TESIS DE MAESTRÍA

TRÁNSITO DE CRECIENTES A TRAVÉS DE CANALES DE AGUAS LLUVIA UTILIZANDO REDES NEURONALES

PRESENTADO POR:
LAINER J. BOHÓRQUEZ MEZA

ASESOR:
JUAN GUILLERMO SALDARRIAGA VALDERRAMA

UNIVERSIDAD DE LOS ANDES
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA CIVIL Y AMBIENTAL
MAESTRÍA EN INGENIERÍA CIVIL
BOGOTÁ D.C.
AGOSTO DE 2015

AGRADECIMIENTOS

Agradezco a Dios primeramente por brindarme la oportunidad de iniciar y culminar esta importante etapa en mi vida profesional y personal, superando con éxito todos los obstáculos presentados.

A mi familia, en especial a mis padres Carmen Meza y Wilson Bohórquez y a mis hermanas que desde la distancia siempre me brindaron palabras de apoyo, ánimo y bendiciones.

A mi novia Lina Solano, doy gracias por animarme, apoyarme y comprenderme durante el tiempo que dediqué a la culminación de mis estudios.

También agradezco a todos mis compañeros de maestría, en especial a Adriana, Néstor e Iván con los cuales compartí momentos arduos de estudio y muchas alegrías.

Nunca consideres el estudio como una obligación, sino como una oportunidad para penetrar en el bello y maravilloso mundo del saber.

Albert Einstein

TABLA DE CONTENIDO

ÍNDICE DE FIGURAS

ÍNDICE DE TABLAS

ÍNDICE DE GRÁFICAS

1. INTRODUCCIÓN

La consecución de información de campo y el grado de certeza de está en el área de los Hidrosistemas o cualquier otra área de trabajo es uno de los problemas más comunes en el desarrollo de proyectos actualmente. Ante esta situación generalmente se recurre a métodos matemáticos y/o estadísticos que permitan estimar o simular las condiciones que un hidrosistema dado presenta en un momento determinado. Para el tránsito de crecientes en un canal de aguas lluvias, tema objeto de este estudio, entre las variables más difíciles de estimar con total certeza se encuentran los hidrogramas de entrada (Información base para el tránsito de crecientes), hidrogramas de salida y el coeficiente de rugosidad; ante esta situación muchas veces se recurre a la experiencia del diseñador para obtener la información requerida.

Existen en la actualidad diversos métodos matemáticos para estimar los parámetros desconocidos necesarios para el tránsito de una creciente. La Inteligencia Artificial o Algoritmos Genéticos hacen parte de una serie de instrumentos matemáticos y computacionales que debido al desarrollo logrado en el campo de la informática en los últimos años están ganando espacio en cuanto a su uso en la resolución de problemas en muchas áreas de estudio, puesto que permite simular situaciones ocurridas con antelación y definir una nueva condición dada en el presente. En el campo de la ingeniería, específicamente la Ingeniería Civil, esta herramienta de análisis tiene una gran aplicabilidad ya sea en el área de estructuras, geotecnia, hidrología e hidráulica, etc.

En lo que tiene que ver con el área de interés de esta investigación (hidrología e hidráulica), el uso de redes neuronales artificiales son de gran ayuda en los procesos de estimación o tránsito de caudales en una cuenca dada, pues como es sabido, a pesar de la existencia de diversos métodos para la estimación de caudales, la determinación de los parámetros requeridos por dichos métodos algunas veces se basa en la subjetividad del diseñador y en la experiencia que este ha adquirido a lo largo de su vida profesional. La metodología empleada para transformar la precipitación en escorrentía o caudal, se basa en etapas o niveles; el primero lo constituye la obtención de los datos de precipitación mediante registros históricos en la zona de interés, definidos como datos de entrada, el segundo nivel lo define la función de transferencia utilizada o etapa

donde se desarrollan los procesos matemáticos que toman los datos de entrada y mediante una secuencia de cálculos proporciona los datos de salida (nivel 3). La selección de una adecuada función de transferencia brinda resultados de mayor confianza mientras que con un método de menor soporte técnico y/o científico ocurre lo opuesto.

Debido a los inconvenientes mencionados la utilización de redes neuronales en la resolución de problemas en el campo de los hidrosistemas se abre paso como una opción o método alterno a los tradicionalmente empleados, pues su concepción o estructura puede ser sujeta a entrenamiento y así ser capaz de relacionar información histórica que servirá de base para adaptarla y obtener un resultado de mayor certeza en el problema que se esté considerando, posicionándolas como una alternativa de alto valor. Las redes neuronales artificiales utilizan una gran cantidad de información del hidrosistema en estudio, al igual que una variedad de parámetros para un eficiente proceso de cálculo, lo que es de gran ayuda cuando no es posible el uso de modelos físicos o cuando la información de trabajo es poca; en algunos casos estas pueden servir de complemento a la información existente. El mecanismo de solución o algoritmo de trabajo, es una secuencia que se va modificando y adaptando paso a paso hasta que la solución obtenida con la red neuronal sea lo más cercana a la solución esperada.

"Las redes neuronales artificiales –RNA– intentan ser una emulación inteligente del comportamiento de los sistemas biológicos, en donde los sistemas nerviosos se basan en la neurona como elemento fundamental. Actualmente, una RNA puede ser considerada como un modelo de "caja negra", es decir, un modelo en donde se tiene certeza de que es lo que se hace pero sin dar importancia a como lo hace. Entre las principales características de una RNA, cabe destacar que es un modelo con múltiples parámetros, capaz de reproducir complejas relaciones no lineales, cuyo proceso de calibración (entrenamiento) requiere de gran cantidad de información." (OBREGÓN, FRAGALA, & PRADA).

Algunas características para considerar una red neuronal como óptima son:

- Menos problemas de convergencia en el proceso de entrenamiento.
- Menor número de parámetros a ajustar.
- Menor número de ciclos de entrenamiento.
- Mejor respuesta en situaciones extremas.

"El aprendizaje en una red neuronal consiste en la determinación de los valores precisos de los pesos para todas sus conexiones; con los pesos ajustados la red podría modelar de forma acertada y eficiente un problema específico. El proceso general de aprendizaje consiste en ir agregando paulatinamente todos los ejemplos del conjunto de aprendizaje y modificar los pesos de las conexiones siguiendo un determinado esquema o algoritmo de aprendizaje. Los algoritmos que permiten refinar los pesos de la red, se basan por lo general en rutinas de gradientes que intentan recorrer un espacio de solución de la forma más eficiente para alcanzar el mínimo global en la superficie de la función de error. Dentro de estos métodos son conocidos los algoritmos de retropropagación, retropropagación con Momentum y los de búsqueda aleatoria. El algoritmo de aprendizaje de una red neuronal artificial es lo que determina el tipo de problemas que es capaz de resolver. La gran utilidad de las redes neuronales se debe a que son sistemas de aprendizaje basados en ejemplos." (MORALES V., 2004).

El tránsito de crecientes es un procedimiento para determinar valores de caudal y niveles en un tiempo determinado en una sección de un canal a partir de hidrogramas de entrada conocidos. Como herramientas de cálculo se utilizan la ecuación de continuidad y la ecuación de Momentum. El tránsito de crecientes en canales se basa en que se utiliza una serie de secciones y con estas se simula un canal de longitud "L", esto se hace por la dificultad de obtener la topología y/o topografía exacta del canal lo que indica que se tiene un conocimiento muy limitado de este, pues es posible que entre secciones simultáneas se presenten cambios abruptos de las condiciones topográficas e hidráulicas. Adicional a la estimación del trazado del canal se debe tratar de ajustar un coeficiente de rugosidad, que en este caso es el definido por la ecuación de Manning (n de Manning), dicho coeficiente debe involucrar los cambios de sección, de pendiente, de superficies y cualquier otra variable desconocida entre dos secciones. Todo este procedimiento se considera problemático debido a que la obtención en campo y la calibración de este valor es muy complicada y costosa a la vez. El objetivo del tránsito de crecientes es obtener un hidrograma aguas abajo del canal, dado un hidrograma de diseño aguas arriba. El hidrograma de diseño representa la variación del caudal en una sección determinada de un canal reflejando los efectos de la cuenca aportante aguas arriba de la sección considerada.

Teniendo en cuenta lo anteriormente expuesto, el objetivo de la investigación se basa en definir y entrenar una o varias redes neuronales mediante el uso de un software apropiado –MATLAB®– con la cual sea posible realizar el tránsito de crecientes a través de canales de aguas lluvias sin contar con las características geométricas e hidráulicas de este o de contar con la totalidad de parámetros hidráulicos, además de esto, analizar si la respuesta de las redes neuronales artificiales –ANN– es sensible a cambios en la pendiente de fondo y coeficiente de rugosidad de un canal determinado y estimar con buena precisión la creciente de salida como método alterno de cálculo a los tradicionalmente utilizados.

1.1 OBJETIVOS GENERALES

- Establecer el tipo de red neuronal y las características apropiadas de esta –arquitectura de la red– para realizar el tránsito de crecientes a través de canales de aguas lluvias con la ayuda del software MATLAB®.

- Realizar el Tránsito de crecientes a través de canales de aguas lluvia utilizando Redes Neuronales artificiales y determinar las ventajas y desventajas de este con relación a los métodos tradicionales.

1.2 OBJETIVOS ESPECIFICOS

- Recopilación de información sobre el uso de las redes neuronales artificiales para el tránsito de crecientes tanto a nivel local como a nivel global.

- Recopilación de información topográfica de canales para la simulación del tránsito de una creciente con redes neuronales artificiales.

- Definir las formas de los hidrogramas de entrada para la simulación de los casos de estudio con redes neuronales artificiales.

- Determinar el tipo de algoritmo de entrenamiento que se debe aplicar a las redes neuronales a partir del Caso de Estudio 1.

- Obtener una estimación del número de neuronas y/o capas ocultas adecuadas para las redes neuronales a partir del Caso de Estudio 1.
- Definir la función de desempeño que mejor evalué el comportamiento de los resultados obtenidos.
- Realizar el tránsito de una creciente con redes neuronales artificiales para todos los casos de estudio analizados.
- Realizar para los casos de estudio un análisis de costos y tiempo entre el tránsito de una creciente con redes neuronales artificiales y el tránsito con un método tradicional.

2. CONTEXTUALIZACIÓN Y MARCO TEÓRICO

2.1 REDES NEURONALES – MODELO BIOLOGICO

El cerebro está conformado por millones de elementos o unidades de procesamiento básicas interconectadas entre sí; estas unidades se denominan neuronas. En una neurona se pueden considerar tres partes básicas, el cuerpo celular, del que se desprende una rama principal denominada axón y las dendritas. La Figura 2.1 (www.histologiaub.blogspot.com) muestra las partes de una neurona biológica, además de las principales ya mencionadas.

De forma general, el funcionamiento de una neurona inicia a través de las dendritas, las cuales reciben señales de entrada y las conducen al cuerpo celular que se encarga de combinarlas e integrarlas para posteriormente emitir señales de salida. El axón transporta esas señales a los terminales axónicos, a partir de los cuales la información pasa a otras neuronas. Por lo general, una neurona recibe información de miles de otras neuronas, y a su vez envía información a miles de neuronas más.

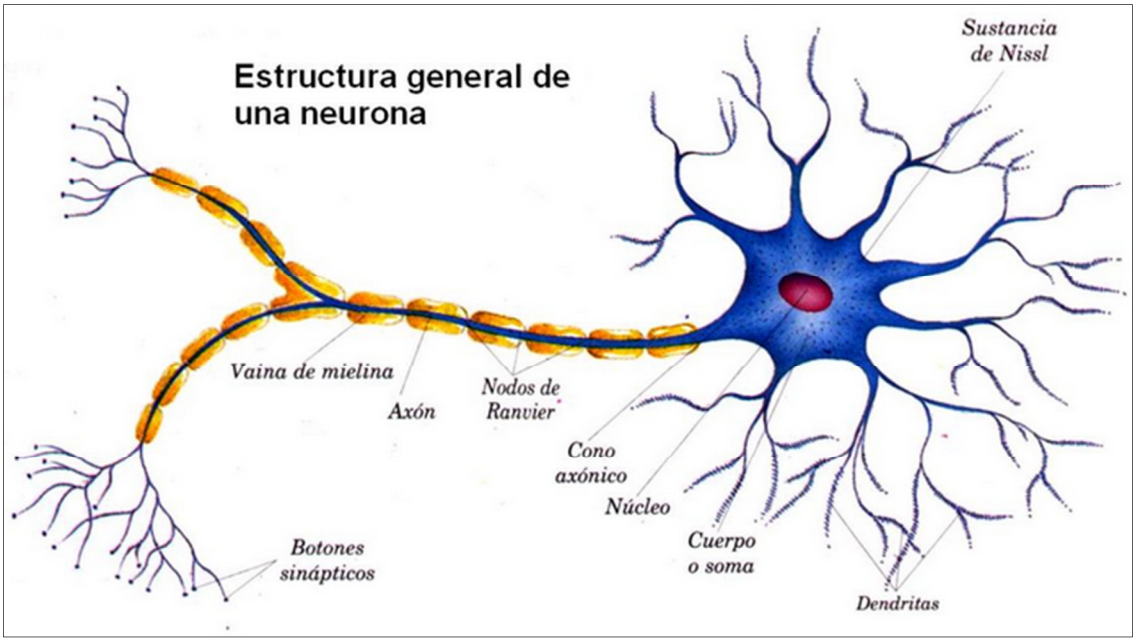

Figura 2.1. Esquema de una neurona biológica. Fuente: (www.histologiaub.blogspot.com).

2.1.1 Naturaleza bioeléctrica de la neurona

Las señales que permiten la comunicación entre neuronas, son de dos tipos distintos: eléctricas y químicas. La señal generada por la neurona y transportada a lo largo del axón es un impulso eléctrico, mientras que la señal que se transmite entre los terminales axónicos de una neurona y las dendritas de las neuronas siguientes es de origen químico y se realiza mediante moléculas de sustancias transmisoras (neurotransmisores) que fluyen a través de unos contactos especiales, llamados sinapsis, que tienen la función de receptor y están localizados entre los terminales axónicos y las dendritas de la neurona siguiente. La generación de las señales eléctricas está íntimamente relacionada con la composición de la membrana celular.

La llegada de señales procedentes de otras neuronas a través de las dendritas actúa acumulativamente, bajando ligeramente el valor del potencial de reposo. Dicho potencial modifica la permeabilidad de la membrana, de manera que cuando llega a cierto valor crítico comienza una entrada masiva de iones sodio que invierte la polaridad de la membrana. La inversión del voltaje de la cara interior de la membrana cierra el paso a los iones sodio y abre el paso a los iones potasio hasta que se restablece el equilibrio en reposo. Después de un periodo refractario, puede seguir un segundo impulso. El resultado de esto es la emisión por parte de la neurona de trenes de impulsos cuya frecuencia varía en función de la cantidad de neurotransmisores recibidos (HILERA & MARTÍNEZ, 2000).

2.1.2 Sinapsis

La interconexión entre dos neuronas se denomina Sinapsis (véase Figura 2.2). La sinapsis química es el tipo más común de interacción; en ésta una señal eléctrica llega al botón sináptico o parte terminal de la neurona izquierda (véase Figura 2.2) lo que origina que se liberen neurotransmisores, que son captados por la dendrita de la neurona de la derecha lo que causa un pulso eléctrico desde la neurona izquierda a la de la derecha. Según la cantidad de neurotransmisor liberada el pulso se reforzará o debilitará entre una y otra neurona, además de esto se debe tener en cuenta el hecho de que si la sumatoria de las entradas captadas por todas las dendritas de la neurona supera un determinado umbral, el pulso se transmite a lo largo del axón pero de no ser así este no se transmitirá a la siguiente neurona.

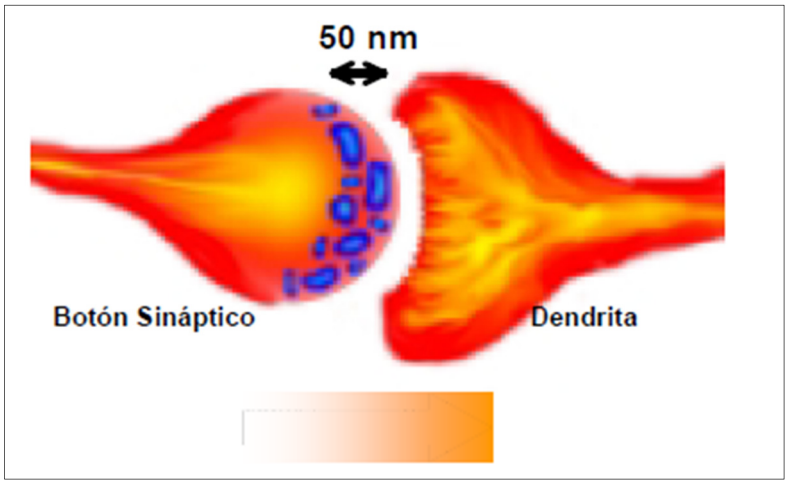

Figura 2.2. Salto sináptico. Fuente: (IZAURIETA & SAAVEDRA).

2.2 REDES NEURONALES ARTIFICIALES

Una red neuronal es un procesador paralelo de información que tiene una inclinación natural a almacenar conocimiento experimental y tenerlo a disposición en cualquier momento para su uso. Por otro lado, también se puede decir que, las redes neuronales artificiales son dispositivos de procesamiento de información no lineal (señales), construidos a partir de dispositivos elementales de procesamiento interconectados, llamados neuronas; el tipo más común de neurona artificial es la de McCulloch-Pitts. Una red neuronal artificial (RNA) o ANN por las siglas en inglés de "artificial neural network", es un instrumento de procesamiento de información inspirado en la forma como el cerebro procesa la información. Tal como ocurre en el cerebro de las personas o animales, las redes neuronales logran el aprendizaje a partir de ejemplos o mediante la repetición de un proceso; estas son configuradas para una aplicación específica, por ejemplo, reconocimiento de patrones, clasificación de información, funciones de ajuste o predicciones de series de tiempo dinámicas. El aprendizaje en sistemas biológicos involucra ajustes en las conexiones sinápticas que existen entre las neuronas. Este también es el caso de las redes neuronales artificiales pero aquí el ajuste se da en los pesos sinápticos de las conexiones entre una y otra neurona, dichas conexiones son utilizadas para almacenar el conocimiento adquirido por la red. Algunas características para determinar una RNA son:

- Arquitectura (conexión entre neuronas).

- Tipo de entrenamiento o aprendizaje (determinación del peso de las conexiones).
- Función de activación.

Las redes neuronales pueden ser definidas a nivel general como un algoritmo computacional parametrizado no lineal para procesamiento (numérico) de datos, señales o imágenes. En consecuencia las RNA son un sistema de procesamiento de información en donde las señales son transmitidas por medio de enlaces; estos poseen un peso asociado el cual es multiplicado por la señal de entrada para cualquier red neuronal típica. La señal de salida se obtiene aplicando una función de activación a la entrada de la red.

La Figura 2.3 muestra una ANN donde se indican cada uno de los parámetros enunciados anteriormente. En esta se tienen un número n de neuronas de entrada (x_1, x_2,…, x_n) y una neurona de salida (y_j), los pesos interconectados están dados por w_{i1} a w_{in}. En la Figura 2.3 varias entradas a la red son representadas por el símbolo matemático x_n y cada una de estas entradas es multiplicada por el peso respectivo de su conexión, w_{in}. En el caso más simple, este producto simplemente se suma a través de una función de transferencia (véase Numeral 2.5) y se genera así la salida y_j tal como se muestra en la figura.

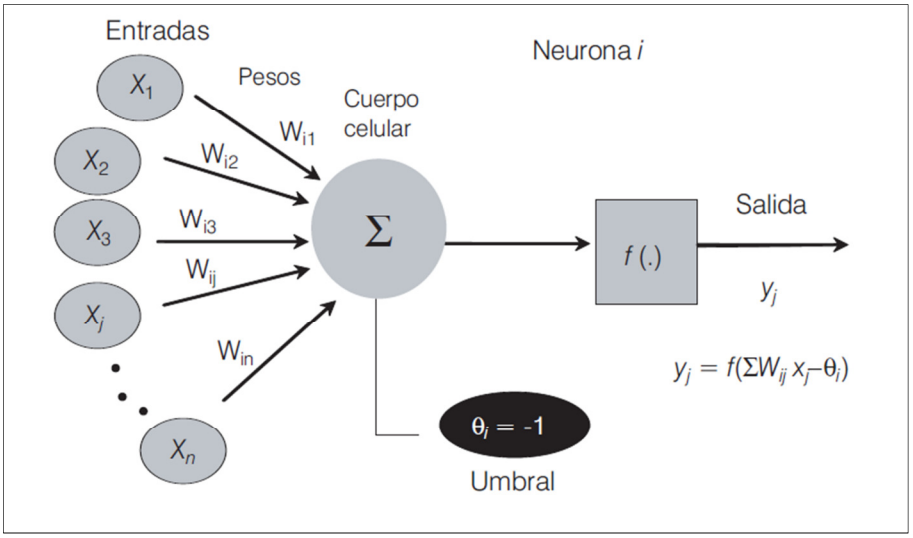

Figura 2.3. Red neuronal artificial simple. Fuente: (MOLINA AGUILAR & APARICIO, 2006).

2.3 DESARROLLO HISTÓRICO DE LAS REDES NEURONALES

De acuerdo con la fecha de aparición o publicación de la contribución realizada en este campo, el desarrollo histórico de las redes neuronales puede ser trazado cronológicamente de la siguiente forma según (SIVANANDAM, SUMATHI, & DEEPA, 2006).

- **1943 – McCulloch and Pitts: Inicio de la era moderna de las redes neuronales.**

  Estos establecen un cálculo lógico para las redes neuronales. Una red consta de un número suficiente de neuronas (usando un modelo simple), y estas, conectadas adecuadamente pueden calcular cualquier función computable. Una simple función lógica es desarrollada por una neurona, en el caso de la neurona de McCulloch-Pitts basada en el ajuste de los pesos de esta. El arreglo o disposición de neuronas en este caso puede ser representado como una combinación de funciones lógicas. La característica más importante de este tipo de neurona es el concepto de umbral; cuando la entrada a una neurona particular es más grande que el umbral especificado por el usuario entonces la neurona se activa. Circuitos lógicos son creados para usar de forma extensa este tipo de neurona.

- **1949 – El Libro de Hebb - "*The organization of behavior*".**

  En este libro fue presentada por primera vez una declaración explícita de una regla para el aprendizaje psicológico para modificación sináptica. Hebb propuso que la conectividad del cerebro está cambiando continuamente como un organismo que aprende diferentes tareas funcionales, y que los montajes neuronales son creados por tales cambios. El concepto detrás de la teoría de Hebb es que si dos neuronas son creadas para ser activadas simultáneamente, la fuerza de conexión entre las dos neuronas debería ser incrementada. Este concepto es similar al del aprendizaje de la matriz de correlación.

- **1958 – Rosenblatt introduce el concepto de Perceptrón.**

En una red perceptrón los pesos de las rutas de conexión pueden ser ajustados; un método iterativo para el ajuste de los pesos puede ser utilizado. La red Perceptrón está creada para converger si los pesos obtenidos le permiten reproducir exactamente todas las parejas de vectores de entradas y objetivos de salida en el entrenamiento.

- **1960 – Widrow and Hoff introducen el término ADALINE.**

  ADALINE, es la abreviatura para *adaptive linear neuron* (Neurona Lineal Adaptativa). Esta utiliza una regla de aprendizaje conocida como regla de los mínimos cuadrados o regla delta, creada para ajustar los pesos así como para reducir la diferencia entre la entrada a la red para la unidad de salida y la salida deseada. El criterio de convergencia en este caso es la reducción del valor del error cuadrado a un valor mínimo. Esta regla delta para una red de una sola capa puede ser denominada como la precursora de la red *backpropagation* utilizada para redes multicapas. La extensión multicapa de Adaline formó la Madaline.

- **1982 – La red de John Hopfield.**

  Hopfield mostró cómo usar "*Ising spin glass*", un tipo de modelo para almacenar información en redes dinámicamente estables. Su trabajo forjó el camino a los físicos para introducirse a la modelación neuronal y de este modo transformar el campo de las redes neuronales. Hay redes extensamente utilizadas como redes de memoria asociativa. Las redes Hopfield son creadas para ser valoradas como continua y discreta a la vez.

- **1972 – Mapas de autoorganización de Kohonen (*Self-Organizing Maps* - SOM).**

  Los mapas de auto-organización de Kohonen son capaces de reproducir aspectos importantes de la estructura de una red neuronal biológica. Ellos hacen uso de representación de datos utilizando mapas topográficos, los cuales son comunes en los sistemas nerviosos. Los SOM muestran como la capa de salida puede recuperar la estructura

correlacional (de la entrada) en forma del arreglo espacial de unidades. Estas redes son aplicadas en muchos problemas de reconocimiento.

- **1985 – Parker, 1986 – Lecum.**

  Durante este periodo la red de retropropagación (*backpropagation*) forjó su camino dentro de las redes neuronales. Este método reparte la información de error en la unidad de salida de nuevo a las unidades ocultas utilizando la regla delta generalizada. Esta red es básicamente una red multicapa, *feedforward* (alimentación hacia adelante) entrenada por medio del algoritmo *backpropagation* (retropropagación). Originalmente, aunque el trabajo fue desarrollado por Parker (1985) el crédito de publicar esta red es para Rumelhart, Hinton y Williams (1986). La red de retropropagación (*backpropagation*) surgió como el más popular algoritmo de aprendizaje para el entrenamiento de perceptrones multicapa y ha sido el caballo de batalla para muchas aplicaciones de redes neuronales.

- **1988 – Grossberg.**

  Grossberg desarrolló una regla de aprendizaje similar a la de Kohonen, la cual es ampliamente utilizada en la red *Counter propagation*. Este tipo de aprendizaje Grossberg, es también utilizado como aprendizaje *outstar* y se produce para todas las unidades en una capa particular.

- **1987, 1990 – Carpenter y Grossberg.**

  Carpenter y Grossberg inventaron la teoría de resonancia adaptativa (*Adaptive Resonance Theory* – ART). ART fue diseñada para entradas binarias y para entradas continuas. El diseño para las entradas binarias ART1 y ART2 entró en vigor cuando el diseño llegó a ser aplicable a las entradas continuas. La característica más importante de estas redes es que los patrones de entrada pueden ser presentados en cualquier orden.

