



**UNIVERSIDAD TÉCNICA PARTICULAR
DE LOJA**

La Universidad Católica de Loja

ÁREA TÉCNICA

TITULACIÓN DE INGENIERO CIVIL

**Aplicación de redes neuronales para la modelización y generación de series
hidrológicas**

TRABAJO DE FIN DE TITULACIÓN.

AUTOR: Carpio Peláez, Karina Patricia

DIRECTOR: Oñate Valdivieso, Fernando Rodrigo, PhD.

LOJA – ECUADOR

2014

APROBACIÓN DEL DIRECTOR DEL TRABAJO DE FIN DE TITULACIÓN

Doctor.

Fernando Rodrigo Oñate Valdivieso

DOCENTE DE LA TITULACIÓN

De mi consideración:

El presente trabajo de fin de titulación: Aplicación de redes neuronales para la modelización y generación de series hidrológicas realizado por Carpio Peláez Karina Patricia, ha sido orientado y revisado durante su ejecución por cuanto se aprueba la presentación del mismo.

Loja, agosto de 2014

f).....

DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS

“Yo Carpio Peláez Karina Patricia declaro ser autora del presente trabajo de fin de titulación Aplicación de redes neuronales para la modelización y generación de series hidrológicas, de la Titulación de Ingeniero Civil, siendo Oñate Valdivieso Fernando Rodrigo, director del presente trabajo; y eximo expresamente a la Universidad Técnica Particular de Loja y a sus representantes legales de posibles reclamos o acciones legales. Además certifico que las ideas, conceptos, procedimientos y resultados vertidos en el presente trabajo investigativo, son de mi exclusiva responsabilidad.

Adicionalmente declaro conocer y aceptar la disposición del Art. 67 del Estatuto Orgánico de la Universidad Técnica Particular de Loja que en su parte pertinente textualmente dice: “Forman parte del patrimonio de Universidad la propiedad intelectual de investigaciones, trabajos científicos o técnicos y tesis de grado que se realicen a través, o con el apoyo financiero, académico o institucional (operativo) de la Universidad”.

f.....

Karina Patricia Carpio Peláez

Ci. 1104882228

DEDICATORIA

Dedico esta tesis a Dios, que supo guiarme por el buen camino, darme fuerza para seguir adelante y no desmayar en los problemas que se me presentaban, enseñándome a superar las adversidades sin perder la dignidad ni desfallecer en el intento.

A mis padres por ser el pilar fundamental en mi formación tanto personal como profesional, por enseñarme que con humildad, paciencia y sabiduría que todo es posible, gracias por estar conmigo en todo momento, ayudándome incondicionalmente, para que yo pueda lograr mi meta, que la he alcanzado, y con humildad y cariño les ofrezco a ustedes, ya que mi triunfo es el suyo, gracias padres queridos.

A mis queridos abuelitos, especialmente a mi mamita Angelita que con tanto afecto la llamaba, quien con la sabiduría de Dios me enseñó a ser quien soy, con su paciencia y consejos me enseñó el camino de la vida, gracias por el amor que me diste hoy que no estas físicamente, para celebrar este triunfo, pero estoy segura que desde el cielo festejas mi éxito que es el tuyo abuelita querida.

A mis hermanas Valeria y Thalía por estar siempre a mi lado apoyándome.

A mi querida sobrina que llego a constituir una parte importante en mi vida, que me motivó a seguir adelante.

A todos mis familiares que de una u otra manera me brindaron su cariño y comprensión, aportando moralmente a culminar exitosamente este trabajo de tesis.

Karina Patricia Carpio Peláez

AGRADECIMIENTO

Mi eterno agradecimiento es para Dios, ya que por su voluntad he podido llegar hasta este punto de mi vida, por haberme permitido lograr mis objetivos y no dejarme nunca.

A la titulación de ingeniería civil de la Universidad Técnica Particular de Loja, especialmente a su planta docente que me supieron impartir sus conocimientos en el transcurso de mi carrera universitaria.

A mis padres y hermanas gracias por su apoyo, durante toda mi vida, y ser incondicionales.

Al Doctor Fernando Oñate director de este proyecto por haberme dirigido con sus arduos conocimientos durante la realización del mismo, por su apoyo, constante guía y por facilitarme los medios necesarios para realizar este proyecto.

Karina Patricia Carpio Peláez

ÍNDICE DE CONTENIDOS

CARATULA.....	i
APROBACIÓN DEL DIRECTOR DEL TRABAJO DE FIN DE TITULACIÓN	ii
DECLARACIÓN DE AUTORÍA Y CESIÓN DE DERECHOS	iii
DEDICATORIA.....	iv
AGRADECIMIENTO	v
ÍNDICE DE CONTENIDOS.....	vi
RESUMEN.....	9
ABSTRACT	10
INTRODUCCIÓN.....	11
GENERALIDADES	13
1 Generalidades	¡Error! Marcador no definido.
1.1 Objetivos.....	14
1.1.1 Objetivo General.....	14
1.1.2 Objetivos Específicos.....	14
1.2 Fundamentos de las redes neuronales artificiales	14
1.2.1 Fundamentos biológicos de las redes neuronales.....	14
1.2.2 Historia de las Redes Neuronales Artificiales	15
1.2.3 Ventajas de las Redes neuronales.....	18
1.2.4 Red neuronal.....	19
1.2.5 Componentes de las redes neuronales artificiales.	19
1.2.6 Arquitectura de las redes neuronales artificiales.....	25
1.2.7 Aprendizaje.....	27
1.2.8 Validación.	28
1.3 Modelos precipitación-escorrentía determinísticos	29
1.3.1 Modelo hidrológico distribuido.....	29
1.4 Modelos estocásticos	29
1.5 Optimización de modelos	30
1.6 Medidas de bondad de un modelo.....	30
1.6.1 Eficiencia de Nash- Sutcliffe.....	30
1.7 Aplicaciones de las redes neuronales.....	31
1.7.1 Diagnóstico.....	31

1.7.2	Procesamiento de señales.....	31
1.7.3	Procesamiento y análisis de imágenes.....	32
1.7.4	Control automático y robótico.....	32
1.7.5	Análisis y generación de lenguaje natural.....	32
MATERIALES Y MÉTODOS.....		34
2	MATERIALES Y MÉTODOS.....	35
2.1	Ubicación y características generales del área de estudio.....	35
2.1.1	Cuenca del río Guayllabamba.....	35
2.1.2	Cuenca del río Quijos.....	38
2.1.3	Cuenca río Chico Portoviejo.....	41
2.1.4	Cuenca del río Pindo Amarillo.....	44
2.1.5	Cuenca Río El Limón.....	48
2.1.6	Cuenca Catamayo – Chira.....	51
2.2	Materiales y Métodos.....	53
2.2.1	Materiales.....	53
2.2.2	Definición de los datos.....	53
2.2.3	Identificación de variables de entrada.....	53
2.2.4	Implementación de arquitecturas de redes neuronales.....	54
2.2.5	Métodos.....	55
2.2.6	Desarrollo de los métodos.....	55
2.2.7	Modelo Presentado para su análisis.....	58
2.2.8	Análisis con la herramienta de identificación de sistemas de Matlab.....	58
2.2.9	Implementación en Matlab – herramienta de redes neuronales – NNTool.....	59
2.2.10	Análisis microcuenca el Limón.....	63
2.2.11	Análisis cuenca Catamayo.....	63
ANÁLISIS DE RESULTADOS.....		65
3	ANÁLISIS DE RESULTADOS.....	66
3.1	Microcuenca El Limón y Catamayo.....	70
CONCLUSIONES.....		¡Error! Marcador no definido.
4	CONCLUSIONES.....	72
RECOMENDACIONES.....		¡Error! Marcador no definido.
5	RECOMENDACIONES.....	73
6	ANEXOS.....	74

BIBLIOGRAFÍA	¡Error! Marcador no definido.
7 BIBLIOGRAFÍA	80

RESUMEN

El presente trabajo de investigación tiene como finalidad simular información de caudales medios mensuales en las cuencas hidrográficas: Río Guayllabamba, Río Quijos, Río Chico, Río Pindo, además datos diarios de la cuenca Catamayo, y la El Limón, mediante el uso de redes neuronales artificiales, para la obtención de nuevos caudales, tomando como datos de entrada las precipitaciones y caudales históricos de las cuencas.

El modelo propuesto presenta una arquitectura de red multicapa (feedforward) que comprende tres capas (entrada, oculta y salida), el número de neuronas de entrada y ocultas varían de acuerdo al modelo. La función de entrenamiento para el modelamiento de las cuencas es el Bayesian regulation backpropagation. La fase de entrenamiento y validación de los modelos con redes neuronales artificiales se realizaron utilizando diferentes cantidad de datos de entrada, dependiendo de la cuenca.

Palabras claves: Redes neuronales, Cálculo de caudales.

ABSTRACT

This research aims to simulate average monthly flow information in watersheds: Rio Guayllabamba River Quijo, Rio Chico, Rio Pindo also daily data Catamayo basin, and Lemon, by using neural networks artificial, to obtain new funds, taking as input rainfall and watershed historical flows.

The proposed model presents a multi-layered network architecture (feedforward) comprising three layers (input, hidden and output), the number of input neurons and hidden vary by model. The training function for modeling the watershed regulation Bayesian backpropagation. The training phase and validation of artificial neural network models is performed using different amount of input data, Depending on the basin.

Keywords: Neural Networks, flow calculation.

INTRODUCCIÓN

En la actualidad los profesionales e investigadores de los recursos hídricos, enfrentan la problemática de escasez de datos hidrológicos, para desarrollar los diversos estudios y trabajos dentro de cada campo al que ellos se dediquen, convirtiendo esto en una necesidad imperativa para poder realizar los cálculos requeridos. En vista de esta problemática y para poder solucionarla, se emplean metodologías de simulación hidrológica como un instrumento para generar información que les permita la toma de decisiones en la planificación y gestión de los recursos naturales dentro de una cuenca hidrográfica.

Siendo de gran importancia la modelación y predicción de caudales medios mensuales, para conocer crecidas máximas y sequías en las diversas cuencas de estudio, se han empleado métodos estadísticos basados en modelos como el Box- Jenkins, los cuales son efectivos, pero demandan variables estacionarias, normalmente distribuidas, además que requieren de un complejo trabajo para encontrar un modelo estructural adecuado, manejo de varios parámetros y dificultades en la estimación de los valores adecuados (Basogain, 2008).

En vista a estos inconvenientes en la modelización se ha optado por utilizar Redes Neuronales Artificiales (RNA), las cuales intentan ser una emulación inteligente del comportamiento de los sistemas biológicos del cerebro, en donde la neurona es el elemento fundamental. Los modelos de Redes Neuronales Artificiales (RNA) tienen como una de sus principales características: tratan incertezas de fácil adaptabilidad a nuevos datos y abstraen el conocimiento físico de los sistemas a ser modelados, ya que el modelo puede ser generado únicamente a partir de datos de entrada y salida (Ballini & Vilca, 2000).

La presente investigación tiene como propósito el desarrollo de modelos de simulación hidrológica usando redes neuronales artificiales en las cuencas: Río Guayllabamba, Río Quijos, Río Chico y la cuenca Río Pindo, el entrenamiento se efectuará a partir de datos de precipitación y caudales antecedentes de las cuencas.

Adicionalmente se ha realizado el análisis de las cuencas del Río el Limón y Catamayo, las cuales cuentan con datos de precipitaciones y caudales diarios, para realizar la comparación con las cuencas que tienen datos mensuales.

Las redes neuronales serán utilizadas para la obtención de caudales, de las cuencas antes mencionadas, dados los datos de precipitación, y datos históricos de caudal como variables de entrada. Este modelo recibe la información de cada estación, sin que los datos hayan sido concentrados, por lo que el modelo es distribuido. Para elaborar un modelo matemático distribuido es necesario tener información más a detalle de la cuenca, como tipo de suelo,

pendientes del terreno, vegetación, uso del suelo, evaporación, evapotranspiración, etc., lo que hace dificultoso su implementación debido a la falta de estos parámetros. Por esta razón al utilizar las redes neuronales para la elaboración de un modelo distribuido, tenemos la ventaja de la independencia de estas variables, debido a que esta busca la función de ajuste de los datos de entrada con los de salida, en este caso, los datos de entrada serían la precipitación y los caudales históricos, y los datos de salida son los caudales futuros.

GENERALIDADES

1.1 Objetivos

1.1.1 Objetivo General.

- Aplicar redes neuronales, para la generación de series hidrológicas.

1.1.2 Objetivos Específicos.

- Utilizar el concepto de redes neuronales para la obtención de datos hidrológicos.
- Determinar una red neuronal óptima, para la predicción de caudales en las cuencas: Río Guayllabamba, Río Quijos, Río Chico, Río Pindo, Río El Limón Y Río Catamayo.
- Comprobar la validez de los modelos aplicados, por medio de análisis estadísticos.

1.2 Fundamentos de las redes neuronales artificiales

1.2.1 Fundamentos biológicos de las redes neuronales.

Las Redes Neuronales Artificiales se basan en el funcionamiento del sistema neuronal del cuerpo humano, en el cual encontramos tres elementos principales: los Órganos receptores que son los encargados de recoger la información del exterior; el sistema nervioso que transmite, analiza y en parte almacena la información elaborada, y los órganos efectores que reciben la información de parte del sistema nervioso y la convierte en una cierta acción (Solomatine, 2002).

La unidad fundamental del sistema nervioso es la neurona, estas se unen unas con otras formando redes. Se componen de un cuerpo o núcleo, llamado axón, que es una ramificación de salida de la neurona, y de un gran número de ramificaciones de entrada llamadas dendritas. Su funcionamiento es el siguiente. Las señales de entrada llegan a la neurona a través de la sinapsis, que es la zona de contacto entre neuronas. La sinapsis recoge información electroquímica procedente de las células adyacentes que están conectadas a la neurona en cuestión. Esta información llega al núcleo de la neurona, a través de las dendritas, que la procesa hasta generar una respuesta, la cual es posteriormente propagada por el axón. (Solomatine, 2002)

Las Redes Neuronales Artificiales se asemejan al cerebro por presentar una serie de características propias del mismo, como el aprender de las experiencias pasadas. Por ejemplo las Redes Neuronales Artificiales, aprenden de la experiencia, sistematizando de ejemplos previos a ejemplos nuevos, es decir abstraen las características principales de una serie de datos.

