada. Además, se presentara los resultados obtenidos de cada una de las pruebas de entrenamiento realizadas.

### **5.8.2.1 Precipitaciones diarias**

Se utilizaron como datos de entrada del fenómeno P-E para la cuenca de Humboldt las precipitaciones diarias de los años 2005, 2007, 2008, 2009, y 2010 de las estaciones P5, P7, P8 y P9. Los valores obtenidos de la modelación serán comparados con los caudales diarios medidos de la estación Humboldt (MS21).

Las pruebas se realizaron variando la información antecedente de las precipitaciones diarias y el algoritmo de entrenamiento Levenberg-Marquardt (LM) y Bayesian

Regularization (BR). El número de neuronas en la capa oculta es 25 y la función de transferencia utilizada es Tansig.

En la Tabla 5.5 se presenta el resumen de resultados obtenidos de las pruebas de entrenamiento de la RNA para la cuenca Humboldt utilizando como datos de entrada solo los valores de las precipitaciones diarias.

**Tabla 5.5.** Comparación de pruebas con datos de entrada de precipitaciones


		P5-P7-P8-P9→MS21			Variación del Tiempo
		Neuronas en Capa Oculta:		25	
Nº	PRUEBA		LM	BR	
1	PR16-PR28	r	0.68	0.71	P al t→0 y Q al t→0
		RMSE	0.12	0.12	
2	PR24-PR29	r	0.71	0.73	P al t→-1 0 y Q al t→0
		RMSE	0.15	0.11	
3	PR25-PR30	r	0.68	0.75	P al t→-2 -1 0 y Q al t→0
		RMSE	0.15	0.10	
4	PR26-PR31	r	0.78	0.79	P al t→-3 -2 -1 0 y Q al t→0
		RMSE	0.10	0.10	
5	PR27-PR32	r	0.77	0.72	P al t→-4 -3 -2 -1 0 y Q al t→0
		RMSE	0.08	0.12	

**Elaborado:** Alexis Aguilar

Las pruebas de entrenamiento utilizando las precipitaciones antecedentes de tres días presentaron los mejores resultados de las medidas de error (r y RMSE). Además, las RNAs que utilizaron el algoritmo de entrenamiento B-R estuvieron sobre las que utilizaron el algoritmo L-M.

En la Figura 5.14 se presentan los caudales diarios de salida del modelo PR31, comparado con los caudales medidos en la estación Humboldt (MS21).

**Figura 5.14.** Comparación de PR31 vs MS21



**Elaboración:** Alexis Aguilar

### 5.8.2.2 Precipitaciones y Caudales

El objetivo de estas pruebas es determinar la influencia del glaciar en el escurrimiento de la cuenca Humboldt con la incorporación de los caudales diarios de la estación Los Crespos (MS28) a los valores de las precipitaciones para lograr un mejor rendimiento de la RNA, el cual debe reflejarse en los errores de medida ( $r$  y RMSE). La incorporación de la serie de caudales diarios de la estación Los Crespos (MS28) es de forma normalizada, de la misma manera que se realizó con los datos de precipitaciones diarias.

Para las pruebas se consideraron los algoritmos de entrenamiento L-M y B-R, en la capa oculta se utilizó 25 neuronas y la función de entrenamiento es Tansig. Además, los datos de entrada presentaran la variación de la información antecedente desde un día hasta cuatros días anteriores.

En la Tabla 5.6 se presentan los resultados de las pruebas de entrenamiento de la RNA utilizando la combinación de las precipitaciones y caudales diarios como datos de entrada. La combinación de las precipitaciones (P5, P7, P8, P9) y los caudales

diarios de la estación Los Crespos (MS28) como datos de entrada logro un mejor rendimiento de los modelos entrenados en comparación a los modelos entrenados solo con precipitaciones diarias. Por otro parte, la utilización del algoritmo de entrenamiento B-R presenta mejores resultados reflejados en la medida de error (r y RMSE). Además, los modelos con valores antecedentes de 4 días antes lograron los mejores resultados. Por lo tanto, de las pruebas de entrenamiento realizadas se aprecia que la prueba PR15 presentó lo mejores indicadores de error.


**Tabla 5.6.** Comparación de pruebas con datos de entrada de P-Q

		P5-P7-P8-P9-MS28→MS21			
		Neuronas en Capa Oculta:		25	Variación del Tiempo
Nº	PRUEBAS		LM	RB	
1	PR5-PR6	r	0.69	0.75	P-Q al t→0 y Q al t→0
		RMSE	0.12	0.11	
2	PR20-PR12	r	0.73	0.83	P-Q al t→-1 0 y Q al t→0
		RMSE	0.16	0.09	
3	PR21-PR13	r	0.74	0.82	P-Q al t→-2 -1 0 y Q al t→0
		RMSE	0.11	0.09	
4	PR22-PR14	r	0.79	0.83	P-Q al t→-3 -2 -1 0 y Q al t→0
		RMSE	0.11	0.09	
5	PR23-PR15	r	0.84	0.86	P-Q al t→-4 -3 -2 -1 0 y Q al t→0
		RMSE	0.06	0.08	

Elaborado: Alexis Aguilar

En la Figura 5.15, se presentan los caudales obtenidos de la PR15 en comparación con los caudales medidos en la estación MS21. Se aprecia que se simulan los caudales picos medidos pero se pierde precisión en el caso de caudales bajos medidos.

**Figura 5.15.** Comparación PR15 vs MS21



**Elaborado:** Alexis Aguilar

### 5.8.3 SELECCIÓN DEL ALGORITMO DE ENTRENAMIENTO

La herramienta NN-Toolbox dispone de una lista de algoritmos de entrenamiento que pueden ser utilizados al momento del entrenamiento de la red neuronal, dichos algoritmos utilizan métodos basados en gradientes o Jacobianos, los cuales se menciona a continuación:

LM: Levenberg-Marquardt

BR: Bayesian Regularization

BFG: BFGS Quasi-Newton

RP: Resilient Backpropagation

SCG: Scaled Conjugate Gradient

CGB: Conjugate Gradient with Powell/Beale Restarts

CGF: Fletcher-Powell Conjugate Gradient

CGP: Polak-Ribière Conjugate Gradient

OSS: One Step Secant

GDX: Variable Learning Rate Backpropagation

En la Tabla 5.7 se presenta las pruebas realizadas para los modelos con los algoritmos de entrenamiento disponibles en la herramienta NN-Toolbox, y cuya arquitectura de la RNA es la siguiente:

Datos de entrada: P5, P7, P8, P9 y  $Q_{MS28}$  al  $t = -4, -3, -2, -1, 0$

Entrenamiento:  $Q_{MS21}$  al  $t \rightarrow 0$

Número de Neuronas en capa oculta: 25

Número de Capas ocultas: 1

**Tabla 5.7.** Resultados de pruebas comparativas con variación del Algoritmo de Entrenamiento

P5-P7-P8-P9-MS28→MS21 P-Q al $t \rightarrow -4 -3 -2 -1 0$ y Q al $t \rightarrow 0$				
Nº	PRUEBA	Neuronas en Capa Oculta: 25		ALGORITMO ENTRENAMIENTO
1	PR23	r	0.84	LM
		RMSE	0.06	
2	PR15	r	<b>0.86</b>	BR
		RMSE	<b>0.08</b>	
3	PR45	r	0.70	BFG
		RMSE	0.12	
4	PR46	r	0.71	RP
		RMSE	0.12	
5	PR47	r	0.69	SCG
		RMSE	0.12	
6	PR48	r	0.69	CGB
		RMSE	0.12	
7	PR49	r	0.67	CGP
		RMSE	0.14	
8	PR50	r	0.69	OSS
		RMSE	0.12	
9	PR51	r	0.66	GDX
		RMSE	0.13	

**Elaboración:** Alexis Aguilar

El algoritmo de entrenamiento que obtuvo los mejores indicadores de medidas de error es la Regularización Bayesiana (B-R), mientras en segundo lugar se encuentra el algoritmo de entrenamiento Levenberg-Marquardt (L-M). De esta forma se justifica el uso de ambos algoritmos de entrenamiento para la determinación del resto de

parámetros en la etapa de entrenamiento de la RNA para la relación P-E en la cuenca Humboldt.