- **1988 – Broomhead y Lowe desarrollaron las funciones de base radial (*Radial Basis Functions* – RBF).**

Esta es una red multicapa similar a la red de retropropagación (*backpropagation*).

- **1990 – Vapnik desarrollo la máquina de vector de soporte.**

  Las máquinas de vectores de soporte o SVM por las siglas en inglés de "*Support Vector Machine*" se basan en minimizar el riesgo estructural, a diferencia de las redes neuronales convencionales que utilizan el principio de minimizar el riesgo empírico. El fundamento de esta teoría se utiliza para aplicaciones como reconocimiento de imágenes y categorización de textos.

2.4 VENTAJAS DE LAS REDES NEURONALES

Según (HILERA & MARTÍNEZ, 2000) algunas ventajas de utilizar redes neuronales artificiales pueden ser:

"Debido a su constitución y fundamentos, las redes neuronales artifíciales (RNA) ofrecen numerosas ventajas entre las que se incluyen:

- *Aprendizaje adaptativo. Capacidad de aprender a realizar tareas basadas en un entrenamiento o experiencia inicial.*
- *Autoorganización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.*
- *Tolerancia a fallos. El daño parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un daño serio.*
- *Operación en tiempo real.*
- *Fácil inserción dentro de la tecnología existente.*

2.4.1 Aprendizaje adaptativo

Esto consiste en aprender a llevar a cabo ciertas tareas mediante un entrenamiento con ejemplos ilustrativos, por ello no es necesario elaborar modelos a priori ni es necesario especificar funciones de distribución de probabilidad.

Una red neuronal puede generar su propia distribución de pesos en los enlaces, esto mediante el aprendizaje; en éste, los enlaces ponderados de las neuronas (pesos sinápticos) se ajustan de manera que se obtengan unos resultados específicos. La función del diseñador es únicamente la obtención de la arquitectura apropiada para la red sin considerar la forma como esta aprenderá a discriminar, por lo que se deberá desarrollar un buen algoritmo de aprendizaje.

2.4.2 Autoorganización

Las redes neuronales usan su capacidad de aprendizaje adaptativo para autoorganizar la información que reciben durante el aprendizaje y/o la operación. Mientras que el aprendizaje es la modificación de cada elemento procesal, la autoorganización consiste en la modificación de la red neuronal completa para llevar a cabo un objetivo específico. Esta autoorganización provoca la generalización, la cual es una facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a las que no habían sido expuestas anteriormente. Esta característica es muy importante cuando se tienen que solucionar problemas en los cuales la información de entrada es poco clara, ya que permite que el sistema de una solución incluso cuando la información de entrada está incompleta.

2.4.3 Tolerancia a fallos

Las redes neuronales son los primeros métodos computacionales con la capacidad inherente de tolerancia a fallos. En las redes neuronales, si se produce un fallo en un pequeño número de neuronas, aunque el comportamiento del sistema se ve influenciado este no sufre una falla repentina. Hay dos aspectos distintos respecto a la tolerancia a fallos:

- *Tolerancia a fallo según los datos; las redes pueden aprender a reconocer patrones con ruido, distorsionados o incompletos.*
- *Pueden seguir realizando su función aunque se destruya parte de la red.*

La razón por la que las redes neuronales son tolerantes a los fallos es que tienen su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento. La mayoría de los ordenadores algorítmicos y sistemas de recuperación de datos almacenan cada pieza de información en un espacio único, localizado y direccionable. Las redes neuronales almacenan información no localizada, por lo tanto, la mayoría de las

interconexiones entre los nodos de la red tendrán unos valores en función de los estímulos recibidos, y se generará un patrón de salida que represente la información almacenada.

2.4.4 Operación en tiempo real

Una de las mayores prioridades de la mayoría de las áreas de aplicación es la necesidad de realizar grandes procesos con datos de forma muy rápida. Las redes neuronales se adaptan bien a esto debido a su implementación paralela. Para que la mayoría de las redes puedan operar en un entorno de tiempo real, la necesidad de cambio en los pesos de las conexiones o entrenamiento es mínima. Por tanto, de todos los métodos posibles, las redes neuronales son la mejor alternativa para reconocimiento y clasificación de patrones en tiempo real.

2.4.5 Fácil inserción dentro de la tecnología existente

Una red individual puede ser entrenada para desarrollar una única y bien definida tarea. Debido a que una red puede ser rápidamente entrenada, comprobada, verificada y trasladada a un hardware de bajo costo, es fácil insertar redes neuronales para aplicaciones específicas dentro de sistemas existentes. De esta manera, las redes neuronales se pueden utilizar para mejorar sistemas de forma incremental, y cada paso puede ser evaluado antes de acometer un desarrollo más amplio".

2.5 ELEMENTOS DE UNA RED NEURONAL ARTIFICIAL

Una correcta elección de las características y una adecuada estructura son los pilares fundamentales para construir una red neuronal que le dé solución al problema que se quiere resolver. Cualquier modelo de red neuronal está conformado por neuronas, a partir de las cuales se pueden generar representaciones específicas como letras, números o cualquier otro objeto. Cada neurona de una red está caracterizada en cualquier instante de tiempo por un valor numérico denominado valor o estado de activación, $a_i\ (t)$, al cual está asociado una función de salida,f_i, que transforma el estado de activación en ese instante en una señal de salida, y_i, la cual esta afecta por la sinapsis o peso sináptico, w_{ij}, de la conexión entre la neurona de entrada y la neurona de salida. La sumatoria de las señales que llegan a una neurona j, Net_j, se puede expresar matemáticamente como lo indica la Ecuación 1.

$$Net_j = \sum_{i=1}^{n} y_i \, w_{ij} \qquad \textbf{Ecuación 1.}$$

Una función de activación, F, determina el nuevo estado de activación $a_i\,(t+1)$ de la neurona, teniendo en cuenta la entrada total calculada y el anterior estado de activación $a_i\,(t)$. Las variables anteriormente mencionadas se muestran esquemáticamente en la Figura 2.3.

(HILERA & MARTÍNEZ, 2000), estructuran y definen los componentes más importantes de una red neuronal artificial como sigue:

- Unidad de procesamiento (Neurona artificial)
- Estado de activación de cada neurona
- Conexiones entre neuronas
- Función de salida o transferencia
- Función o Regla de activación
- Regla de aprendizaje.

2.5.1 Unidades de Proceso - Neurona Artificial

El conjunto de neuronas cuyas entradas provienen de la misma fuente y cuyas salidas se dirigen al mismo destino se conoce como capa o nivel. Si se tienen N neuronas o unidades, estas se pueden ordenar arbitrariamente y designar la *i*-ésima neurona como U_i. Su trabajo es simple y único, y consiste en recibir las entradas de las células vecinas y calcular un valor de salida, el cual es enviado a todas las células restantes.

En cualquier sistema modelado, se pueden caracterizar tres tipos de unidades o capas: entradas, salidas y ocultas. Las unidades de entrada reciben señales desde el entorno; dichas entradas pueden ser señales provenientes de sensores o de otros sectores del sistema. Las unidades de salida son las encargadas de enviar la señal fuera del sistema y las unidades ocultas son aquellas cuyas entradas y salidas se encuentran dentro del sistema, es decir, no tienen contacto con el exterior.

2.5.2 Estado de Activación

Adicionalmente al conjunto de neuronas, la representación de la red neuronal necesita los estados del sistema en un tiempo t. Esto se especifica por un vector de N números reales $A(t)$, que representan el estado de activación del conjunto de unidades de procesamiento (Véase Ecuación 2). Cada elemento del vector representa la activación de una neurona en el tiempo t. La activación de una neurona U_i en el tiempo t se designa por $a(t)$, es decir:

$$A(t) = (a_1(t), a_2(t), \dots, a_i(t), \dots, a_N(t)) \qquad \textbf{Ecuación 2}.$$

Todas las neuronas que componen la red se hallan en cierto estado de activación, este puede ser reposo o excitado y a cada uno de ellos se le asigna un valor. Dichos valores de activación pueden ser continuos o discretos o también limitados o ilimitados. Si son discretos suelen tomar valores pequeños o binarios. El estado activo se caracteriza por la emisión de un impulso por parte de la neurona, mientas que el estado pasivo indica que la neurona está en reposo. Para determinar el estado de activación de una neurona se deben considerar dos factores: el mecanismo de interacción entre neuronas y la señal que envía cada una a las neuronas vecinas.

2.5.3 Conexiones entre neuronas

Las conexiones que unen a las neuronas que forman una RNA tienen asociado un peso (w), que es el que hace que la red adquiera conocimiento. Considerando $\mathrm{y_i}$ como el valor de salida de la neurona i en un instante dado y que cada conexión (sinapsis) entre la neurona i y la neurona j está definida por un peso $\mathrm{w_{ij}}$, se tiene que la entrada neta que recibe una neurona $\mathrm{Net_j}$ es la suma del producto de cada señal individual por el valor de la sinapsis que conecta ambas neuronas, esto se conoce como regla de propagación (Véase Ecuación 3).

$$Net_j = \sum_{i}^{N} w_{ij} \, . \, y_i \qquad \textbf{Ecuación 3}.$$

Si $\mathrm{w_{ij}}$ es positivo indica que la interacción entre las neuronas i y j es excitadora, es decir, siempre que la neurona i este activada, la neurona j recibirá una señal

de i que tenderá a activarla. Si w_{ij} es negativo, la sinapsis será inhibidora. En este caso, si i esta activada, enviará una señal a j que tenderá a desactivarla. Por último, si w_{ij} es igual a 0, se considera que no hay conexión entre ambas.

2.5.4 Función de Salida o Transferencia

Entre las unidades o neuronas que forman una ANN existe un conjunto de conexiones que unen unas a otras. Cada neurona transmite señales a aquellas que están conectadas con su salida. Asociada con cada neurona 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 $y_i(t)$ (véase Ecuación 4).

$$Y_i(t) = f_i\ (a_i(t)) \qquad \textbf{Ecuación 4}.$$

El vector que contiene las salidas de todas las neuronas en un instante t se puede definir como lo muestra la Ecuación 5.

$$Y\ (t) = \left(f_1\ (a_1\ (t)), f_2\ (a_2\ (t)), \dots, f_i(a_i\ (t)), \dots, f_N\ (a_N\ (t))\right) \qquad \textbf{Ecuación 5}.$$

En algunos modelos, esta salida es igual al nivel de activación de la neurona, en cuyo caso la función f_i es la función identidad, $f_i(a_i(t)) = a_i(t)$. Existen cuatro tipos de funciones de transferencia, aunque generalmente la función de salida o de transferencia es de tipo sigmoidal.

- Función escalón
- Función lineal y mixta
- Función sigmoidal
- Función gaussiana

Función Escalón. Esta se utiliza cuando las salidas de la red son binarias. La salida de una neurona se activa solo cuando el estado de activación es mayor o igual a cierto valor umbral. La función escalón no puede definir la derivada en un punto de transición, razón por la que esta no es muy útil a los métodos de aprendizaje donde se utilizan derivadas. Las redes formadas por este tipo de neuronas son fáciles de implementar en *hardware* (véase Figura 2.4).

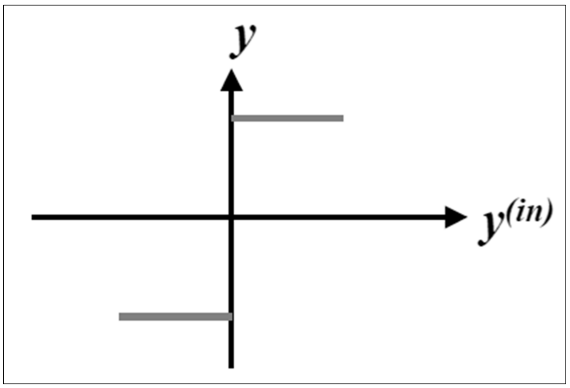

Figura 2.4. Función de Transferencia tipo escalón. Fuente: (IZAURIETA & SAAVEDRA).

Función lineal y mixta. Esta responde a la expresión f(x)=x. En las neuronas con función mixta, si la suma de las señales de entrada es menor a 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 las entradas está comprendida entre ambos límites entonces la activación se define como una función lineal de la suma de las señales de entrada (véase Figura 2.5).

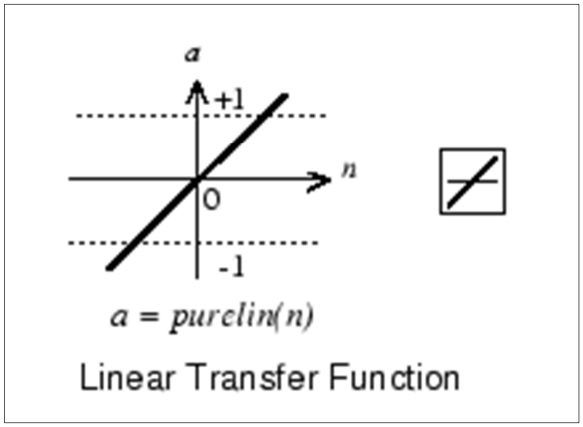

Figura 2.5. Función de transferencia lineal (Fuente: *Toolbox* MATLAB®).

Función Continua o Sigmoidal. Con la función sigmoidal, para la mayoría de los valores de entrada, el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace que en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoide. Cuando la pendiente es elevada esta función tiende a la función escalón. La importancia de la función sigmoidal radica en el hecho de que su derivada es siempre positiva y cercana a cero para valores grandes positivos o negativos y toma su valor máximo cuando x es igual a 0 (véase Figura 2.6).

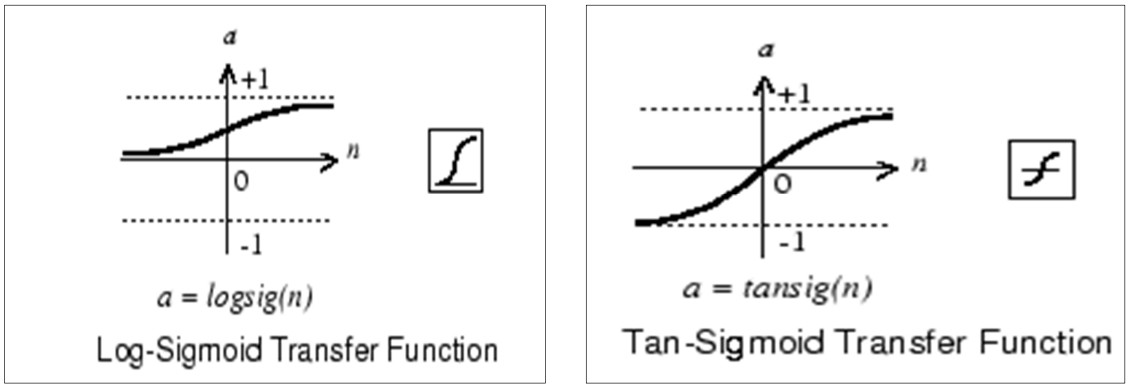

Figura 2.6. Función de transferencia sigmoidal (Fuente: *Toolbox* MATLAB®).

Las funciones logsig y tansig calcula la salida de una capa a partir de su entrada a la red y retorna elementos entre 0 y 1 y entre 1 y -1 respectivamente.

Función Gaussiana. Los centros y alto de estas funciones pueden ser adaptados, lo cual las hace más adaptativas que las funciones sigmoidales. Mapeos que suelen requerir dos capas ocultas utilizando la función sigmoidal, algunas veces se pueden realizar con una sola capa en redes con neuronas de función gaussiana (véase Figura 2.7).

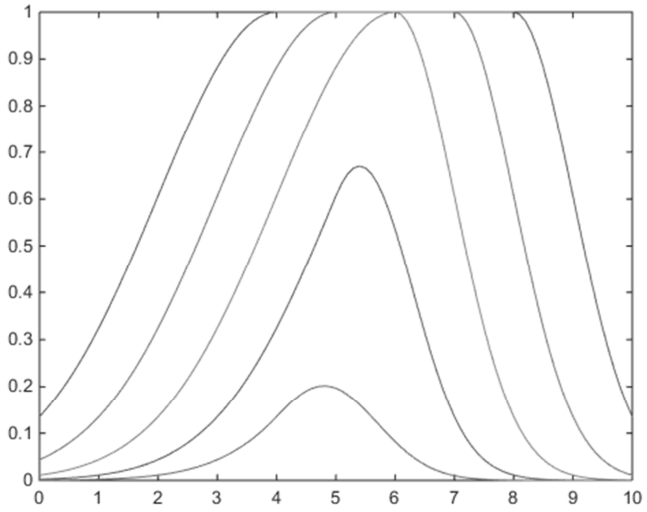

Figura 2.7. Función de transferencia Gaussiana (Fuente: *Toolbox* MATLAB®).

En la Tabla 2.1 se muestran las funciones de transferencia mencionadas, la ecuación que la representa y el rango de valores de aplicación.

Nombre	Función	Rango
Escalón	$y = \text{sign}(x)$	[–1, +1]
	$y = H(x)$	[0, +1]
Lineal	$y = x$	[–∞, +∞]
Sigmoidal	$y = \frac{1}{1+e^{-x}}$	[0, +1]
	$y = tgh(x)$	[–1, +1]
Gaussiana	$y = Ae^{-Bx}$	[0, +1]

Tabla 2.1 Funciones de transferencia y rango de aplicación. Fuente: (MOLINA AGUILAR & APARICIO, 2006).

2.5.5 Función o Regla de Activación

Así como es necesaria una regla que combine las entradas a una neurona con los pesos de las conexiones, también se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función que se podría denominar, 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 obtiene aplicando la llamada función de activación, como se muestra en la Ecuación 6.

$$a_i\,(t+1) = F\,(a_i\,(t),\ \ Net_i) \qquad \textbf{Ecuación 6}.$$

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. La salida de una neurona *i* (y_i) se puede expresar como lo indica la Ecuación 7.

$$y_i\,(t+1) = f\,(Net_i) = f\left(\sum_{j=1}^{N} w_{ij}\ .\ y_i\,(t)\right) \qquad \textbf{Ecuación 7}.$$

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 lo cual no es igual en todas. Este valor se denota como θ_i, y representa el umbral de activación de la neurona i. De acuerdo con lo anterior la salida de la neurona para esta situación se puede reescribir como lo indica la Ecuación 8.

$$y_i\,(t+1) = f\,(Net_i - \theta_i) = f\left(\sum_{j=1}^{N} w_{ij}\ .\ y_i\,(t) - \theta_i\right) \qquad \textbf{Ecuación 8}.$$

La salida que se obtiene en una neurona considerando el tipo de función de activación utilizada puede tomar múltiples valores como se muestra a continuación para cada una de las funciones de activación.

- **Función de activación tipo escalón**. Si el conjunto de los estados de activación es E = [0, 1], se tiene que la salida para un tiempo t+1 puede ser:

$$y_i\,(t+1) = \begin{vmatrix} 1 & si\ [Net_i > \theta_i] \\ y\,(t) & si\ [Net_i = \theta_i] \\ 0 & si\ [Net_i < \theta_i] \end{vmatrix}$$

  Si el conjunto de los estados de activación es E = [-1, 1], se tiene que:

$$y_i\,(t+1) = \begin{vmatrix} +1 & si\ [Net_i > \theta_i] \\ y\,(t) & si\ [Net_i = \theta_i] \\ -1 & si\ [Net_i < \theta_i] \end{vmatrix}$$

- **Función de activación lineal o identidad**. En esta el conjunto de estados E puede contener cualquier número real (véase Ecuación 9).

$$y_i\,(t+1) = Net_i - \theta_i \qquad \textbf{Ecuación 9}.$$

- **Función de activación lineal-mixta**. Con esta función, el estado de activación de la neurona está obligado a permanecer dentro de un intervalo de valores reales prefijados como se muestra a continuación:

$$y_i\,(t+1) = \begin{vmatrix} b & Net_i \leq\ b + \theta_i \\ Net_i - \ \theta_i & b + \theta_i \ <\ Net_i \ <\ B + \ \theta_i \\ B & Net_i \geq\ B \end{vmatrix}$$

- **Función de activación sigmoidal.** Esta es una función continua, por lo que el espacio de los estados de activación es un intervalo del eje central (véase Ecuación 10).

$$y_i\,(t+1) = \frac{1}{(1 + \ e^{-(Net_i - \ \theta_i)})} \qquad \textbf{Ecuación 10}.$$

Para simplificar la expresión de la salida de una neurona se puede considerar una neurona ficticia con valor de salida 1 y peso $-\theta_i$ para la conexión con la neurona de entrada. De acuerdo con esta premisa la salida se puede expresar como lo indica la Ecuación 11.

$$y_i\,(t+1) = f\left(\sum_{j=1}^{N} w_{ij}\ .\ y_j\,(t) - \ \theta_i * 1\right) = f\left(\sum_{j=0}^{N} w_{ij}\ .\ y_j\,(t) \ = \ f\,(Net_i)\right) \qquad \textbf{Ecuación 11}.$$

2.5.6 Regla de Aprendizaje

El aprendizaje se puede definir como la modificación del comportamiento inducido por la interacción con el entorno y como resultado de la experiencia conducente al establecimiento de nuevos modelos de respuesta a estímulos externos. Cada modelo de red neuronal dispone de una o varias técnicas de aprendizaje y este depende del número de neuronas y de cómo estén conectadas entre sí.

2.6 CARACTERÍSTICAS DE LAS REDES NEURONALES

Según (HILERA & MARTÍNEZ, 2000), existen tres aspectos que caracterizan una red neuronal, estos son:

- La topología
- El mecanismo de aprendizaje
- Tipo de asociación realizada entre la información de entrada y salida

2.6.1 Topología de la Red Neuronal

Esta se refiere a la organización y disposición de las neuronas en la red formando capas. Los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexión entre neuronas. Según la topología se pueden tener redes de una capa o monocapa y redes con múltiples capas o multicapas.

Las redes monocapa se utilizan generalmente para obtener o completar información cuando esta se tiene incompleta o distorsionada. Las redes multicapa son aquellas que disponen de conjuntos de neuronas agrupados en varios niveles o capas. Estas redes pueden ser de los siguientes tipos:

- *Feedforward* o con conexiones hacia adelante. Las redes más conocidas de este tipo son: Perceptrón, *Adaline. Madaline, Linear Adaptative Memory (LAM), Drive_Reinforcement, Backpropagation*. Todas estas son muy útiles en aplicaciones de reconocimiento o clasificación de parones.
- *Feedback* o con conexión hacia atrás.
- Además de estas dos también se tienen redes que disponen de conexiones tanto hacia adelante como hacia atrás o redes *feedforward/feedback*. Los modelos más conocidos de este tipo son: La red ART (*Adaptative Resonance Theory*) y la red BAM (*Bidirectional Associative Memory*). Dentro de este grupo se pueden incluir la red Neocognitron en la que las neuronas se disponen en planos superpuestos y la red CABAM (*Competitive Adaptative Bidirectional Associative Memory*) que es un tipo de red con conexiones laterales entre neuronas de la misma capa.

2.6.2 Mecanismo de Aprendizaje

Este es el proceso por el cual una red neuronal modifica sus pesos en respuesta a la información de entrada. En un modelo de red neuronal artificial, la creación de una nueva conexión implica que el peso de esta pasa a tener un valor distinto de cero, en caso contrario la conexión se destruye. Durante el proceso de aprendizaje, los pesos de las conexiones de la red sufren modificaciones; bajo esta premisa cuando los pesos permanecen estables entre iteraciones sucesivas se puede afirmar que el proceso ha terminado o que la red ha aprendido.

Considerando la presencia o no de un agente externo que controle el proceso de aprendizaje, las redes neuronales se pueden clasificar como:

- Redes con aprendizaje supervisado
- Rede con aprendizaje no supervisado
- Redes con aprendizaje híbrido
- Redes con aprendizaje reforzado

Redes con aprendizaje supervisado. Se caracterizan por que el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo que determina la respuesta que debería generar la red a partir de una entrada determinada. Para este tipo de aprendizaje se consideran tres formas de llevarlo a cabo:

- Aprendizaje por corrección de error. Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los valores obtenidos en la salida de la red. La Ecuación 12 ilustra este proceso:

$$\Delta w_{ij} = \propto y_i \left(d_j - y_j\right) \qquad \textbf{Ecuación 12}.$$

siendo,
Δw_{ij} = Variación en el peso de la conexión entre las neuronas i y j

$$\left(\Delta w_{ij} = w_{ij}^{actual} - w_{ij}^{anterior}\right)$$

y_i = Valor de salida de la neurona i
d_j = Valor de salida deseado para la neurona j
y_j = Valor de salida obtenido en la neurona j
$\propto$ = Factor de aprendizaje ($0 < \propto \leq 1$) que regula la velocidad con que este se realiza.

Una limitación de este tipo de algoritmo es que no considera la magnitud del error global cometido durante el proceso de aprendizaje, pues solo tiene en cuenta el error individual. La regla de aprendizaje del perceptrón es un ejemplo de este tipo.

Un algoritmo con mayor rango de aplicabilidad y mucho más rápido, es el desarrollado por Widrof y Hoff, conocido como Regla Delta, en este se considera el error global para así determinar la variación del peso. La Ecuación 13 define la forma de cálculo del error global, mientras que la Ecuación 14 muestra como calcular la variación en el peso de las conexiones.

$$Error_{global} = \frac{1}{2P} \sum_{k=1}^{P} \sum_{j=1}^{N} \left(y_j^{(k)} - d_j^{(k)} \right)^2 \qquad \textbf{Ecuación 13}.$$

siendo,

N = Numero de neuronas de salida

P = Numero de datos de la Información que debe aprender la red

$\frac{1}{2} \sum_{j=1}^{N} \left(y_j^{(k)} - d_j^{(k)} \right)^2$ = Error cometido en el aprendizaje de la información k-ésima.

$$\Delta w_{ij} = k \frac{\partial \, Error_{global}}{\partial \, w_{ij}} \qquad \textbf{Ecuación 14}.$$

Aplicando la Ecuación 13 y la Ecuación 14 se obtiene un conjunto de pesos con los que se consigue minimizar el error. El algoritmo de la Regla Delta Generalizada, es una modificación de este para poderlo aplicar a redes con capas de entrada, oculta y de salida.