Las Redes Neuronales Artificiales pueden cambiar su comportamiento en función del entorno. Se les muestra un conjunto de entradas y ellas mismas se ajustan para producir unas salidas consistentes, es decir pueden aprender. Además pueden generalizar automáticamente datos debido a su propia estructura y naturaleza. Estas redes pueden ofrecer, dentro de un margen, respuestas correctas a entradas que presentan pequeñas variaciones debido a los efectos de ruido o distorsión (Méndez, 2009).

1.2.2 Historia de las Redes Neuronales Artificiales.

Los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes, en 1943, lanzaron una teoría de la forma de trabajar de las neuronas (McCulloch citado por (Hilera & Martínez, 2000)).

Warren McCulloch, y Walter Pitts modelaron una red neuronal simple mediante circuitos eléctricos, de esta forma fijan las características de trabajo de lo que posteriormente se conocerá como neurona McCulloch- Pitts (Serrano, Soria, & Martin, 2014).

En este modelo, cada neurona consta de un conjunto de entradas, S_i , y una sola salida S_j . Cada entrada i está afectada por un coeficiente que se denomina peso y que se representa por w_{ij} . El subíndice i refleja que el peso afecta a la entrada i , y el subíndice j que se trata de la neurona j .

La cantidad calculada como la suma del producto de cada entrada multiplicada por su respectivo peso se denomina activación de la neurona x_j . La salida S_j de la neurona es una función de la activación de ésta. Es decir:

$$x_j = S_i \times (w_{ij}) + Q_j \quad (\text{Ec. 1. 1})$$

$$S_j = f \times (x_j) \quad (\text{Ec. 1. 2})$$

Donde el término Q_j es un valor umbral y $f(x_j)$ es una función de la activación de la neurona.




Figura 1.1. Neurona McCulloch-Pitts

Fuente: (Hilera & Martínez, 2000)

Una de las primeras arquitecturas neuronales aplicadas es el Perceptrón, que utiliza la siguiente función de salida:

$$S_j = 0 \quad ; \quad x_j < h \quad \quad \quad (\text{Ec. 1.3})$$

$$S_j = 1 \quad ; \quad x_j \geq h \quad \quad \quad (\text{Ec. 1.4})$$

Donde la constante h se denomina umbral. Esta es una función de salida de tipo binaria, y existen otras de tipo lineal puro, lineal con umbral, y sigmoidea, entre otras. En este modelo tan sencillo puede verse que la activación de la neurona depende del valor que tomen los pesos y las entradas, de forma que la variación de éstos originan distintas salidas para la misma entrada a la neurona (Warren S. McCulloch, 1943).

Otros importantes aportes a la evolución de las Redes Neuronales Artificiales son:

- En 1957, Frank Rosenblatt comenzó el desarrollo del Perceptrón, el cual es la más antigua red neuronal, y se usa hoy en día de varias formas para la aplicación como reconocedor de patrones. Este modelo era capaz de generalizar; es decir, después de haber aprendido una serie de patrones era capaz de reconocer otros similares, aunque no se le hubieran presentado anteriormente. Más una limitación que tenía es que no era capaz de clasificar clases no separables linealmente (Hilera & Martínez, 2000).

- En 1959, Bernard Widrow y Marcial Hoff, de Stanford, desarrollaron el modelo ADALINE (ADAPtative LINEear Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros adaptativos para eliminar ecos en las líneas telefónicas) y se ha usado comercialmente durante varias décadas (Hilera & Martínez, 2000).
- Uno de los mayores investigadores de las redes neuronales desde los años 60 hasta nuestros días es Stephen Grossberg (Universidad de Boston). A partir de su extenso conocimiento fisiológico, ha escrito numerosos libros y desarrollado modelos de redes neuronales. Estudió los mecanismos de la percepción y la memoria. Grossberg realizó en 1967 una red, Avalancha, que consistía en elementos discretos con actividad que varía con el tiempo que satisface ecuaciones diferenciales continuas, para resolver actividades tales como reconocimiento continuo del habla y aprendizaje del movimiento de brazos de un robot (Hilera & Martínez, 2000).
- En 1969 surgieron numerosas críticas que frenaron, hasta 1982, el crecimiento que estaba experimentando las investigaciones sobre redes neuronales. Marvin Minsky y Seymour Papert, del instituto Tecnológico de Massachusetts (MIT) publicaron un libro, Perceptrons (Hilera & Martínez, 2000).
- En 1982, coincidieron numerosos eventos que hicieron resurgir el interés por las redes neuronales. John Hopfield presentó su trabajo sobre redes neuronales en la Academia Nacional de las Ciencias. En el trabajo, describe con claridad y rigor matemático una red a la que ha dado su nombre, que es una variación del Asociador lineal, pero, además, mostro cómo tales redes pueden trabajar y qué pueden hacer (Hilera & Martínez, 2000).
- En 1985, el Instituto Americano de Física comenzó lo que ha sido la reunión anual "Neural Networks for Computing". En 1989 la International Joint Conference on Neural Networks (IJCNN) produjo 430 artículos, 63 de los cuales enfocados a una aplicación (Hilera & Martínez, 2000).

- Actualmente, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen y las empresas que lanzan al mercado productos nuevos, tanto hardware como software. (Hilera & Martínez, 2000).

1.2.3 Ventajas de las Redes neuronales.

En este trabajo se mencionan las ventajas que tienen las redes neuronales para trabajar con valores no lineales, pero además de esta ventaja, “hay otras propiedades que las hacen especialmente atractivas para ser usadas en problemas prácticos” (Haykin, 1994), las cuales se mencionan a continuación:

- Son sistemas tolerantes a fallas: Una red neuronal, al ser un sistema distribuido, permite el fallo de algunos elementos individuales (neuronas) sin alterar significativamente la respuesta total del sistema.
- Adaptabilidad: Una red neuronal tiene la capacidad de modificar los parámetros de los que depende su funcionamiento de acuerdo con los cambios que se produzcan en su entorno de trabajo. Hay que tener en cuenta que la capacidad de adaptación no puede ser excesivamente grande ya que por esto se puede tener un sistema inestable.
- Son sistemas distribuidos no lineales: Una red neuronal es un elemento no lineal por lo que una interconexión de ellas también será un dispositivo no lineal. Esta propiedad permitirá la simulación de sistemas no lineales y caóticos, simulación que, con los sistemas clásicos lineales no se puede realizar.
- Establecen relaciones no lineales entre datos: “Las redes neuronales son capaces de relacionar dos conjuntos de datos. Comparando con los métodos estadísticos clásicos que realizan la misma misión tienen como principal ventaja que los datos no tienen que cumplir las condiciones de linealidad, gaussianidad, y estacionariedad” (Proakis, 1997).

1.2.4 Red neuronal.

Las redes neuronales artificiales son como redes interconectadas masivamente en paralelo de elementos simples y con organización jerárquica, las cuales intentan interactuar con los objetivos del mundo real del mismo modo que lo hace el sistema nervioso biológico, compleja operación de las redes neuronales es el resultado de abundantes lazos de realimentación junto, con no linealidades de los elementos de proceso y cambios adaptativos de sus parámetros, que pueden definir incluso fenómenos dinámicos muy complicados. Las redes neuronales artificiales han sido utilizadas en temas ambientales para analizar tendencias y patrones y la previsión del tiempo (Hilera & Martínez, 2000).

La estructura de una red neuronal artificial está conformada por: unidades de procesamiento, estado de activación de cada neurona, patrón de conectividad entre neuronas, regla de propagación, función de transferencia, regla de activación, regla de aprendizaje. La organización está representada por: número de niveles o capas, número de neuronas por nivel, patrones de conexión, flujo de información (Hilera & Martínez, 2000).

1.2.5 Componentes de las redes neuronales artificiales.

Los componentes de una red neuronal artificial son:

1.2.5.1 Neurona artificial o unidad de proceso.

Mukata (2008) citado por (Méndez, 2009), menciona que una neurona artificial es un modelo abstracto de una neurona natural, como se ilustra en la Figura 1.2. Como se puede ver en esta figura nosotros tenemos entradas x_1, x_2, \dots, x_m . Estas entradas son los niveles de simulación de la neurona natural. Cada entrada x_i es multiplicado por su correspondiente peso w_i , entonces el producto $x_i w_i$ ingresa al cuerpo de la neurona. Los pesos representan la sinapsis biológica en una neurona natural.




Figura 1.2. (a) un modelo de neurona que retiene la imagen de una neurona natural. (b) una mayor abstracción de la figura.

Fuente: (Mukata, 2008)

La neurona suma todos los productos para $i=1,m$. La suma de los productos es generalmente denotado como una red en la literatura de redes neuronales. Esto es, las neuronas evaluadas.

$$\text{Net} = \sum_i y_i w_{ji} \quad (\text{Ec. 1.5})$$

En términos matemáticos, está dado por dos vectores $x = (x_1, x_2, \dots, x_m)$ y $w = (w_1, w_2, \dots, w_m)$, net es el punto (o escalar) producto de los dos vectores, x y w . Finalmente, la neurona calcula su salida y como una función determinada de net, así por ejemplo $y = f(\text{net})$. Esta función es llamada función de activación (o algunas veces de transferencia). Podemos pensar en una neurona como una especie de recuadro negro, recibe como entrada en vector x luego produce un escalar como salida (y), este valor de salida puede ser enviado a través de múltiples aristas que salen de la neurona.

1.2.5.2 Estado de activación.

Hilera y Martínez (2000), mencionan, que todas las neuronas que componen una red se hallan en cierto estado. En una visión simplificada, podemos decir que hay dos posibles estados, reposo y excitado, a los que se les denomina globalmente estados de activación, y a cada uno de los cuales se le asigna un valor. Los valores de activación pueden ser continuos o discretos. Además, pueden ser limitados o ilimitados. Si son discretos suelen tomar un conjunto de valores o bien valores binarios. En notación binaria, un estado activo se indicaría por 1, y se caracteriza por la emisión de un impulso por parte de la neurona (potencial de acción), mientras que un estado pasivo se indicaría por un 0, y significaría que la neurona está en reposo. En otros modelos se considera un conjunto de estados de activación, en lugar de

solo dos estados, en cuyo caso se les asigna un valor entre [0,1] o en el intervalo [-1,1], generalmente siguiendo una función sigmoideal.

Finalmente, es necesario saber qué criterios o reglas siguen las neuronas para alcanzar tales estados de activación. En principio, esto va a depender de dos factores: a) Por un lado, puesto que las propiedades macroscópicas de las redes neuronales no son producto de actuación de elementos individuales, sino entre las neuronas. El estado de activación estará fuertemente influenciado por tales iteraciones, ya que el efecto que producirá una neurona sobre otra será proporcional a la fuerza, peso o magnitud de la conexión entre ambas. b) Por otro lado, la señal que envía cada una de las neuronas a sus vecinas dependerá de su propio estado de activación. La activación de una unidad U_i en el tiempo t se designa por $a_i(t)$; es decir:

$$A(t) = (a_1(t), a_2(t), \dots, a_N(t)) \quad (\text{Ec. 1. 6})$$

Donde:

$A(t)$: Estado de Activacion.

a_1 : Valor de entrada a la neurona.

t : Tiempo.

1.2.5.3 Función de salida o de transferencia.

Hilera y Martínez (2000), indican, que entre las unidades o neuronas que forman una red neuronal artificial existe un conjunto de conexiones que unen unas a otras. Cada unidad transmite señales a aquellas que están conectadas con su salida. Asociada con cada unidad U_i hay una función de salida $f_i(a_i(t))$, que transforma el estado actual de activación $a_i(t)$ en una señal de salida $y_i(t)$; es decir:

$$y_i(t) = f_i(a_i(t)) \quad (\text{Ec. 1. 7})$$

El vector que contiene las salidas de todas las neuronas en un instante t es:

$$Y(t) = (f_1(a_1(t)), f_2(a_2(t)), \dots, f_i(a_i(t)), \dots, f_N(a_N(t))) \quad (\text{Ec. 1. 8})$$

En algunos modelos, esta salida es igual al nivel de activación de la unidad, en cuyo caso la función f_i es la función identidad, $f_i(a_i(t))=a_i(t)$. A menudo f_i es de tipo sigmoideal, y suele ser la misma para todas las unidades.

Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas:

a) Función lineal y mixta.

La función lineal o identidad responde a la expresión $f(x)=x$. En las neuronas con función mixta, si la suma de las señales de entrada es menor que un límite inferior, la activación se define como 0 o -1. Si dicha suma es mayor o igual que el límite superior, entonces la activación es 1. Si la suma de entradas está comprendida entre ambos límites, superior e inferior, entonces la activación está comprendida entre ambos límites, superior e inferior, entonces la activación se define como una función lineal de la suma de las señales de entrada.

b) Función escalón.

Son funciones que dan una salida binaria dependiente de si el valor de entrada está por encima o por debajo del valor umbral. Por ejemplo la función signo, y el escalón estándar, $A(x)$, definida como sigue:

$$A(X) = \begin{cases} -1; & \text{si } x < 0 \\ 1; & \text{en otro caso} \end{cases} \quad A(X) = \begin{cases} 0; & \text{si } x < 0 \\ 1; & \text{en otro caso} \end{cases} \quad (\text{Ec. 1. 9})$$

c) Función sigmoideal:

Son funciones monótonas acotadas que dan una salida gradual no lineal para entradas. Las funciones sigmoideales más populares son:

Función logística:

$$y_{pj} = f(I_j) = \frac{1}{1 + e^{-I_j}} \quad (\text{Ec. 1. 10})$$

Función tangente hiperbólica: de -1 a 1:

$$f(I_j) = \tanh(I_j) \quad (\text{Ec. 1. 11})$$

d) Función gaussiana.

Los centros y anchuras de estas funciones pueden ser adaptados, lo cual las hace más adaptativas que las funciones sigmoideas. Mapeos que suelen requerir dos niveles ocultos (neuronas en la red que se encuentran entre las de entrada y las de salida) utilizando neuronas con funciones de transferencia sigmoideas; algunas veces se pueden realizar con un solo nivel en redes con neuronas de función gaussiana.

1.2.5.4 Conexiones entre neuronas.

Hilera y Martínez (2000) indican, que las conexiones que unen a las neuronas que forman una red neuronal artificial, tienen asociado un peso, que es el que hace que la red adquiera conocimiento. Considerando y_i como el valor de salida de una neurona i en un instante dado. Una neurona recibe un conjunto de señales que le dan información del estado de activación de todas las neuronas i y la neurona j esta ponderada por un peso w_{ij} . Normalmente, como simplificación, se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe una neurona (potencial postsináptico) net_j es la suma del producto de cada señal individual por el valor de la sinapsis que conecta ambas neuronas.