#### 5.8.4 SELECCIÓN DE LA FUNCIÓN DE TRANSFERENCIA

Las funciones de transferencia probadas fueron:

- Función de transferencia lineal (purelin)
- Función de transferencia log-sigmoidal (logsig)
- Función de transferencia sigmoide tangencial hiperbólica (tansig)

Las funciones de transferencia fueron utilizadas en la capa oculta de las pruebas entrenadas, las cuales presentaron la siguiente arquitectura:

Datos de entrada: P5, P7, P8, P9, Q<sub>MS28</sub> al t -4, -3, -2, -1, 0

Predicción: Q<sub>MS21</sub> al t→0

Número de Neuronas en capa oculta: 25

Número de Capas ocultas: 1

**Tabla 5.8.** Resultados de las pruebas comparativas de la función de transferencia.

P5-P7-P8-P9-MS28→MS21 P-Q al t→-4 -3 -2 -1 0 y Q al t→0						
Nº	PRUEBAS	FUNCION TRANSFERENCIA	ERROR	LM	BR	Variación del Tiempo
1	PR52-PR54	PURELIN	r	0.70	0.71	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.11	0.12	
2	PR55-PR53	LOGSIG	r	0.80	0.78	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.08	0.11	
3	PR23-PR15	TANSIG	r	0.84	0.86	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.06	0.08	

**Elaboración:** Alexis Aguilar

La función tangente hiperbólica (Tansig) presenta los mejores resultados reflejados en los indicadores de medida de error (r y RMSE), para lo cual las pruebas PR15 y PR23 fueron las mejores.

### 5.8.5 SELECCIÓN DEL NUMERO DE CAPAS OCULTAS

Continuando con la búsqueda de la arquitectura óptima de la RNA aplicada a la relación P-E en la cuenca Humboldt, se realizaron pruebas utilizando 1 y 2 capas ocultas, variando el número de neuronas (5, 10, 15, 20 y 25) y manteniendo constante los siguientes parámetros de entrenamiento:

Datos de entrada: P5, P7, P8, P9, Q<sub>MS28</sub> al t -4, -3, -2, -1, 0

Modelación: Q<sub>MS21</sub> al t→0

Función de transferencia: Tansig

Algoritmo de entrenamiento: L-M y B-R

En la Tabla 5.9 se presentan los resultados de las pruebas realizadas a los modelos de entrenamiento, variando el número de capas ocultas. Siendo las pruebas PR15 y PR23 con una sola capa oculta las de mejor rendimiento en la etapa de Entrenamiento, en base a los indicadores de medidas de error obtenidos.

**Tabla 5.9.** Resultados comparativos de Pruebas variando el Número de Capas Ocultas

P5-P7-P8-P9-MS28→MS21						
Nº	PRUEBAS	#NEURONAS CAPA OCULTA	ERROR	LM	BR	VARIACION DEL TIEMPO Q al t→0
1	PR61-PR57	H: 5 - 5	r	0.69	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.16	0.09	
2	PR62-PR56	H: 10 - 10	r	0.80	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.19	0.09	
3	PR63-PR59	H: 15 - 15	r	0.80	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.13	0.09	
4	PR64-PR58	H: 20 - 20	r	0.80	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.11	0.09	
5	PR65-PR60	H: 25 - 25	r	0.80	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.09	0.09	
6	PR66-PR70	H: 5 - 0	r	0.78	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.10	0.09	
7	PR67-PR71	H: 10 - 0	r	0.77	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.13	0.09	
8	PR68-PR72	H: 15 - 0	r	0.80	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.08	0.09	
9	PR69-PR73	H: 20 - 0	r	0.80	0.83	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.08	0.09	
10	PR23-PR15	H: 25 - 0	r	0.84	0.86	P-Q al t→-4 -3 -2 -1 0
			RMSE	0.06	0.08	

**Elaboración:** Alexis Aguilar



### 5.8.6 TEMPERATURA COMO VARIABLE DE ENTRADA

La cuenca Humboldt por tener influencia del glaciar aguas arriba del punto de interés, adicionalmente al caudal de la estación Los Crespos se considera a la temperatura debido a que ejerce una gran influencia en el retroceso del glaciar en las últimas décadas (Manciati, y otros, 2014), el cual se refleja en el aumento o disminución del escurrimiento de la cuenca en el punto de medición de la estación Humboldt (MS21). Para realizar las pruebas se consideró los valores medidos de la temperatura (T) en el aire de la estación ORE que serán combinados con los valores de precipitaciones y caudales. A continuación se presenta la arquitectura utilizada para el entrenamiento de la RNA.

Datos de entrada: P5, P7, P8, P9, T(aire),  $Q_{MS28}$  al t -4, -3, -2, -1, 0

Periodo de datos de entrada: 2005-2007-2008-2009

Modelación:  $Q_{MS21}$  al t  $\rightarrow$  0

Función de transferencia en capa oculta: Tansig

Algoritmo de entrenamiento: B-R

Número de Capas Ocultas: 1 y 2

Número de Neuronas en capa oculta: 25

En la Tabla 5.10 se indica los resultados del entrenamiento de la red utilizando como variables de entrada los valores de precipitaciones, caudales y temperaturas diarias.

**Tabla 5.10.** Resultados de pruebas con datos de entrada P-Q-T

P5-P7-P8-P9-Taire-MS28 $\rightarrow$ MS21 P-Q-T al t $\rightarrow$ -4 -3 -2 -1 0 y Q al t $\rightarrow$ 0					
PRUEBA	#NEURONAS CAPA OCULTA	ALGORITMO ENTRENAMIENTO	RMSE	r	VARIACION DEL TIEMPO Q al t $\rightarrow$ 0
PR74	H: 25-0	BR	0.068	0.877	P-Q-T al t $\rightarrow$ -4 -3 -2 -1 0
PR75	H:25-25	BR	0.069	0.878	P-Q-T al t $\rightarrow$ -4 -3 -2 -1 1

**Elaboración:** Alexis Aguilar

Al considerar la temperatura como variable de entrada produce que la modelación de la red neuronal en la etapa de entrenamiento y parada genere un mejor rendimiento, los cuales sean reflejados en los indicadores de medida de error ( $r$  y RMSE). Adicionalmente, se observó que la utilización de dos capas ocultas no refleja mayor variación en los resultados en comparación con la red que utilizó una sola capa oculta. Es importante indicar que adicionalmente a las variables de precipitaciones y temperatura, existen más parámetros climáticos tales como humedad relativa, Nubosidad, velocidad del viento, heliofanía, pero no son factores principales en el balance de masa del glaciar.