- Aprendizaje por refuerzo. Este es más lento que el aprendizaje por corrección de errores, y se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, de no indicar durante el entrenamiento exactamente la salida que se desea que proporcione la red ante una determinada entrada. Ejemplos de este tipo de algoritmos son el denominado *Linear Reward Penalty* o Lr-p (Algoritmo lineal con recompensa y penalización) y el conocido como *Adaptive Heuristic Critic*, que se utiliza en redes *feedforward* de tres capas especialmente diseñadas.

- Aprendizaje estocástico. Este consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad. La red conocida como Boltzmann *Machine* utiliza este tipo de aprendizaje y lo combina con el aprendizaje Hebbiano o con el aprendizaje por corrección de error. El procedimiento de utilizar ruido y combinarlo con asignación probabilística mediante capas ocultas, es lo que se conoce como aprendizaje estocástico.

Redes con aprendizaje no supervisado. Estas no reciben ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta, por lo que se dice que este tipo de redes se pueden autoorganizar. En cuanto a los algoritmos de aprendizaje no supervisado, en general se suelen considerar dos tipos, los cuales dan lugar a los siguientes aprendizajes: el aprendizaje Hebbiano y el aprendizaje competitivo o cooperativo.

- Aprendizaje Hebbiano. El aprendizaje Hebbiano consiste básicamente en el ajuste de los pesos de las conexiones de acuerdo con la correlación de los valores de activación (Salidas) de las dos neuronas conectadas, como se muestra en la Ecuación 15.

$$\Delta w_{ij} = y_i \, . \, y_j \qquad \textbf{Ecuación 15}.$$

  De la Ecuación 15, se tiene que si las dos unidades son activas (Positivas), se produce un reforzamiento de la conexión, pero cuando una es activa y la otra pasiva (Negativa), se produce un debilitamiento de la conexión.

- Aprendizaje competitivo y cooperativo; este suele orientarse hacia la clasificación de los datos de entrada. Con este tipo de aprendizaje se pretende que cuando se presente a la red cierta información de entrada, solo una de las neuronas de salida de la red, o una por cierto grupo de neuronas, se active. En este tipo de redes, cada neurona tiene asignado un peso total, que equivale a la suma de todos los pesos de las conexiones que tiene a su entrada.

Redes con aprendizaje híbrido. Para este tipo de aprendizaje unas capas de la red tienen un aprendizaje supervisado y otras capas de la red tienen un aprendizaje no supervisado.

Redes con aprendizaje forzado. Es un aprendizaje con características del supervisado y con características del autoorganizado, diferenciándose del híbrido en que en este solo se proporciona un porcentaje de error que debe cumplirse al no indicarle la salida deseada.

2.6.3 Tipo de asociación entre la información de entrada y salida

Existen dos formas primarias de realizar la asociación entre la información de entrada y salida según la naturaleza de la información almacenada en la red.

La primera se denomina heteroasociación, que se refiere al caso en el que la red aprende parejas de datos (A_1, B_1), (A_2, B_2)… (A_n, B_n), de tal forma que cuando se presenta cierta información de entrada A_i, deberá responder generando la correspondiente salida asociada B_i. En cuanto a su conectividad, existen redes heteroasociativas con conexiones hacia adelante o *feedforward*, redes con conexión hacia atrás *feedforward*/*feedback*, redes con conexiones laterales y redes con capas multidimensionales como la Neocognitron. El aprendizaje de este tipo de red puede ser con supervisión o sin supervisión.

La segunda forma se conoce como autoasociación, donde la red aprende cierta información A_1, A_2,…, A_n, de tal forma que cuando se le presenta una información de entrada realizara una autocorrelación, respondiendo con uno de los datos almacenados más parecido al de entrada. Estas redes suelen utilizarse en tareas de filtrado de información para la reconstrucción de datos, eliminando distorsiones o ruido; también se utilizan para facilitar la búsqueda por contenido en bases de datos y para resolver problemas de optimización.

3. MANEJO DE LA HERRAMIENTA DE SIMULACIÓN – MATLAB®

En este capítulo se describe paso a paso la forma como se realiza el montaje y simulación de una red neuronal artificial. La totalidad de la información aquí resumida se extrajo de las ayudas y tutoriales proporcionados por el *software* de diseño (MATLAB®) con la finalidad de que cualquiera pueda reproducir lo aquí desarrollado.

En la actualidad existen diversos mecanismos y lenguajes de programación para realzar el montaje y simulación de un determinado caso de estudio utilizando redes neuronales artificiales (RNA). En esta investigación, se utilizará la herramienta de redes neuronales artificiales que proporciona el software MATLAB® en su versión R2012b, pues este presenta una interfaz de manejo de fácil comprensión para el usuario y de interacción amigable.

El *toolbox* de redes neuronales artificiales en MATLAB® ofrece funciones y aplicaciones para modelar complejos sistemas no lineales que no son fáciles de representar con una ecuación; también permite realizar aprendizaje supervisado con redes de alimentación hacia adelante (*feedforward*), redes de base radial (*radial basis*), y redes dinámicas. Con las herramientas del *toolbox* se puede diseñar, entrenar, visualizar y simular redes neuronales; además se puede utilizar para aplicaciones tales como ajuste de datos, reconocimiento de patrones, predicción de series de tiempo y modelado y control de sistemas dinámicos.

3.1 USO DEL TOOLBOX EN MATLAB®

Hay cuatro formas de utilizar el *toolbox* de redes neuronales artificiales ofrecido por MATLAB®.

- La primera forma es a través de una de las cuatro interfaces gráficas de usuario o GUI, por las siglas en inglés de *Graphical User Interfaces*. También se pueden abrir estas GUIs desde una interfaz gráfica de usuario principal, con el comando **nnstart**. Estas proporcionan una manera rápida y fácil para acceder a los beneficios del *toolbox* para las siguientes tareas:
  - *Fitting function* (Función de ajuste)
  - *Pattern recognition* (Reconocimiento de patrones)
  - *Data clustering* (Agrupación de datos)
  - *Time series analysis* (Análisis de series de tiempo)

En la Figura 3.1 se muestra la forma como se presenta la interfaz gráfica para esta versión del software, utilizando el comando **nnstart**.

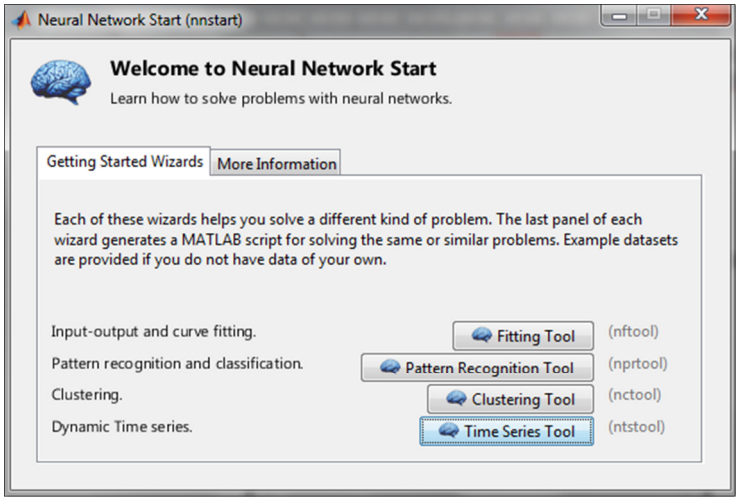

Figura 3.1. Acceso principal a la herramienta de redes neuronales (Fuente: *Toolbox* MATLAB®).

En esta investigación para la simulación de las redes neuronales artificiales se utilizará el análisis de series de tiempo dinámicas (Opción resaltada en color azul); por esta razón se enfatizará solo en el montaje de las redes neuronales a través de esta opción.

- La segunda manera de utilizar el *toolbox* es a través de las operaciones básicas de la línea de comandos, estas ofrecen más flexibilidad que la interfaz gráfica de usuario, pero con algo de complejidad añadida. La GUI puede generar *scripts* de código MATLAB® para crear funciones personalizadas.

- La tercera forma de utilizar el *toolbox* es a través de la personalización. Esta capacidad permite crear redes neuronales propias, sin dejar de tener acceso a todas las funciones del *toolbox*. Se puede crear además redes con conexiones arbitrarias, y todavía será capaz de entrenarlas utilizando las funciones de entrenamiento existentes en la herramienta.

- La cuarta forma de utilizar el *toolbox* es a través de la capacidad de modificar cualquiera de las funciones contenidas en este. Cada componente computacional es escrito en código MATLAB® y es totalmente accesible.

3.2 SERIES DE TIEMPO DINÁMICAS

Las redes neuronales dinámicas son buenas para la predicción de series de tiempo. Como se mencionó anteriormente, este tipo de problemas se pueden resolver de dos formas:

1. Utilizando la interfaz gráfica del usuario (GUI), con el comando **ntstool**, la cual despliega la ventana mostrada en la Figura 3.1.
2. Utilizando las funciones de la línea de comando.

La guía de análisis ofrecida por MATLAB® sugiere que generalmente es mejor empezar con la interfaz gráfica, y luego utilizar la GUI para generar automáticamente *scripts* para la línea de comandos; este consejo se consideró para el desarrollo y personalización de las RNA analizadas en la investigación.

3.2.1 Definición del problema

Para definir un problema de series de tiempo del *toolbox*, se debe organizar un conjunto de vectores de entrada TS como columnas en una matriz de celdas. A continuación, organizar otro conjunto de vectores objetivo TS (los vectores de salida correctos para cada uno de los vectores de entrada) en una segunda matriz de celdas. Sin embargo, hay casos en los que sólo se necesita un conjunto de datos objetivo. La forma de organizar los datos es como sigue:

targets = {1 2 3 4 5};

3.2.2 Estructuras de datos

En esta se hace referencia a cómo el formato de la estructura de los datos de entrada afecta la simulación de redes. Se inicia con redes estáticas, y luego se continúa con redes dinámicas. Hay dos tipos básicos de vectores de entrada: los que se producen simultáneamente (al mismo tiempo, o en ninguna secuencia de tiempo particular), y los que se producen secuencialmente en el tiempo. Para los vectores concurrentes, el orden no es importante, y si hay un número de redes que funcionan en paralelo, se podría presentar un vector de entrada para cada una de las redes. Para los vectores secuenciales, el orden en que aparecen los vectores es importante.

3.3 USO DE LA INTERFAZ GRÁFICA PARA SERIES DE TIEMPO

Este capítulo describe la secuencia de pasos seguida para el montaje de las redes neuronales artificiales analizadas en esta etapa de la investigación, comenzando por el uso de la interfaz gráfica (GUI) y luego realizando modificaciones a cada *script* según el requerimiento del investigador.

1. Inicialmente se necesita desplegar la interfaz gráfica de redes neuronales con el comando, **nnstart**, con lo cual se despliega la ventana mostrada en la Figura 3.1.

2. Dando clic en la opción *Time Series Tool* se abre la ventana que muestra la herramienta de redes neuronales para series de tiempo dinámicas (Véase Figura 3.2).

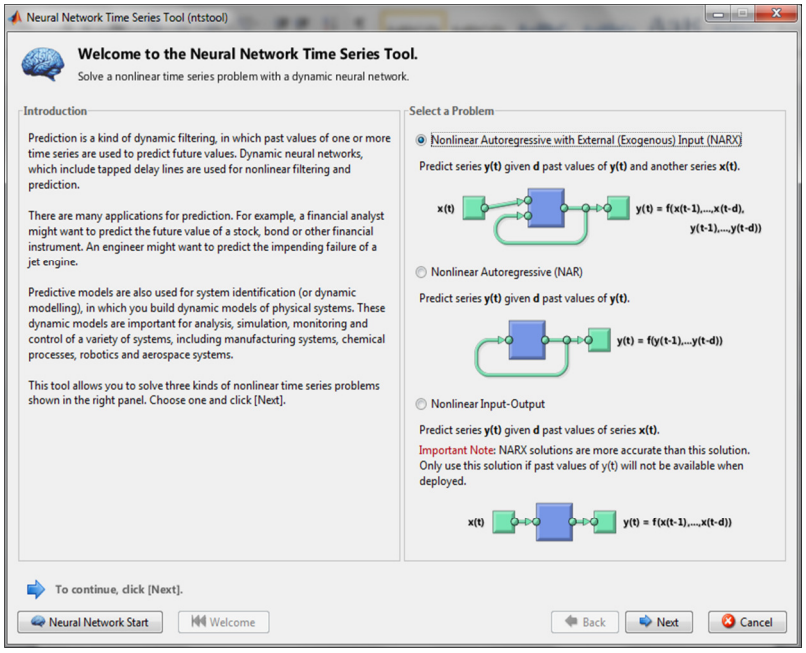

Figura 3.2. Acceso a la herramienta de series de tiempo dinámicas (Fuente: *Toolbox* MATLAB®).

El panel abierto muestra que esta opción (**ntstool**) se puede utilizar para resolver tres tipos de problemas de series de tiempo.

- En el primer tipo de problema se quiere predecir los valores futuros de una serie de tiempo $y(t)$ a partir de los valores pasados de la serie y valores pasados de una segunda serie de tiempo $x(t)$. Esta forma de

predicción se denomina autorregresiva no lineal con entrada exógena (externa), o NARX, y se puede escribir como lo muestra la Ecuación 16.

$$y(t) = f(y(t-1), \dots, y(t-d), x(t-1), \dots, (t-d)) \quad \textbf{Ecuación 16}.$$

Este modelo podría ser utilizado para predecir los valores futuros de una acción de una compañía, basado en variables económicas como las tasas de desempleo, PIB, etc.

- En el segundo tipo de problema, hay solo una serie involucrada. Los valores futuros de una serie de tiempo $y(t)$ son predichos solo desde valores pasados de esa serie. Esta forma de predicción es llamada no lineal autorregresiva, o NAR y puede ser escrita como lo muestra la Ecuación 17.

$$y(t) = f(y(t-1), \dots, y(t-d)) \quad \textbf{Ecuación 17}.$$

Este modelo también se podría utilizar para predecir instrumentos financieros, pero sin el uso de una serie compañera.

- El tercer problema de series de tiempo es similar al primero, en el que dos series están involucradas, una serie de entrada $x(t)$ y una serie de salida/objetivo $y(t)$. En esta se quiere predecir valores de $y(t)$ a partir de valores previos de $x(t)$, pero sin el conocimiento de valores previos de $y(t)$. Este modelo entradas/salidas puede ser escrito como lo indica la Ecuación 18.

$$y(t) = f(x(t-1), \dots, x(t-d)) \quad \textbf{Ecuación 18}.$$

En esta investigación se utilizará el modelo NARX ya que proporciona mejores predicciones que los otros modelos modelo de entrada-salida, pues como se mencionó, puede utilizar información adicional contenida en los valores anteriores de $y(t)$ para obtener una mejor respuesta. Sin embargo, puede haber algunas aplicaciones en las que los valores anteriores de $y(t)$ no estarían disponibles. Esos son los únicos casos en los que se querría utilizar otro de estos modelos en lugar del tipo NARX.

3. Para escoger el modelo tipo NARX se selecciona dicha opción, como lo muestra la Figura 3.2, y se da clic en *next* para proceder. Luego de esto se despliega la ventana donde se deberán cargar los datos de entrada (*Inputs*) y los objetivos (*Targets*) de la red, además se debe escoger el tipo de formato de la serie de tiempo, para este caso se selecciona *Matrix column* (Véase Figura 3.3).

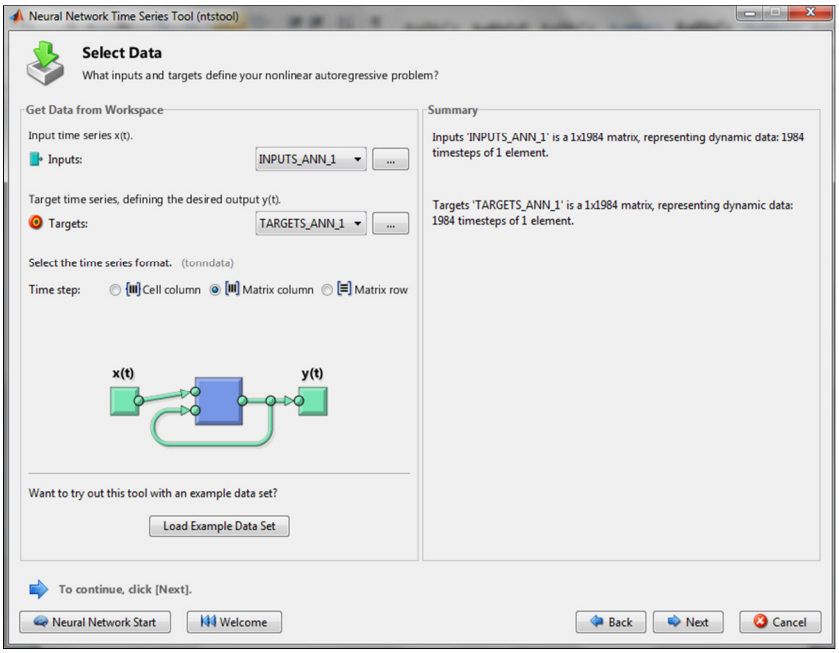

Figura 3.3. Panel para cargar datos y objetivos – Red tipo NARX (Fuente: *Toolbox* MATLAB®).

4. Después de cargar los datos de entradas y objetivos, se da clic en el botón *Next* para abrir la ventana de validación y prueba de datos (Véase Figura 3.4). En esta primera aproximación a través de la interfaz gráfica, se observa que de manera predeterminada el porcentaje de datos para entrenamiento (*Training*) es del 70%, mientas que un 15% será utilizado para validar (*Validation*) que la red está generalizando y para detener el entrenamiento cuando se detecte sobreentrenamiento y el restante 15% será utilizado para una prueba completamente independiente de generalización de la red (*Testing*).

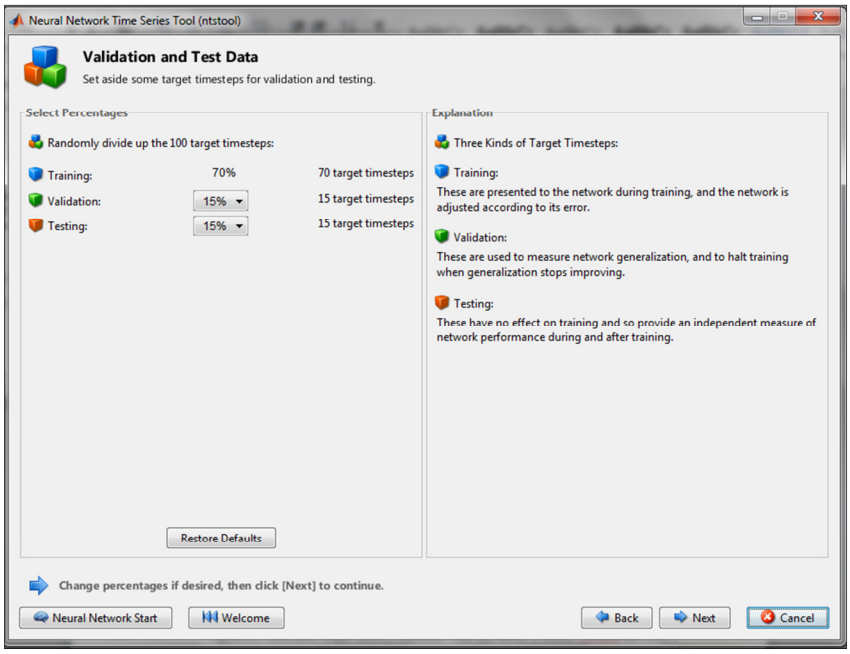

Figura 3.4. Panel para validación y prueba de datos (Fuente: *Toolbox* MATLAB®).

De acuerdo con la cantidad de datos cargados para la ejecución de la red neuronal este porcentaje deberá o no ser ajustado. Para este caso se debió ajustar cada uno de estos porcentajes con el objetivo de tener una adecuada división de datos, dicho ajuste se realizará directamente en el *script* de la red como se indica en el Numeral 3.4.

5. Dando clic en el botón *Next*, se despliega la ventana donde se muestra la arquitectura predeterminada para la red tipo NARX; esta es una red *feedforward* de dos capas, con una función de transferencia sigmoidal en la capa oculta y una función de transferencia lineal en la capa de salida. El número predeterminado de neuronas ocultas es 10 y el número predeterminado de retrasos en 2 (Véase Figura 3.5). Si el desempeño del entrenamiento de la red es deficiente, estos datos se podrán ajustar en busca de una mejor respuesta.

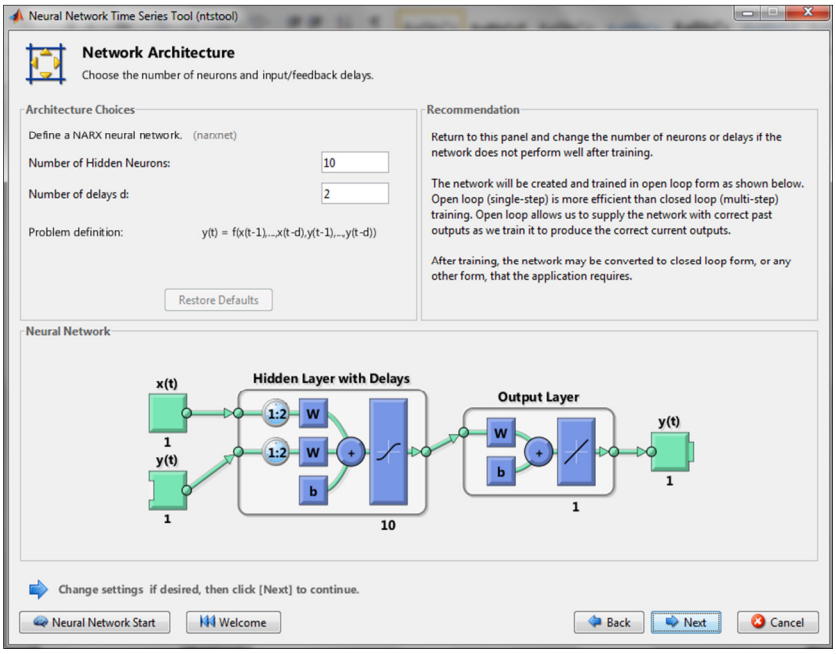

Figura 3.5. Panel para ajustar arquitectura de la red (Fuente: *Toolbox* MATLAB®).

Este tipo de red utiliza líneas de retardo para almacenar los valores anteriores de las secuencias $x(t)$ y $y(t)$. Nótese que la salida de la red NARX, $y(t)$, retroalimenta la entrada de la red (a través de los retrasos), ya que $y(t)$ es una función de $y(t-1), y(t-2), \dots, y(t-d)$. Sin embargo, para un entrenamiento eficiente se puede abrir este ciclo de retroalimentación.

Debido a que la salida verdadera está disponible durante el entrenamiento de la red, se puede utilizar la arquitectura de bucle abierto mostrada en la Figura 3.5, en la que la salida real se utiliza en lugar de retroalimentar la salida estimada, esto tiene dos ventajas. La primera es que la entrada a la red *feedforward* es más precisa. La segunda es que la red resultante tiene una arquitectura puramente *feedforward*, y por lo tanto un algoritmo más eficiente puede ser utilizado para el entrenamiento.

6. Haciendo clic en el botón *Next* se despliega la ventana para entrenamiento (Véase Figura 3.6). De forma predeterminada la red viene ajustada con el algoritmo de entrenamiento de Levenberg-Marquardt (**trainlm**) el cual puede ser modificado dependiendo de los requerimientos del investigador. Para este caso de estudio se utilizó el

algoritmo de entrenamiento como una variable de diseño, por lo que se debió variar el tipo de algoritmo utilizado.

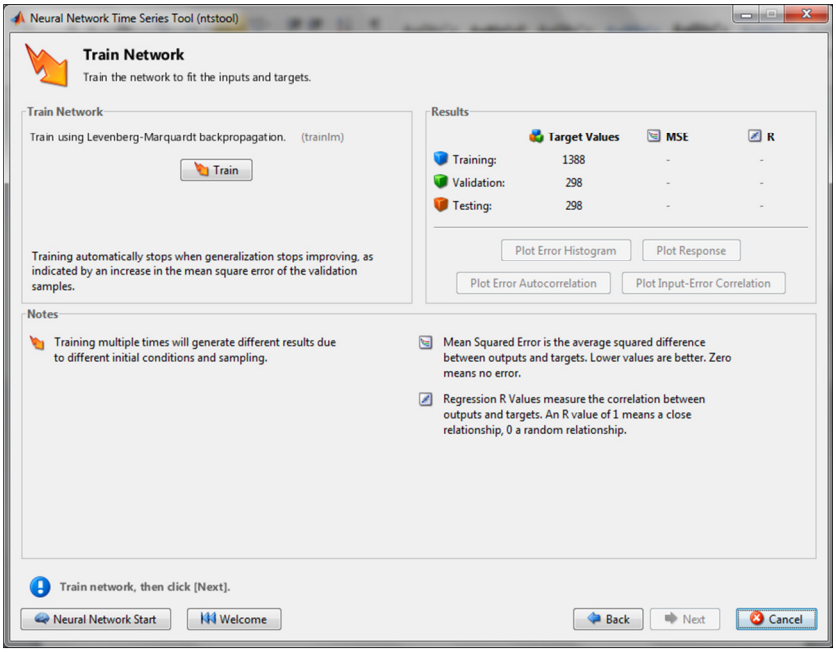

Figura 3.6. Panel para entrenamiento de la red (Fuente: *Toolbox* MATLAB®).

7. Al hacer clic en la opción *Train* se inicia el entrenamiento de la red, el cual continúa hasta que el error de validación no logra disminuir durante seis iteraciones. Una vez finaliza el entrenamiento se despliega una nueva ventana (Véase Figura 3.7), a través de la cual se puede observar el comportamiento de variables como *Performance, Training state, Error histogram, Regression, Time-Series Respose, Error Autocorrelation* e *Input-Error Cross-Correlation.* Además se puede observar la arquitectura utilizada para la red y otras variables de decisión.