1.2.5.5 Función o regla de activación.

Hilera y Martínez (2000) mencionan que así como es necesaria una regla que combine las entradas a una neurona con los pesos de las conexiones, también se requiere una regla que combine entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función F produce un nuevo estado de activación en una neurona a partir del estado (a_i) que existía y la combinación de las entradas con los pesos de las conexiones (net_i). Dado el estado de activación $a_i(t)$ de la unidad U_i y la entrada total que llega a ella, Net_i , el estado de activación siguiente, $a_i(t+1)$, se obtienen aplicando una función F , llamada función de activación.

$$a_i(t + 1) = f(a_i(t), Net_i) \quad (\text{Ec. 1. 12})$$

En la mayoría de los casos, F es la función identidad, por lo que el estado de activación de una neurona en $t+1$ coincidirá con el Net de la misma en t . En este caso, el parámetro que se le pasa a la función de salida, f , de la neurona será directamente el Net . El estado de activación no se tiene en cuenta. Según esto la salida de una neurona i (y_i), quedará según la expresión:

$$y_i(t + 1) = f(Net_i) = f\left(\sum_{j=1}^N w_{ij} (y_j(t))\right) \quad (\text{Ec. 1. 13})$$

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

$$y_i(t + 1) = f(\text{Net}_i - \theta_i) = f\left(\sum_{j=1}^N w_{ij} (y_j(t) - \theta_j)\right) \quad (\text{Ec. 1. 14})$$

La salida que se obtiene en una neurona para las diferentes formas de la función f será:

- ✓ Función de activación escalón.
- ✓ Función de activación lineal o identidad.
- ✓ Función de activación lineal-mixta.
- ✓ Función de activación sigmoideal.

Para simplificar la expresión de la salida de una neurona i , es habitual considerar la existencia de una neurona ficticia, con valor de salida unidad, asociada a la entrada de cada neurona i mediante una conexión con peso de valor $-\theta_i$. De esta forma la expresión de salida quedará:

$$y_i(t + 1) = f\left(\sum_{j=1}^N w_{ij} (y_j(t) - \theta_j)\right) = f\left(\sum_{j=1}^N w_{ij} (y_j(t))\right) \quad (\text{Ec. 1. 15})$$

En la Figura 1.3, se puede apreciar un esquema de un sistema neuronal.




Figura 1.3 Sistema neuronal

Fuente: (Hilera & Martínez, 2000)

1.2.5.6 Regla de aprendizaje.

Existen muchas definiciones del concepto general de aprendizaje, una de ellas podría ser. La modificación de comportamiento inducido por la interacción con el entorno y como resultado de experiencias conducente al establecimiento de nuevos modelos de respuesta a estímulos externos. Esta definición fue enunciada muchos años antes de que surgieran las redes neuronales, sin embargo puede ser aplicada también a los procesos de aprendizaje de estos sistemas (Hilera & Martínez, 2000).

Biológicamente, se suele aceptar que la información memorizada en el cerebro está más relacionada con los valores sinápticos de las conexiones entre las neuronas que con ellas mismas; es decir, el conocimiento se encuentra en las sinapsis. En el caso de las redes neuronales artificiales, se puede considerar que el conocimiento se encuentra representado en los pesos de las conexiones entre neuronas. Todo proceso de aprendizaje implica cierto número de cambios en estas conexiones, En realidad, puede decirse que se aprende modificando los valores de los pesos de la red.

Al igual que el funcionamiento de una red depende del número de neuronas de las que disponga y de cómo estén conectadas entre sí, cada modelo dispone de sus o sus propias técnicas de aprendizaje.

1.2.6 Arquitectura de las redes neuronales artificiales.

Según (Alegre, 2003), las neuronas se pueden organizar en capas conectadas por varios tipos de uniones incluyendo conexiones hacia adelante, laterales y hacia atrás.

a) Redes con conexiones hacia adelante: conectan neuronas de una capa con la capa siguiente. Cada una de estas conexiones implica composición funcional entre las funciones de activación de las correspondientes neuronas y da a la red neuronal la capacidad de reproducir una amplia clase de funciones no lineales.

b) Redes con conexiones laterales: conectan neuronas de la misma capa. Junto con el caso simple de una sola capa, este tipo de conexión se usa generalmente en capas competitivas, donde cada nodo se conecta a si mismo mediante un peso positivo (excitante) y a los demás nodos de la capa con pesos negativos (inhibitorios).

c) Redes con conexiones hacia atrás: incorporadas a las redes para tratar modelos dinámicos y temporales, es decir, modelos con memoria. La arquitectura de una red se puede representar por una matriz de pesos $W = (w_1; w_2, \dots, w_n)$ donde w_1 es el vector que contiene los pesos de las conexiones con las demás neuronas como, por ejemplo de la neurona x_j a la neurona x_i : $w_i = (w_{1j}; \dots, w_{ij}; \dots; w_{in})$.

Teniendo en cuenta la topología de la red, según (Laqui, 2008), se puede clasificar las unidades neuronales de la siguiente manera.

a) Capa de entrada de una red neuronal: Una unidad se dice que está en la capa de entrada de una red neuronal (X; U), si es la entrada de al menos una unidad procesadora de U y no es la salida de ninguna unidad procesadora de U.

b) Capa de salida de una red neuronal: una unidad se dice que está en la capa de salida de una red neuronal (X; U), si es la salida de al menos una unidad procesadora de U y no es la entrada de ninguna unidad procesadora de U.

c) Capas intermedias u ocultas de una red neuronal: una unidad se dice que está en la capa intermedia de una red neuronal (X;U), si es la entrada de al menos una unidad procesadora de U y, al mismo tiempo, es la salida de al menos una unidad procesadora de U.

Entre las arquitecturas de red más poderosas y populares se destacan las llamadas redes de retro-propagación, o Perceptrón multicapa, que están formadas por una capa de entrada, un número de capas ocultas, y una capa de salida. Cada una de las neuronas ocultas o de salida,

recibe una entrada de las neuronas de la capa previa (conexiones hacia atrás). Una RNA también puede incluir capas competitivas, donde las neuronas compiten por tener mayor actividad para un patrón dado.

1.2.7 Aprendizaje.

Una de las características de las RNA es su capacidad de aprender a partir de ciertos datos. Una vez que ha sido elegida la arquitectura de red para un determinado problema, los pesos de las conexiones se ajustan para codificar la información contenida en un conjunto de datos de entrenamiento. Los métodos de aprendizaje se clasifican en dos categorías, dependiendo del tipo de información disponible (Alegre, 2003).

1.2.7.1 Aprendizaje supervisado.

En este caso, los patrones para el aprendizaje están formados por parejas, $f(a_p; b_p)$ $p = 1; \dots, rg$, que constan de un vector de variables de entrada, a , junto con las salidas correspondientes b . Por tanto cada valor de salida es la respuesta deseada a las señales de entrada. En este caso, los pesos se obtienen minimizando alguna función de error que mide la diferencia entre los valores de salida deseados y los calculados por la red neuronal. En este tipo de aprendizaje se debe tener en cuenta el problema de la convergencia del error. En general, la función de error resultante puede contener múltiples mínimos locales y, por lo tanto, el proceso de aprendizaje puede no converger al mínimo global óptimo.

1.2.7.2 Aprendizaje no supervisado.

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

a) Aprendizaje Hebbiano: consiste en modificar los pesos de acuerdo con algún criterio de correlación entre las actividades neuronales.

b) Aprendizaje competitivo: neuronas diferentes se conectan con pesos negativos (inhibitorios) que fuerzan una competición para ganar la actividad neuronal.

c) Representación de características: que concierne a la ordenación geométrica de los vectores peso de las unidades competitivas.

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

1.2.8 Validación.

(Alegre, 2003), menciona que una vez que se ha terminado el proceso de aprendizaje y los pesos de la red neuronal han sido calculados, es importante comprobar la calidad del modelo resultante. Por ejemplo, en el caso del aprendizaje supervisado, una medida de la calidad puede darse en términos de los errores entre los valores de salida deseados y los obtenidos por la red neuronal. Algunas medidas estándar del error son:

a) Error cuadrático medio (ECM): definido como:

$$ECM = \frac{1}{n} \sum_{i=1}^n (y_i - z_i)^2 \quad (Ec. 1. 16)$$

b) Error porcentual medio (EPM): definido como:

$$EPM = \frac{100}{n} \sum_{i=1}^n \frac{(y_i - z_i)^2}{y_i} \quad (Ec. 1. 17)$$

c) Error absoluto medio (EAM): definido como:

$$EAM = \frac{1}{n} \sum_{i=1}^n |y_i - z_i|^2 \quad (Ec. 1. 18)$$

Donde n representa el número de elementos que intervienen en el pronóstico, y_i representa el valor real y z_i representa la salida pronosticada.

También es necesario realizar una validación cruzada para obtener una medida de la calidad de predicción del modelo. Por este propósito, los datos obtenidos se pueden dividir en dos partes, una parte destinada al entrenamiento de la red y otra parte a la comprobación (testeo o validación). Cuando el error de comprobación es mucho mayor que el error de entrenamiento, se produce un problema de sobreajuste durante el proceso de entrenamiento.

En Estadística se sabe que cuando se utiliza un modelo con muchos parámetros para ajustar un conjunto de datos procedente de un proceso con pocos grados.

1.3 Modelos precipitación-escorrentía determinísticos

Se formula utilizando las leyes físicas que rigen los procesos involucrados descritos mediante ecuaciones diferenciales, un modelo determinístico no considera aleatoriedad; una entrada dada produce siempre una misma salida, los modelos determinístico hacen pronósticos (Chow, Maidment, & Mays, 1994).

A continuación se describen dos modelos determinísticos los cuales van a servir para evaluar el rendimiento de los modelos precipitación-escorrentía basados en Redes Neuronales Artificiales.

1.3.1 Modelo hidrológico distribuido.

Los modelos hidrológicos tratan de reproducir el fenómeno lluvia-escorrentía en una cuenca. Los modelos se pueden clasificar de manera general en globales y distribuidos. Los modelos globales consideran básicamente a la precipitación y a las características físicas de la cuenca como un “promedio” de toda la cuenca. En cambio, los modelos distribuidos sí toman en cuenta la variación espacial de la precipitación y de las características físicas de la cuenca mediante una discretización espacial. Esta se realiza dividiendo o discretizando la cuenca en una malla de cuadros o subcuencas. (UAEM, 2014).

1.4 Modelos estocásticos

Un modelo estocástico tiene salidas que son por lo menos parcialmente aleatorias, estos hacen predicciones, a pesar de que todos los fenómenos hidrológicos implican algún grado de aleatoriedad la variabilidad resultante en la salida puede ser pequeña cuando se le compara con la variabilidad resultante de otros factores conocidos.

(Raghunath, 2006), menciona que en los modelos estocásticos la oportunidad de ocurrencia de las variables es considerada por lo tanto introduce el concepto de probabilidad. Un modelo estocástico es dependiente del tiempo mientras el modelo probabilístico es independiente del tiempo. Para el proceso probabilístico independiente del tiempo, la secuencia de ocurrencia de las variables involucradas en el proceso, son ignoradas y la probabilidad de su ocurrencia se supone que siguen una distribución definida en la que las variables se consideran puramente al azar. Para el proceso estocástico dependiente del tiempo, la secuencia de ocurrencia de las variables es observada y las variables pueden ser cualquiera, escogidas al

azar o no, pero la distribución de probabilidad de las variables pueden o no variar con el tiempo. Por ejemplo la curva de duración es probabilística, mientras que el flujo que pasa a través de un embalse es un proceso estocástico.

1.5 Optimización de modelos

La optimización es el proceso de maximizar o minimizar una función objetivo deseado en la cual debe cumplir las limitaciones existentes. En la naturaleza existen una gran cantidad de ejemplos en los que se busca un estado óptimo del sistema. Para que los profesionales puedan aplicar la optimización en sus trabajos, es necesario tener una comprensión de la teoría, las técnicas y los algoritmos. Esto se debe a que hay un considerable esfuerzo para aplicar las técnicas de optimización en los problemas prácticos para lograr una mejora. En este esfuerzo siempre es necesario ajustar los parámetros de los algoritmos, escalas e incluso modificar las técnicas para la aplicación específica. Además el usuario puede tener que probar varios métodos de optimización para encontrar uno que pueda ser aplicado con éxito (Belegundu & Chandrupatla, 2011).

1.6 Medidas de bondad de un modelo

1.6.1 Eficiencia de Nash- Sutcliffe.

Mirosław y Okruszko (2011), mencionan que este criterio de eficiencia es comúnmente utilizado para la evaluación de modelos, ya que implica la estandarización de la varianza residual, y su valor esperado no cambia con la longitud del registro o la magnitud de la escorrentía. La eficiencia de Nash- Sutcliffe se utiliza para evaluar la capacidad de reproducir la evolución temporal de los caudales, su valor puede variar desde un valor negativo a 1, donde 1 indica un ajuste perfecto entre la simulación y los valores observados, un valor por debajo de cero indica que el caudal promedio medido habría sido un buen predictor como un caudal modelo. Está representado mediante la siguiente ecuación:

$$CR_3 = \frac{\sum_{i=1}^N (Q_{ob} - Q_{ob2})^2 - \sum_{i=j}^N (Q_{ob} - Q_{ob})^2}{\sum_{i=j}^N (Q_{ob} - Q_{ob2})^2} \quad \text{Ec. 1. 26}$$

Donde:

CR_3 : Representa la eficiencia de Nash- Sutcliffe.

Q_{3SI} : Caudal simulado (m^3/s).

Q_{ob} : Caudal observado (m^3/s).

Q_{ob2} : Promedio de los caudales observados (m^3/s).

1.7 Aplicaciones de las redes neuronales

Según (ROSANO, 2002), los campos potenciales de aplicación de las Redes neuronales se pueden agrupar en las siguientes secciones:

1.7.1 Diagnóstico.

El diagnóstico comprende la identificación de la naturaleza y causas de una situación presente. La operación de diagnóstico es empleada en numerosos campos, tales como la planeación estratégica de organizaciones, la medicina, la ingeniería de servicio y mantenimiento, la economía, la sociología, las ciencias políticas, etc.

En el diagnóstico se observan un conjunto de síntomas, que son valores de variables observables del sistema, los cuales se asocian con un conjunto de factores ambientales que actúan o han actuado sobre éste, para inferir el estado del sistema, así como una explicación causal del mismo.