### 5.8.7 PREDICCIONES

La predicción de los caudales de la cuenca Humboldt aplicando RNA como datos de entrada las estaciones MS21 y la combinación de las estaciones MS21 y M28. La importancia de este análisis es determinar el número de días antecedentes necesarios para predecir el caudal al día siguiente. Es por ello, que se debe proponer una arquitectura que logre el mejor rendimiento de la red neuronal en la etapa de entrenamiento. Para ello, basándose en la arquitectura obtenida en la sección 5.8.5 se realizó las pruebas de los modelos ingresando las siguientes características a la red de entrenamiento:

Datos de entrada:  $Q_{MS21}$  y la combinación de  $Q_{MS28}-Q_{MS21}$

Periodo: año 2005, 2007, 2008, 2009 y 2010

Tiempo Antecedente: (t-2, t-1, t); (t-3, t-2, t-1, t); (t-4, t-3, t-2, t-1, t)

Predicción:  $Q_{MS21}$  al  $t \rightarrow +1$

Numero de capas ocultas: 1 y 2

Numero de neuronas en capas ocultas: 25

Función de transferencia: Tansig

Algoritmo de entrenamiento: B-R

Función de error: RMSE y r

En la Tabla 5.11 y Tabla 5.12 se presenta los resultados obtenidos de las modelaciones realizadas con las características propuestas para obtener la mejor arquitectura en la predicción de caudales.

**Tabla 5.11.** Resultados para Predicción QMS21→QMS21

Q (MS21) -> Q (MS21)					
Nº	PRUEBAS	ERROR	H: 25	H: 25 - 25	Prediccion Q al t+1
1	PR33-PR39	r	0.745	0.760	Q al t→-2 -1 0
		RMSE	0.034	0.031	
2	PR35-PR41	r	0.737	0.762	Q al t→-3 -2 -1 0
		RMSE	0.034	0.031	
3	PR37-PR43	r	0.740	0.767	Q al t→-4 -3 -2 -1 0
		RMSE	0.033	0.031	

Elaboración: Alexis Aguilar

**Tabla 5.12.** Resultados para Predicción QMS28-MS21→QMS21

Q (MS28-MS21) --> Q (MS21)					
Nº	PRUEBAS	ERROR	H: 25	H: 25 - 25	Prediccion Q al t+1
1	PR34-PR40	r	0.769	0.785	Q al t→-2 -1 0
		RMSE	0.033	0.031	
2	PR36-PR42	r	0.782	0.783	Q al t→-3 -2 -1 0
		RMSE	0.029	0.032	
3	PR38-PR44	r	0.772	0.783	Q al t→-4 -3 -2 -1 0
		RMSE	0.033	0.032	

Elaboración: Alexis Aguilar

De las modelaciones realizadas se aprecia que las arquitecturas que utilizaron 2 capas ocultas presentaron el mejor rendimiento de la RNA. Mientras, se determinó que el tiempo antecedente de 4 días sería el óptimo para la predicción de caudales diarios en la cuenca Humboldt. Finalmente, se recalca que la influencia de los caudales de la estación Los Crespos (MS28) combinado con los caudales de la estación Humboldt (MS21) genera un mejor rendimiento de la red neuronal, la cual es reflejada en los indicadores de error (r y RMSE).

## 5.9 ETAPA DE VALIDACION

La etapa de validación es la fase en la cual se utiliza la RNA entrenada con los arreglos óptimos en la arquitectura y aplicarlos a un periodo diferente de datos de entrada y datos deseados al utilizarlo en la fase de entrenamiento. En la fase de validación se pretende que los resultados sean cercanos a los obtenidos en la etapa de entrenamiento, caso contrario indicaría una particularización del modelo de RNA, la cual obligaría a repetir la etapa de entrenamiento hasta llegar a un modelo generalizado y aplicable a cualquier periodo de datos para la cuenca de Humboldt.

Luego haber obtenido las arquitecturas óptimas en la etapa de entrenamiento de la RNA aplicada a la cuenca de Humboldt, en la cual se determinó que la prueba PR15 y PR74 generaron los mejores resultados, se procede a realizar la etapa de validación de la RNA. Para ejecutar la fase de validación se escogió como datos de entrada y datos deseados los valores medidos en el periodo 2006. A continuación se describe la arquitectura utilizada:

Datos de entrada 1: P5, P7, P8, P9, Q<sub>MS28</sub> al t -4, -3, -2, -1, 0

Datos de entrada 2: P5, P7, P8, P9, T<sub>ORE</sub>, Q<sub>MS28</sub> al t -4, -3, -2, -1, 0

Periodo de datos de entrada: 2006

Modelación: Q<sub>MS21</sub> al t→0

Función de transferencia: Tansig

Algoritmo de entrenamiento: BR

Numero de Capas Ocultas: 1

En la Tabla 5.13 se presenta la comparación de los resultados obtenidos en la etapa de validación de la RNA para las dos arquitecturas óptimas (PR15 y PR74).

**Tabla 5.13.** Resultados de la Etapa de Validación

VALIDACION PERIODO 2006 P5-P7-P8-P9-Taire-MS28→MS21				
PRUEBA	VARIABLES DE ENTRADA	NEURONAS OCULTAS	TIEMPO ANTECEDENTE	CORRELACION LINEAL
				r
PR15	P-Q	H:25-0	t→-4 -3 -2 -1 0	0.842
PR74	P-T-Q	H:25-0	t→-4 -3 -2 -1 0	0.864

**Elaboración:** Alexis Aguilar

Finalmente, después de cumplir con la etapa de validación y obtener resultados satisfactorios, se puede indicar que el arreglo obtenido en la etapa de entrenamiento de la RNA aplicada a la cuenca de Humboldt es el idóneo, ya sea para datos de entrada P-Q y para datos P-Q-T.

## 5.10 ARQUITECTURA ÓPTIMA DE LA RNA APLICADA A LA RELACION P-E EN LA CUENCA DE HUMBOLDT

La arquitectura óptima que encapsula de mejor manera la relación precipitación-escorrentía para la cuenca Humboldt sin la consideración de la variable climática de la Temperaturas es:

Datos de entrada: P5, P7, P8, P9, Q<sub>MS28</sub> al t -4, -3, -2, -1, 0

Modelación: Q<sub>MS21</sub> al t→0

Numero de capas ocultas: 1

Numero de neuronas en capas ocultas: 25

Función de transferencia: Tansig

Algoritmo de entrenamiento: B-R

Función de error: RMSE y r

En el caso de considerar la temperatura como dato de entrada, la arquitectura óptima se mantiene en el resto de parámetros mencionados:

Datos de entrada: P5, P7, P8, P9, Taire,  $Q_{MS28}$  al t -4, -3, -2, -1, 0

Modelación:  $Q_{MS21}$  al  $t \rightarrow 0$

Numero de capas ocultas: 1

Numero de neuronas en capas ocultas: 25

Función de transferencia: Tansig

Algoritmo de entrenamiento: B-R

Función de error: RMSE y r

## **CAPITULO 6**

### **CONCLUSIONES Y RECOMENDACIONES**

#### **6.1 CONCLUSIONES**

Las RNA es una herramienta muy útil para aplicar a fenómenos no lineales como es la relación precipitación-escorrentía de la cuenca de Humboldt, cuyo resultado depende de los datos de entrada y de la arquitectura propuesta. La precisión del modelo depende de las características seleccionadas para la RNA, lo cual permite un rendimiento óptimo representado en los indicadores error entre los datos modelados y datos medidos. A continuación se presenta las conclusiones más importantes extraídas de la investigación realizada.