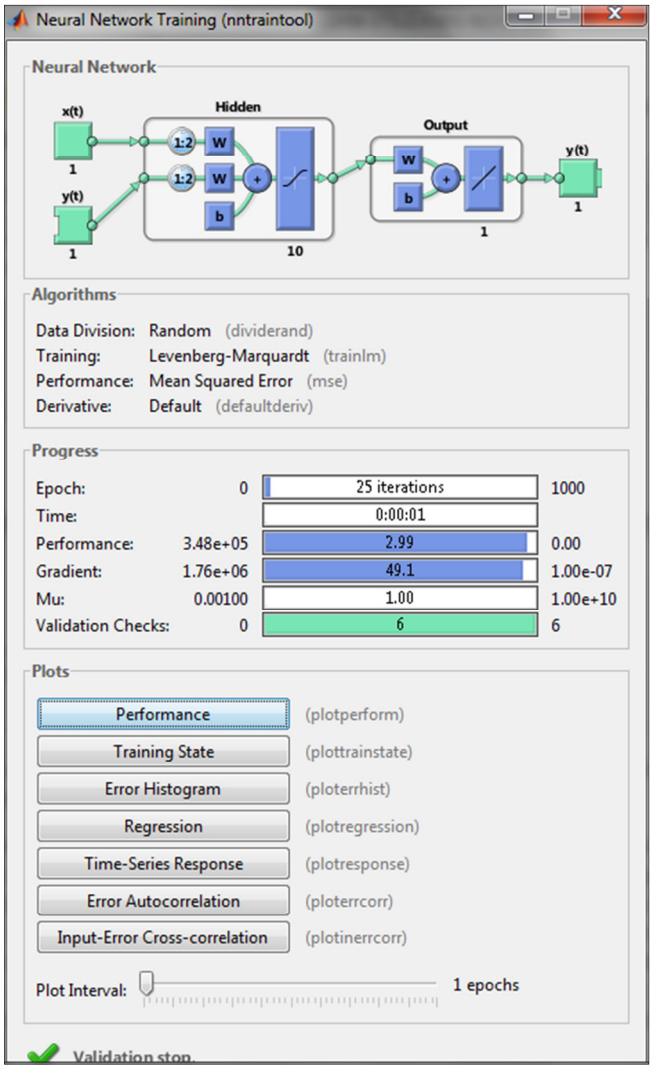

Figura 3.7. Variables de decisión e información del entrenamiento (Fuente: *Toolbox* MATLAB®).

8. En la parte baja del panel dando clic en la opción *Time Series Respose*, se muestran los objetivos y errores versus tiempo. También indica que puntos fueron seleccionados para entrenamiento, prueba y validación (Véase Gráfica 3.1).

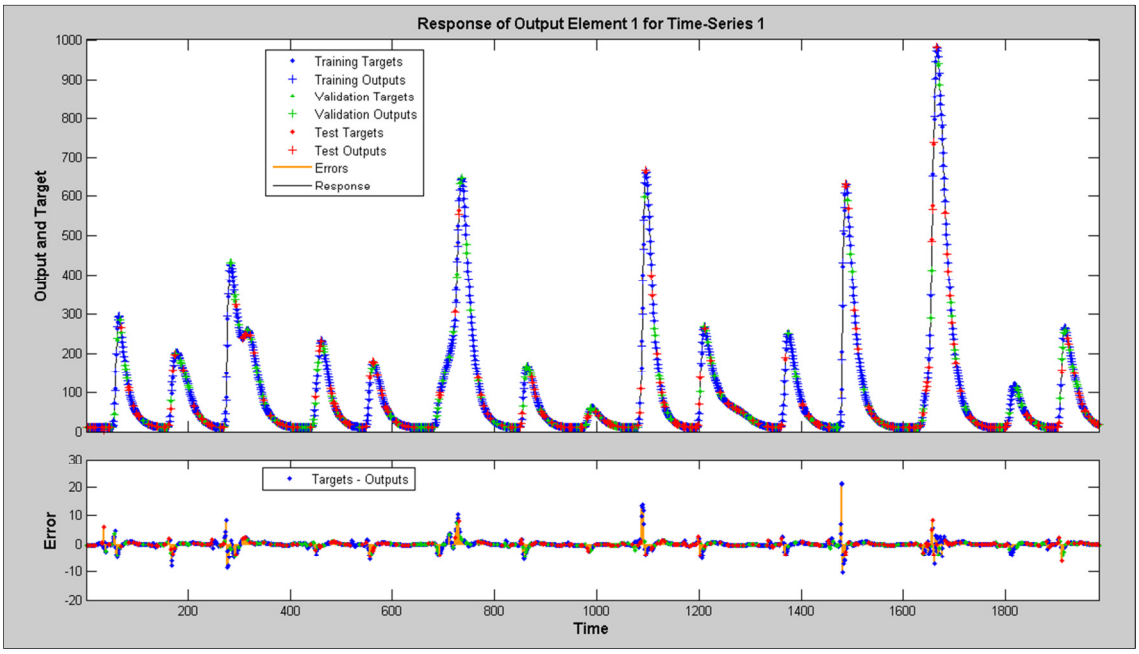

Gráfica 3.1. Panel para validación y prueba de datos (Fuente: *Toolbox* MATLAB®).

Como se observa en la Gráfica 3.1, los datos escogidos para entrenamiento, validación y prueba están seleccionados en forma aleatoria; esto se puede ajustar cambiando en el *script* de la red neuronal la forma de división de datos mediante la escogencia de la opción **divideblock** (véase Tabla 3.1). Esto se definirá en detalle en el Numeral 3.4.

9. Otra de las variables de decisión que se puede obtener una vez realizado el entrenamiento de la red es la opción *Error Autocorrelation,* la cual se utiliza para validar el desempeño de la ANN. En la Gráfica 3.2 se muestra la función de autocorrelación de errores para el ejemplo utilizado.

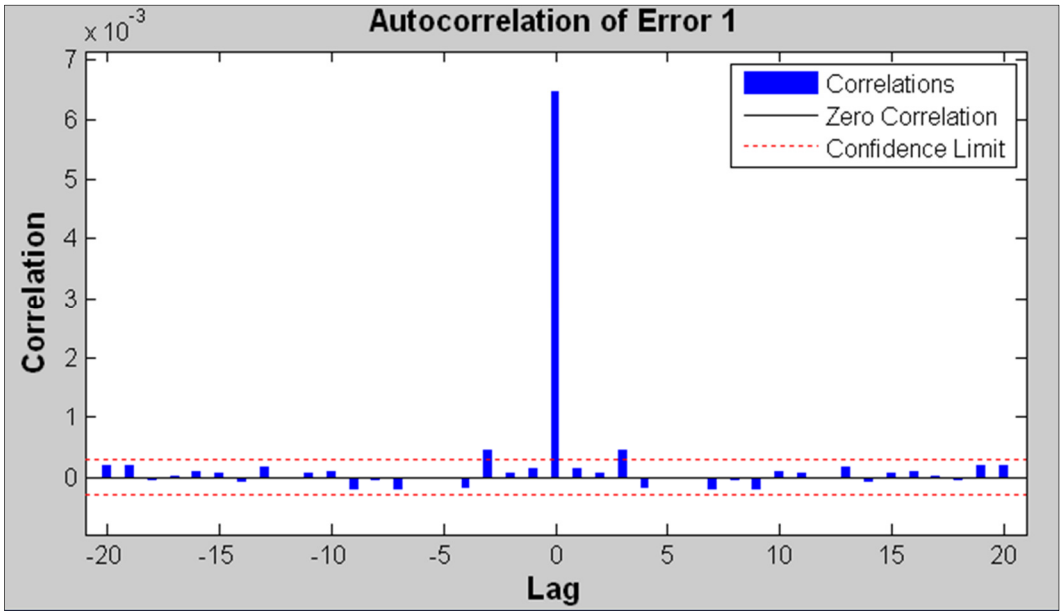

Gráfica 3.2. Error de autocorrelación (Fuente: *Toolbox* MATLAB®).

La Gráfica 3.2 describe cómo los errores de predicción se relacionan en el tiempo. Para un modelo de predicción perfecto, sólo debe haber un valor distinto de cero en la función de autocorrelación, y debería ocurrir en retraso cero (cero lag), este es el error cuadrático medio. Lo anterior significa que los errores de predicción están completamente no correlacionados entre sí (ruido blanco). Si se tiene una correlación significativa en los errores de predicción, entonces debería ser posible mejorar la predicción, tal vez aumentando el número de retrasos en las líneas de retardo. En este caso (Gráfica 3.2), las correlaciones, a excepción de la que está en retraso cero, caen aproximadamente dentro de los límites de confianza del 95% alrededor de cero, por lo que podría decirse que el modelo es adecuado. Si se requieren resultados aún más precisos, se puede reentrenar la red haciendo clic en ***Retrain*** en ntstool. Este procedimiento cambia los pesos iniciales y los umbrales de la red, y puede producir una red mejorada después del reentrenamiento.

10. Para realizar una verificación adicional del desempeño de la red se puede desplegar también la función *Input-Error Cross-Correlation*, dando clic en el botón del mismo nombre, véase Figura 3.7. Realizado el anterior procedimiento se podrá ver una representación como la mostrada en la Gráfica 3.3.

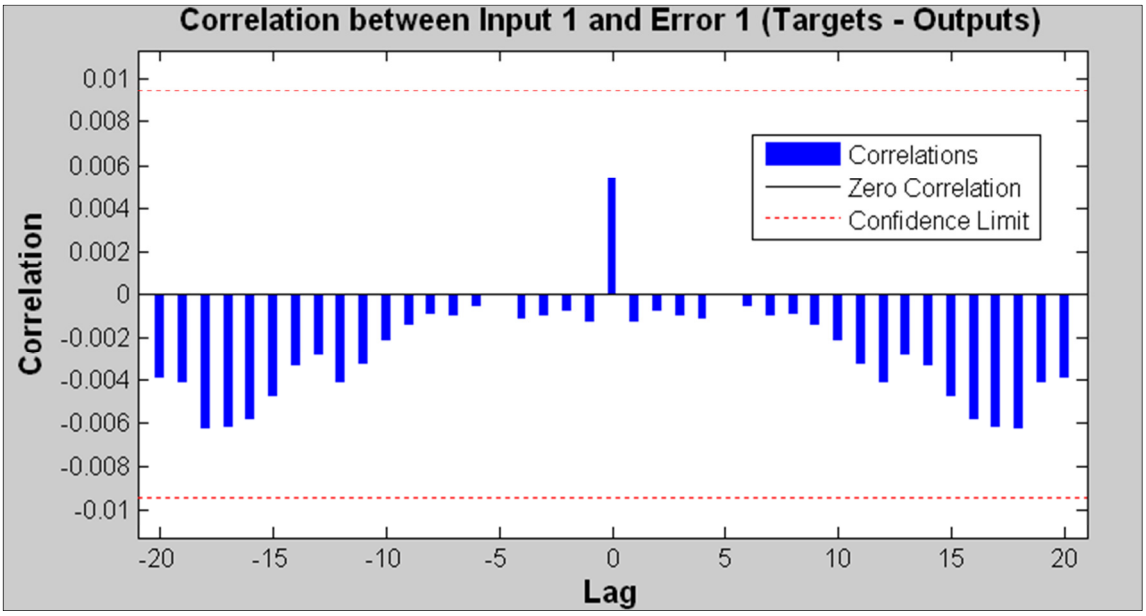

Gráfica 3.3. Correlación entre entradas y errores (Fuente: *Toolbox* MATLAB®).

La gráfica de la función *input-error cross-correlation* muestra como los errores están correlacionados con la secuencia de entrada x(t). Para un modelo perfecto de predicción, todas las correlaciones deberían ser cero. Si la entrada se correlaciona con el error, entonces debería ser posible mejorar la predicción, tal vez incrementando el número de retrasos en las líneas de retardo. En este caso, todas las correlaciones caen dentro de los límites de confianza alrededor de cero.

11. Dando clic en el botón *Next* en la herramienta de series de tiempo para evaluar la red (véase Figura 3.6), es posible probar la red con nuevos datos en el nuevo panel que se despliega (véase Figura 3.8). Si no se está satisfecho con el desempeño de la red con los datos de origen o con los nuevos se puede probar con los ajustes siguientes:

    - Entrenar de nuevo la red.
    - Incrementar el número de neuronas y/o el número de retrasos.
    - Obtener un conjunto de datos de entrenamiento más amplio.

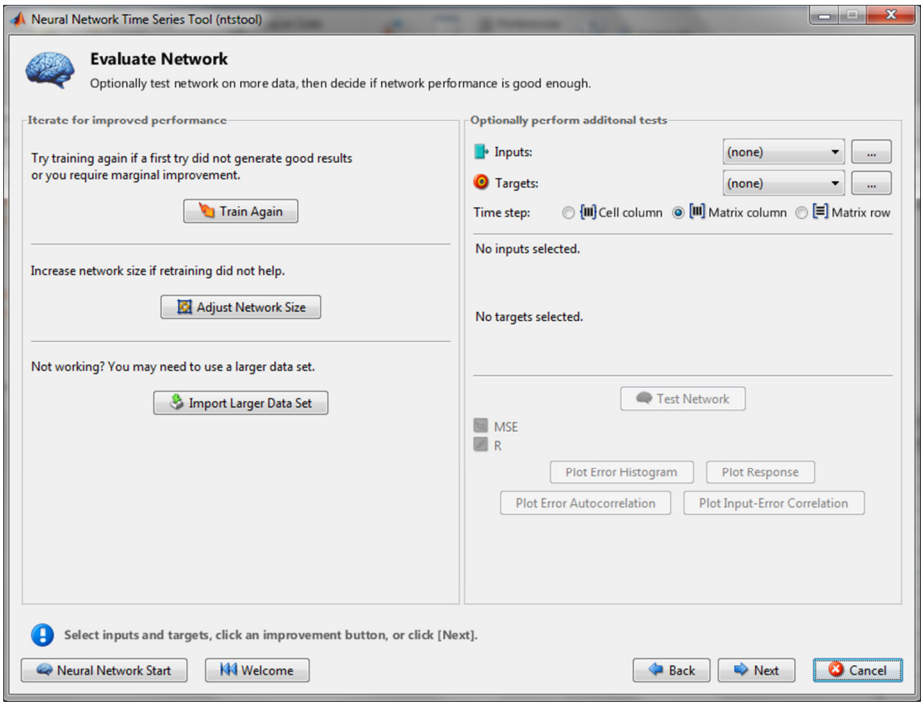

Figura 3.8. Panel para pruebas de la red (Fuente: *Toolbox* MATLAB®).

Si el desempeño en el conjunto de entrenamiento es bueno, pero el desempeño en el conjunto de prueba no es el adecuado, esto podría indicar sobreentrenamiento, entonces reduciendo el número de neuronas se pueden mejorar los resultados.

Si no se está satisfecho con los resultados obtenidos a través de la interfaz gráfica, es posible personalizar la estructura de la red dando clic en la opción *advanced script* (véase Figura 3.9) con lo cual el investigador puede cambiar parámetros como el tipo de algoritmo de entrenamiento, el número de neuronas y/o capas ocultas, el tipo de división de datos, etc. En el numeral 3.4 se da una descripción de la forma como se edita un determinado *script*.

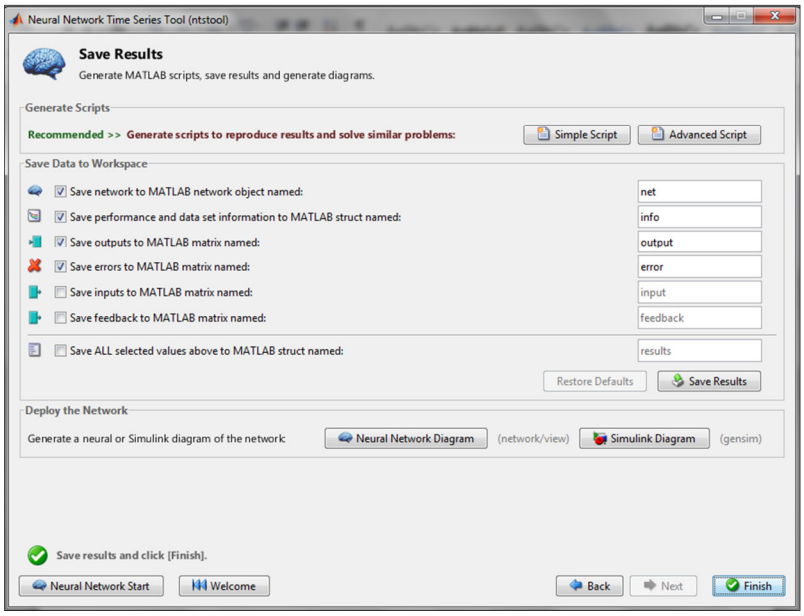

Figura 3.9. Panel para validación y prueba de datos (Fuente: *Toolbox* MATLAB®).

3.4 USO DE LAS FUNCIONES DE LA LÍNEA DE COMANDO

La forma fácil para aprender cómo utilizar la funcionalidad de la línea de comando del *toolbox* de redes neuronales artificiales (RNA) disponible en MATLAB® es generando *scripts* desde la interfaz gráfica (GUI), y luego modificarlos para personalizar el entrenamiento de la red. Para editar un *script* se puede seguir el procedimiento sugerido a continuación:

1. Cargar entradas y objetivos. El *script* asume que los vectores de entrada y vectores objetivo ya están cargados en el espacio de trabajo. Si no lo están, pueden cargarse como sigue para un caso determinado, para este estudio las entradas se denominan INPUTS_n y los objetivos TARGETS_n siendo n un consecutivo desde 1 hasta la cantidad total de redes requeridas.

```
load ANN_1_dataset
inputSeries = INPUTS_1;
targetSeries = TARGETS_1;
```

2. Crear una red. En esta investigación como ya se mencionó anteriormente se utilizará una red tipo NARX para la simulación de las redes

neuronales. La red NARX, **narxnet**, es una red *feedforward* con una función de transferencia sigmoidal en la capa oculta y una función de transferencia lineal en la capa de salida, ambas predeterminadas. Esta red tiene dos entradas, una es una entrada externa y la otra es una conexión de realimentación desde la salida de la red, como se observa en la Figura 3.5. Para asignar la arquitectura a una red tipo NARX, se deben seleccionar los retrasos asociados con cada línea de retardo, y también el número de neuronas de la capa oculta. En las líneas de ejemplo siguientes se indica cómo se asignan los retrasos de entrada y los retrasos de retroalimentación, para este caso en un rango de 1 a 4 y el número de neuronas ocultas como 10.

```
inputDelays = 1:4;
feedbackDelays = 1:4;
hiddenLayerSize = 10;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);
```

NOTA: Aumentar el número de neuronas y el número de retrasos requiere más cálculo, y esto tiene una tendencia a sobreentrenar la red cuando los números son demasiado altos, pero permite a la red resolver problemas más complicados. Más capas requieren más cálculo, pero su uso podría resultar en una red resolviendo problemas complejos de manera más eficiente. Para utilizar más de una capa oculta, se ingresa el tamaño de la capa oculta como elementos de un matriz en el comando **fitnet**, es decir, si se requiere una red con dos capas ocultas, teniéndose 10 neuronas en la primera capa y 5 neuronas en la segunda capa, el ajuste se debe realizar como se indica:

```
hiddenLayerSize = [10,5];
```

3. Ajustar la división de datos. Al entrenar redes multicapas, la práctica general es dividir primero los datos en tres subconjuntos. El primer subconjunto es el conjunto de entrenamiento (*training*), el cual se utiliza para calcular el gradiente y actualizar los pesos y los umbrales de la red. El segundo subconjunto es el grupo de validación (*validation*), el error en este conjunto es monitoreado constantemente durante el proceso de entrenamiento. El error de validación normalmente disminuye durante la fase inicial de entrenamiento, al igual que el error del conjunto de entrenamiento; sin embargo, cuando la red comienza a sobreentrenar los

datos, el error en el conjunto de validación típicamente comienza a elevarse. Los pesos de la red y los umbrales se guardan para el mínimo valor de error del conjunto de validación. El tercer subconjunto es el de prueba (*testing*); el error del conjunto de prueba no es utilizado durante el entrenamiento, pero si es utilizado para comparar diferentes modelos. Si el error en el conjunto de prueba alcanza un mínimo en un número de iteración significativamente diferente que el error del conjunto de validación, esto podría indicar una pobre división del conjunto de datos. De forma predeterminada MATLAB® proporciona el siguiente ajuste:

```
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;
```

Con este ajuste los vectores de entrada y objetivo serán aleatoriamente divididos, con 70% para entrenamiento, 15% para prueba y 15% para validación.

Hay cuatro funciones provistas por MATLAB® para dividir los datos en grupos de entrenamiento, validación y prueba. Estas son **dividerand** (función por defecto), **divideblock**, **divideint** y **divideind**. La Tabla 3.1 indica la forma de división de datos según la función seleccionada.

FUNCIÓN	ALGORITMO
dividerand	Divide los datos aleatoriamente (Función por defecto)
divideblock	Divide los datos en bloques contiguos
divideint	Divide los datos mediante una selección intercalada
divideind	Divide los datos por un índice o clasificación

Tabla 3.1 Funciones para división de datos (Fuente: *Toolbox* MATLAB®).

La función de división `net.divideFcn` se incluye de forma automática cada vez que la red es entrenada, y se utiliza para dividir los datos en subgrupos de entrenamiento, validación y de prueba. Si `net.divideFcn` se establece en **'dividerand'** (función por defecto), entonces los datos se dividen al azar en tres subconjuntos utilizando los parámetros de división `net.divideParam.trainRatio`, `net.divideParam.valRatio` y `net.divideParam.testRatio`. La fracción de los datos que se coloca en el conjunto de entrenamiento es `trainRatio / (trainRatio + valRatio + testRatio)`, una fórmula similar aplica para los otros dos

grupos. Los valores por defecto para entrenamiento, prueba y validación son 0.7, 0.15 y 0.15, respectivamente.

Si `net.divideFcn` se establece en **'divideblock'**, entonces los datos se dividen en tres subgrupos utilizando tres bloques contiguos del conjunto de datos original (para entrenamiento toma el primer bloque, para validación el segundo y para prueba el tercero). La fracción de los datos originales que entra en cada subconjunto se determina por los mismos tres parámetros de división utilizados para **dividerand** o el investigador puede asignar diferentes porcentajes según sus requerimientos.

Si `net.divideFcn` se establece en **'divideint'**, entonces los datos se dividen mediante un método intercalado, como en el tratamiento de una baraja de cartas. Está hecho para que diferentes porcentajes de datos entren en los tres subgrupos. La fracción de los datos originales que entra en cada subconjunto se determina por los mismos tres parámetros de división utilizados para dividerand.

Cuando `net.divideFcn` se establece en **'divideind'**, los datos se dividen por el índice. Los índices para los tres subgrupos están definidos por los parámetros de división `net.divideParam.trainInd`, `net.divideParam.valInd` y `net.divideParam.testInd`. La asignación predeterminada de estos índices es la matriz nula, por lo que se deben establecer los índices al utilizar esta opción.

4. Entrenar la red. Una vez se inician los pesos y biases (umbrales), la red está lista para el entrenamiento. La red multicapas *feedforward* puede ser entrenada para aproximación de funciones (regresión no lineal) o para reconocimiento de patrones. El proceso de entrenamiento requiere un adecuado conjunto de entradas a la red "p" y salidas objetivo "t".

   El proceso de entrenar una red neuronal implica afinar los valores de los pesos y *biases* para optimizar el rendimiento de la red, de acuerdo con la definición de la función de desempeño de la red `net.performFcn`. La función de desempeño predeterminada para redes *feedforward* es el error cuadrado medio (MSE) entre la salida de la red "a" y la salida objetivo "t". La Ecuación 19 define esta expresión:

$$F = mse = \frac{1}{N}\sum_{i=1}^{N}(e_i)^2 = \frac{1}{N}\sum_{i=1}^{N}(t_i - a_i)^2 \qquad \textbf{Ecuación 19.}$$

Hay dos maneras diferentes como el entrenamiento se puede implementar: el modo incremental y el modo por grupos. En el modo incremental, el gradiente se calcula y los pesos se actualizan después que cada entrada se aplica a la red. En el modo por grupos, todas las entradas en el conjunto de entrenamiento se aplican a la red antes de que se actualicen los pesos. Para la mayoría de los problemas, cuando se utiliza en el *toolbox* de red neuronal, el entrenamiento por grupos es significativamente más rápido y produce errores de menor tamaño que el entrenamiento incremental.

Las redes neuronales artificiales en MATLAB® utilizan por defecto para entrenamiento el algoritmo de Levenberg-Marquardt. La Tabla 3.2 muestra los algoritmos disponibles en el *toolbox* de redes neuronales del *software*. Estos algoritmos están basados en los métodos del gradiente y en el jacobiano.

FUNCIÓN	ALGORITMO
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traincgb	Conjugate Gradient with Powell/Beale Restarts
traincgf	Fletcher-Powell Conjugate Gradient
traincgp	Polak-Ribiére Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

Tabla 3.2 Algoritmos de entrenamiento ofrecidos por MATLAB® (Fuente: *Toolbox* MATLAB®).

La función de entrenamiento más rápida es generalmente **trainlm**, y es la función por defecto para redes *feedforward*. El método cuasi-Newton, **trainbfg**, también es bastante rápido. Ambos métodos tienden a ser menos eficiente para redes grandes (con miles de pesos), ya que requieren más memoria y más tiempo de cálculo. La función **trainlm** realiza mejor problemas de función de ajuste (regresión no lineal) que problemas de reconocimiento de patrones.

Cuando se tienen redes de gran tamaño y redes para reconocimiento de patrones, **trainscg** y **trainrp** son buenas opciones. Sus requisitos de memoria son relativamente pequeños y sin embargo son mucho más rápidos que los algoritmos de descenso de gradiente estándar. Durante el entrenamiento de una red se abre la ventana mostrada en la Figura 3.10; el entrenamiento se detiene en forma automática cuando el error de validación aumenta luego de 6 iteraciones.