De lo anterior resulta la conveniencia de utilizar Redes Neuronales que, basándose en ejemplos concretos y con la tutoría de un experto, aprendan a diagnosticar sistemas complejos, sin requerir el análisis lógico causal explícito que requerirían los Sistemas Expertos.

Así, en el diagnóstico médico se ha desarrollado DESKNET (Yoon, 1989), que es una Red Neuronal basada en retropropagación que es capaz de diagnosticar 10 diferentes enfermedades de la piel, basándose en un conjunto de 18 síntomas y pruebas de laboratorio. Otra aplicación ha sido desarrollada por (Apolloni, 1990) para el diagnóstico de variedades de epilepsia.

1.7.2 Procesamiento de señales.

Un problema importante del procesamiento de señales es la recuperación de una señal analógica después de haber sido transmitida por un canal ruidoso o distorsionador.

Para este problema se han desarrollado enfoques tradicionales basados en filtros y ecualizadores de canales y la aplicación de estimación estadística para conformar un estimado óptimo de la señal deseada. Sin embargo, la falta de conocimiento de parámetros estadísticos de la señal obstaculiza el uso de la teoría de la estimación.

Una posible solución es la construcción de filtros adaptativos entrenados en instalaciones reales, que aprendan a dar como salida la señal deseada y basados en Redes Neuronales. Douglas Palmer de Hecht-Nielsen Neurocomputer Inc (Palmer, 1987) comparó el filtrado resultante de una Red Neuronal multicapa con el de un filtro adaptativo lineal en una señal de electroencefalograma y los resultados de la red aparecían menos ruidosos que los del filtro.

Otro problema importante es la predicción de series de tiempo. Alan Lapedes y Robert Farber han aplicado Redes Neuronales (Lapedes & Farber, 1987) en forma de un Perceptrón de varias capas para predecir el comportamiento de un sistema dinámico no lineal con comportamiento caótico descrito por la ecuación diferencial no lineal de Glass-Mackey, dando por resultado una mayor precisión en la predicción con Redes Neuronales que utilizando predictores polinomiales y el filtro adaptativo lineal de Widrow-Hoff.

En este mismo sentido, se han aplicado Redes Neuronales para predecir el comportamiento de un mercado bursátil, asesorando adecuadamente sobre el mejor momento para comprar o vender acciones. El modelo tuvo un desempeño calificado como excelente. (Kimoto, Yoda et al. 1990). Odom y Sharda reportan también el empleo de Redes Neuronales para predecir la quiebra de una institución bancaria. (Odom & Sharda, 1990).

1.7.3 Procesamiento y análisis de imágenes.

El procesamiento de imágenes es un campo muy promisorio de aplicaciones de las Redes Neuronales, en donde la imagen digitalizada original o bien preprocesada se utiliza como entrada de una red, obteniéndose como salida una clasificación e identificación de la imagen o de segmentos de ella. Como procedimientos de preprocesamiento pueden utilizarse transformadas de Fourier, algoritmos de extracción de características especiales y otras técnicas.

Entre las aplicaciones que se han desarrollado están la identificación de blancos militares camuflados (Ruck, 1987), utilizando imágenes obtenidas mediante un radar laser y una red multicapas, obteniéndose una más alta efectividad de la solución neuronal (86.4%) de reconocimiento de tanques, en comparación con un clasificador estadístico (76.5%).

1.7.4 Control automático y robótico.

Un tema fundamental en Ingeniería de Control es diseñar un controlador que, con base en el estado presente de un sistema, determine el conjunto óptimo de señales que hagan que un sistema de actuadores lleve al sistema al estado deseado.

Wang y Yeh han explorado el uso de Redes Neuronales para la construcción de controladores auto-adaptativos, caracterizados por su habilidad de aprender a partir de ejemplos, sin necesidad de modelar la planta a controlar.

Estos controladores se distinguen por su adaptatividad dinámica ante cambios de la misma planta, así como por sus propiedades de robustez. (Wang & Yeh, 1990).

1.7.5 Análisis y generación de lenguaje natural.

En cuanto a la aplicación de Redes Neuronales para el reconocimiento de lenguaje hablado, se está trabajando activamente para mejorar el reconocimiento de fonemas, haciéndolo independiente del hablante (Cole, 1990), así como su clasificación, introduciendo redes con retrasos.

Asimismo, se están empleando Redes Neuronales para analizar un vocablo hablado, identificando sus parámetros fonéticos, con el fin de asociarlo con la palabra escrita correspondiente, permitiendo su reconocimiento. (Sung & Jones, 1990).

En lo que respecta a la generación de lenguaje, los trabajos más famosos son los de Terrence Sejnowsky y Charles Rosenberg que introducen su sistema NETTALK como un sistema que aprende a leer en voz alta. A partir de NETTALK ha habido nuevas contribuciones en cuanto al mejor tipo de red neuronal a utilizar. (Kamikura, 1990).

MATERIALES Y MÉTODOS

2.1 Ubicación y características generales del área de estudio.

2.1.1 Cuenca del río Guayllabamba.

2.1.1.1 Ubicación.

La cuenca alta del río Guayllabamba, está localizada en la Sierra Norte del Ecuador “coordenadas latitud 00°09'03"N, 00°25'05"S y longitud 78°01'01"W, 78°44'10"W” (Samaniego, 2008) , en la provincia de Pichincha; es además la parte alta de la cuenca de río Esmeraldas, vertiente del Pacífico Ecuatoriano, tiene una “extensión de 3488,76 Km², con un perímetro de 308,1 Km” (Samaniego, 2008), y la “comparten cinco cantones: Mejía, Rumiñahui, Cayambe, Pedro Moncayo y el Distrito Metropolitano de Quito” (Corporacion Toisan , 2014).




Figura 2.1 Localización de la cuenca alta del río Guayllabamba.

Fuente: FONAG.

2.1.1.2 Características climáticas.

Según Pourrut (1995), citado por De Bievre (2008), debido a la variación de relieve que existe en la cuenca esta posee tres tipos de climas:

- Tropical semiárido temperado en la parte baja, en la zona de Pomasqui y San Antonio de Pichincha. La temperatura varía entre (16 y 24) °C, la precipitación esta entre (400 y 700) mm/año, estas condiciones se presentan en un rango de altitudinal de (1000 y 3000) msnm.

- Mesotérmico semi- húmedo y seco a lo largo de la meseta de Quito: piso altitudinal entre (2000 y 3000) msnm, con temperaturas medias diarias de (12 a 20) °C. Las precipitaciones oscilan entre (700 a 1500) mm/año repartidos en dos estaciones lluviosas.
- Ecuatorial de alta montaña, que se presenta básicamente en las cordilleras oriental y occidental que circundan a la cuenca: con altitudes mayores a 3000 msnm, en donde la precipitación oscila entre (1000 a 1600) mm/año y con una temperatura característica menor a 8°C.

2.1.1.3 **El uso del suelo.**

Según Peralvo (2006), citado por De Bievre (2008), la vegetación natural remanente representa 38% de toda la cuenca. Sin embargo, en el estudio de Verduga y Zak, el cambio de uso de suelo para finales del 2007 es como se resume en la Tabla 2.1. El área urbana representa 7% pastos y cultivos 45%.

Tabla 2.1. Distribución del uso del suelo en la cuenca en el 2007

Tipo del Uso del Suelo	% del Área Total
Pastos	27
Bosques y matorrales	18
Páramos	18
Cultivos	18
Urbana	7
Aguas + glaciares	0,5
Escasa cobertura	9
Otros	2,5
Total	100

Fuente: De Bievre et al, 2008




Figura 2.2 Cuenca del río Guayllabamba.
Fuente: (SIRGH-CG, 2014) ; (Corporacion Toisan , 2014).

2.1.1.4 Precipitación media:

La precipitación media anual tiene un intervalo de 702 a 1241mm, con los valores superiores en la cuenca alta y valores menores en la cuenca baja. La misma variación ocurre con la evapotranspiración que tiene un intervalo 333 a 569mm. (Instituto Nacional de Meteorología e Hidrología , 2009).

2.1.1.5 Características hidrológicas de la cuenca.

La forma de la cuenca es de oval redonda a oval oblonga, lo que indica que la tendencia a crecidas del río es media, y posee una densidad de drenaje regular (Samaniego, 2008). En la figura 2.3, se observa el comportamiento durante un periodo continuo de tiempo, de los caudales mensuales, en la Cuenca del Río Guayllabamba.




Figura 2.3. Serie de caudales medios mensuales río Guayllabamba.

Fuente: Adaptacion datos obtenidos INAMHI.

2.1.2 Cuenca del río Quijos.

2.1.2.1 Ubicación.

El río Quijos se encuentra ubicado en el cantón Quijos cuyas “coordenadas de latitud son: 00°06'10"N, 00°28'07"S y longitud 78°06'01"W, 78°35'04"W” (Samaniego, 2008), nace de las faldas orientales del volcán Antisana y su curso toma una dirección noreste, para recorrer luego paralelo a la vía Interoceánica formando un valle que abarca las

jurisdicciones de los cantones Quijos y El Chaco, a partir del cual toma el nombre de río Coca (recorrido inferior) para finalmente desembocar en el río Napo. (AMES, 2014)




Figura 2.4 Ubicación del río Quijos.

Fuente: (Ecuador M. d., 2014); (Ecuador P. d., 2014)

2.1.2.2 **Extensión.**

El Río Quijos tiene aproximadamente 44,5 Km, una área 2586,43 Km², y un perímetro de 233,98 Km (Samaniego, 2008).

2.1.2.3 **Clima.**

Su curso está a una altura promedio de 1 963 m.s.n.m., con temperatura de 16°C (AMES, 2014).

2.1.2.4 **Características hidrológicas de la cuenca.**

La forma de la cuenca es de oval redonda a oval oblonga, lo que indica que la tendencia a crecidas del río es media, y posee una densidad de drenaje regular (Samaniego, 2008).

En la Figura 2.5, se observa una fotografía del río Quijos.



Figura 2.5 Fotografía del río Quijos.

Fuente: (AMES, 2014)

En la figura 2.6, se observa el comportamiento durante un periodo continuo de tiempo, de los caudales mensuales, en la Cuenca del Río Quijos.

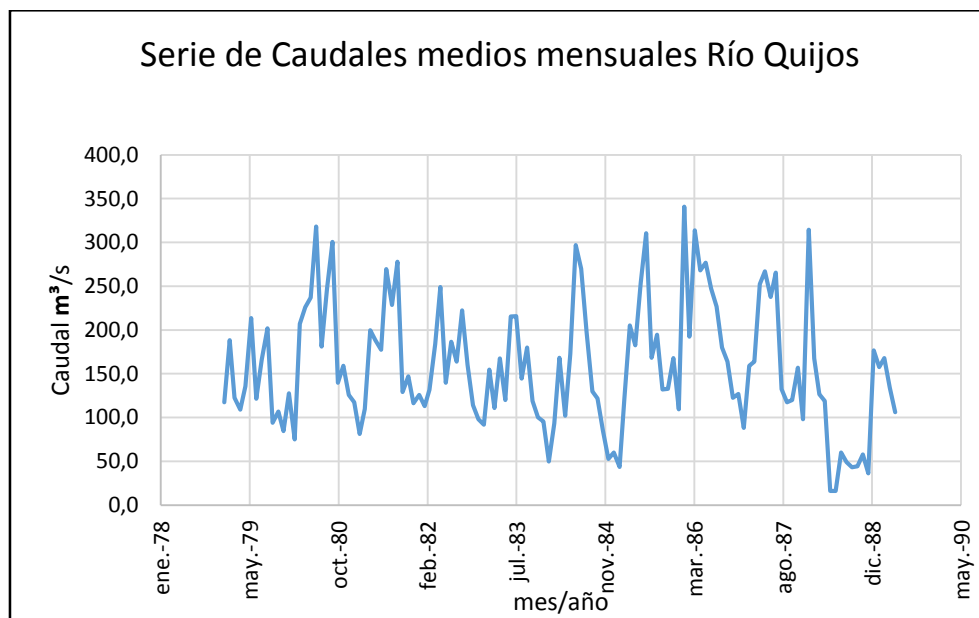


Figura 2.6 Serie de Caudales medios mensuales Río Quijos.

Fuente: Adaptacion datos obtenidos INAMHI.

2.1.3 Cuenca río Chico Portoviejo.

2.1.3.1 Ubicación.

Está ubicado en Portoviejo coordenadas latitud 00°50'03"N, 01°10'05"S y longitud 79°52'03"W, 80°25'03"W (Samaniego, 2008).

El río Chico, es un afluente del río Portoviejo, interviene en un área de 585 Km² con perímetro de 96,93 Km (Samaniego, 2008), de las parroquias San Plácido, Alajuela, Calderón, Río Chico y Resbalón (Alarcón, Castillo, & Chang, 2010).

En la Figura 2.7, se puede observar la ubicación del río Chico.





Figura 2.7 Ubicación río Chico.

Fuente: (Google maps, 2014); (Manabí Gobierno Provincial , 2014)

2.1.3.2 *Clima.*

En el cantón Portoviejo se presentan 2 estaciones definidas: una lluviosa (invierno), entre los meses de Enero a Abril, y la estación seca (verano) que se produce entre los meses de Mayo a diciembre (Dirección Nacional Forestal, 1998) citado por (Empresa Municipal de Aseo y

Servicios Públicos EMASEP, 2004). La temperatura media anual, registrada en la Estación Meteorológica de Portoviejo oscila entre los 26°C.

La humedad relativa tiene valores promedios de 76.2 anuales. El diagrama ombrotérmico de la Estación Meteorológica Portoviejo de los últimos años señala que los meses ecológicamente húmedos van de febrero a abril; el mes de marzo es ecológicamente el más húmedo (INEFAN, 1996, Op. Cit.) citado por (Empresa Municipal de Aseo y Servicios Públicos EMASEP, 2004).

La evaporación anual es de 1.574,8 mm, valor que comparado con el de precipitación (491 mm) deja ver claramente la existencia de un déficit hídrico en la zona. (Empresa Municipal de Aseo y Servicios Públicos EMASEP, 2004).

De acuerdo con el Mapa Bioclimático del Ecuador, Portoviejo está localizada en una región clasificada por Holdridge como Sub-desértica Tropical. Según el mismo autor, la ciudad y su área de influencia se ubican en una región ecológica clasificada como monte espinoso tropical. (Empresa Municipal de Aseo y Servicios Públicos EMASEP, 2004).