- La generalización del modelo de RNA depende de la longitud de la serie de datos diarios manejados como datos de entrada tanto en la serie de precipitaciones diarias (P5, P7, P8 y P9), variables climáticas (Taire) y la serie de caudales diarios (MS28 y MS21) que intervinieron en la relación precipitación-escorrentía para la cuenca Humboldt.
- Mientras mayor sea la serie de datos de entrada, mas eventos serán considerados en la etapa de entrenamiento de la RNA. Es por ello que para la etapa de entrenamiento se consideraron una serie de cinco años (2005, 2007, 2008, 2009 y 2010) de datos diarios, mientras para la etapa de validación del modelo se utilizó los datos del periodo 2006. Los valores considerados tanto en la etapa de entrenamiento como de validación son aquellos que presentaron una relación directa entre precipitaciones y caudales a lo largo de la serie en cada uno de los periodos utilizados. Por tal motivo la serie de datos no presentaba una continuidad durante los cinco periodos.
- La aplicación de las RNAs a la cuenca Humboldt presentó dos problemas principales: El primero fue al momento de realizar la modelación de la red neuronal utilizando como datos de entrada los valores de precipitaciones diarias, ya que por tener influencia del glaciar la cuenca Humboldt, era necesario considerar los valores diarios de la estación limnimétrica Los

Crespos (MS28); el segundo problema fue la calibración del parámetro de parada de entrenamiento de la RNA, para el cual fue considerado el error cuadrático medio (MSE) entre los valores modelados y los valores medidos en la estación Humboldt (MS21).

- Los modelos RNA aplicados a la relación precipitación-escorrentía pueden ser utilizados como modelos causa - efecto y como modelos de predicción de series temporales. El modelo causa - efecto (conocido como modelo global) se realiza en base a las variables precipitación, climáticas y escorrentía como datos de entrada, y el modelo de predicción de series temporales (conocido como modelo local) se basa en escorrentías previas y escorrentías aguas arriba de la cuenca como datos de entrada. El rendimiento de la RNA aplicado a modelos globales presenta mejores indicadores de error ( $r$  y RMSE) al momento del entrenamiento y validación de la red comparados con los modelos locales.
- Los modelos de RNA aplicados a la relación precipitación-escorrentía en la cuenca Humboldt fueron capaces de relacionar las precipitaciones y los caudales aguas arriba de la cuenca, de forma directa y de forma anticipada. Es decir, permitió modelos con valores directos y modelos con valores antecedentes. Por ello la relación de la serie de precipitaciones y de caudales se complementaron satisfactoriamente para la cuenca Humboldt.
- La influencia del glaciar en la cuenca Humboldt fue representada por los caudales de la estación Los Crespos (MS28), cuya cuenca está cubierta por glaciar, lo cual permitió ser considerado en el modelo global y en el modelo local.
- La estandarización o normalización de los datos de entrada y los datos medidos en la etapa de entrenamiento de la RNA permitieron que las funciones de transferencia trabajen de manera correcta. Además el pre-procesamiento de la serie de datos iniciales permitió que la red neuronal en la etapa del entrenamiento pueda aprender las relaciones de una manera adecuada.
- Para el desarrollo del modelo RNA aplicado a la relación precipitación-escorrentía sería más factible para el modelador si considera varias pautas básicas tales como: datos confiables de influencia en la cuenca de interés, la



serie utilizada debe tratar de cubrir la mayor cantidad de eventos extremos, la influencia de las variables en la cuenca, la correcta relación entre precipitaciones y caudales. Esto permite que las pruebas a modelar y la interpretación de los resultados de entrenamiento sea más fácil. Además, el modelador debe tener una amplia comprensión de las técnicas existentes en la herramienta seleccionada para realizar los modelos de RNA.

- Los algoritmos de entrenamiento Levenberg-Marquardt (L-M) y Regularización Bayesiana (B-R) presentaron los mejores resultados en la etapa de entrenamiento de la RNA aplicado a la relación P-E en la cuenca Humboldt.
- La arquitectura optima en la etapa de entrenamiento y en la etapa de validación sin considerar la variable climática de la temperatura es:
  - Datos de entrada: P5, P7, P8, P9,  $Q_{MS28}$  al t -4, -3, -2, -1, 0
  - Modelación:  $Q_{MS21}$  al t→0
  - Numero de capas ocultas: 1
  - Numero de neuronas en capas ocultas: 25
  - Función de transferencia: Tansig
  - Algoritmo de entrenamiento: B-R
  - Función de error: RMSE y r

## 6.2 RECOMENDACIONES

- El incremento en las neuronas de la capa oculta deben permitir obtener mejores resultados en un modelo generalizado de RNA pues, llega un punto en el modelo que la variación en los indicadores de error es mínima, y en ese instante se llegó al número máximo de neuronas en la capa oculta.
- No se debe exceder el tiempo antecedente de los datos en el entrenamiento del modelo RNA, pues se observó que al momento de aumentar indiscriminadamente los valores antecedentes de datos de entrada y datos medidos, la RNA tiende a sobre-entrenarse.
- Las variables de entrada deben representar de forma directa la influencia en la cuenca es decir, las precipitaciones y caudales aguas arriba deben presentar una relación con los caudales en sitio de interés de la cuenca. En el caso

estudiado, el modelo precipitación-escurrimiento para la cuenca Humboldt se manejaron 4 estaciones de precipitaciones (P5-P7-P8-P9), las cuales se ubican espacialmente sobre la cuenca, y una estación hidrológica aguas arriba (MS28) para el entrenamiento de la Red.

- Es importante, cuando se poseen series de datos no continuas, realizar las combinaciones necesarias en los tramos continuos permitidos y utilizar Redes de entrenamiento Estáticas, de esta manera se tiene mayor control en el entrenamiento del modelo RNA a diferencia de utilizar Redes de entrenamiento Dinámicas, que son aplicables solo cuando la serie de datos de entrada y objeto son continuas.
- No es necesario utilizar más de 2 capas ocultas en la arquitectura del modelo RNA, utilizar 3 capas presenta poca variación en los resultados, y además se presentaría un sobre-entrenamiento de la Red.
- Se debe tener claro el valor mínimo MSE como parámetro de parada en la etapa de entrenamiento de la RNA, ya que es muy común sobre-entrenarla por alcanzar el mínimo error entre los resultados del entrenamiento y los valores medidos, y en la etapa de validación los resultados presentan menor correlación con los valores medidos.

## REFERENCIAS BIBLIOGRAFICAS

- Abrahart, R. J., Kneale, P. E., & See, L. M. (2004). *Neural Network for Hydrological Modelling*. Londres: A.A. Balkema Publishers.
- Aguilar Jaramillo, J. (s.f.). <http://www.flacsoandes.edu.ec/>. Obtenido de [http://www.flacsoandes.edu.ec/comunicacion/aaa/imagenes/publicaciones/pub\\_30.pdf](http://www.flacsoandes.edu.ec/comunicacion/aaa/imagenes/publicaciones/pub_30.pdf)
- Almeida Roman, M. (Octubre de 2010). Instructivo de Procesamiento de Información Hidrometeorológica. Quito, Ecuador: EPN.
- Aparicio Mijares, F. J. (1992). *Fundamentos de hidrología de Superficie*. Mexico D.F.: Limusa.
- Basogain, X. (1997). Redes Neuronales Artificiales y sus Aplicaciones. *Curso de Redes Neuronales Artificiales y sus Aplicaciones* (pág. 76). Bilbao: Xabier Basogain Olabe.
- Beale, M. H., Hagan, M., & Demuth, H. (septiembre de 2015). Neural Network Toolbox UG. The MathWorks, Inc.
- Beale, M., Hagan, M., & Demuth, H. (2015). *Neural Network Toolbox™-User's Guide*. USA: The MathWorks, Inc.
- Beale, R., & Jackson, T. (1997). *Neural Computing An Introduction*. Philadelphia: Institute of Physics Publishing.
- Caceres, B., Maisincho, L., Manciatí, C., Loyo, C., Cuenca, E., Villacis, M., . . . Cadier, E. (2011). *Glaciares del Ecuador Antisana 15 Y 12, Carihuayraso*. INAMHI-IRD-EMAAPQ-EPN. Quito: INAMHI-IRD-EMAAPQ-EPN.
- Caceres, B., Maisincho, L., Manciatí, C., Loyo, C., Cuenca, E., Villacis, M., . . . Cadier, E. (2012). *Informe 2009 Glaciares del Ecuador Antisana 15*. Quito: IRD-INAMHI-EMMAP-Q-EPN.