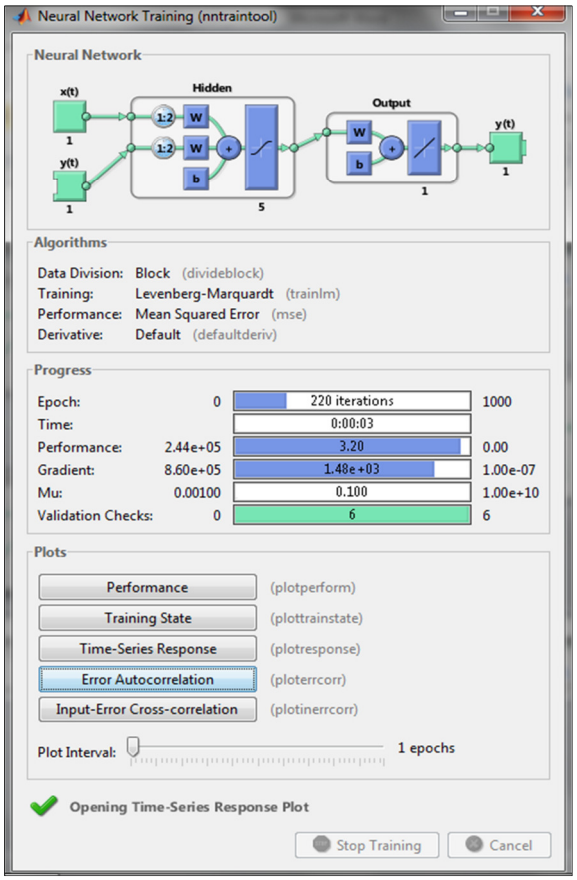

Figura 3.10. Ventana de proceso del entrenamiento (Fuente: *Toolbox* MATLAB®).

5. Probar la red. Después que la red ha sido entrenada, se puede utilizar para calcular las salidas de la misma. El siguiente código calcula las salidas de la red, errores y desempeño total.

```
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)
```

6. Desempeño del entrenamiento. Este se determina para comprobar si hay un potencial sobreentrenamiento en la red. La función `figure, plotperform(tr)` muestra la Gráfica 3.4 donde se ve el comportamiento de la red. De esta grafica se puede afirmar que en cuanto a los errores de entrenamiento, validación y prueba, todos disminuyeron hasta aproximadamente la iteración 64. No parece que se haya producido algún sobreentrenamiento, ya que ningún error de prueba o de validación aumento antes de la iteración 64, de observarse en la curva de prueba un aumentado de manera significativa antes que la curva de validación aumentara, entonces es posible que algún sobreentrenamiento pudiera haber ocurrido.

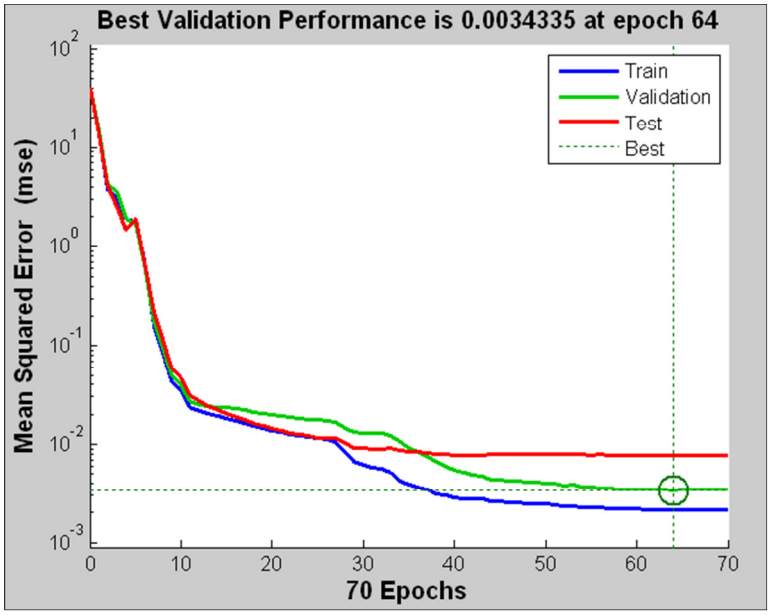

Gráfica 3.4 Desempeño de la red neuronal (Fuente: *Toolbox* MATLAB®).

7. Cerrar el ciclo en la red NARX. Cuando el bucle de retroalimentación está abierto en la red NARX, se está realizando una predicción de un solo paso hacia adelante, se predice el siguiente valor de y (t) a partir de los valores anteriores de y(t) y x(t). Con el bucle de realimentación cerrado, este se puede utilizar para realizar predicciones multi-paso hacia adelante. Esto es porque las predicciones de y(t) se utilizan en lugar de los valores reales futuros de y(t). Los siguientes comandos se pueden utilizar para cerrar el bucle y calcular el rendimiento del circuito cerrado.

```
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] =
preparets(netc,inputSeries,{},targetSeries);
yc = netc(xc,xic,aic);
perfc = perform(netc,tc,yc)
```

La Figura 3.11 muestra una red NARX con el circuito cerrado.

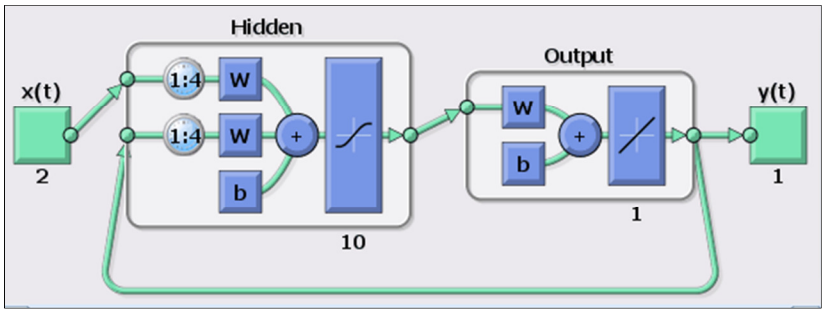

Figura 3.11. Red NARX de circuito cerrado (Fuente: *Toolbox* MATLAB®).

8. Eliminar un retraso de la red. Para obtener la predicción un paso en el tiempo más temprano, el siguiente código permite realizar esta operación.

```
nets = removedelay(net);
nets.name = [net.name ' - Predict One Step Ahead'];
view(nets)
[xs,xis,ais,ts]=
preparets(nets,inputSeries,{},targetSeries);
ys = nets(xs,xis,ais);
earlyPredictPerformance = perform(nets,ts,ys)
```

Cuando los resultados y el desempeño de la red no son satisfactorios se puede intentar alguna de las siguientes aproximaciones:

- Restablecer los pesos y umbrales iniciales de la red a nuevos valores con `init` y entrenar de nuevo.
- Incrementar el número de neuronas ocultas o retrasos.
- Incrementar el número de vectores de entrenamiento.
- Incrementar el número de valores de entrada, si está disponible más información relevante.
- Probar un algoritmo de entrenamiento diferente.

4. METODOLOGÍA DESARROLLADA

En esta investigación, posterior a la etapa de búsqueda y recopilación del material bibliográfico existente y reconocimiento del estado del arte de este tipo de metodologías tanto a nivel local como a nivel general, se seguirán las etapas indicadas más adelante con el fin de lograr el objetivo de la investigación, el cual se fundamenta en determinar la viabilidad de utilizar un método basado en inteligencia artificial (ANN) para realizar en forma adecuada el tránsito de crecientes a través de un tramo de canal o cauce determinado. Para los casos de análisis o como se denominaran de aquí en adelante "Caso de Estudio 1, Caso de Estudio 2 y Caso de Estudio 3", el alcance de la investigación se indica en las etapas 1 a 5, las cuales se describen a continuación.

Etapa 1. En la parte inicial de la investigación se define en principio un tramo de canal o cauce con características hidráulicas sencillas, es decir, con una sola entrada de caudal y una sola salida. Se resalta que en las siguientes etapas de la investigación se considerarán modelos más complejos con varias entradas y una o varias salidas, para validar y reforzar los resultados obtenidos. El cauce utilizado como Caso de Estudio 1, corresponde a un tramo de río del territorio colombiano de aproximadamente 30 Km de longitud, con algunas curvas en su recorrido, la pendiente de fondo es del orden de 0,0012 m/m y el ancho de la sección del orden de 150 m. La Figura 4.1 muestra un trazado en planta del caso de estudio mencionado; indicados con puntos de color rojo se muestran los sitios donde se localizan las secciones batimétricas. La Figura 4.2 muestra además de forma esquemática el perfil de fondo del cauce analizado; en esta se exagera la escala vertical para observar las irregularidades que este pueda tener.

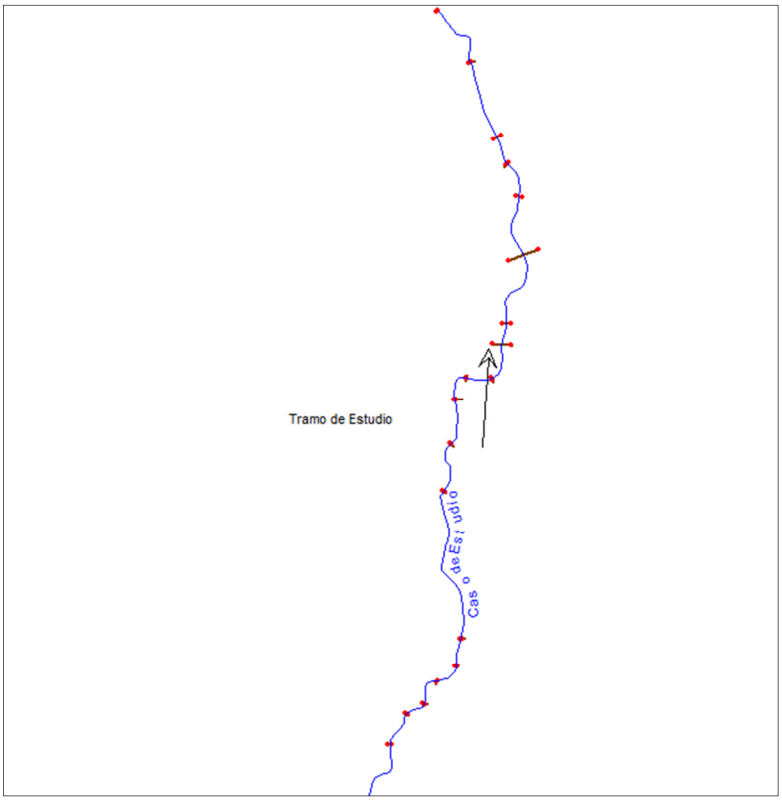

Figura 4.1 Trazado en planta – Caso de Estudio 1.

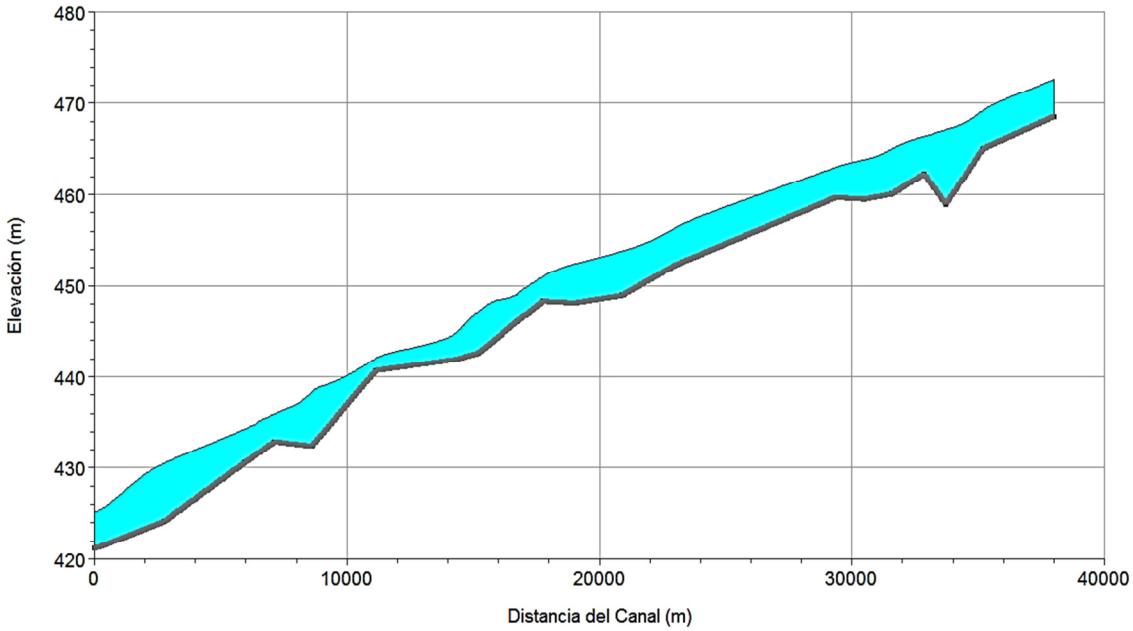

Figura 4.2 Perfil del fondo del cauce – Caso de Estudio 1.

Teniendo la información básica del Caso de Estudio 1, a partir de un hidrograma de diseño inicial se elaboran una serie de hidrogramas de diferentes tamaños y formas, buscando con esto tener un rango de información amplio que permita abarcar un mayor y más significativo grupo de datos para el aprendizaje de las redes neuronales. Esta misma metodología se utilizará para determinar los hidrogramas de entrada (Datos de entrada) en el Caso de Estudio 2 y en el Caso de Estudio 3.

Seguido a esto, con la serie de hidrogramas definidos se procede al ejecutar el tránsito en el tramo de canal del Caso de Estudio 1, este se hace en primera instancia con ayuda de un software confiable, para este ejercicio se utiliza HEC-RAS. La información de entrada para comenzar el proceso de simulación está conformada por un grupo de 20 secciones batimétricas, con las cuales se genera un modelo digital del cauce a analizar. La Figura 4.3 muestra una imagen tridimensional del tramo en mención y la Gráfica 4.1 muestra los hidrogramas utilizados para el tránsito en el modelo digital. Se resalta que el espaciamiento entre uno y otro hidrograma se determinó con el objetivo de evitar que la respuesta de un determinado hidrograma afectara la respuesta del hidrograma siguiente.

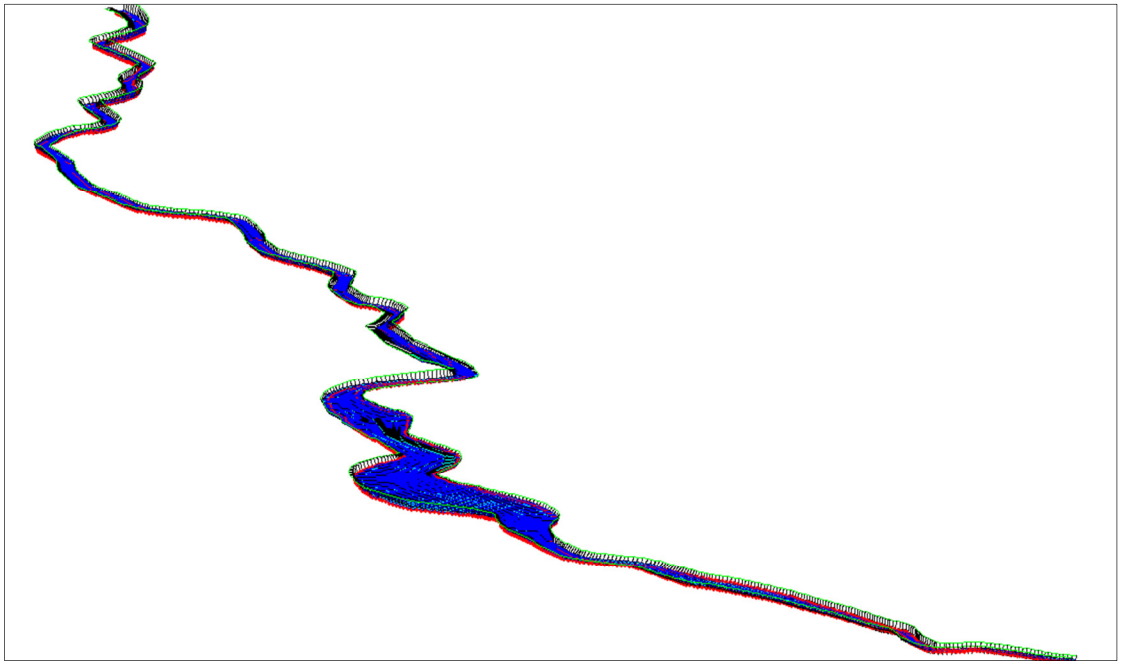

Figura 4.3 Modelo digital del Caso de Estudio 1.

Con la información batimétrica, la serie de hidrogramas y demás variables de entrada al modelo, se procede a determinar la serie de hidrogramas de salida en la última sección aguas abajo del modelo digital en HEC-RAS; el resultado de esto se muestra en la Gráfica 5.1.

Etapa 2. En esta etapa de la investigación se realiza la escogencia de las arquitecturas de las redes neuronales cuyo entrenamiento, calibración y/o grupo de prueba muestre el mejor comportamiento o desempeño; dicha selección se basa en someter una red neuronal definida a múltiples procesos de cálculo variando algunos parámetros que definen su arquitectura, como son:

- Número de neuronas en la capa oculta. Se consideró evaluar este parámetro para 5, 10, 15 y 20 neuronas. Según el número de capas ocultas, el total de neuronas se distribuyó en el total de capas como se muestra en la Tabla 4.1.

- Número de capas ocultas. De acuerdo con el número de estas (máximo 3), la cantidad total de neuronas se distribuyó según se muestra en la Tabla 4.1.

Número total de neuronas	**Distribución de neuronas por capa**		
	1 capa oculta	2 capas ocultas	3 capas ocultas
5	5	3 y 2	2, 2 y 1
10	10	5 y 5	4, 3 y 3
15	15	10 y 5	5, 5 y 5
20	20	10 y 10	10, 5 y 5

Tabla 4.1. Distribución de neuronas según el número de capas ocultas.

- Tipo de algoritmo de entrenamiento utilizado por la red. En cuanto a algoritmos de entrenamiento, MATLAB® proporciona las opciones indicadas en la Tabla 3.2. Para este análisis sólo se utilizaron los algoritmos siguientes, los cuales mostraron resultados con mejor ajuste a los objetivos o *targets* deseados.
  - *Levenberg-Marquardt*
  - *Bayesian Regularization*
  - *BFGS Quasi-Newton*
  - *Resilient Backpropagation*

- *Variable Learning Rate Gradient Descent*
- *Scaled Conjugate Gradient*
- *One Step Secant*

- Tipo de división de datos. La escogencia del conjunto de datos a analizar se puede realizar de cuatro formas diferentes; estas son: aleatoriamente, por bloques contiguos, mediante una selección intercalada o con la ayuda de un índice. En el Numeral 3.4 se explica en detalle cómo opera cada una de estas opciones. Para este caso se seleccionará la forma de división por bloques contiguos, escogiendo un 60% de los datos para entrenamiento, 22% para validación y 18% para evaluar la red. El por qué de esta división se explica por el hecho de evitar que un mismo hidrograma haga parte de dos bloques, es decir, entrenamiento y validación o validación y prueba. Para el Caso de Estudio 2, el Caso de Estudio 3 y las demás distribuciones de hidrogramas del Caso de Estudio 1, los porcentajes mencionados varían debido a que el número de datos analizados es diferente.

Bajo las anteriores consideraciones se construyó un total de 84 arquitecturas de redes neuronales diferentes, las cuales se evalúan considerando el error medio cuadrado (MSE) para calificar o valorar el comportamiento de una determinada arquitectura; dicho valor indica el nivel de desempeño logrado por cada red neuronal (véase Ecuación 20). Para este parámetro se tiene que entre más cercano a cero se encuentre el valor, el desempeño de una determinada arquitectura de red neuronal será mejor. La Tabla 4.2 muestra las diferentes arquitecturas utilizadas para cada red neurona. Aunque MATLAB® proporciona otros algoritmos de entrenamiento sólo se analizan los ya mencionados, pues los demás, en pruebas previas no muestran un desempeño confiable. De aquí se seleccionarán las redes neuronales que muestren el mejor desempeño y a partir de estas se continuará el análisis en las etapas 3, 4 y 5 de la investigación, pero como ya se había mencionado, con los modelos de los Casos de Estudio 2 y 3.

$$MSE = \frac{\sum_{i=1}^{N}(Q_{observado} - Q_{estimado})^2}{N}$$ **Ecuación 20**.

siendo,

$Q_{observado}$ = Caudal Observado (HEC-RAS)

$Q_{estimado}$ = Caudal Estimado (MATLAB®)

N = Número de datos

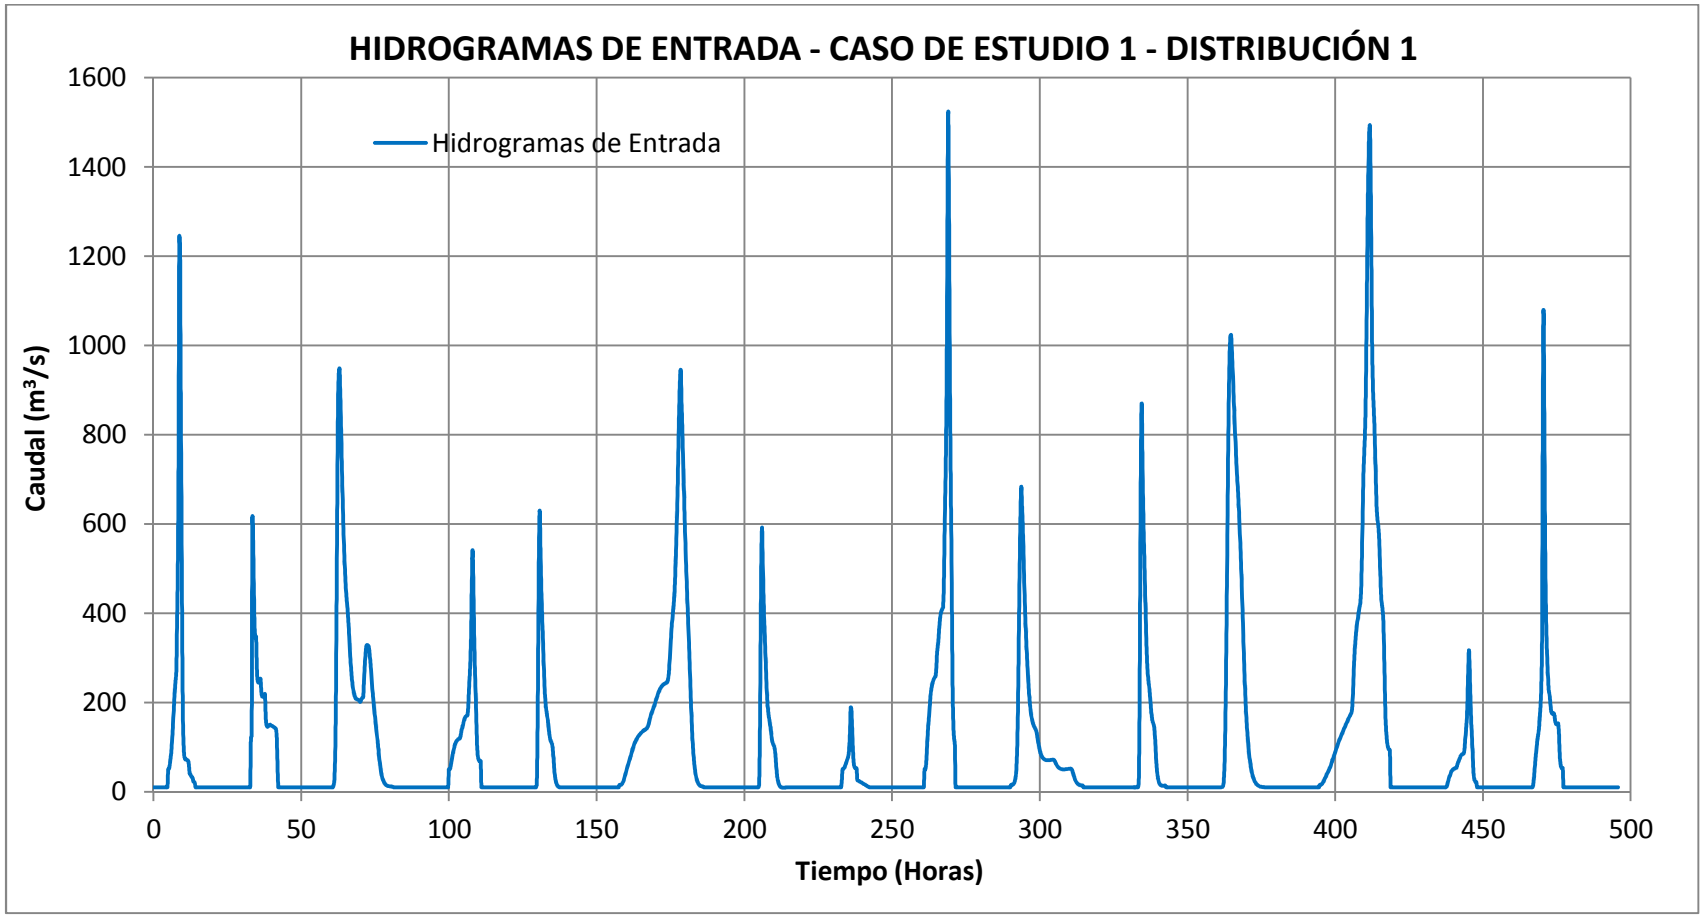

Gráfica 4.1 Hidrogramas de entrada al modelo en HEC-RAS – Caso de Estudio 1 – Distribución 1.