2.1.3.3 Suelos.

Los suelos tienen características de sedimentos marmos, con bosques tropicales y subtropicales secos, constituyéndose en suelos productores de ceibos, algarrobos, guayacán, caña gajúa, palma real entre otros. (Empresa Municipal de Aseo y Servicios Públicos EMASEP, 2004)

Fernández (1994) citado por (Empresa Municipal de Aseo y Servicios Públicos EMASEP, 2004), señala que en Portoviejo se presenta el tipo de suelo zonal, que corresponde a la zona de vida denominada bosque espinoso tropical. Son suelos con predominancia de areniscas, sobre colinas de fuerte pendiente, donde predominan las areniscas, se encuentra un suelo desarrollado, con horizontes típico de alteración, poco profunda de textura limosa y en proceso de erosión. Tiene buenas condiciones para la agricultura y ganadería por ser relativamente fértiles y planos.

2.1.3.4 Características hidrológicas de la cuenca.

La forma de la cuenca es de oval redonda a oval oblonga, lo que indica que la tendencia a crecidas del río es media, y posee una densidad de drenaje regular (Samaniego, 2008).

En la figura 2.8, se observa el comportamiento durante un periodo continuo de tiempo, de los caudales mensuales, en la Cuenca del Río Chico.




Figura 2.8 Serie de Caudales medios mensuales Río Chico.

Fuente: Adaptacion datos obtenidos INAMHI.

2.1.4 Cuenca del río Pindo Amarillo.

2.1.4.1 Ubicación.

El área de la investigación se halla situada en el distrito minero Portovelo – Zaruma cuyas coordenadas de latitud son: 03°30'02"N, 03°59'30"S y longitud 79°11'25"W, 79°45'10"W (Samaniego, 2008), y se encuentra ubicada al Sur-Este de la Provincia de El Oro (Figura 2.9).




Figura 2.9 Ubicación del río Pindo

Fuente: (I.G.M.) Instituto Geográfico Militar, 2008.

2.1.4.2 Clima y Vegetación.

Por las características geográficas y topográficas de la zona, podemos encontrar microclimas de marcada diferencia con régimen climático temperado y con altitudes entre los (600 y 3771) m.s.n.m. El clima de la región corresponde a subtropical húmedo, en donde se dan dos estaciones bien marcadas, el periodo denominado invierno, que se prolonga desde enero a abril y el período que va desde mayo a diciembre que se caracteriza por ausencia de precipitaciones y se conoce como verano (Mero, 2014).

En la tabla 2.2, se muestran los indicadores climáticos del cantón Portovelo.

Tabla 2.2 Indicadores Climáticos Medios cantón Portovelo.

Precipitación total anual	1229 mm.
Precipitación media mensual	102 mm
Evaporación media mensual	62 mm
Humedad relativa	84 %
Nubosidad	6/8
Temperatura ambiental media mensual	21.8 °C

Fuente: Plan de Desarrollo Estratégico - Municipio de Zaruma. 2004.

2.1.4.3 Suelos.

De acuerdo al mapa de Cobertura Vegetal y Uso Actual del Suelo Figura 2.10, realizado por el Ministerio de Agricultura y Ganadería (MAG), se puede distinguir las siguientes formaciones vegetales y usos del suelo en la zona de estudio:

- **Zonas de Ocupación Poblacional:** Estas zonas comprenden la parte urbana y rural.
- **Zonas de Actividad Agrícola:** Comprende los cultivos indiferenciados en el mapa, pero tradicionales en la zona de estudio, tales como: café, maíz, caña de azúcar, yuca.
- **Zonas de Actividad Ganadera:** Representada principalmente por el ganado vacuno y ocupa las zonas de pastizales naturales y cultivados.
- **Zonas de Actividad Minera:** Representada por las explotaciones mineras y sus respectivas escombreras.




Figura 2.10. Mapa de Cobertura Vegetal y Uso Actual.

Fuente: Mapa de Cobertura Vegetal y Uso Actual de Zaruma.

Escala: 1:30.000. (MAG).

Características hidrológicas de la cuenca.

La forma de la cuenca es de oval redonda a oval oblonga, lo que indica que la tendencia a crecidas del río es media, y posee una densidad de drenaje regular (Samaniego, 2008). En la Figura 2.11, se observa el río Pindo.



Figura 2.11 Imagen Río Pindo.

Fuente: (Agencia de Prensa El Oro-APO, 2014)

En la figura 2.12, se observa el comportamiento durante un periodo continuo de tiempo, de los caudales mensuales, en la Cuenca del Río Pindo.




Figura 2.12 Serie de Caudales medios mensuales Río Pindo.

Fuente: Adaptacion datos obtenidos INAMHI.

2.1.5 Cuenca Río El Limón.

2.1.5.1 Ubicación Geográfica.

Según (Castro & Ordoñez, 2006), la microcuenca hidrográfica El Limón se encuentra ubicada al sureste de la ciudad de Zamora dentro de la jurisdicción regional de la parroquia El Limón, cantón Zamora, provincia de Zamora Chinchipe. Sus límites son al norte con la quebrada Chorrillos, al sur, este y oeste con el Parque Nacional Podocarpus. Esta microcuenca es la que provee de agua a la ciudad de Zamora.

El sitio más alto de la microcuenca hidrográfica está en la cota aproximada de 2 680 m.s.n.m., mientras que la cota más baja está a 900 m.s.n.m. y se encuentra en la Zona 17 S proyección Transversa de Mercator, ubicada en las siguientes coordenadas planas: Latitud: 9°59'12.00" a 9°54'47.00" W, Longitud: 72°13'00" a 72°18'00" S.

Debido a la orientación y diferencias altitudinales de la microcuenca, en el área se generan pequeñas variaciones microclimáticas respecto a la ciudad de Zamora.

La topografía del área es muy irregular; en su mayoría existen pendientes con promedio del 70 %, especialmente el lado que comprende el límite con El Parque Nacional Podocarpus. La microcuenca hidrográfica El Limón tiene un área total de 1 019 hectáreas, la vegetación incluye bosques de chaparro, bosques naturales, bosques secundarios, matorrales, pastizales (Silva, Analisis Cuenca el Limon, 2014).

La zona de mayor altura, de la micro-cuenca hidrográfica está en la cota cercana de 2 680 m s.n.m., mientras que la cota más baja está a 900 m.s.n.m. y se encuentra en la Zona 17 S (Silva, Microcuenca El Limon, 2014).

2.1.5.2 Caracterización morfométrica de la cuenca.

El área de estudio según el Centro Interamericano de Desarrollo Integral de Aguas y Tierras citado por Escobar (2001) por la superficie que posee se clasifica como una microcuenca. (Coronel y Jaramillo, 2005).

Tabla 2.3 Caracterización morfométrica de la micro- cuenca el Limón.

PÁRAMETRO	UNIDAD	RESULTADO	INTERPRETACIÓN
MORFOLOGÍA DE LA MICROCUENCA			
	Km^2		
Área		10.19	Cuenca pequeña
Perímetro	Km	15.3	
Longitud axial	Km	6.27	
Ancho promedio	Km	1.26	
Factor de forma		0.25	Microcuenca alargada, poco peligro de crecidas
Coefficiente de compacidad		1.34	Oval redonda a oval oblonga (ovalada)
Índice simétrico		7.3	Microcuenca asimétrica
FISIOGRAFÍA			
Mediana de altitud	m.s.n.m.	1 592	
Altura media	m.s.n.m.	880	
Altitud media	m.s.n.m.	1676.3	
Pendiente media	%	62.4	
Orientación		Este-Oeste	
	Km/Km^2		
Coefficiente de masividad		0.086	
Coefficiente orográfico	m	75.68	Relieve accidentado
MORFOLOGÍA DE DRENAJE			
Clasificación de corrientes		Corriente perenne	Transporta agua todo el año y siempre están alimentadas totalmente
Orden de corrientes		Orden 3	
Densidad de drenaje	Km/Km^2	1.78	Se trata de una microcuenca mal drenada

Fuente: (Silva, Microcuenca El Limon, 2014).

2.1.5.3 Cobertura vegetal.

La microcuenca “El Limón” constituye una área 1006 ha, la superficie total de la cuenca se encuentra cubierta por diferentes tipos de vegetación en un 98.77%. Los tipos de vegetación son: bosque alto maduro con 36,79 % (374,944 ha). El bosque alto secundario corresponde al 31,71 % (323,195 ha). El bosque achaparrado ocupa el 5,42 % del total del área (55,259 ha) El complejo pastizal-bosque representa el 7,60 % (77,502 ha). La comúnmente denominada luzara ocupa 19,122 ha (1,87 %). Finalmente los pastizales ocupan el 15,38 % de la cobertura, es decir 156,731 ha. En la parte más baja de la microcuenca se encuentra la

zona urbana con 12,524ha que corresponde 1,22 % donde se encuentra el barrio El Limón. (Silva, Microcuenca El Limon, 2014).

Posee un clima subtropical, templado-húmedo, con una precipitación que oscila entre (1800 – 2200) mm/año y una temperatura media anual de 20 °C. En la Figura 2.14, se presenta la ubicación del sitio de la cuenca del río el Limón.



Figura 2.13 Ubicación del área de estudio

Fuente: (Ecuador M. d., 2014); (Silva, Analisis Cuenca el Limon, 2014)

En la figura 2.14, se observa el comportamiento durante un periodo continuo de tiempo, de los caudales mensuales, en la Cuenca del río el Limón.

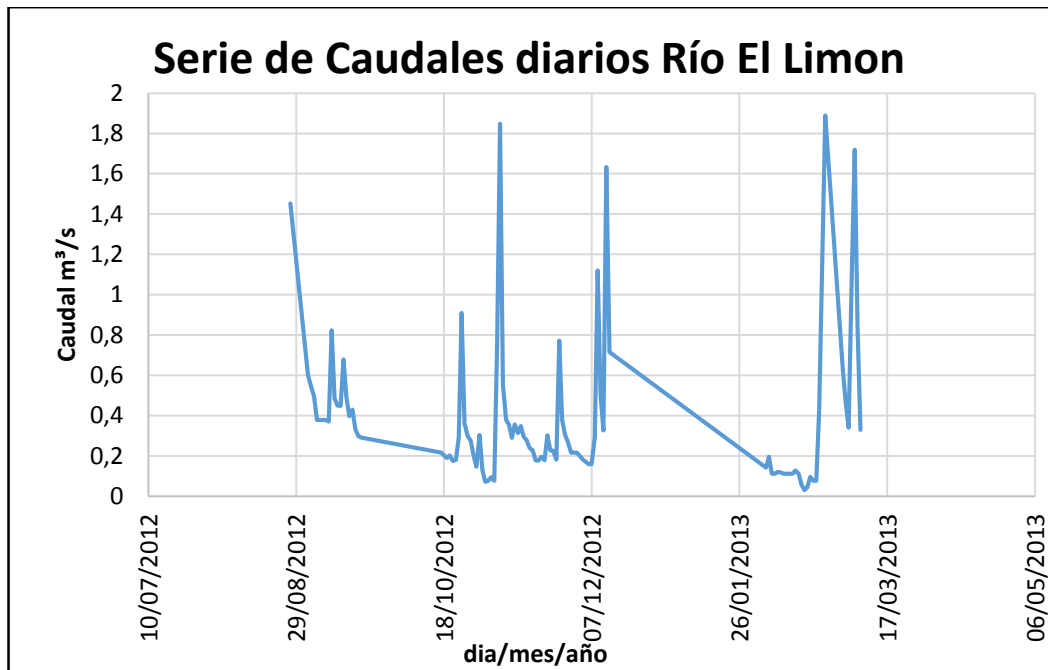


Figura 2.14 Serie de Caudales diarios Río El Limón.

Fuente: Adaptacion datos obtenidos (Silva, Analisis Cuenca el Limon, 2014).

2.1.6 Cuenca Catamayo – Chira.

La Cuenca Binacional Catamayo-Chira, se extiende entre las coordenadas 3° 30´ a 5° 8´ de latitud sur y 79° 10´ a 81° 11´. Cubre la región fronteriza sur occidental entre Ecuador y Perú con una extensión de 17 199.19 Km²; nace en las cumbres de la divisoria continental de aguas (Ecuador) y desemboca en el Océano Pacífico (Perú), atravesando escenarios montañosos y costaneros, con climas tropicales, ecosistemas, usos y sistemas administrativos; que determinan características territoriales naturales y antrópicas muy diversas. La geografía de la cuenca es abrupta con rangos de altitud que oscilan entre los 3 700 y 0 metros sobre el nivel del mar. En este escenario se presentan once zonas de vida, que van desde el desierto tropical (D-T) hasta el bosque pluvial montano (Bp-M). La precipitación media anual es del orden de los 800 mm variando entre 10 mm en la zona baja, hasta 1000 mm en su cabecera (Oñate, y otros, 2011).

En la figura 2.11, se observa la ubicación de la cuenca Catamayo, en la provincia de Loja.



Figura 2.15 Ubicación del Área de estudio.

Fuente: (Wikipedia, 2014); (Acaro, 2014); (Ecuador P. d., 2014).

En la figura 2.16, se observa el comportamiento durante un periodo continuo de tiempo, de los caudales mensuales, en la Cuenca del río Catamayo.




Figura 2.16 Serie de Caudales diarios cuenca Catamayo.

Fuente: (Oñate, y otros, 2011)

2.2 Materiales y Métodos

2.2.1 Materiales.

Los materiales utilizados en la presente investigación están conformados por datos de estaciones meteorológicas e hidrométricas, tomadas de las tesis de (Samaniego, 2008), (Silva, Analisis Cuenca el Limon, 2014), artículo publicado de (Oñate, y otros, 2011), y del INAMHI.

2.2.2 Definición de los datos.

Las series de tiempo de las variables de entrada deben ser lo más completas posible en las fechas o intervalos de tiempo escogidos. Esto ha dificultado la disponibilidad de series de tiempo prolongadas. En el caso de modelos concentrados es posible hacer una ponderación de los datos de las estaciones faltantes mediante técnicas estadísticas. Para el modelo que se ha estudiado en esta tesis es necesario información de cada estación, debido a que el modelo es altamente sensible a la información de cada estación.

2.2.3 Identificación de variables de entrada.

Las variables que están involucradas en el problema de predicción de caudales son precipitación y caudales históricos, la precipitación no se refleja instantáneamente como caudal en el río, por el contrario esta precipitación es retenida en los diferentes componentes

de caudal dentro de una cuenca, por lo que a pesar de ser un parámetro importante para el cálculo del caudal, se necesitan más datos para obtener el caudal, pero si se trabaja con anteriores caudales y la precipitaciones al entrenar las redes se facilita el cálculo de los futuros caudales que se podrían obtener con cierta precipitación.