- Chow, V. (1994). *Hidrología Aplicada*. Mac Graw Hill.
- Dawson, C. W., & Wilby, R. L. (2001). *Hydrological modelling using artificial neural networks*. UK, USA.
- Dawson, C., & Wilby, R. (1998). An Artificial Neural Network Approach. *An Artificial Neural Network Approach* (pág. 21). Londres: Tylor & Francis.
- De Vos, N. J. (2003). Rainfall-Runoff Modelling Using Artificial Neural Network. Holanda: TUDELFT.
- Flores, H. (2015). Redes Neuronales Artificiales aplicadas a la detección de Cancer de Mama. Mexico, D.F.: IPN. Obtenido de Introducción a las Redes Neuronales Artificiales: <http://www.hugo-inc.com/RNA/Unidad%201/1.5.html>
- Flores, R., & Fernandez, J. M. (2008). *Las Redes Neuronales Artificiales*. Coruña: Netbiblo.
- Hagan, M. T., Demuth, H. B., Beale, M. H., & De Jesús, O. (1996). *Neural Network Design*. Boston: Hagan and Demuth.
- Hagan, M., Demuth, H., Beale, M., & De Jesus, O. (2014). *Neural Network Design*. Texas: Martin Hagan.
- Huerta, A., Quispe, J. C., Ramos, E. M., Fernández, E., & Molina, Y. P. (25 de julio de 2012). *Sector Electricidad*. Obtenido de Aplicación de Redes Neuronales para el Pronóstico de Demanda a Corto Plazo: <http://www.sectorelectricidad.com/2625/aplicacion-de-redes-neuronales-para-el-pronostico-de-demanda-a-corto-plazo/>
- Instituto Geofísico-EPN*. (2015). Obtenido de <http://www.igepn.edu.ec>
- Kohonen, T. (1988). *An Introduction to Neural Computing*. Helsinki: Pergamon Journal Ltda.
- Manciati, C., Villacís, M., Taupin, J.-D., Cadier, E., Galárraga, R., & Cáceres, B. (2014). Empirical mass balance modelling of South American tropical glaciers: case study of Antisana volcano, Ecuador. En *Hydrological Sciences Journal* (págs. 1-17). Ecuador: Hydrological Sciences Journal.

- Mena Correa, S. P. (Octubre de 2010). Evolución de la Dinámica de los Esguerrimientos en Zonas de Alta Montaña: Caso Volcán Antisana. Quito, Pichincha, Ecuador: EPN.
- Minns, A. (1998). Artificial Neural Network as Subsymbolic Process Descriptors. Holanda: UT DELFT.
- Proaño, O. (1998). Emulation of a Sewer System Computational Model for the Statistical Processing of Large Numbers of Events. IIIHE-DELFT.
- Ruiz, H. J. (2015). Simulación de la Hidrología de la Cuenca Humbolt del Volcan Antisana. Quito, Ecuador: EPN.
- Suárez Martínez, L. E. (2012). *Predicción de Comportamientos a traves de Redes Neuronales en Matlab*. Matanzas: Universidad de Matanzas "Camilo Cienfuegos".
- UNESCO, I. (2003). Flood Forecasting using Artificial Neural Network. Holanda: Swets & Zeitlinger.
- Villacis, M. (2008). Ressources en eau glaciaire dans les Andes d'Equateur en relation avec les variations du climat-Le cas du volcan Antisana. Montpellier.
- Villacis, M. (2009). ¿Por qué estudiar la interacción entre los aportes de agua de origen glaciar y del páramo en cuencas hidrográficas del Ecuador? Loja.
- Villon, M. (2002). *Hidrología*. Lima: Villon.

**ANEXOS**

## ANEXO A

### ALGORITMO LEVENBERG MARQUARDT

El algoritmo Levenberg Marquardt es una modificación del Método de Newton, que fue diseñado para minimizar funciones que son sumas de los cuadrados de otras funciones no-lineales. Este tipo de algoritmos es muy usado para la formación de redes neuronales donde el índice de rendimiento es el error cuadrático medio.

En el método de Newton el índice de rendimiento es una suma de cuadrados, en la cual para optimizar un índice de rendimiento  $F(x)$  es

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (\text{Ec. a1})$$

Donde:

$$A_k \equiv \nabla^2 F(x)|_{x=x_k} \quad g_k \equiv \nabla F(x)|_{x=x_k}$$

Asumiendo  $F(x)$  es a una función de suma de cuadrados

$$F(x) = \sum_{i=1}^N v_i^2(x) = v^T(x) v(x) \quad (\text{Ec. a2})$$

Entonces el enésimo elemento del gradiente debería ser:

$$[\nabla F(x)]_j = \frac{\partial F(x)}{\partial x_j} = 2 \sum_{i=1}^N v_i(x) \frac{\partial v_i(x)}{\partial x_j} \quad (\text{Ec. a3})$$

El gradiente puede ser escrito en forma de matriz:

$$\nabla F(x) = 2J^T(x) v(x) \quad (\text{Ec. a4})$$

Donde  $J$  es la matriz Jacobiana:

$$J(x) = \begin{bmatrix} \frac{\partial v_1(x)}{\partial x_1} & \frac{\partial v_1(x)}{\partial x_2} & \dots & \frac{\partial v_1(x)}{\partial x_n} \\ \frac{\partial v_2(x)}{\partial x_1} & \frac{\partial v_2(x)}{\partial x_2} & \dots & \frac{\partial v_2(x)}{\partial x_n} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial v_N(x)}{\partial x_1} & \frac{\partial v_N(x)}{\partial x_2} & \dots & \frac{\partial v_N(x)}{\partial x_n} \end{bmatrix} \quad (\text{Ec. a5})$$

El siguiente paso es determinar la matriz Hessian. El elemento  $k, j$  de la matriz Hessian sería

$$[\nabla^2 F(x)]_{k,j} = \frac{\partial^2 F(x)}{\partial x_k \partial x_j} = 2 \sum_{i=1}^N \frac{\partial v_i(x)}{\partial x_k} \frac{\partial v_i(x)}{\partial x_j} + v_i(x) \frac{\partial^2 v_i(x)}{\partial x_k \partial x_j} \quad (\text{Ec. a6})$$

La matriz Hessian puede ser expresada de la siguiente forma:

$$\nabla^2 F(x) = 2\mathbf{J}^T(x)\mathbf{J}(x) + 2\mathbf{S}(x) \quad (\text{Ec. a7})$$