NOMBRE	ALGORITMO DE ENTRENAMIENTO	NEURONAS EN LA CAPA OCULTA	NEURONAS POR CAPA	CAPAS OCULTAS	TIME STEP	NOMBRE	ALGORITMO DE ENTRENAMIENTO	NEURONAS EN LA CAPA OCULTA	NEURONAS POR CAPA	CAPAS OCULTAS	TIME STEP
ANN_1	Levenberg-Marquardt - trainlm	5	5	1	2	ANN_49	Variable Learning Rate Gradient Descent - traingdx	5	5	1	2
ANN_2		10	10	1	2	ANN_50		10	10	1	2
ANN_3		15	15	1	2	ANN_51		15	15	1	2
ANN_4		20	20	1	2	ANN_52		20	20	1	2
ANN_5		5	3,2	2	2	ANN_53		5	3,2	2	2
ANN_6		10	5,5	2	2	ANN_54		10	5,5	2	2
ANN_7		15	10,5	2	2	ANN_55		15	10,5	2	2
ANN_8		20	10,10	2	2	ANN_56		20	10,10	2	2
ANN_9		5	2,2,1	3	2	ANN_57		5	2,2,1	3	2
ANN_10		10	4,3,3	3	2	ANN_58		10	4,3,3	3	2
ANN_11		15	5,5,5	3	2	ANN_59		15	5,5,5	3	2
ANN_12		20	10,5,5	3	2	ANN_60		20	10,5,5	3	2
ANN_13	Bayesian Regularization - trainbr	5	5	1	2	ANN_61	Scaled Conjugate Gradient - trainscg	5	5	1	2
ANN_14		10	10	1	2	ANN_62		10	10	1	2
ANN_15		15	15	1	2	ANN_63		15	15	1	2
ANN_16		20	20	1	2	ANN_64		20	20	1	2
ANN_17		5	3,2	2	2	ANN_65		5	3,2	2	2
ANN_18		10	5,5	2	2	ANN_66		10	5,5	2	2
ANN_19		15	10,5	2	2	ANN_67		15	10,5	2	2
ANN_20		20	10,10	2	2	ANN_68		20	10,10	2	2
ANN_21		5	2,2,1	3	2	ANN_69		5	2,2,1	3	2
ANN_22		10	4,3,3	3	2	ANN_70		10	4,3,3	3	2
ANN_23		15	5,5,5	3	2	ANN_71		15	5,5,5	3	2
ANN_24		20	10,5,5	3	2	ANN_72		20	10,5,5	3	2
ANN_25	BFGS Quasi-Newton - trainbfg	5	5	1	2	ANN_73	One Step Secant - trainoss	5	5	1	2
ANN_26		10	10	1	2	ANN_74		10	10	1	2
ANN_27		15	15	1	2	ANN_75		15	15	1	2
ANN_28		20	20	1	2	ANN_76		20	20	1	2
ANN_29		5	3,2	2	2	ANN_77		5	3,2	2	2
ANN_30		10	5,5	2	2	ANN_78		10	5,5	2	2
ANN_31		15	10,5	2	2	ANN_79		15	10,5	2	2
ANN_32		20	10,10	2	2	ANN_80		20	10,10	2	2
ANN_33		5	2,2,1	3	2	ANN_81		5	2,2,1	3	2
ANN_34		10	4,3,3	3	2	ANN_82		10	4,3,3	3	2
ANN_35		15	5,5,5	3	2	ANN_83		15	5,5,5	3	2
ANN_36		20	10,5,5	3	2	ANN_84		20	10,5,5	3	2
ANN_37	Resilient Backpropagation - trainrp	5	5	1	2						
ANN_38		10	10	1	2						
ANN_39		15	15	1	2						
ANN_40		20	20	1	2						
ANN_41		5	3,2	2	2						
ANN_42		10	5,5	2	2						
ANN_43		15	10,5	2	2						
ANN_44		20	10,10	2	2						
ANN_45		5	2,2,1	3	2						
ANN_46		10	4,3,3	3	2						
ANN_47		15	5,5,5	3	2						
ANN_48		20	10,5,5	3	2						

Tabla 4.2 Arquitecturas de redes neuronales utilizadas para el análisis del Caso de Estudio 1 – Distribución 1.

Etapa 3. Con las mejores arquitecturas de redes neuronales se realizará un análisis de sensibilidad al modelo del Caso de Estudio 1 para observar el comportamiento de la respuesta proporcionada por las redes neuronales ante cambios en parámetros importantes como la pendiente de fondo del cauce y el coeficiente de rugosidad.

Luego de analizar los resultados obtenidos, se analizarán otros canales o sistemas de canales con características geométricas e hidráulicas más complejas (Caso de Estudio 2 y Caso de Estudio 3), pero esta vez solo se tendrá los datos de los hidrogramas de entrada y de los hidrogramas de salida. La idea principal de esto es que con las mejores arquitecturas de las redes neuronales definidas en la anterior etapa y con los datos de entrada y los datos objetivos conocidos evaluar la nueva respuesta de las redes neuronales para una condición diferente de varias entradas y una salida. A continuación se describen los modelos utilizados para los Casos de Estudio 2 y 3.

- **Caso de Estudio 2**. El sistema utilizado como Caso de Estudio 2, está conformado por el tramo principal de un río del territorio colombiano (Cauce 3) de aproximadamente 1,60 Km de longitud, con varias curvas cerradas en la zona de análisis, la pendiente de fondo es del orden de 0,0015 m/m y el ancho de la sección varía entre 20 y 30 m. A este cauce principal descargan 2 cauces de menor capacidad denominados Cauce 1 y Cauce 2. El Cauce 1 tiene aproximadamente 1,3 Km de longitud, pocos cambios de dirección en su recorrido, la pendiente promedio del fondo es del orden de 0,004 m/m y el ancho de la sección varía entre 5 y 10 m. En cuanto al Cauce 2, este tiene aproximadamente 1,5 Km de longitud, pocos cambios de dirección en su recorrido, la pendiente promedio del fondo es del orden de 0,009 m/m y el ancho de la sección varía entre 5 y 12 m. La Figura 4.4 muestra la configuración en planta del caso de estudio mencionado, indicados con puntos de color rojo se muestran los sitios donde se localizan las secciones batimétricas. La Figura 4.5 muestra además de forma esquemática el perfil de fondo de los tres cauces analizados, exagerando la escala vertical para observar las irregularidades que estos puedan tener.

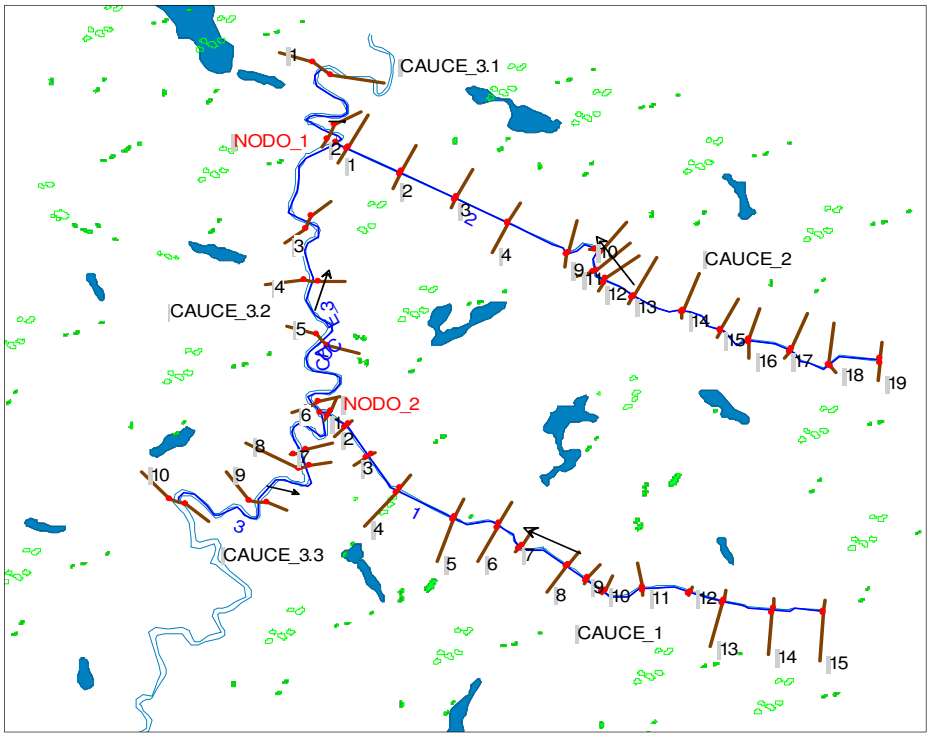

Figura 4.4 Trazado en planta – Caso de Estudio 2.

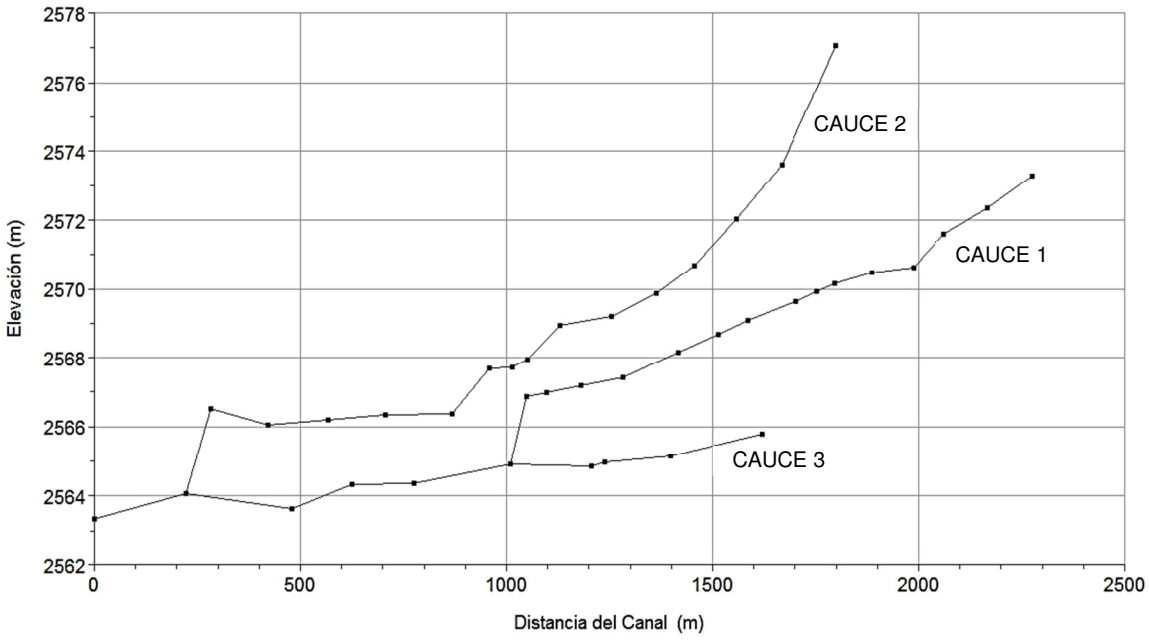

Figura 4.5 Perfil del fondo del cauce – Caso de Estudio 2.

- **Caso de Estudio 3**. El Caso de Estudio 3, está conformado por un tramo principal de un río del territorio colombiano (Cauce 1) de aproximadamente 2,0 Km de longitud, con varias curvas cerradas en la zona de análisis, la pendiente de fondo es del orden de 0,003 m/m y el ancho de la sección principal del cauce varía entre 12 y 30 m. A este cauce principal descarga un tributario denominado Cauce 2, el cual tiene aproximadamente 1,2 Km de longitud, con varios cambios de dirección en el recorrido analizado, la pendiente promedio del fondo es del orden de 0,009 m/m y el ancho de la sección varía entre 8 y 30 m en el cauce principal. La Figura 4.6 muestra la configuración en planta del caso de estudio mencionado; indicados con puntos de color rojo y líneas de color café se muestran los sitios donde se localizan las secciones batimétricas. La Figura 4.7 muestra además de forma esquemática el perfil del fondo de los dos cauces analizados; se exagera la escala vertical para observar las irregularidades que este pueda tener.

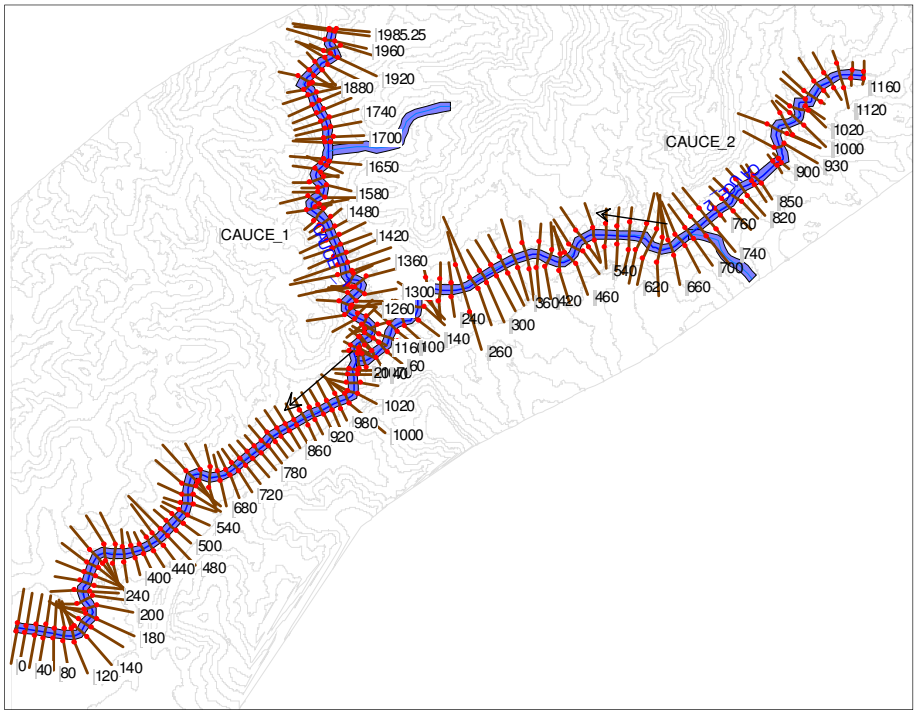

Figura 4.6 Trazado en planta – Caso de Estudio 3.

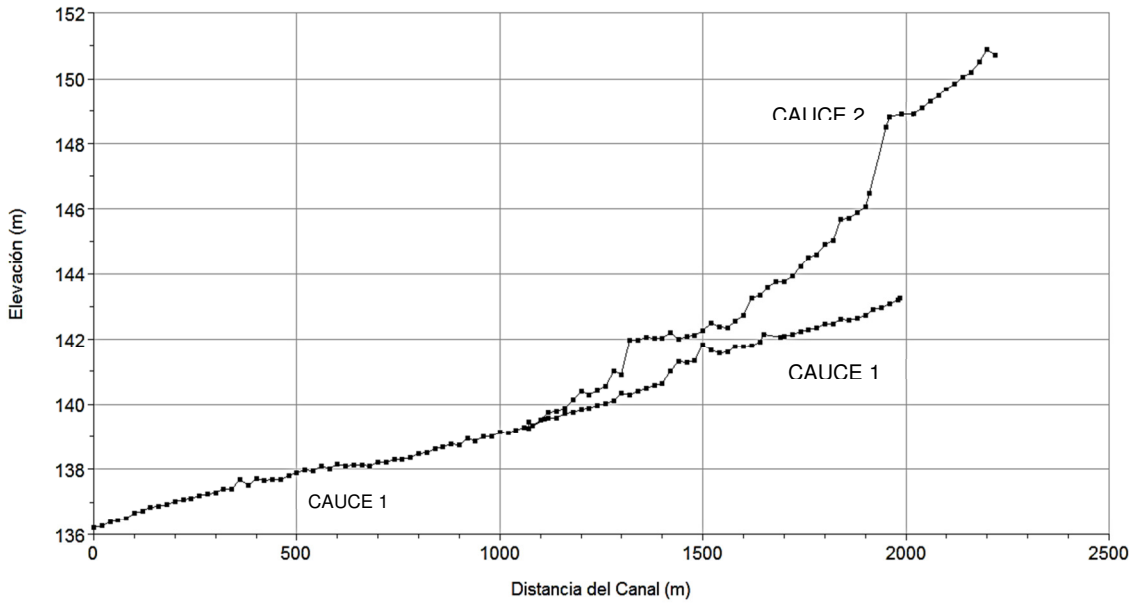

Figura 4.7 Perfil del fondo del cauce – Caso de Estudio 3.

Etapa 4. En este nivel de la investigación se busca validar u observar el comportamiento de la respuesta de las redes neuronales para condiciones de análisis diferentes. En esta etapa se somete nuevamente a evaluación por parte de las ANN los tres casos de estudio mencionados, pero esta vez las series de hidrogramas de entrada tendrán variaciones en la magnitud de los picos, en la localización de los mismos, en la forma y duración de los hidrogramas, lo que proporcionara salidas diferentes para alimentar las redes neuronales escogidas, es decir, aquellas con mejor desempeño en las Etapas 1 y 2.

Etapa 5. Finalmente se compararan todos los resultados logrados con las ANN y con el software de comprobación (HEC-RAS). De acuerdo con los resultados obtenidos en las Etapas 3 y 4 se podrá dar un juicio, sustentado en los resultados obtenidos mostrando las ventajas y desventajas de las redes neuronales artificiales en el tránsito de crecientes en canales con respecto a los métodos tradicionales. Además del análisis hidráulico se considerará como parámetro adicional de decisión un análisis de costos entre ambos métodos para determinar la viabilidad o no de utilizar ANN.

5. ANÁLISIS DE RESULTADOS

Como se describió en el capítulo anterior, el Caso de Estudio 1 es el más sencillo de los tres Casos de Estudio evaluados, este se utilizó como base para la evaluación de los Casos de Estudio 2 y 3, es decir, los resultados del análisis inicial para determinar qué tipos de arquitectura de redes neuronales son las que mejor desempeño presentan servirán de base para el desarrollo de los Casos de Estudio 2 y 3. Esto indica que para el análisis de los tres casos de estudio se utilizarán las mismas arquitecturas de ANN. A continuación se describe el procedimiento para determinar que arquitecturas de redes neuronales tienen el mejor desempeño, es decir, cuales se ajustan mejor al objetivo deseado.

5.1 CASO DE ESTUDIO 1

Una vez definido el modelo digital para el Caso de Estudio 1 y la información que sirve de entrada para dicho modelo, se realizó un análisis de flujo no uniforme con ayuda del software HEC-RAS, obteniéndose como resultado para la serie de hidrogramas de entrada de la Gráfica 4.1 la serie de hidrogramas de salida mostrada en la Gráfica 5.1.

Esta serie de hidrogramas de salida obtenidos pasan a ser ahora el objetivo buscado de cada una de las 84 arquitecturas de redes neuronales configuradas. El procedimiento utilizado para el montaje de cada red neuronal es el descrito en el Capítulo 3, mientras que la topología utilizada para cada red se muestra en la Tabla 4.2. Como ya se ha mencionado, uno de los objetivos es definir cuál configuración de red neuronal simulada tiene la mejor sensibilidad en cuanto a la predicción de la información, es decir, cual proporciona resultados más aproximados a los definidos como objetivos o *targets*, como se denominan en la interfaz del software de análisis, MATLAB®. A continuación se presenta el *script* general (en este caso el de la red neuronal 1, ANN_1) a partir del cual se realizan las modificaciones a los parámetros de diseño de la red neuronal, las líneas de código donde se muestran dichos parámetros se indican resaltadas en color rojo.

```
% Solve an Autoregression Problem with External Input with a NARX
Neural Network
% Script generated by NTSTOOL
% Created Fri Nov 07 20:58:53 COT 2014
%
% This script assumes these variables are defined:
```

```
%
%    IN_ANN_1 - input time series.
%    TAR_ANN_1 - feedback time series.

inputSeries = tonndata(IN_ANN_1,true,false);
targetSeries = tonndata(TAR_ANN_1,true,false);

% Create a Nonlinear Autoregressive Network with External Input
inputDelays = 1:2;
feedbackDelays = 1:2;
hiddenLayerSize = 5;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);

% Choose Input and Feedback Pre/Post-Processing Functions
% Settings for feedback input are automatically applied to feedback
output
% For a list of all processing functions type: help nnprocess
% Customize input parameters at: net.inputs{i}.processParam
% Customize output parameters at: net.outputs{i}.processParam
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
net.inputs{2}.processFcns = {'removeconstantrows','mapminmax'};

% Prepare the Data for Training and Simulation
% The function PREPARETS prepares timeseries data for a particular
network,
% shifting time by the minimum amount to fill input states and layer
states.
% Using PREPARETS allows you to keep your original time series data
unchanged, while
% easily customizing it for networks with differing numbers of delays,
with
% open loop or closed loop feedback modes.
[inputs,inputStates,layerStates,targets] =
preparets(net,inputSeries,{},targetSeries);

% Setup Division of Data for Training, Validation, Testing
% The function DIVIDERAND randomly assigns target values to training,
% validation and test sets during training.
% For a list of all data division functions type: help nndivide
net.divideFcn = 'divideblock';  % Divide data randomly
% The property DIVIDEMODE set to TIMESTEP means that targets are
divided
% into training, validation and test sets according to timesteps.
% For a list of data division modes type: help
nntype_data_division_mode
net.divideMode = 'value';  % Divide up every value
net.divideParam.trainRatio = 60/100;
net.divideParam.valRatio = 22/100;
net.divideParam.testRatio = 18/100;

% Choose a Training Function
```

```
% For a list of all training functions type: help nntrain
% Customize training parameters at: net.trainParam
net.trainFcn = 'trainlm';  % Levenberg-Marquardt

% Choose a Performance Function
% For a list of all performance functions type: help nnperformance
% Customize performance parameters at: net.performParam
net.performFcn = 'mse';  % Mean squared error

% Choose Plot Functions
% For a list of all plot functions type: help nnplot
% Customize plot parameters at: net.plotParam
net.plotFcns = {'plotperform','plottrainstate','plotresponse', ...
  'ploterrcorr', 'plotinerrcorr'};

% Train the Network
[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Test the Network
outputs = net(inputs,inputStates,layerStates);
errors = gsubtract(targets,outputs);
performance = perform(net,targets,outputs)

% Recalculate Training, Validation and Test Performance
trainTargets = gmultiply(targets,tr.trainMask);
valTargets = gmultiply(targets,tr.valMask);
testTargets = gmultiply(targets,tr.testMask);
trainPerformance = perform(net,trainTargets,outputs)
valPerformance = perform(net,valTargets,outputs)
testPerformance = perform(net,testTargets,outputs)

% View the Network
view(net)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, plotregression(targets,outputs)
%figure, plotresponse(targets,outputs)
%figure, ploterrcorr(errors)
%figure, plotinerrcorr(inputs,errors)

% Closed Loop Network
% Use this network to do multi-step prediction.
% The function CLOSELOOP replaces the feedback input with a direct
% connection from the outout layer.
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
[xc,xic,aic,tc] = preparets(netc,inputSeries,{},targetSeries);
```

```
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(netc,tc,yc)

% Early Prediction Network
% For some applications it helps to get the prediction a timestep
early.
% The original network returns predicted y(t+1) at the same time it is
given y(t+1).
% For some applications such as decision making, it would help to have
predicted
% y(t+1) once y(t) is available, but before the actual y(t+1) occurs.
% The network can be made to return its output a timestep early by
removing one delay
% so that its minimal tap delay is now 0 instead of 1.  The new network
returns the
% same outputs as the original network, but outputs are shifted left
one timestep.
nets = removedelay(net);
nets.name = [net.name ' - Predict One Step Ahead'];
view(nets)
[xs,xis,ais,ts] = preparets(nets,inputSeries,{},targetSeries);
ys = nets(xs,xis,ais);
earlyPredictPerformance = perform(nets,ts,ys)
```

Con este *script* se realiza el montaje y ejecución de las 84 arquitecturas de redes neuronales. En la Tabla 5.1 se muestra el desempeño para cada red neuronal en el Caso de Estudio 1, utilizando para la valoración y/o evaluación los indicadores, error medio cuadrático (MSE) y coeficiente de correlación (R^2), en color verde se resalta la red neuronal con mejor desempeño para cada algoritmo de entrenamiento utilizado. Por otro lado, la Gráfica 5.2 y la Gráfica 5.3 muestran mediante un diagrama de barras los valores obtenidos para el error medio cuadrático y el coeficiente de correlación de cada una de las arquitecturas analizadas.

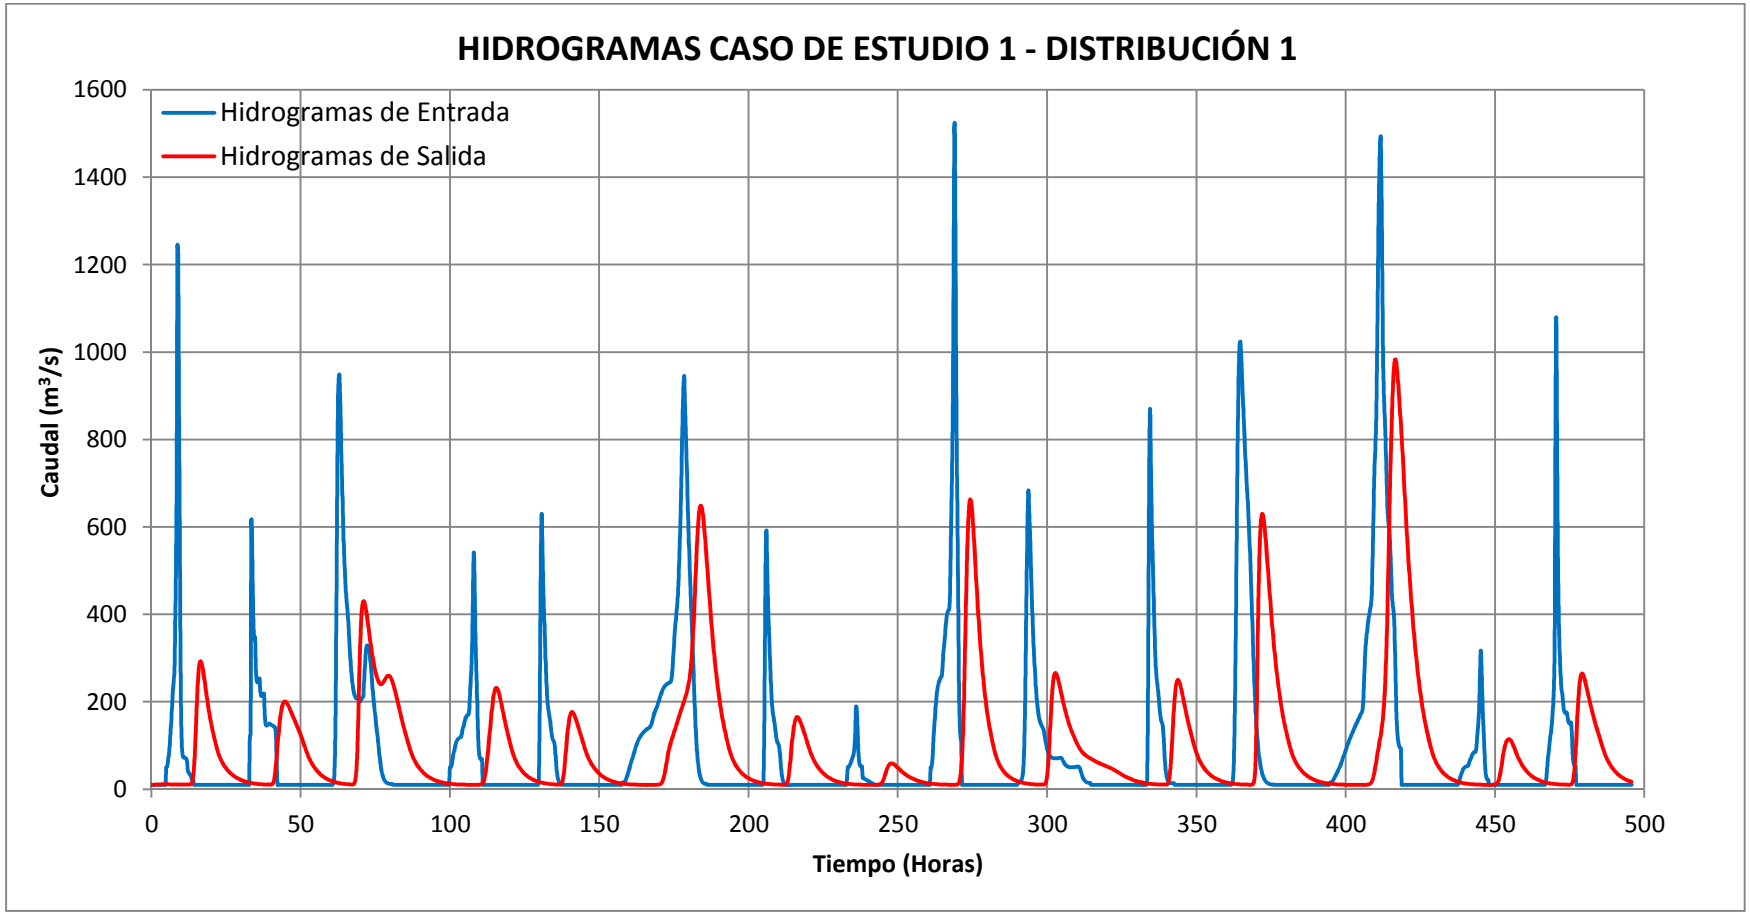

Gráfica 5.1Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 1 - Distribución 1.