2.2.4 Implementación de arquitecturas de redes neuronales.

2.2.4.1 Toolbox de Matlab.

El programa elegido para realizar esta tesis fue Matlab debido a que tiene un Toolbox de redes neuronales que es bastante general y flexible.

Este toolbox permite cambiar el número de capas, número de neuronas, su función de activación, diversos tipos de interconexión entre capas, diversas funciones de error para optimizar la red, varios tipos de algoritmos de aprendizaje. Todas estas opciones son programables.

La interfaz es bastante manejable, permite trabajar con ventanas, desde teclado o con scripts. Una opción que se ha utilizado del toolbox es la diferenciación interna entre muestra de entrenamiento, validación y predicción o test. La red se entrena con los datos de entrada y va calculando una llamada varianza dentro de los cuadrados medios del error, y habitualmente representada por MSE (Mean Square Error) o MSW (Mean Square Within) que se calcula como la media de las k varianzas muestrales. MSE es un cociente: al numerador se le llama suma de cuadrados del error y se representa por SSE y al denominador grados de libertad por ser los términos independientes de la suma de cuadrados. (Jiménez, 2009).

Debido al aprendizaje en cada iteración, este MSE de entrenamiento va disminuyendo. Paralelamente el programa va calculando el MSE con los datos de validación que globalmente van disminuyendo hasta cierto punto y luego aumentan paulatinamente. En ese punto Matlab automáticamente detiene el entrenamiento de la red, debido a que la red se está sobreentrenando para los datos de entrenamiento, pero se está distanciando de datos que no hayan intervenido en su entrenamiento. Esta característica se llama "early stopping" y evita la especialización de la red, lo cual es poco deseable para la generalización deseada. Una vez que la red test (Jiménez, 2009).

2.2.4.2 Red aplicada.

Para identificar la red óptima para el problema que ocupa esta tesis, se ha trabajado con el número de capas, número de nodos o neuronas por capa, los tipos de conexión entre capas y neuronas entre capas y las funciones de transferencia utilizadas. La versatilidad que ofrece el toolbox de Matlab ha permitido probar varias arquitecturas de red.

2.2.4.3 MLP: Multilayer perceptron.

Es una red de varias capas básicamente. Las capas son la de entrada, una o varias intermedias u ocultas y la de salida. Mediante el toolbox de Matlab se puede optar por varias capas ocultas, pero de acuerdo a referencias bibliográficas, esto podría llevar a una red muy específica o sobreentrenada, en el entrenamiento de la red este caso se utilizó 10, 50, 80 y 85 capas ocultas, las que nos permitieron obtener los mejores resultados.

2.2.5 Métodos.

Los métodos usados en la presente investigación se han dividido en dos etapas, las cuales son:

A) Recolección y análisis de la información hidrometeorológica

Análisis de las series temporales de los caudales medios mensuales.

B) Modelamiento determinístico de caudales mensuales

- Determinación de las variables de los modelos a emplear.
- Simulación del modelo hidrológico distribuido.
- Análisis de bondad de los modelos.

2.2.6 Desarrollo de los métodos.

2.2.6.1 Determinación de la arquitectura y parámetros de los modelos de redes neuronales artificiales.

El tipo de red usada en el modelamiento con redes neuronales artificiales de los caudales medios mensuales de las cuencas del Río Guayllabamba, Río Quijos, Río Chico, la cuenca Río Pindo, y los caudales diarios de las cuencas Catamayo, y El Limón, es la red multicapa feedforward que comprende tres capas: de entrada, intermedias u ocultas y de salida. En las redes feedforward, todas las señales neuronales se propagan hacia adelante a través de las capas de la red (Hilera & Martínez, 2000).

La determinación de la arquitectura para cada uno de los modelos de redes neuronales artificiales se realizó para toda la serie, esto con la finalidad de que el modelo pueda tener más datos para el entrenamiento, además se asume que existe una relación directa entre las variables de entrada y el caudal de las cuencas en cada mes o día.

En la práctica no existe una regla definida para establecer el número inicial de neuronas y capas intermedias u ocultas, por lo que la metodología seguida fue la de prueba-error.

2.2.6.2 Agrupación de los datos de entrada.

Los datos fueron agrupados de tal forma que sigan la serie cronología mensual y anual establecida, se utilizó el 75% de datos para el entrenamiento, dejando el 25% de datos para la verificación del modelo, excepto en las cuencas del río Guayllabamba, Quijos donde se utilizó el 85% de datos para el entrenamiento y en la cuenca del río Catamayo se utilizó el 80% de datos para el cálculo. Quedando la distribución como se ve en la Tabla 2.4 para los caudales medios, y en la Tabla 2.5 para los caudales diarios.

Tabla 2.4 Distribución de la información de las cuencas analizadas con datos mensuales.

Cuenca	Datos para entrenamiento (años)	Datos para comprobación (años)
Río Guayllabamba	12	2
Río Quijos	9	3
Río Chico	10	4
Río Pindo	24	8

Fuente: Elaboración propia.

Tabla 2.5 Distribución de la información de las cuencas analizadas con datos diarios.

Cuenca	Datos para entrenamiento (días)	Datos para comprobación (días)
El Limón	75	19
Catamayo	216	54

Fuente: Elaboración propia.

2.2.6.3 Entrenamiento de los modelos de redes neuronales artificiales.

Este proceso consistió en evaluar las distintas opciones de entrenamiento haciendo variar la cantidad de iteraciones y la tasa de aprendizaje con la finalidad de minimizar el error en los caudales simulados.

Durante la etapa de entrenamiento de las redes, se determina iterativamente los pesos de las conexiones, w_{ji} que conectan a las neuronas de entrada con las de la capa oculta y w_j para la transferencia entre la capa oculta y la de salida. A partir de los datos de entrada la red en cada iteración genera una salida, a través de las neuronas que la componen, con los pesos y función de transferencia considerada, esta salida es comparada con los valores objetivos (caudales observados), obteniéndose así un error. Esta fase concluye cuando la red converge

y es capaz de minimizar el error. La función de transferencia y activación ha sido la del tipo sigmoidea.

El toolbox de Matlab cuenta con diversos algoritmos de entrenamiento de las redes entre los cuales esta TRAINBR(Bayesian regulation backpropagation), TRAINLM (Levenberg-Marquardt backpropagation), TRAINRP (Resilient backpropagation), trainscg(Scaled conjugate gradient backpropagation), y algunos más cuya función es entrenar la red.

El entrenamiento Bayesian regulation backpropagation es una función de entrenamiento que actualiza los valores de los pesos y el sesgo de acuerdo con la optimización de Levenberg-Marquardt backpropagation. Se minimiza una combinación de errores cuadráticos y pesos, luego determina la combinación correcta de manera que produzca una correcta red generalizada. (Jiménez, 2009).

La regulación bayesiana (MATHWORKS, 2011) se lleva a cabo en el algoritmo de Levenberg-Marquardt. La retropropagación es usada para calcular el Jacobiano jX de performance adecuada con respecto al peso y sesgo de las variables X . Cada variable es ajustada de acuerdo con Levenberg-Marquardt.

$$\begin{aligned}ij &= jX(jX) \\je &= jX(E) \\dX &= \frac{(ij + I(\mu))}{je}\end{aligned}\tag{Ec. 2. 1}$$

Donde “E” son todos los errores e “I” es la matriz identidad. El valor adaptativo μ se incrementa por μ_inc hasta que el cambio se muestre por encima de los resultados lo que indica un valor de reducción del rendimiento. El cambio se hace entonces a la red y μ decrece por μ_dec .

El algoritmo converge cuando:

- El número máximo de iteraciones es alcanzado.
- El error es minimizado hacia el objetivo.
- El gradiente de rendimiento cae por debajo del valor mínimo.

2.2.6.4 Simulación de los modelos de redes neuronales artificiales.

La simulación de los modelos de Redes Neuronales Artificiales se realizó mediante el software científico MATLAB con la Neural Network Toolbox. Como el algoritmo de entrenamiento usado presenta un proceso de optimización se apreció que la variación de neuronas en la capa oculta no representa variaciones considerables en los caudales simulados, teniendo como función objetivo la eficiencia de Nash- Sutcliffe, por lo cual se establecieron los modelos con una cantidad de (10 a 80) neuronas ocultas (dependiendo de la cantidad de neuronas de entrada) en la capa oculta o intermedia. Las iteraciones en los modelos varían desde 600 a 1000 dependiendo del modelo y el proceso que le tome en converger al mejor resultado.

2.2.6.5 Análisis de bondad de los modelos determinísticos.

Para análisis la bondad de los modelos determinísticos simulados se usó la eficiencia de Nash- Sutcliffe.

2.2.7 Modelo Presentado para su análisis.

En la Tabla 2.6 se presenta el modelo analizado, donde las entradas son las precipitaciones (P) y caudales históricos de la cuenca (Q), y en la salida se tienen los caudales futuros (Q).

Tabla 2.6 Modelo analizado

ENTRADAS		SALIDA
P1	Q1	Q5
P2	Q2	Q6
P3	Q3	Q7
P4	Q4	Q8
.....

Fuente: Elaboración propia

2.2.8 Análisis con la herramienta de identificación de sistemas de Matlab.

Para realizar este análisis, utilizando el software Matlab, se procedió a trabajar con diversos modelos para realizar el entrenamiento de la red, se trabajó con un total del 75%, 80% y 85% de los datos históricos obtenidos de la Cuencas de estudio, esto se lo hizo debido a que en unas cuencas se tenía menor cantidad de información por lo que se utilizó un mayor porcentaje de datos para el entrenamiento, el porcentaje restante se lo dejo para su realizar la comprobación de los datos simulados.

2.2.9 Implementación en Matlab – herramienta de redes neuronales – NNTool.

La herramienta de Redes neuronales de Matlab, NNTool, consiste de un conjunto de funciones y estructuras que manejan las redes neuronales, que se presenta en un entorno de ventanas de trabajo, donde se ingresan los datos del problema a resolver y se seleccionan las funciones de activación, los algoritmos de formación, que se usaran, con distintas opciones se ingresa o selecciona información sobre la estructura de la red neuronal, por ejemplo el número y estructura de sus capas, la conectividad entre las capas, datos necesarios para generar la red neuronal, (Demuth & Beale, 1998)

El análisis de una red neuronal usando la NNTool de Matlab, se inicia en el entorno de trabajo de la herramienta de redes neuronales, se ingresan los datos a ser analizados, en las Figura 2.17 puede observarse los datos cargados para posteriormente ser emplearlos en la simulación de la red.




Figura 2.17 Matlab-NNTool: Ventana NNTool, con la Red Neuronal y los datos usados en la Generación de la red.

Fuente: Elaboración propia.

En la Figura 2.17, se observan los archivos que se utilizan para realizar el entrenamiento, siendo:

P: Los registros de precipitaciones históricos de cada cuenca analizada.

C: Los registros históricos de caudales de las cuencas.

Adr: Son los datos de precipitaciones con las que se hará los cálculos de los caudales futuros.

En la Figura 2.18 se observan la nueva red donde especifica la estructura y se indican los datos de entrada de la red, el número de neuronas y las diversas funciones para el entrenamiento de la red.




Figura 2.18: Matlab-NNTool: Ventana de Creación de la red neuronal, donde se indican datos y se configuran las funciones y la estructura de la red neuronal

Fuente: Elaboración propia.

En la Figura 2.19, se observa la estructura de la red utilizada para la simulación de los caudales.




Figura 2.19: Matlab-NNTool: Estructura de la Red Neuronal.

Fuente: Elaboración propia.

En la Figura 2.20 se observa la ventana de entrenamiento donde se coloca en número de iteraciones que se necesita para el entrenamiento de la red.




Figura 2.20: Matlab-NNTool: Simulación de la Red.

Fuente: Elaboración propia.

En las Figuras 2.21 y 2.22, se presentan las gráficas del mejor entrenamiento obtenido y la mejor correlación del entrenamiento interno de la red.

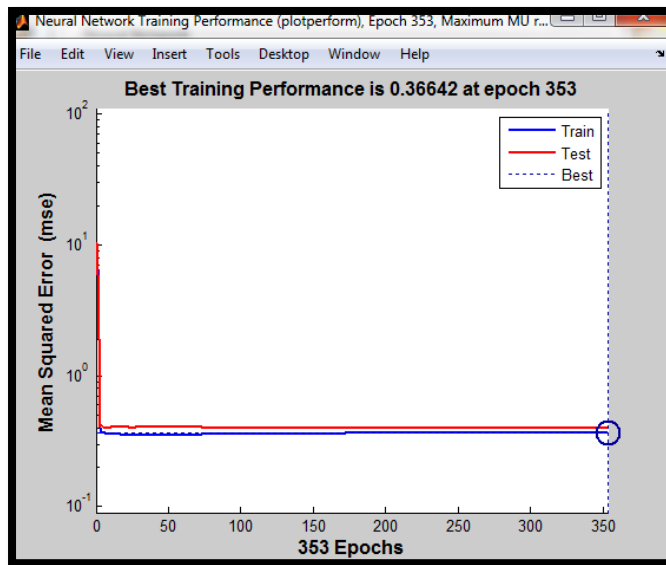


Figura 2.21: Matlab-NNTool: gráficas con los resultados del entrenamiento de la RN, función de entrenamiento TRAINBR.

Fuente: Elaboración propia.

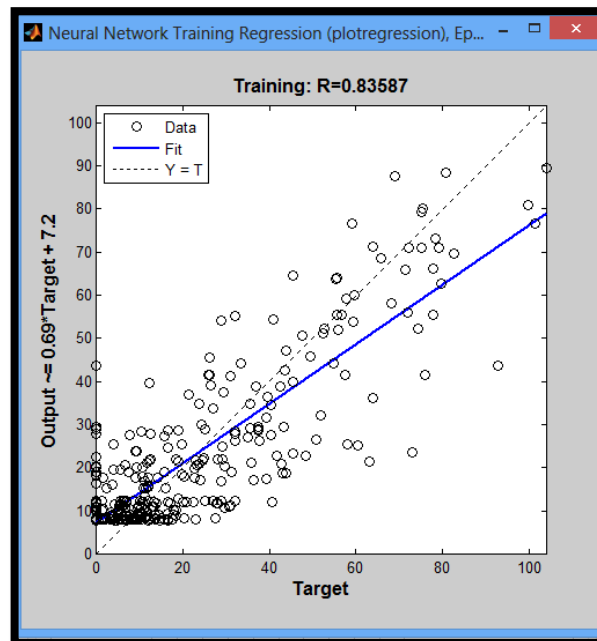


Figura 2.22: Matlab-NNTool: gráficas con los resultados del entrenamiento de la correlación de la Red Neuronal.