Donde:

$$\mathbf{S}(x) = \sum_{i=1}^N v_i(x)\nabla^2 v_i(x) \quad (\text{Ec. a8})$$

Si asumimos que  $\mathbf{S}(x)$  es pequeño, entonces podemos aproximar a la matriz Hessian como

$$\nabla^2 F(x) \equiv 2\mathbf{J}^T(x)\mathbf{J}(x) \quad (\text{Ec. a9})$$

Si sustituimos la ecuación (Ec. a7) y la ecuación (Ec. a4) en la ecuación (Ec. a1), obtenemos el método de Gauss Newton

$$\begin{aligned} x_{k+1} &= x_k - [2\mathbf{J}^T(x_k)\mathbf{J}(x_k)]^{-1} 2\mathbf{J}^T(x_k) v(x_k) \\ &= x_k - [\mathbf{J}^T(x_k)\mathbf{J}(x_k)]^{-1} \mathbf{J}^T(x_k) v(x_k) \end{aligned} \quad (\text{Ec. a10})$$

Un problema con el metodo Gauss Newton es que la matriz  $\mathbf{H}=\mathbf{J}^T \mathbf{J}$  no podria ser invertida. Para ello se usa la siguiente modificación:

$$\mathbf{G} = \mathbf{H} + \mu \mathbf{I} \quad (\text{Ec. a11})$$

Los valore propios y vectores propios de  $\mathbf{H}$  son  $\{\lambda_1, \lambda_2, \dots, \lambda_n\}$  y  $\{z_1, z_2, \dots, z_n\}$ . Entonces:

$$\mathbf{G}z_i = [\mathbf{H} + \mu\mathbf{I}]z_i = \mathbf{H}z_i + \mu z_i = \lambda_i z_i + \mu z_i = (\lambda_i + \mu)z_i \quad (\text{Ec. a12})$$

Esto nos lleva al algoritmo Levenberg-Marquardt:

$$x_{k+1} = x_k - [\mathbf{J}^T(x_k)\mathbf{J}(x_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(x_k) v(x_k) \quad (\text{Ec. a13})$$

$$\Delta x_k = -[\mathbf{J}^T(x_k)\mathbf{J}(x_k) + \mu_k \mathbf{I}]^{-1} \mathbf{J}^T(x_k) v(x_k) \quad (\text{Ec. a14})$$

Este algoritmo tiene características muy utilizadas como  $\mu_k$  es incrementada acercando el algoritmo de descenso más pronunciado con una pequeña relación de aprendizaje.



Aplicando el algoritmo Levenberg-Marquardt para el entrenamiento de problemas de redes multicapas. El índice de rendimiento para el entrenamiento en redes multicapas es el error cuadrático medio. Si cada valor deseado se genera con igual probabilidad, el error cuadrático medio (MSE) es proporcional a la suma de errores cuadrados sobre los Caudales deseados en el conjunto de entrenamiento:

$$\begin{aligned} F(x) &= \sum_{q=1}^Q (t_q - a_q)^T (t_q - a_q) \\ &= \sum_{q=1}^Q e_q^T e_q = \sum_{q=1}^Q \sum_{j=1}^{S^M} (e_{j,q})^2 = \sum_{i=1}^N (v_i)^2 \end{aligned} \quad (\text{Ec. a15})$$

Donde  $e_{i,q}$  es el  $i$ -ésimo elemento del error para la  $q$ -ésimo par de entrada/deseado.

La ecuación (Ec. a15) es equivalente al índice de rendimiento, (Ec. a2), para el que algoritmo de Levenberg-Marquardt fue diseñado.

El paso clave en el algoritmo de Levenberg-Marquardt es el cálculo de la matriz Jacobiana. Para realizar este cálculo se utiliza una variación del algoritmo de Retropropagación. Para crear la matriz Jacobiana necesitamos calcular las derivadas de los errores, en lugar de las derivadas de los errores al cuadrado. Si consideramos la (Ec. a5), el vector error es:

$$V^T = [v_1 \ v_2 \ \dots \ v_N] = [e_{1,1} \ e_{2,1} \ \dots \ e_{S^M,1} \ e_{1,2} \ \dots \ e_{S^M,Q}] \quad (\text{Ec. a16})$$

El vector parámetro es:

$$X^T = [x_1 x_2 \ \dots \ x_n] = [w_{1,1}^1 w_{1,2}^1 \ \dots \ w_{S^1,R}^1 \ \dots \ b_{S^1}^1 w_{1,1}^2 \ \dots \ b_{S^M}^M] \quad (\text{Ec. a17})$$

$$N = Q * S^M \quad \text{y} \quad n = S^1(R + 1) + S^2(S^1 + 1) + \dots + S^M(S^{M-1} + 1)$$

Sustituyendo en la (Ec. a5), la matriz Jacobiana para el entrenamiento de redes multicapa puede escribirse:

$$J(x) = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_{1,1}^1} & \frac{\partial e_{1,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{1,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{1,1}}{\partial b_1^1} & \dots \\ \frac{\partial e_{2,1}}{\partial w_{1,1}^1} & \frac{\partial e_{2,1}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{2,1}}{\partial w_{S^1,R}^1} & \frac{\partial e_{2,1}}{\partial b_1^1} & \dots \\ \vdots & \vdots & & \vdots & \vdots & \\ \frac{\partial e_{SM,1}}{\partial w_{1,1}^1} & \frac{\partial e_{SM,1}}{\partial w_{1,2}^1} & & \frac{\partial e_{2,1}}{\partial w_{1,2}^1} & \frac{\partial e_{2,1}}{\partial b_1^1} & \dots \\ \frac{\partial e_{1,2}}{\partial w_{1,1}^1} & \frac{\partial e_{1,2}}{\partial w_{1,2}^1} & \dots & \frac{\partial e_{1,2}}{\partial w_{S^1,R}^1} & \frac{\partial e_{1,2}}{\partial b_1^1} & \dots \\ \vdots & \vdots & & \vdots & \vdots & \end{bmatrix} \quad (\text{Ec. a18})$$

Las iteraciones del algoritmo de Retropropagación de Levenberg-Marquardt puede ser resumido de la siguiente forma:

- i. Presentando todos los datos de entrada a la red y calcular la salida de red correspondiente y los errores  $e_q = t_q - a_q^M$ . Calcular la suma de los errores al cuadrado sobre todas las entradas.
- ii. Calcular la matriz Jacobiana (Ec. a18)
- iii. Resolver la (Ec. a14) para obtener  $\Delta x_k$ .
- iv. Recalcular la suma de los errores al cuadrado usando  $x_k + \Delta x_k$ . Si esta nueva suma de cuadrados es menor que la calculada en el paso 1, entonces dividir  $\mu$  para  $\vartheta$ , sacar  $x_{k+1} = x_k + \Delta x_k$ , y regresar al paso 1. Si la suma de los cuadrados no es reduces, entonces multiplicar  $\mu$  por  $\vartheta$  y regresar al paso 3.

Se asume que el algoritmo ha convergido cuando la norma del gradiente, ecuación (Ec. a4). Es menor que un valor predeterminado, o cuando la suma de cuadrados ha sido reducida a algún de error deseado.