	ERROR MAXIMO (m^3/s)			ERROR MINIMO (m^3/s)			DESEMPEÑO - MSE $(m^3/s)^2$				
NOMBRE	TRAINING	VALIDATON	TEST	TRINING	VALIDATON	TEST	TRAINING	VALIDATION	TEST	TOTAL	R^2 (%)
ANN_1	18.68	37.81	34.16	0.00	0.00	0.00	3.21	8.62	31.69	9.53	99.96
ANN_2	12.49	23.31	91.49	0.00	0.00	0.00	1.61	4.71	217.18	41.10	99.85
ANN_3	11.54	24.23	83.72	0.00	0.00	0.00	1.74	4.69	232.88	43.99	99.84
ANN_4	13.77	22.36	240.49	0.00	0.00	0.00	1.66	4.08	1269.56	230.42	99.10
ANN_5	13.20	24.59	29.82	0.00	0.00	0.00	2.00	4.76	29.57	7.57	99.97
ANN_6	10.86	24.47	133.31	0.00	0.00	0.00	1.81	4.74	462.07	85.30	99.68
ANN_7	7.80	17.53	73.94	0.00	0.00	0.00	0.81	2.00	117.23	22.03	99.90
ANN_8	8.34	16.26	124.18	0.00	0.00	0.00	0.79	3.01	430.90	78.70	99.66
ANN_9	18.02	36.86	51.29	0.00	0.00	0.01	3.69	8.30	64.54	15.66	99.94
ANN_10	16.25	32.15	85.25	0.00	0.00	0.00	2.56	7.84	150.71	30.39	99.88
ANN_11	17.72	20.92	52.12	0.00	0.00	0.00	2.02	4.97	72.77	15.40	99.94
ANN_12	16.68	37.36	158.98	0.00	0.00	0.01	6.02	10.73	1021.31	189.81	99.23
ANN_13	14.22	0	60.79	0.00	0	0.00	1.21	0	108.11	20.45	99.92
ANN_14	7.42	0	209.20	0.00	0	0.00	0.39	0	814.45	146.92	99.93
ANN_15	6.81	0	148.15	0.00	0	0.00	0.31	0	590.19	106.49	99.56
ANN_16	6.94	0	264.06	0.00	0	0.00	0.31	0	1182.90	213.18	99.10
ANN_17	15.68	0	106.65	0.00	0	0.00	1.66	0	197.56	36.92	99.85
ANN_18	7.17	0	71.14	0.00	0	0.00	0.41	0	70.28	12.99	99.95
ANN_19	6.30	0	58.38	0.00	0	0.00	0.33	0	55.46	10.25	99.96
ANN_20	7.59	0	176.89	0.00	0	0.00	0.40	0	579.14	104.57	99.62
ANN_21	32.68	0	49.94	0.00	0	0.00	3.84	0	59.87	13.92	99.95
ANN_22	9.01	0	132.30	0.00	0	0.00	0.74	0	551.81	99.93	99.63
ANN_23	9.21	0	104.14	0.00	0	0.00	0.83	0	189.23	34.74	99.84
ANN_24	7.02	0	181.20	0.00	0	0.00	0.38	0	672.83	121.42	99.47
ANN_25	140.74	172.32	210.45	0.02	0.03	0.11	278.45	417.92	1421.25	514.84	97.67
ANN_26	60.96	87.63	182.65	0.01	0.02	0.11	57.24	74.94	1044.00	238.75	98.95
ANN_27	124.71	83.53	248.71	0.02	0.01	0.03	128.72	138.81	1584.23	392.93	98.33
ANN_28	172.07	167.52	248.61	0.00	0.11	0.04	344.46	412.93	1951.39	648.77	97.65
ANN_29	159.19	182.06	401.32	0.01	0.01	0.37	349.75	470.51	6572.45	1496.40	95.56
ANN_30	131.61	163.76	292.23	0.00	0.04	0.03	417.71	466.05	4076.67	1086.96	95.28
ANN_31	132.86	159.98	542.38	0.03	0.04	0.00	197.76	289.07	7055.15	1452.18	93.55
ANN_32	159.65	176.70	214.75	0.03	0.02	0.09	357.13	488.86	1165.71	531.65	97.45
ANN_33	127.99	149.58	395.47	0.00	0.03	0.07	615.64	486.19	5701.84	1502.68	93.36
ANN_34	176.43	138.53	255.77	0.01	0.06	0.02	410.93	276.20	2661.45	786.38	96.32
ANN_35	124.40	139.55	218.92	0.00	0.02	0.00	209.26	300.05	1464.15	455.11	97.98
ANN_36	153.34	188.68	222.89	0.01	0.01	0.05	291.30	460.55	1627.50	569.05	97.45
ANN_37	169.51	163.32	374.91	0.04	0.00	0.03	488.99	482.69	4451.34	1200.83	94.44
ANN_38	113.26	72.86	356.63	0.00	0.03	0.01	75.53	63.59	3069.95	611.90	97.48
ANN_39	159.04	185.04	165.78	0.00	0.05	0.04	392.44	511.37	1060.50	538.86	97.61
ANN_40	61.70	52.69	528.06	0.00	0.00	0.03	35.90	41.75	3603.58	679.37	97.47
ANN_41	152.38	189.93	274.14	0.01	0.01	0.02	830.91	677.09	2909.51	1171.22	94.57
ANN_42	62.08	81.84	241.24	0.00	0.02	0.05	52.38	76.94	1904.18	391.10	98.46
ANN_43	86.94	100.91	132.21	0.01	0.01	0.10	89.19	88.37	561.56	174.04	99.18
ANN_44	170.11	95.99	302.10	0.00	0.12	0.15	356.39	217.36	3628.97	914.87	96.12
ANN_45	91.50	92.64	358.44	0.02	0.03	0.03	295.08	274.50	4621.78	1069.36	95.52
ANN_46	57.50	89.70	329.55	0.00	0.00	0.02	56.26	60.03	3761.17	723.97	97.00
ANN_47	53.93	74.66	283.01	0.00	0.00	0.01	34.71	50.80	2056.44	402.16	98.40
ANN_48	41.56	55.98	462.17	0.00	0.01	0.03	23.37	31.41	5548.11	1019.59	95.69

	ERROR MAXIMO (m^3/s)			ERROR MINIMO (m^3/s)			DESEMPEÑO - MSE $(m^3/s)^2$				
NOMBRE	TRAINING	VALIDATON	TEST	TRINING	VALIDATON	TEST	TRAINING	VALIDATION	TEST	TOTAL	R^2 (%)
ANN_49	203.46	233.31	403.52	0.01	0.00	0.02	755.62	850.93	5575.43	1644.16	92.39
ANN_50	150.95	163.12	405.79	0.01	0.00	0.00	506.11	480.50	3642.82	1065.09	95.89
ANN_51	345.48	222.41	565.26	0.03	0.06	0.01	1445.87	1543.26	5097.62	2124.61	91.73
ANN_52	372.72	184.67	384.66	0.01	0.01	0.02	1119.84	791.86	4736.37	1698.66	91.87
ANN_53	247.64	242.80	435.74	0.02	0.08	0.23	1581.69	912.12	6212.10	2267.85	89.21
ANN_54	148.30	201.61	442.86	0.01	0.03	0.03	796.69	807.47	7113.90	1936.16	91.45
ANN_55	132.59	187.05	238.08	0.01	0.05	0.07	404.43	515.17	1546.57	634.38	97.09
ANN_56	157.89	120.81	314.66	0.02	0.01	0.07	471.09	406.93	4274.45	1141.58	94.87
ANN_57	165.15	135.71	654.60	0.03	0.13	0.00	755.97	792.61	12778.84	2928.15	86.71
ANN_58	279.14	254.61	507.54	0.20	0.13	0.31	1881.40	1050.60	8864.37	2955.56	86.43
ANN_59	371.62	265.02	419.06	0.00	0.00	0.03	1022.41	913.60	7170.32	2105.09	90.38
ANN_60	229.89	177.36	494.23	0.04	0.07	0.03	1799.70	1288.53	10273.82	3212.59	86.04
ANN_61	158.57	194.16	364.74	0.01	0.01	0.06	408.99	557.70	4749.15	1222.94	94.71
ANN_62	64.54	53.94	543.51	0.01	0.01	0.02	102.95	80.02	8038.45	1526.30	93.30
ANN_63	100.65	53.27	347.81	0.01	0.04	0.02	155.74	83.87	2941.45	641.35	97.63
ANN_64	147.30	166.62	183.65	0.01	0.07	0.08	521.89	511.23	1077.30	619.52	97.42
ANN_65	246.72	240.36	435.50	0.00	0.08	0.11	1566.76	863.78	6464.23	2293.65	89.22
ANN_66	63.30	80.38	247.34	0.00	0.05	0.00	72.63	89.87	1633.97	357.46	98.40
ANN_67	163.77	184.64	317.67	0.00	0.03	0.00	403.37	510.81	2882.02	873.16	96.14
ANN_68	126.56	176.01	397.15	0.01	0.03	0.00	327.20	449.27	4076.28	1028.89	95.37
ANN_69	31.54	54.87	113.94	0.01	0.00	0.01	18.41	23.48	400.51	88.30	99.68
ANN_70	183.46	185.26	265.63	0.02	0.01	0.02	682.53	443.95	1503.44	777.80	96.28
ANN_71	140.73	163.93	272.14	0.08	0.02	0.02	438.49	498.77	2523.27	827.01	96.29
ANN_72	130.10	146.98	443.66	0.02	0.01	0.06	395.64	430.95	6139.48	1437.30	93.62
ANN_73	117.04	148.15	256.73	0.01	0.01	0.13	286.43	382.31	2127.96	639.00	97.12
ANN_74	125.70	139.93	386.89	0.01	0.04	0.00	309.95	392.11	3481.83	898.96	95.81
ANN_75	136.58	183.58	417.16	0.00	0.02	0.05	372.21	502.52	3983.01	1050.82	95.22
ANN_76	142.31	156.49	208.86	0.01	0.07	0.04	269.13	370.07	1311.49	478.96	98.07
ANN_77	41.04	46.91	151.85	0.00	0.00	0.01	26.29	26.45	753.35	157.19	99.37
ANN_78	149.51	204.57	401.50	0.03	0.10	0.27	397.11	580.46	4251.01	1131.15	95.36
ANN_79	136.01	188.23	245.16	0.03	0.01	0.04	433.20	506.56	1750.49	686.45	97.22
ANN_80	101.88	120.43	142.00	0.01	0.02	0.00	210.53	238.29	877.56	336.70	98.54
ANN_81	42.94	50.48	376.41	0.02	0.02	0.03	41.84	40.02	3362.99	639.25	97.61
ANN_82	164.06	162.81	202.29	0.01	0.00	0.02	460.50	405.25	1748.85	680.25	96.80
ANN_83	152.55	191.90	124.50	0.01	0.07	0.01	291.94	402.74	438.82	342.76	98.36
ANN_84	119.71	137.72	323.07	0.02	0.01	0.05	283.76	363.51	3922.09	956.21	95.79

Tabla 5.1 Resultados del proceso de entrenamiento para cada arquitectura – Caso de Estudio 1 – Distribución 1.

5.1.1 Desempeño de las Redes Neuronales – Caso de Estudio 1

Las arquitecturas con el mejor desempeño según el tipo de algoritmo de entrenamiento, es decir, la mejor para cada uno de estos son las siguientes redes: ANN_5, ANN_19, ANN_26, ANN_43, ANN_55, ANN_69 y ANN_77 (véase valores resaltados en la Tabla 5.1). La Gráfica 5.4 muestra el comportamiento de los datos arrojados por estas redes en la etapa de prueba, ya que dicha etapa define que tan bien es la generalización de una red neuronal, con esto no se quiere decir que estas sean las arquitecturas con mejor desempeño a nivel general.

En la Gráfica 5.2 y Gráfica 5.3 se observa que las redes neuronales que presentan un mejor desempeño son las 24 primeras arquitecturas, es decir, aquellas que utilizan el algoritmo de entrenamiento de Levenberg-Marquardt y el algoritmo de Bayesian Regularization, pues son las que muestran un R^2 más próximo al 100% y el error medio cuadrático más cercano a cero. En la Tabla 5.1 se nota además que, para la mayoría de redes con un mayor número de neuronas ocultas, 20 en este caso, el desempeño mostrado en relación a las demás es bajo, y que las configuraciones con dos capas ocultas muestran los mejores valores de desempeño. En cuanto a los valores de desempeño más bajos, estos se presentan en redes con el mayor número de neuronas y mayor número de capas ocultas (3 capas ocultas).

Teniendo en cuenta lo anterior, se escogió para el análisis del Caso de Estudio 1 las cinco redes con el mejor desempeño, es decir, aquellas cuyo error medio cuadrado (MSE) sea lo más cercano a cero y R^2 lo más cercano al 100%. Entre las que utilizan el algoritmo de Levenberg-Marquardt se seleccionan la red ANN_1 y la ANN_5, mientras que las mejores utilizando el algoritmo de Bayesian Regularization son la ANN_18, ANN_19 y ANN_21. En la Gráfica 5.5 se muestra los resultados obtenidos con estas redes en la etapa de prueba; en esta se aprecia que tan buenos son los resultados en comparación con los *targets*. Al igual que para la gran mayoría de arquitecturas utilizadas, el mayor grado de imprecisión se observa en la estimación de los caudales pico, tal como se puede notar en la Gráfica 5.4 y Gráfica 5.5.

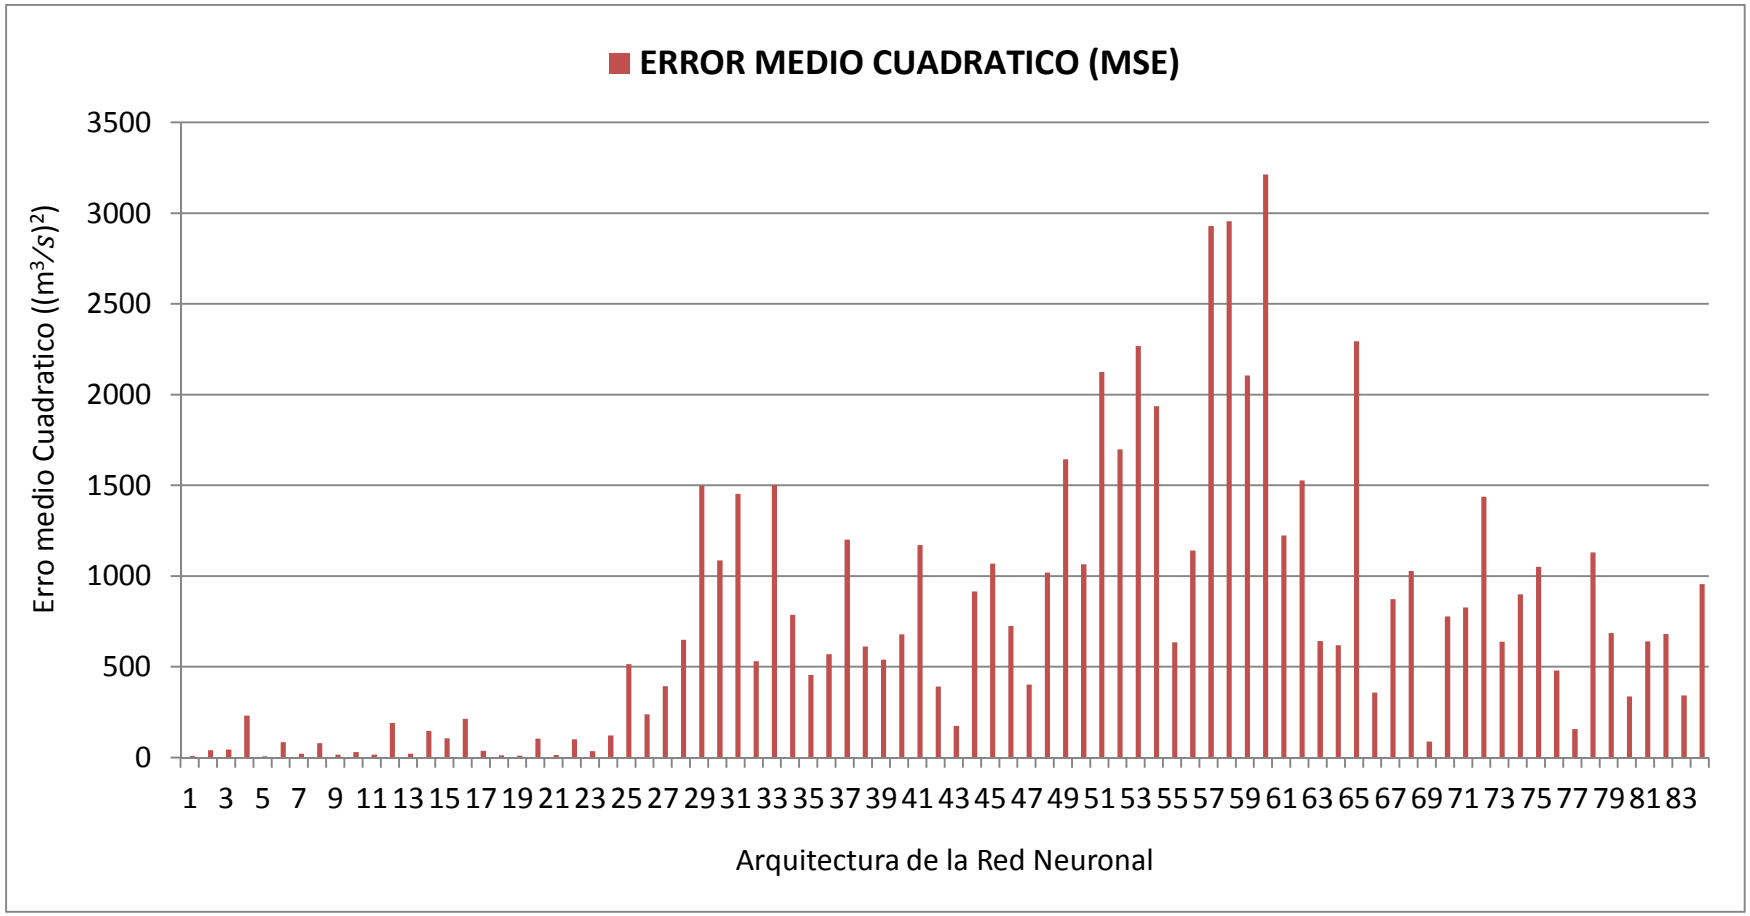

Gráfica 5.2. Desempeño (MSE) para cada una de la Redes neuronales analizadas – Caso de Estudio 1 – Distribución 1.

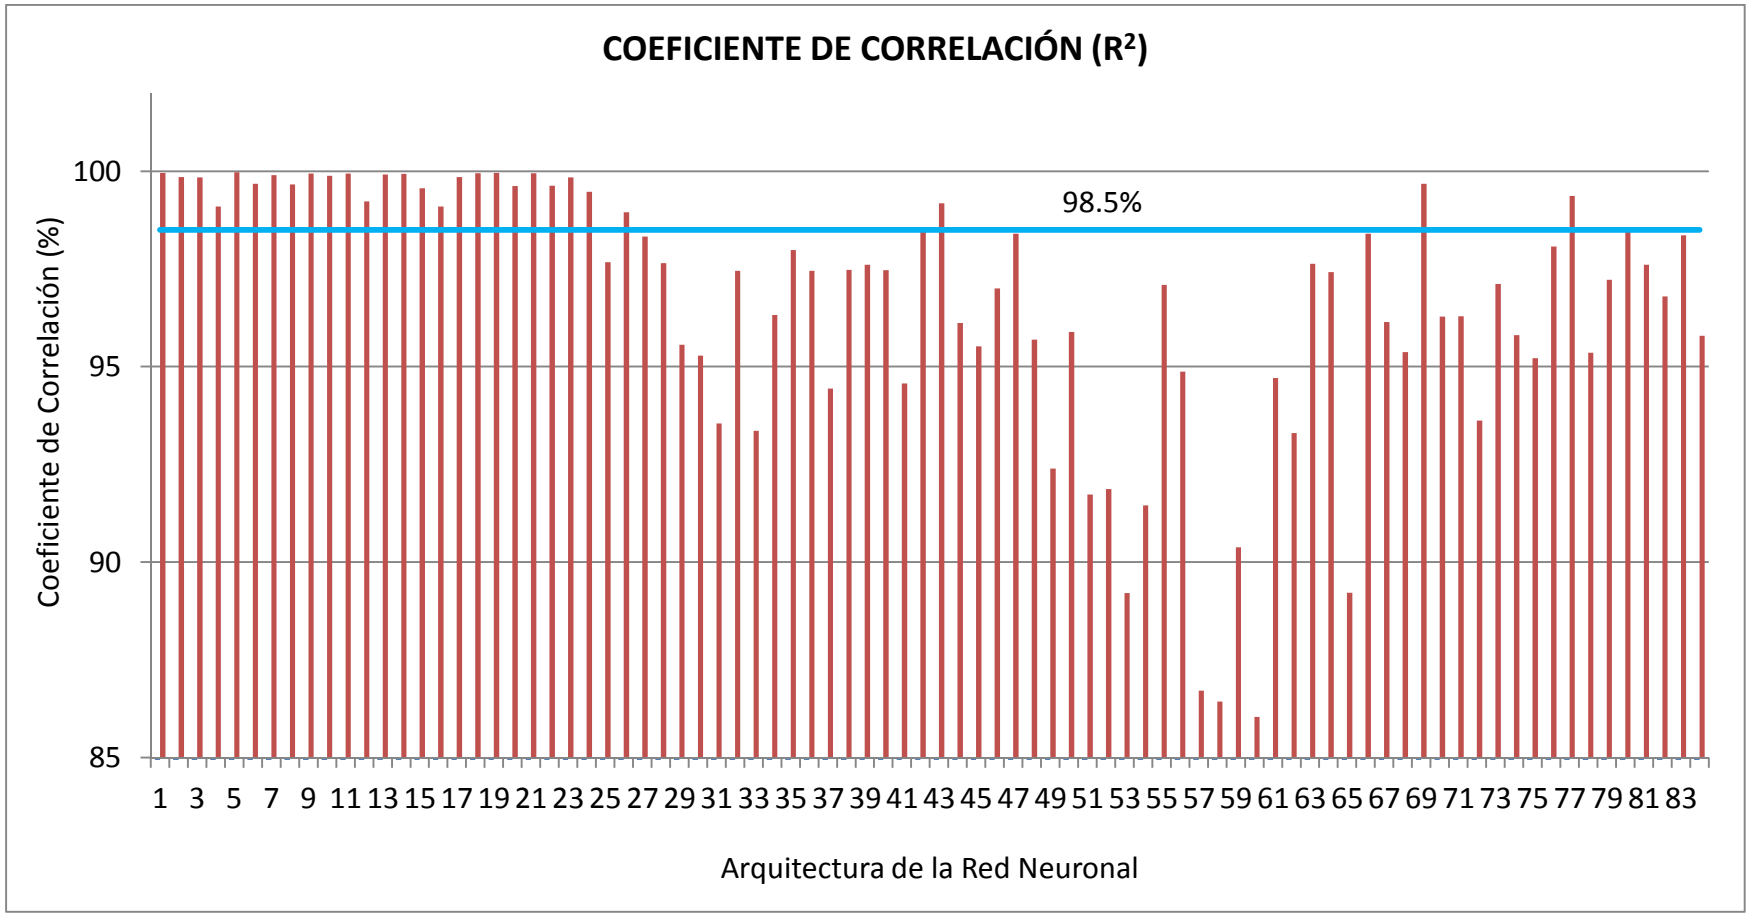

Gráfica 5.3. Coeficiente de correlación (R^2) para cada una de las Redes neuronales analizadas – Caso de Estudio 1 – Distribución 1.