Fuente: Elaboración propia.

2.2.10 Análisis microcuenca el Limón.

Para la comparación de datos mensuales, con datos diarios se utilizó los datos diarios de tres estaciones de la microcuenca El Limón las cuales se encuentran en las coordenadas que se encuentran en la Tabla 2.7.

Tabla 2.7 Coordenadas Estaciones El Limón.

NOMBRE ESTACION	COORDENADAS		DESCRIPCIÓN
	NORTE	ESTE	
P1	9548906	723840	Pluviómetro 1
P2	9549241	724842	Pluviómetro 2
E	9550067	725148,6	Estación meteorológica

Fuente: (Silva, Microcuenca El Limon, 2014)

Con estos datos se utilizó el método de polígono Thiessen para obtener la precipitación media diaria de la cuenca.

Se tuvo que realizar el cálculo de los caudales diarios, con datos de la altura, empleando la siguiente ecuación de autoría (Silva, Generacion de Informacion Base y Estudios de Relaciones Lluvia- Escorrentia en la Micro-Cuenca El Limon Zamora Chinchipe, 2014).

$$Q = 452,2228 \times h^{3,6024} \quad (\text{Ec. 3.1})$$

Donde:

Q: Caudal diario m³/s.

H: Altura máxima en m.

2.2.11 Análisis cuenca Catamayo.

Para el análisis de la cuenca Catamayo se trabajó con datos diarios de caudal y precipitación de las estaciones Malacatos, Quilanga, Quinara, Yangana.

Se realizó el relleno de datos faltantes por el método de correlación entre las estaciones antes mencionadas, posteriormente se calculó la precipitación media de la cuenca por medio del método de polígonos de Thiessen.

En la Tabla 2.8 se observa las coordenadas de las estaciones utilizadas para el análisis de la cuenca Catamayo.

Tabla 2.8 Coordenadas estaciones cuenca Catamayo.

ESTACION	COORDENADAS	
	NORTE	ESTE
MALACATOS	9534449,7	690908,49
QUILANGA	9525631,7	677567,41
QUINARA	9523381	695324,36
YANGANA	9517835,7	701972,06

Fuente: (Oñate, y otros, 2011)

ANÁLISIS DE RESULTADOS

Una vez aplicadas las metodologías, se ha procedido a realizar el análisis de resultados mediante el cálculo de sensibilidad de datos, comparando los caudales simulados con los caudales dados.

En la Tabla 3.1, se observa tres diferentes tipos de entrenamiento que nos permite realizar el toolbox de Matlab y su respectivo coeficiente de eficiencia de Nash & Sutcliffe, el algoritmo TRAINBR o de regularización bayesiana, es el que se propone para ser utilizado en la red neuronal, porque presentó un mejor desempeño con los distintos grupos de datos de entrenamiento que se probaron en la generación de la red neuronal; considerando también que este algoritmo reduce al mínimo una combinación estrictamente convexa del error cuadrado medio y de los pesos cuadrados medios.

Tabla 3.1 Análisis de los errores para el entrenamiento.

Tipo de Entrenamiento	Coeficiente de eficiencia de Nash & Sutcliffe
TRAINS	0.659
TRAINLM	0.648
TRAINBR	0.670

Fuente: Elaboración propia.

En la Tabla 3.2 se presentan los resultado de los coeficientes de eficiencia de Nash & Sutcliffe, para varios número de neuronas, como se puede observar según se aumenta las neuronas mejora el coeficiente, pero esto ocurre hasta cierto punto, ya que posteriormente el coeficiente empieza a disminuir, esto se debe al sobreentrenamiento de la red, el mejor coeficiente se lo obtuvo con 10 neuronas, con este número se logró el mejor coeficiente en la mayoría de los casos por lo que fue elegido para el modelamiento de las redes.

Tabla 3.2 Análisis del número de neuronas necesarias para el modelo de red óptimo.

N° neuronas	Coeficiente de eficiencia de Nash & Sutcliffe
1	0.668
10	0.671
20	0.57
100	-0.36

Fuente: Elaboración propia.

En la Tabla 3.3 se puede observar los parámetros de validación para cada cuenca, existiendo una relación directa entre el número de datos de entrenamiento, y el Coeficiente de eficiencia de Nash y Sutcliffe, entre mayor cantidad de datos mejora el coeficiente, también un parámetro importante es el monitoreo de cada cuenca, entre mayor número de estaciones tenga la cuenca, mejor es el coeficiente, con excepción del caso observado en el río Chico, que si bien tiene un mayor número de estaciones, la cantidad de registros es baja, lo que sugiere, que con un mayor número de registros es mayor el desempeño de la red.

Tabla 3.3 Parámetros de Validación de las Redes

Cuenca	Área (Km ²)	Número Estaciones	Densidad Estaciones por (Km ²)	Número de registros	Coef. Efi. Nash & Sutcliffe
Río Guayllabamba	3488,76	5	0,0014	14	0,3
Río Quijos	2586,53	3	0,0011	12	0,17
Río Chico	416,74	5	0,0119	14	0,37
Río Pindo	511,84	3	0,0059	32	0,67

Fuente: Elaboración propia.

Se efectuó la selección de los mejores modelos teniendo como principal criterio de evaluación, la capacidad de desempeño y generalización a través de las estadísticas de validación de los modelos, tanto para la fase de entrenamiento como para la de validación.

En las Figuras (3.1, 3.2, 3.3 y 3.4) se pueden apreciar las gráficas de las series hidrológicas de caudales observados y los caudales simulados versus sus fechas de ocurrencias; los caudales observados son los caudales que se obtuvo del INAMHI, y los caudales simulados son los caudales obtenidos en el entrenamiento de la red en Matlab, se aprecia que las series coinciden en ciertos puntos, en la cuenca del río Pindo se aprecia que el ajuste de datos dados y simulados es bueno ya que coincide en varios puntos.




Figura 3.1 Comparación de series hidrológicas de caudales calculados y simulados de la cuenca Río Guayllabamba.

Fuente: Elaboración propia.




Figura 3.2 Comparación de series hidrológicas de caudales calculados y observados de la cuenca Río Quijos.

Fuente: Elaboración propia.




Figura 3.3 Comparación de series hidrológicas de caudales calculados y observados de la cuenca Río Chico.

Fuente: Elaboración propia.

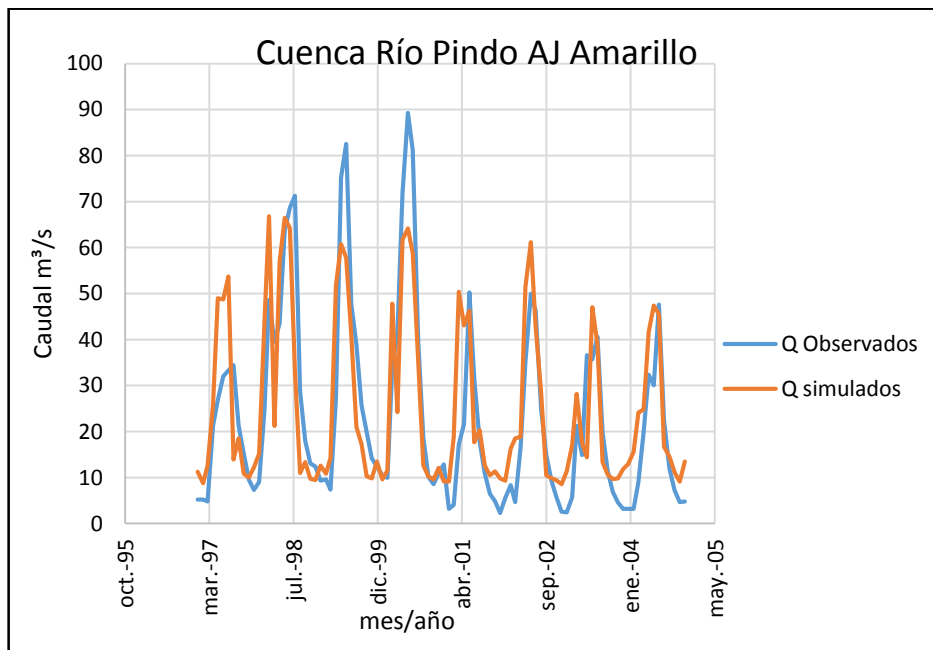


Figura 3.4 Comparación de series hidrológicas de caudales calculados y observados de la cuenca Río Pindo.

Fuente: Elaboración propia.

3.1 Microcuenca El Limón y Catamayo.

En la Tabla 3.4 se observan los parámetros de validación de las cuencas, El Limón y Catamayo el coeficiente de eficiencia de Nash & Sutcliffe es bajo, esto quiere decir que la relación entre los caudales dados y los simulados no es buena, esto se debe a que hay poca correspondencia de los datos, por la variabilidad de la información, ya que existen puntos en los que no se registra precipitaciones en ninguna estación, sin embargo existen datos de caudales considerables esto hace que la red no encuentre un buen patrón entre los datos, y el entrenamiento no sea bueno.

Tabla 3.4 Parámetros de validación.

Cuenca	Coeficiente de eficiencia de Nash & Sutcliffe	
El Limón	EF=	0,006
Catamayo	EF=	0,015

Fuente: Elaboración propia.

En las Figuras (3.1, 3.2, 3.3 y 3.4) se pueden apreciar las gráficas de las series hidrológicas de caudales observados y los caudales simulados versus sus fechas de ocurrencias; los caudales observados son los caudales que se obtuvo del INAMHI, y los caudales simulados son los caudales obtenidos en el entrenamiento de la red en Matlab, se aprecia que las series no coinciden, esto se debe a la variabilidad de los registros existentes, dificultando que la red encuentre un patrón adecuado entre los datos.




Figura 3.5 Comparación de series hidrológicas de caudales calculados y observados de la Microcuenca Río El Limón.

Fuente: Elaboración propia.




Figura 3.6 Comparación de series hidrológicas de caudales calculados y observados de la Cuenca Catamayo.

Fuente: Elaboración propia.

CONCLUSIONES

- De acuerdo a la evaluación realizada aplicando redes neuronales, para la generación de caudales en los ríos Guayllabamba, Quijos, Chico, Pindo, El Limón, y Catamayo, la cuenca en la que se obtuvieron los mejores resultados fue la del río Pindo, ya que se consiguió un valor del coeficiente de eficiencia de Nash & Sutcliffe de 0.67 lo que indica que la red se comportó de una forma casi ideal, esto se debió a que fue la cuenca con mayor cantidad de datos.
- Durante el análisis se obtuvieron mejores resultados con datos de caudales mensuales que con los datos de caudales diarios, esto se debió a que los datos diarios presentan una mayor dispersión de la información, y los datos mensuales al ser datos totales o promedios, compensan estas diferencias y la red aprende de mejor forma y obtiene mejores simulaciones.
- La red que tuvo un mejor desempeño, fue la red con una capa de entrada, diez neuronas, una capa oculta, y una capa de salida la cual representa el caudal, usando la función Bayesian regularization como función de entrenamiento ya que con esta se obtuvo los mejores resultados durante la mayoría de las simulaciones.
- Se observó una relación directa entre el número de datos para el entrenamiento, y el coeficiente de eficiencia de Nash & Sutcliffe, siendo este coeficiente mejor con mayor cantidad de datos.
- En la investigación también se observó la intervención del tipo de monitoreo de cada cuenca, entre mejor sea la densidad de estaciones en el área de estudio, se obtiene un mejor coeficiente de eficiencia de Nash & Sutcliffe.
- Las Redes Neuronales obtienen información más precisa dependiendo de la exactitud de los datos de entrada y que tan continuos en el tiempo sean estos.

RECOMENDACIONES

- Se debe trabajar con la mayor cantidad de datos disponibles, para que la red pueda entrenarse con más datos históricos y obtener mejores simulaciones, ya que esto influye de gran manera para tener un mejor desempeño de la red.
- Para la utilización de más capas de entrada a la red, revisar que estas sean proporcionales al número de datos del tarjetero utilizado, en caso contrario el toolbox de Matlab no entrenará la red.
- Realizar estudios de simulación de caudales diarios, mensuales utilizando redes neuronales artificiales, usando como neuronas de entrada variables que caractericen la respuesta hidrológica de la cuenca, como el número de curva o algún índice que vegetación, temperatura, etc.
- Realizar el análisis de consistencia de la información de precipitación y caudales, la continuidad en el tiempo de estas variables, como paso previo e indispensable al momento de utilizar las redes neuronales artificiales para la simulación de caudales.
- Implementar modelos de simulación basados en redes neuronales que puedan simular sistemas complejos y difíciles de explicar, como son los procesos hidrológicos, de impactos ambientales, por medio de otro tipo de arquitectura de redes neuronales artificiales distintas a las presentadas en esta investigación.
- Seguir investigando en el tema de Redes Neuronales Artificiales, involucrando un mayor número de variables que intervengan en el comportamiento de la cuenca, trabajando con redes que tengan más de una capa de entrada, para así poder verificar qué importancia tiene cada variable empleada para el cálculo de caudales.

ANEXOS

Tabla 5.1 Caudales simulados Río Guayllabamba (m³/s).

		Río Guayllabamba AJ Cubi											
		Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1986		48,33	38,43	42,32	32,92	30,91	33,15	33,66	53,98	43,36	39,75	31,93	45,36
1987		44,93	38,33	45,58	31,45	34,50	33,39	37,94	31,76	32,59	34,37	33,12	38,15

Fuente: Elaboración propia.

Tabla 5.2 Caudales simulados Río Quijos (m³/s).

		Río Quijos DJ Oyacachi											
		Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1988		20,53	20,53	20,53	20,53	20,53	20,53	103,10	107,14	108,21	108,68	108,20	20,53
1989		20,53	20,53	20,53	20,53	20,53	20,53	107,04	107,97	105,35	108,42	106,84	102,05
1990		106,81	97,11	20,53	20,53	20,53	20,53	100,68	104,47	101,47	108,68	36,75	20,63

Fuente: Elaboración propia.

Tabla 5.3 Caudales simulados Río Chico (m^3/s).

	Río Chico AJ Portoviejo											
	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1997	1,19	2,95	1,94	5,17	8,67	5,4	11,36	12,17	12,41	1,98	2,56	2,47
1998	4,06	0,77	0,53	0,52	0,37	0,52	2,73	3,14	1,87	1,24	6,99	0,57
2004	0,63	0,52	0,64	0,69	0,55	0,57	1,36	0,39	1,01	3,05	0,68	0,51
2005	0,52	0,53	0,52	0,54	0,56	0,85	1,05	0,9	1,07	1,14	1,18	1,07

Fuente: Elaboración propia.