El principal inconveniente del algoritmo LM-RetroPropagación es el requisito de almacenamiento. El algoritmo debe almacenar la matriz aproximada Hessian. Esta es una matriz, donde está el número de parámetros (pesos y bias) en la red. Recordemos que los otros métodos discutidos sólo necesitan almacenar el gradiente, que es un vector n-dimensional. Cuando el número de parámetros es muy grande, puede ser impráctico utilizar el algoritmo de Levenberg-Marquardt. (Lo que constituye "muy grande" depende de la memoria disponible en su computadora, pero normalmente unos pocos miles de parámetros son un límite superior). (Hagan M. T., Demuth, Beale, & De Jesús, 1996)

## ANEXO B

### ALGORITMO DE RETROPROPAGACION

El algoritmo de Retro-propagación tiene como índice de rendimiento el Error Cuadrático Medio (MSE). El algoritmo provee un conjunto de ejemplos propios del comportamiento de la red.

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \quad (\text{Ec. b1})$$

Donde  $p_q$  es una entrada a la red y  $t_q$  es la correspondiente salida deseada.

Para redes multicapas, la ecuación que describe esta operación es:

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) \text{ por } m=0,1,\dots,M-1 \quad (\text{Ec. b2})$$

Donde M es el número de capas en la red, a es la salida de la red, W es el peso de la red y b es el bias de la red.

El algoritmo debe ajustar los parámetros de red para minimizar el error cuadrático medio.

$$F(x) = E[e^2] = E[(t - a)^2] \quad (\text{Ec. b3})$$

Donde x es el vector de pesos y bias de la red. Si la red tiene multiple salidas, esta se generaliza por:

$$F(x) = E[e^T e] = E[(t - a)^T (t - a)] \quad (\text{Ec. b4})$$

Se aproximaría al error cuadrático medio por:

$$F(x) = (t(k) - a(k))^T (t(k) - a(k)) = e^T(k)e(k) \quad (\text{Ec. b5})$$

Donde la expectativa del error cuadrático ha sido reemplazada por el error al cuadrado en iteración k.

El algoritmo de descenso más pronunciado para el error cuadrático medio aproximado es:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial F}{\partial w_{i,j}^m} \quad (\text{Ec. b6})$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial F}{\partial b_i^m} \quad (\text{Ec. b7})$$

Donde  $\alpha$  es la relación de aprendizaje.

Si se aplica la regla en cadena, la cual se define como:

$$S_i^m \equiv \frac{\partial F}{\partial n_i^m} \quad (\text{Ec. b8})$$

La sensibilidad de los cambios en el  $i$ -ésimo elemento de la entrada neta en la capa  $m$ , entonces la (Ec. b6) y la ecuación (Ec. b7) se puede simplificar como:

$$\frac{\partial F}{\partial w_{i,j}^m} = s_i^m a_j^{m-1} \quad (\text{Ec. b9})$$

$$\frac{\partial F}{\partial b_i^m} = s_i^m \quad (\text{Ec. b10})$$

De esta manera se puede expresar el algoritmo de descenso más pronunciado como

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (\text{Ec. b11})$$

$$b_i^m(k+1) = b_i^m(k) - \alpha s_i^m \quad (\text{Ec. b12})$$

En forma de matriz se puede describir de la siguiente manera:

$$\mathbf{W}^m(k+1) = \mathbf{W}^m(k) - \alpha s^m (\mathbf{a}^{m-1})^T \quad (\text{Ec. b13})$$

$$\mathbf{b}^m(k+1) = \mathbf{b}^m(k) - \alpha s^m \quad (\text{Ec. b14})$$

Finalmente, los pesos y bias se actualizan usando la ecuación (Ec. b13) y (Ec. b14)

## ANEXO C

### SCRIPT PARA MODELACION DE LA RNA PARA P-R

#### RNA CON 1 CAPA OCULTA

```

net=feedforwardnet([25]); %REDES DE ALIMENTACION HACIA ADELANTE 1 CAPAS OCULTAS
net.divideParam.trainRatio = 80/100; %SUBCONJUNTO DE ENTRENAMIENTO
net.divideParam.valRatio = 20/100; %SUBCONJUNTO DE PARADA DE ENTRENAMIENTO
net.divideParam.testRatio = 0/100; %SUBCONJUNTO DE PRUEBAS
net.layers{1}.transferFcn = 'tansig'; %FUNCION DE TRANSFERENCIA EN LA CAPA OCULTA
net.layers{2}.transferFcn = 'purelin'; %FUNCION DE TRANSFERENCIA EN LA CAPA SALIDA
net.trainFcn = 'trainbr'; %FUNCION DE ENTRENAMIENTO REGULARIZACION BAYESIANA
net.trainParam.epochs=100; %PARTE TEMPORAL MAXIMA PARA EL ENTRENAMIENTO DE LA RED
net.trainParam.goal=5e-3; %VALOR DE ERROR CUADRATICO MEDIO COMO PARAMETRO DE
ENTRENAMIENTO DE LA RED
net.trainParam.max_fail=10; %MAXIMO VALOR DE VALIDACION DE PARADA
net=init(net); %REINICIO DE PESOS Y BIAS DE FORMA ALEATORIA
[net,tr] = train(net,NOMBRE DE ARCHIVO ENTRADA,NOMBRE ARCHIVO MEDIDO);%ENTRENAMIENTO
DATOS ENTRADA,DATOS TARGET
Y=net(NOMBRE DE ARCHIVO ENTRADA); %RESULTADOS DE LA MODELACION DE LA RED ENTRENADA
Z=net(NOMBRE DE ARCHIVO ENTRADA);% RESULTADOS DE LA SIMULACION CON DATOS DE VALIDACION
EN LA RED ENTRENADA

```

#### RNA CON 2 CAPAS OCULTAS

```

net=feedforwardnet([25 25]); %REDES DE ALIMENTACION HACIA ADELANTE 2 CAPAS OCULTAS
net.divideParam.trainRatio = 80/100; %SUBCONJUNTO DE ENTRENAMIENTO
net.divideParam.valRatio = 20/100; %SUBCONJUNTO DE PARADA DE ENTRENAMIENTO
net.divideParam.testRatio = 0/100; %SUBCONJUNTO DE PRUEBAS
net.layers{1}.transferFcn = 'tansig'; %FUNCION DE TRANSFERENCIA EN LA CAPA OCULTA
net.layers{2}.transferFcn = 'tansig'; %FUNCION DE TRANSFERENCIA EN LA CAPA OCULTA
net.layers{3}.transferFcn = 'purelin'; %FUNCION DE TRANSFERENCIA EN LA CAPA SALIDA
net.trainFcn = 'trainbr'; %FUNCION DE ENTRENAMIENTO REGULARIZACION BAYESIANA
net.trainParam.epochs=100; %PARTE TEMPORAL MAXIMA PARA EL ENTRENAMIENTO DE LA RED
net.trainParam.goal=5e-3; %VALOR DE ERROR CUADRATICO MEDIO COMO PARAMETRO DE
ENTRENAMIENTO DE LA RED
net.trainParam.max_fail=10; %MAXIMO VALOR DE VALIDACION DE PARADA
net=init(net); %REINICIO DE PESOS Y BIAS DE FORMA ALEATORIA
[net,tr] = [net,tr] = train(net,NOMBRE DE ARCHIVO ENTRADA,NOMBRE ARCHIVO
MEDIDO);%ENTRENAMIENTO DATOS ENTRADA,DATOS TARGET
Y=net(NOMBRE DE ARCHIVO ENTRADA); %RESULTADOS DE LA MODELACION DE LA RED ENTRENADA
Z=net(NOMBRE DE ARCHIVO ENTRADA);% RESULTADOS DE LA SIMULACION CON DATOS DE VALIDACION
EN LA RED ENTRENADA

```

**ANEXO D**

**RESUMEN DE PRUEBAS ENTRENADAS APLICANDO RNA PARA LA  
RELACION P-E EN LA CUENCA HUMBOLDT**



	DATOS DE ENTRADA			DATOS DE CALIBRACION	CAPAS OCULTAS	NEURONAS OCULTAS	ALGORITMO ENTRENAMIENTO	FUNCION TRANSFERENCIA	TIEMPO ANTECEDENTE		TIEMPO PREDICION		R <sup>2</sup>	MSE	RMSE	CE	r
	ESTACIONES PLUVIOMETRICAS	ESTACIONES HIDROMETRICA	ESTACION ORE						DIAS	DIAS							
PRUEBA 38		MS28-MS21		MS21	1	25	BR	TANSIG	-4,-3,-2,-1,0	1	0.596	0.0052	0.033	0.596	0.772		
PRUEBA 39		MS21		MS21	2	25	BR	TANSIG	-2,-1,0	1	0.577	0.0055	0.031	0.577	0.760		
PRUEBA 40		MS28-MS21		MS21	2	25	BR	TANSIG	-2,-1,0	1	0.616	0.0050	0.031	0.615	0.785		
PRUEBA 41		MS21		MS21	2	25	BR	TANSIG	-3,-2,-1,0	1	0.581	0.0054	0.031	0.581	0.762		
PRUEBA 42		MS28-MS21		MS21	2	25	BR	TANSIG	-3,-2,-1,0	1	0.613	0.0050	0.032	0.613	0.783		
PRUEBA 43		MS21		MS21	2	25	BR	TANSIG	-4,-3,-2,-1,0	1	0.589	0.0053	0.031	0.589	0.767		
PRUEBA 44		MS28-MS21		MS21	2	25	BR	TANSIG	-4,-3,-2,-1,0	1	0.613	0.0050	0.032	0.613	0.783		
PRUEBA 45	P05	P08	P09	MS21	1	25	BFG	TANSIG	-4,-3,-2,-1,0	0	0.484	0.0067	0.123	0.482	0.696		
PRUEBA 46	P05	P07	P08	MS21	1	25	RP	TANSIG	-4,-3,-2,-1,0	0	0.507	0.0064	0.121	0.500	0.712		
PRUEBA 47	P05	P07	P08	MS21	1	25	SCG	TANSIG	-4,-3,-2,-1,0	0	0.480	0.0067	0.122	0.480	0.693		
PRUEBA 48	P05	P07	P08	MS21	1	25	CGB	TANSIG	-4,-3,-2,-1,0	0	0.471	0.0068	0.138	0.469	0.687		
PRUEBA 49	P05	P07	P08	MS21	1	25	CGP	TANSIG	-4,-3,-2,-1,0	0	0.444	0.0081	0.145	0.374	0.667		
PRUEBA 50	P05	P07	P08	MS21	1	25	OSS	TANSIG	-4,-3,-2,-1,0	0	0.477	0.0067	0.122	0.477	0.691		
PRUEBA 51	P05	P07	P08	MS21	1	25	GDX	TANSIG	-4,-3,-2,-1,0	0	0.442	0.0074	0.131	0.426	0.665		
PRUEBA 52	P05	P07	P08	MS21	1	25	BR	PURELIN	-4,-3,-2,-1,0	0	0.499	0.0064	0.120	0.499	0.707		
PRUEBA 53	P05	P07	P08	MS21	1	25	BR	LOGSIG	-4,-3,-2,-1,0	0	0.613	0.0050	0.110	0.612	0.783		
PRUEBA 54	P05	P07	P08	MS21	1	25	LM	PURELIN	-4,-3,-2,-1,0	0	0.492	0.0066	0.112	0.490	0.701		
PRUEBA 55	P05	P07	P08	MS21	1	25	LM	LOGSIG	-4,-3,-2,-1,0	0	0.642	0.0046	0.083	0.643	0.801		
PRUEBA 56	P05	P07	P08	MS21	2	10	BR	TANSIG	-4,-3,-2,-1,0	0	0.692	0.0040	0.090	0.691	0.832		
PRUEBA 57	P05	P07	P08	MS21	2	5	BR	TANSIG	-4,-3,-2,-1,0	0	0.689	0.0040	0.087	0.689	0.830		
PRUEBA 58	P05	P07	P08	MS21	2	20	BR	TANSIG	-4,-3,-2,-1,0	0	0.689	0.0040	0.091	0.689	0.830		
PRUEBA 59	P05	P07	P08	MS21	2	15	BR	TANSIG	-4,-3,-2,-1,0	0	0.692	0.0040	0.089	0.693	0.832		
PRUEBA 60	P05	P07	P08	MS21	2	25	BR	TANSIG	-4,-3,-2,-1,0	0	0.691	0.0040	0.088	0.691	0.831		
PRUEBA 61	P05	P07	P08	MS21	2	5	LM	TANSIG	-4,-3,-2,-1,0	0	0.479	0.0072	0.156	0.444	0.692		
PRUEBA 62	P05	P07	P08	MS21	2	10	LM	TANSIG	-4,-3,-2,-1,0	0	0.636	0.0070	0.190	0.452	0.798		
PRUEBA 63	P05	P07	P08	MS21	2	15	LM	TANSIG	-4,-3,-2,-1,0	0	0.637	0.0051	0.126	0.605	0.798		
PRUEBA 64	P05	P07	P08	MS21	2	20	LM	TANSIG	-4,-3,-2,-1,0	0	0.637	0.0049	0.114	0.615	0.798		
PRUEBA 65	P05	P07	P08	MS21	2	25	LM	TANSIG	-4,-3,-2,-1,0	0	0.646	0.0048	0.087	0.630	0.804		
PRUEBA 66	P05	P07	P08	MS21	1	5	LM	TANSIG	-4,-3,-2,-1,0	0	0.603	0.0051	0.095	0.602	0.776		
PRUEBA 67	P05	P07	P08	MS21	1	10	LM	TANSIG	-4,-3,-2,-1,0	0	0.591	0.0055	0.130	0.574	0.769		
PRUEBA 68	P05	P07	P08	MS21	1	15	LM	TANSIG	-4,-3,-2,-1,0	0	0.638	0.0048	0.080	0.628	0.799		
PRUEBA 69	P05	P07	P08	MS21	1	20	LM	TANSIG	-4,-3,-2,-1,0	0	0.644	0.0050	0.082	0.614	0.802		
PRUEBA 70	P05	P07	P08	MS21	1	5	BR	TANSIG	-4,-3,-2,-1,0	0	0.690	0.0040	0.087	0.690	0.831		
PRUEBA 71	P05	P07	P08	MS21	1	10	LM	TANSIG	-4,-3,-2,-1,0	0	0.690	0.0040	0.092	0.690	0.830		
PRUEBA 72	P05	P07	P08	MS21	1	15	LM	TANSIG	-4,-3,-2,-1,0	0	0.690	0.0040	0.091	0.689	0.830		
PRUEBA 73	P05	P07	P08	MS21	1	20	LM	TANSIG	-4,-3,-2,-1,0	0	0.691	0.0040	0.090	0.690	0.831		
PRUEBA 74	P05	P07	P08	MS21	1	25	BR	TANSIG	-4,-3,-2,-1,0	0	0.769	0.0030	0.068	0.767	0.877		
PRUEBA 75	P05	P07	P08	MS21	2	25	BR	TANSIG	-4,-3,-2,-1,0	0	0.771	0.0029	0.069	0.771	0.878		