Tabla 5.4 Caudales simulados Río Pindo AJ Amarillo (m³/s).

Río Pindo AJ Amarillo												
	Enero	Febrero	Marzo	Abril	Mayo	Junio	Julio	Agosto	Septiembre	Octubre	Noviembre	Diciembre
1997	11,78	9,16	13,14	26,44	49,43	49,15	54,03	14,50	19,16	11,32	10,48	12,74
1998	15,76	44,73	66,74	21,90	57,02	66,40	64,25	33,81	11,48	13,89	10,15	9,85
1999	13,13	11,33	14,80	52,07	60,87	57,91	41,49	21,70	17,88	10,74	10,22	14,04
2000	10,01	12,01	48,24	24,89	61,81	64,18	58,86	36,11	13,17	10,65	10,01	12,60
2001	9,62	9,55	19,45	50,74	43,61	46,78	18,33	20,99	13,07	10,93	11,80	10,23
2002	9,71	16,88	19,16	19,49	51,79	61,22	43,31	29,27	10,93	10,32	9,77	8,93
2003	13,44	16,21	24,85	25,47	42,20	47,83	46,03	17,31	15,12	11,61	9,52	14,07
2004	13,68	12,97	18,44	13,56	9,57	9,12	5,83	4,23	3,47	6,75	2,80	21,16

Fuente: Elaboración propia.

Tabla 5.5 Caudales simulados Río El Limón (m³/s).

Río El Limón	
Día	Caudal Simulado
07/04/2013	0,212697805
08/04/2013	0,313017644
09/04/2013	0,183879581
10/04/2013	0,276680375
11/04/2013	0,056501511
12/04/2013	0,361117556
13/04/2013	0,330505394
14/04/2013	0,267969605
15/04/2013	0,275764061
16/04/2013	0,057456698
17/04/2013	0,168053156
18/04/2013	0,260275474
19/04/2013	0,158964847
20/04/2013	0,114281063
21/04/2013	0,068419085
22/04/2013	0,258431516
23/04/2013	0,413603483
24/04/2013	0,357572275

Fuente: Elaboración propia.

Tabla 5.6 Caudales simulados Río Catamayo (m³/s).

Río Catamayo	
Día	Caudales Simulados
07/04/1982	20,35
08/04/1982	18,84
09/04/1982	19,03
10/04/1982	19,32
11/04/1982	19,92
12/04/1982	19,64
13/04/1982	20,02
14/04/1982	23,72
15/04/1982	21,85
16/04/1982	22,78
17/04/1982	18,74
18/04/1982	19,05
19/04/1982	18,93
20/04/1982	23,64
21/04/1982	19,17

Río Catamayo	
Día	Caudales Simulados
22/04/1982	22,63
23/04/1982	20,92
24/04/1982	22,76
25/04/1982	19,65
26/04/1982	20,11
27/04/1982	19,20
28/04/1982	19,75
29/04/1982	20,79
30/04/1982	20,56
01/05/1982	22,35
02/05/1982	21,00
03/05/1982	23,94
04/05/1982	22,14
05/05/1982	20,51
06/05/1982	19,25

Río Catamayo	
Día	Caudales Simulados
07/05/1982	22,63
08/05/1982	23,95
09/05/1982	20,29
10/05/1982	23,86
11/05/1982	19,72
12/05/1982	19,78
13/05/1982	21,34
14/05/1982	23,45
15/05/1982	21,55
16/05/1982	20,11
17/05/1982	23,79
18/05/1982	22,02
19/05/1982	23,81
20/05/1982	21,81
21/05/1982	23,70

Río Catamayo	
Día	Caudales Simulados
22/05/1982	22,57
23/05/1982	19,69
24/05/1982	19,13
25/05/1982	21,63
26/05/1982	23,95
27/05/1982	22,35
28/05/1982	23,94
29/05/1982	22,14
30/05/1982	20,52
31/05/1982	19,25
01/06/1982	22,63
02/06/1982	23,95
03/06/1982	20,29
04/06/1982	23,86
05/06/1982	19,72

Fuente: Elaboración propia.

Río Catamayo	
Día	Caudales Simulados
06/06/1982	23,45
07/06/1982	20,11
08/06/1982	23,79
09/06/1982	23,70

Fuente: Elaboración propia.

BIBLIOGRAFÍA

- Acaro, K. (11 de 09 de 2014). *Canton Catamayo*. Obtenido de <http://katherineacaro.wordpress.com/2012/01/13/canton-catamayo/>
- Agencia de Prensa El Oro-APO. (17 de 06 de 2014). *Agencia de Prensa El Oro-APO*. Obtenido de <http://agenciadeprensaeloro.blogspot.com/2010/08/blog-post.html>
- Alarcón, N. M., Castillo, R. C., & Chang, M. P. (2010). *CALIDAD DE LAS AGUAS UTILIZADAS EN EL RIEGO DE CULTIVOS EN LAS AREAS*. Santo Domingo.
- Alegre, A. (2003). *Simulación de redes neuronales artificiales: Una aplicación didáctica. Tesis Lic. Sistemas. Universidad Nacional del Nordeste*. Argentina.
- AMES. (17 de 06 de 2014). Obtenido de CANTÓN QUIJOS : <http://www.ame.gob.ec/ame/index.php/ley-de-transparencia/57-mapa-cantones-del-ecuador/mapa-napo/202-canton-quijos>
- Apolloni. (1990). "Diagnosis of epilepsy via backpropagation . *Proc.IJCNN International Joint Conference Proc.IJCNN International Joint Conference*, (págs. 571-578). Washington DC.
- Ballini, R., & Vilca, c. p. (2000). *Análise e previzão de vazões utilizando modelos de séries temporais, redes neurais e redes neurais nebulosas. Tesis Dr. Brasil: REVISTA PERUANA GEO-ATMOSFÉRICA RPGA*.
- Basogain, X. (2008). *REDES NEURONALES ARTIFICIALES Y SUS APLICACIONES*.
- Belegundu, A., & Chandrupatla, T. (2011). *Optimization Concepts and Applications in Engineering*. New York.
- Castro, R. C., & Ordoñez, A. J. (2006). *VALORACIÓN ECONÓMICA DEL SERVICIO AMBIENTAL HÍDRICO DE LA MICROCUENCA HIDROGRÁFICA "EL LIMÓN"-ZAMORA CHINCHIPE, ECUADOR*. Loja.
- Chow, V., Maidment, D., & Mays, L. (1994). *Hidrología Aplicada. Trad. JG, Saldarriaga*. Santa Fé de Bogotá; Colombia: Mc Graw Hill. 584 p.
- Cole. (1990). Speaker independent recognition of spoken english letters. *International Joint Conference on Neural Networks*, (págs. 45-52). San Diego.
- Corporacion Toisan . (17 de 06 de 2014). *bosques*. Obtenido de <http://toisanintag.wordpress.com/bosques/>
- Demuth, H., & Beale, M. (1998). *Neural Network Toolbox, for use with Matlab*.
- Ecuador, M. d. (11 de 09 de 2014). *Noticias del Ecuador* . Obtenido de <http://ecuadorecuatoriano.blogspot.com/search/label/MAPA%20ECUADOR>
- Ecuador, P. d. (11 de 09 de 2014). *Provincias del Ecuador* . Obtenido de http://www.codeso.com/Turismoecuador/Mapa_Napo.html

- Empresa Municipal de Aseo y Servicios Públicos EMASEP. (2004). *EL CANTON PORTOVIEJO*.
- Google maps. (11 de 09 de 2014). *Tageo.com*. Obtenido de Maps Satellite :
<http://www.tageo.com/index-e-ec-v-14-d-m1378723.htm>
- Haykin, S. (1994). *Neural Networks*. Macmillan College Publishing Company.
- Hilera, J., & Martínez, V. (2000). *Redes Neuronales Artificiales: Fundamentos, modelos y aplicaciones*. México: MX. Ra-ma. 390 p.
- Instituto Nacional de Meteorología e Hidrología . (2009). *ANUARIO HIDROLOGICO*. Quito.
- Jiménez, M. A. (2009). *IMPLEMENTACIÓN EN MATLAB DE TÉCNICAS MATEMÁTICAS EN EL ANÁLISIS DE EXPERIMENTOS; PROYECTO FIN DE CARRERA*. Cartagena.
- Kamikura. (1990). Application of temporal supervised learning algorithm to generation of natural language. *International Joint Conference on Neural Networks*, (págs. 201-207). San Diego.
- Lapedes, A., & Farber, R. (1987). Nonlinear signal processing using neural networks. *Conference on Neural Information Processing Systems - Natural and Synthetic, IEEE, November*.
- Laqui, W. (2008). *Predicción de caudales medios mensuales del río Huancané utilizando modelos de redes neuronales artificiales*. Tesis Mg. Lima, Pe.
- limon, P. d. (2003).
- Manabi Gobierno Provincial . (17 de 06 de 2014). *Portoviejo*. Obtenido de
<http://www.manabi.gob.ec/cantones/portoviejo>
- Méndez, M. C. (2009). *Modelización estadística con redes Neuronales. Aplicación a la Hidrología, Aerobiología y Modelización de procesos*. Tesis Doctoral Universidadn da Coruña.
- Mero, P. C. (12 de 06 de 2014). *Repositorio de la Escuela Superior Politecnica del Litoral* . Obtenido de Evaluación Y Zonificación De Riesgos Geodinámicos En El Distrito Minero De Zaruma Y Portovelo; publicación: 17-feb-2009:
<http://www.dspace.espol.edu.ec/handle/123456789/216>
- Mirosław, D., & Okruszko., T. (2011). *Modelling of Hydrological Processes in the Narew Catchment*. New York.
- Niel, H. (2003). *Study of parameter stability of a lumped hydrologic model in a context of climatic variability*. *Journal of Hydrology* 278(1-4): 213-230.
- Odom, & Sharda. (1990). A neural network model for bankruptcy prediction. *Proc.IJCNN International Joint Conference on Neural Networks.*, (págs. 163-168). San Diego.
- Oñate, F., Duque, E., León, P., Duque1, F., Duque, F., Rojas, W., & Tenesaca, F. (2011). *CARACTERIZACIÓN CLIMÁTICA, METEOROLÓGICA E HIDROLÓGICA DE LA CUENCA BINACIONAL CATAMAYO-CHIRA PREVIO A LA IMPLEMENTACIÓN DE LOS MODELOS SWAT Y WATEM/SEDEM CON FINES DE SU PLANIFICACIÓN TERRITORIAL*. Loja.

- Palmer. (1987). *Removing random noise from ekg signals using a back propagation network. Informal paper from Hecht-Nielsen Neurocomputer.*
- Raghunath, H. M. (2006). *Hydrology: Principles-Analysis-Design. 2 ed. New age publicación internacional. Nueva Delhi. 477 p.*
- Ramos, C., A. M., & Guerreo., P. (2004). *Modelo Hidrológico Distribuido de Generación de Caudales en Cuencas con escasa Información.* Lima, PE.
- RODRÍGUEZ, A. M. (s.f.). *Desarrollo de una interfaz gráfica de redes neuronales usando Matlab.* Madrid : UNIVERSIDAD CARLOS III MADRID.
- ROSANO, F. L. (2002). *FUNDAMENTOS DE REDES NEURONALES ARTIFICIALES.*
- Ruck. (1987). *Multisensor target detection and classification.* Air Force Institute of Technology, Computer Science Dept.
- Salas, J. (1993). *Analysis and Modeling of Hydrologic Time Series.* The McGraw Hill Handbook of Hydrology, Maidment.
- Samaniego, J. L. (2008). *Validación y Calibración de los Parámetros Hidrológicos del Polinomio Ecológico.* Loja.
- Serrano, A. J., Soria, E., & Martin, J. D. (11 de 06 de 2014). *Open Course Ware de la Universitat de València.* Obtenido de Open Course Ware de la Universitat de València: <http://ocw.uv.es/ingenieria-y-arquitectura/1-2/material-de-clase/>
- Silva, K. (2014). *Analisis Cuenca el Limon.* Loja.
- Silva, K. (2014). *Generacion de Informacion Base y Estudios de Relaciones Lluvia- Escorrentia en la Micro-Cuenca El Limon Zamora Chinchipe.* Loja.
- Silva, K. (2014). *Microcuenca El Limon.*
- SIRGH-CG. (09 de 11 de 2014). *Cuenca del Guayllabamba.* Obtenido de Sistema de Monitoreo para Evaluar la disposicion de agua y evaluar los impactos Asociados al Cambio Climatico: <http://www.infoagua-guayllabamba.ec/sirhcg/index.php/sirh-cg>
- Solomatine, D. (2002). *Data-driven modelling: machine learning and data mining in water related.*
- Sung, & Jones. (1990). A speech recognition system featuring neural network processing of global lexical features. *International Joint Conference on Neural Networks Washington*, (págs. 437-440).
- TAGEO.com. (17 de 06 de 2014). *Yageo.com.* Obtenido de Rio quijos: <http://www.tageo.com/index-e-ec-v-23-d-m1379261.htm>
- UAEM. (17 de 06 de 2014). *Centro de Recursos Idrisi.* Obtenido de Introducción a la modelación hidrológica utilizando el modelo distribuido CEQUEAU: <http://idrissi.uaemex.mx/index.php/esta-semana/nocion/lista-de-nociones/79-introduccion-a-la-modelacion-hidrologica-utilizando-el-modelo-distribuido-cequeau>

VILCA, W. F. (2008). *Aplicación de Redes Neuronales Artificiales a la Modelización y Previsión*. Perú.

Wang, & Yeh. (1990). Self adaptive neural architectures for control applications. *International Joint Conference on Neural Networks*, (págs. 309-314).

Wikipedia. (11 de 09 de 2014). *Zamora (Ecuador)*. Obtenido de [http://es.wikipedia.org/wiki/Zamora_\(Ecuador\)](http://es.wikipedia.org/wiki/Zamora_(Ecuador))

Wikipedia La enciclopedia libre. (12 de 06 de 2014). *Cantón Portovelo. (2014, 21 de febrero)*. Obtenido de Cantón Portovelo. (2014, 21 de febrero): http://es.wikipedia.org/w/index.php?title=Cant%C3%B3n_Portovelo&oldid=72712592.

Yoon. (1989). "A desktop neural network for dermatology diagnosis.