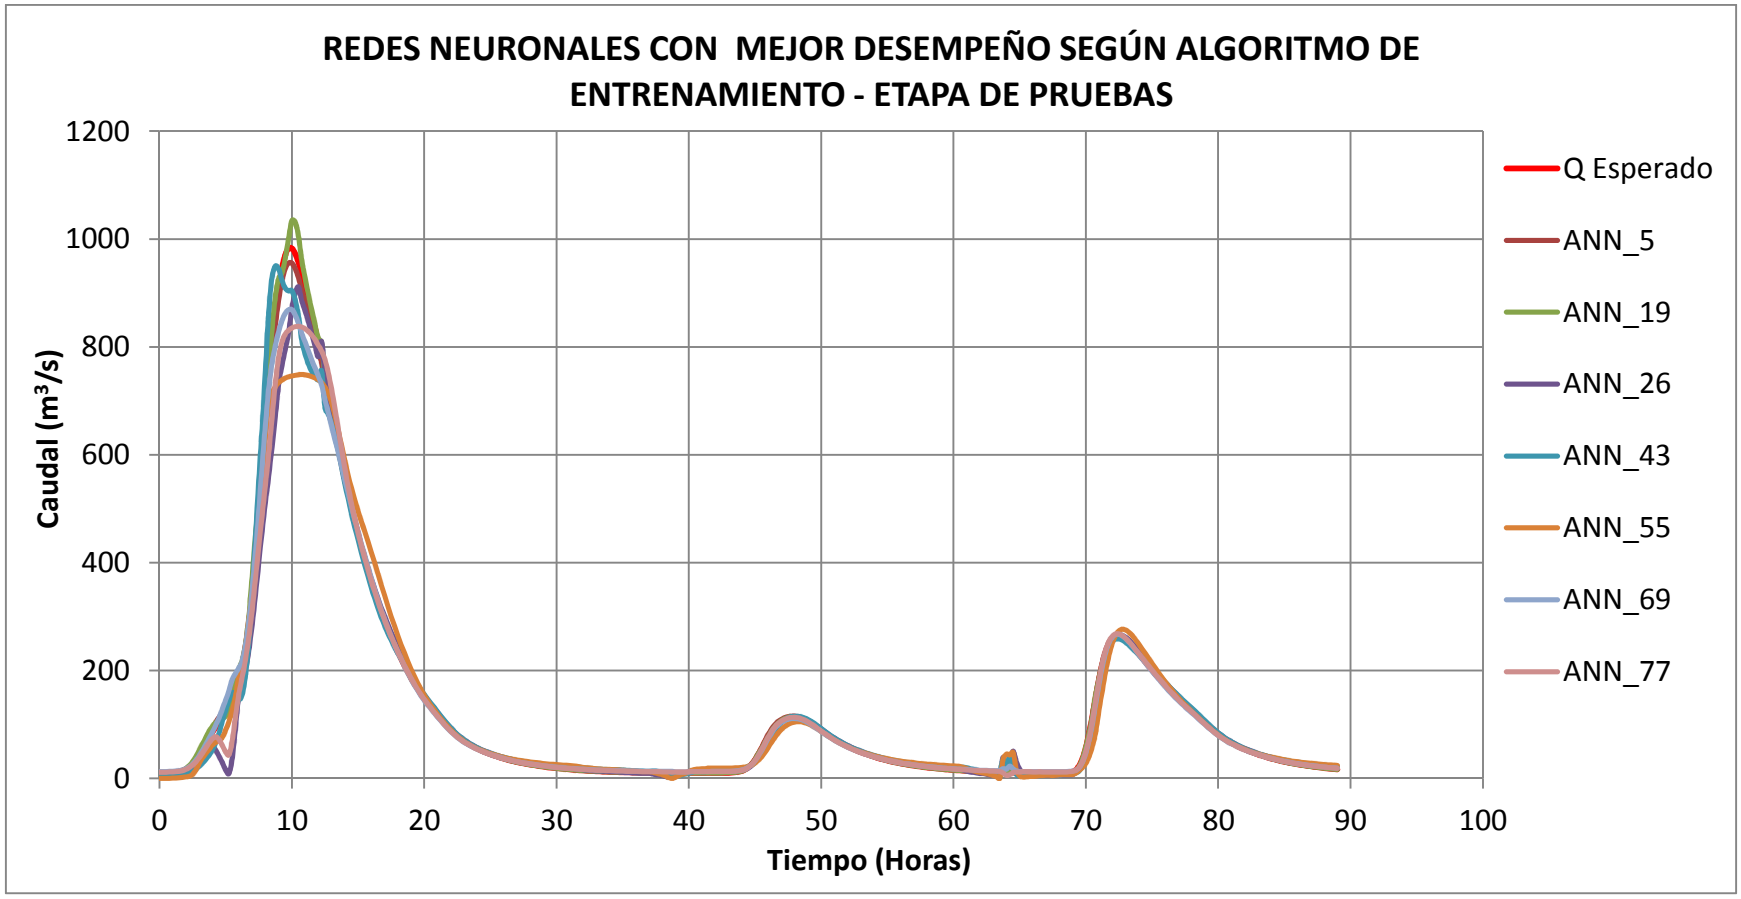

Gráfica 5.4. Redes neuronales con mejor desempeño según el algoritmo de entrenamiento – Caso de Estudio 1 – Distribución 1.

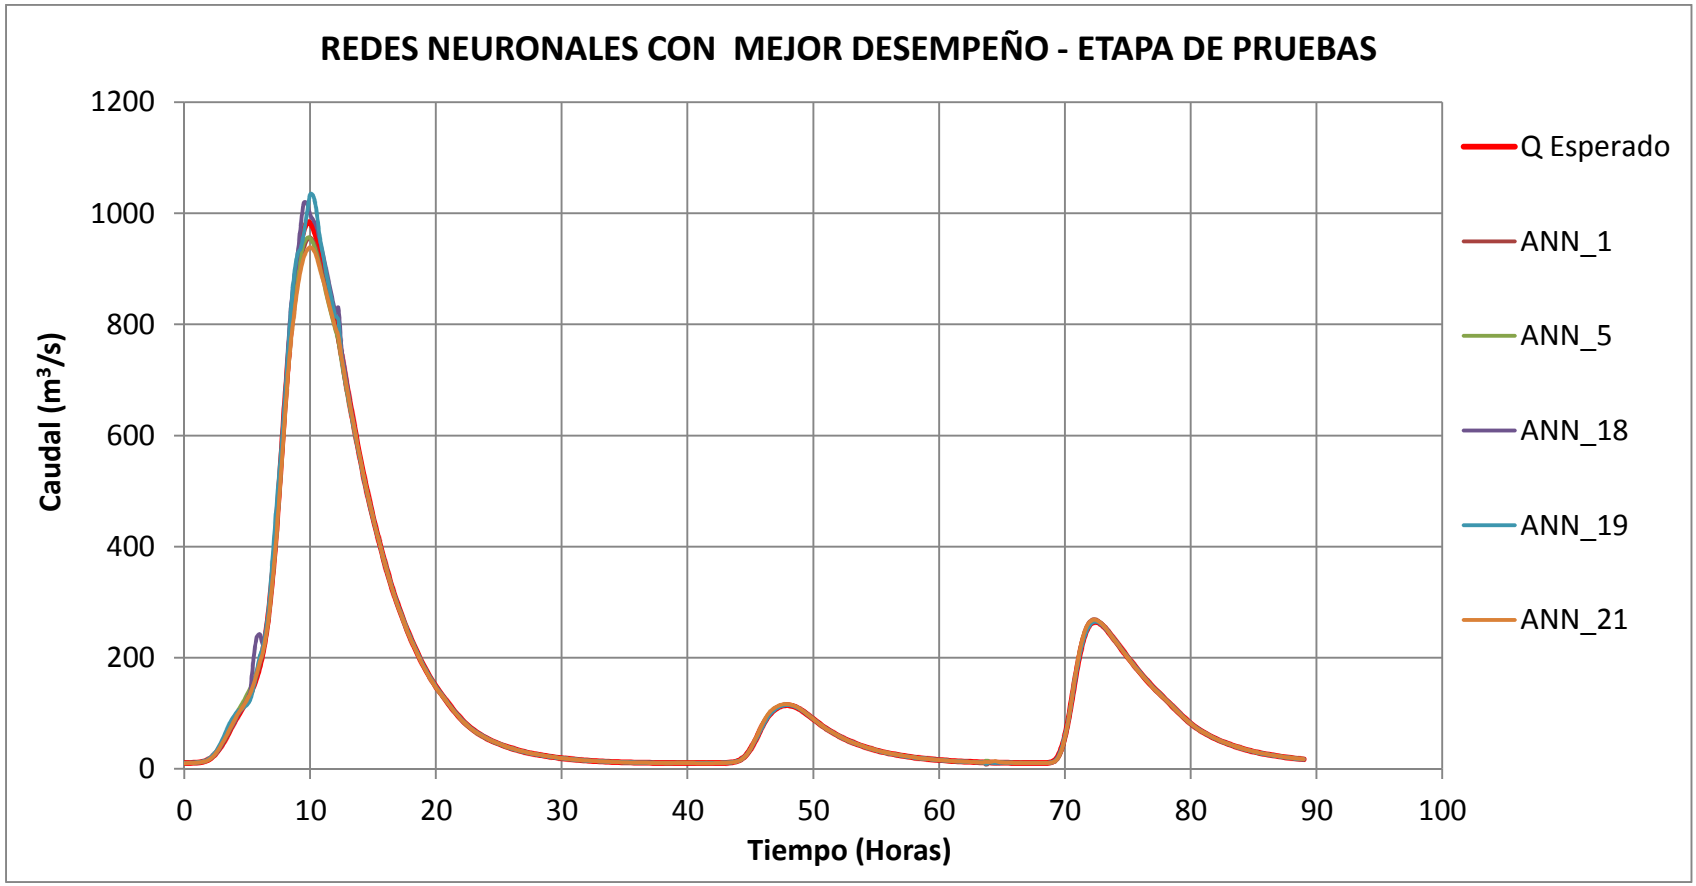

Gráfica 5.5. Redes neuronales con mejor desempeño en la etapa de prueba – Caso de Estudio 1 – Distribución 1.

5.1.2 Correlación de Resultados – Caso de Estudio 1

Además de la evaluación de las redes mediante la función de desempeño MSE, se tiene en cuenta también el valor del coeficiente de correlación (R^2) para estimar que arquitecturas muestran el mejor comportamiento. El criterio R^2 es, en esencia, una medida global del rendimiento del modelo analizado con respecto al del modelo de base, y está estrechamente relacionado con el de mínimos cuadrados. Matemáticamente se pude expresar como lo muestra la Ecuación 21.

$$R^2 = \frac{F_0 - F}{F_0} \qquad \textbf{Ecuación 21}.$$

donde,

$$F = \sum (Q_{Estimado} - Q_{Observado})^2$$

$Q_{Estimado}$ = Caudal estimado por la red neuronal (m^3/s)

$Q_{Observado}$ = Caudal observado o medido en HEC-RAS (m^3/s)

$$F_0 = \sum (Q_{Observado} - Q_{Promedio})^2$$

$Q_{Promedio}$ = Promedio de los caudales observados para el periodo de Calibración escogido

La Tabla 5.1 y la Gráfica 5.3 muestran el valor del coeficiente de correlación para cada una de las redes neuronales estudiadas; de estos resultados se puede resaltar que el rango de variación de la respuesta para el total de redes neuronales se encuentra entre el 86,04% y el 99,97%, y que para valores de R^2 superiores al 98.5% los resultados obtenidos tienen una buena aproximación y son muy cercanos a los objetivos. Por otro lado, para las cinco arquitecturas con mejor desempeño (ANN_1, ANN_5, ANN_18, ANN_19 y ANN_21) el mínimo valor de R^2 se sitúa en 99,95% mostrando así el buen desempeño de las redes. Las Gráfica 5.6 a Gráfica 5.10 muestran la forma como se correlacionan los datos para cada una de estas.

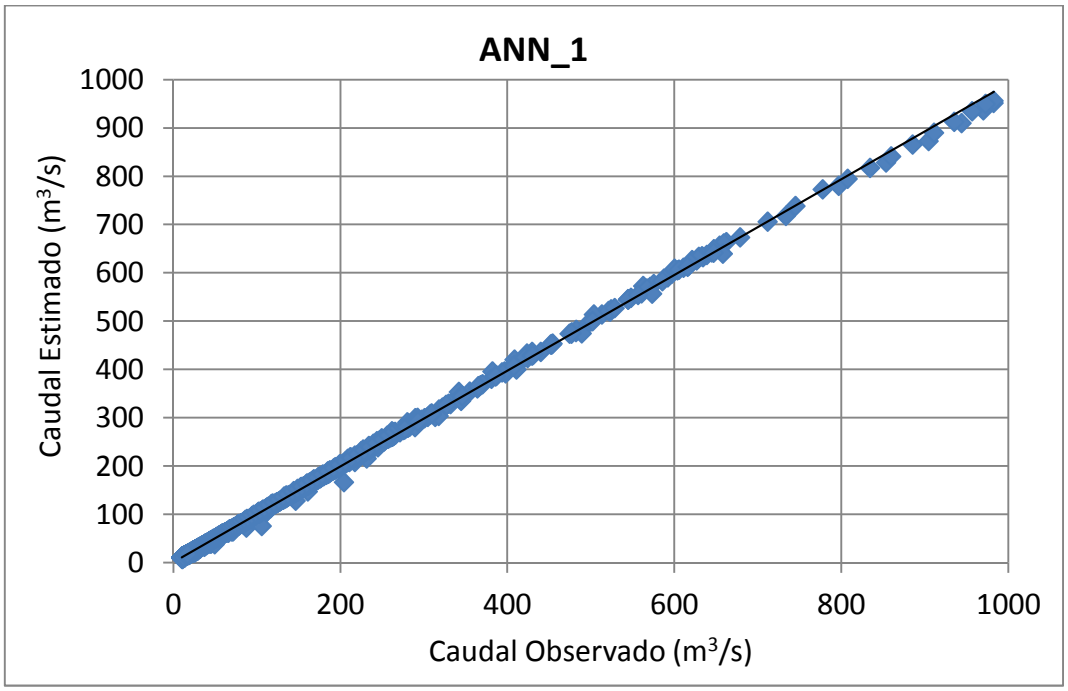

Gráfica 5.6 Correlación de datos para arquitectura 1 (ANN_1).

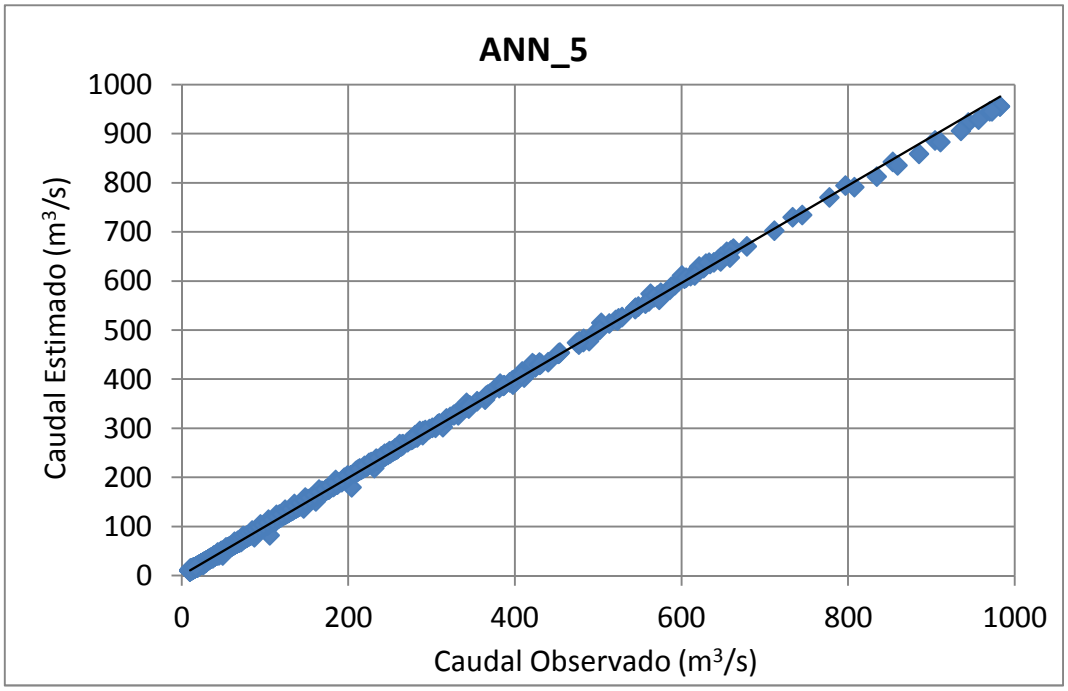

Gráfica 5.7 Correlación de datos para arquitectura 5 (ANN_5).

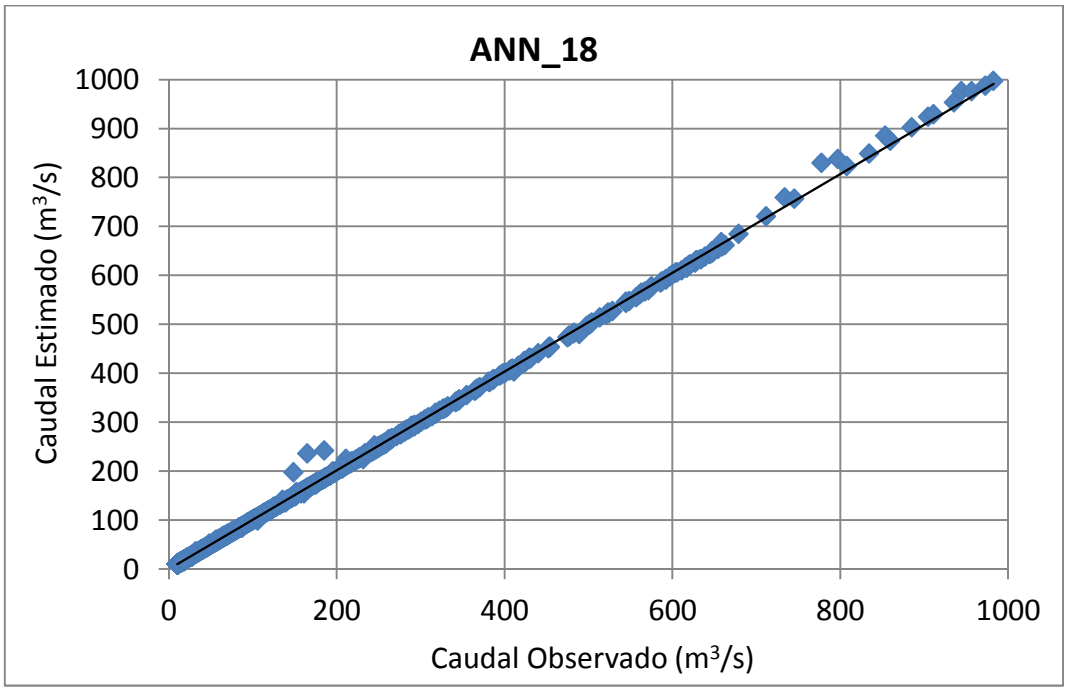

Gráfica 5.8 Correlación de datos para arquitectura 18 (ANN_18).

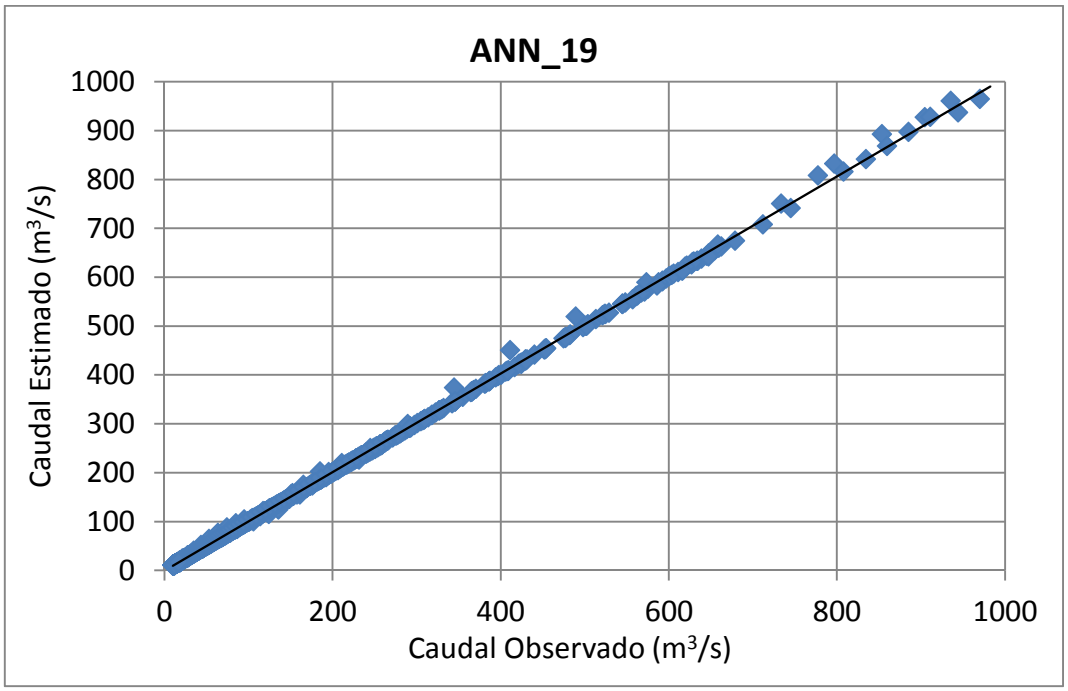

Gráfica 5.9 Correlación de datos para arquitectura 19 (ANN_19).

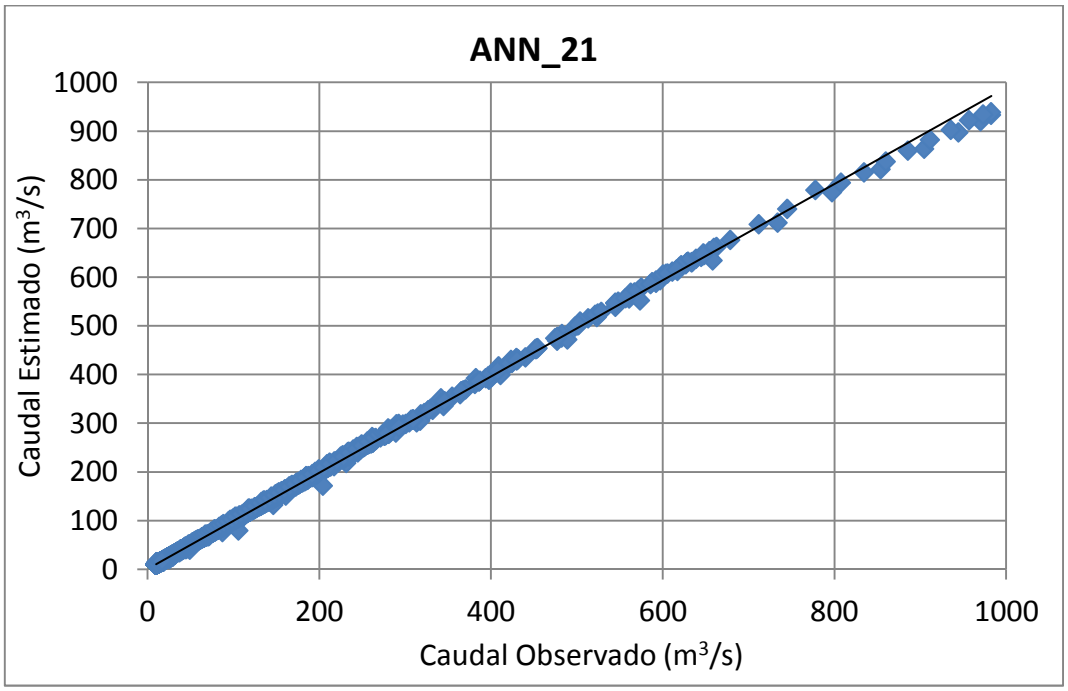

Gráfica 5.10 Correlación de datos para arquitectura 21 (ANN_21).

De las anteriores graficas se puede resaltar que el ajuste de los datos es muy bueno en comparación con los datos buscados, lo que permite concluir que estas redes neuronales serán las utilizadas para evaluar y analizar los modelos de los Casos de Estudio 2 y 3.

5.1.3 Análisis de sensibilidad – Caso de Estudio 1

Con el fin de determinar si el desempeño de las redes neuronales artificiales se ve influenciado por la variación de los parámetros hidráulicos de un canal, por ejemplo, pendiente de fondo y coeficiente de rugosidad, se analizó la respuesta proporcionada por la arquitectura con mejor desempeño, es decir, la ANN_5 para diferentes valores de pendiente y coeficiente de rugosidad del canal utilizado como Caso de Estudio 1. Los resultados de esta evaluación se muestran en la Tabla 5.2 y en la Tabla 5.3. Resaltado en color verde se observa en ambas tablas el valor de los parámetros de diseño del modelo, mientras que los demás valores corresponden a la variación hecha.

PENDIENTE (m/m)	DESEMPEÑO - MSE $(m^3/s)^2$			DESEMPEÑO TOTAL - MSE $(m^3/s)^2$	R^2
	ENTRENAMIENTO	VALIDACIÓN	PRUEBA		
0,00001	0,00366	0,00377	0,19880	0,03881	100,00%
0,00005	0,01705	0,02400	1,59252	0,30216	99,99%
0,0001	0,03813	0,05565	3,22481	0,61559	99,99%
0,0005	0,15948	0,27049	0,73701	0,28786	100,00%
0,001	2,76193	5,56715	780,47515	143,36746	99,48%
0,00125	4,12771	8,83056	457,08656	86,69493	99,69%
0,005	26,57324	46,96720	788,53342	168,21274	99,49%

Tabla 5.2 Análisis de sensibilidad mediante la ANN_5 para cambios en la pendiente de fondo – Caso de Estudio 1 – Distribución 1.

COEFICIENTE DE RUGOSIDAD (n)	DESEMPEÑO - MSE $(m^3/s)^2$			DESEMPEÑO TOTAL - MSE $(m^3/s)^2$	R^2
	ENTRENAMIENTO	VALIDACIÓN	PRUEBA		
0,010	0,001881	0,00373	0,37562	0,06956	100,00%
0,020	11,17993	19,22280	57,45330	21,27857	99,92%
0,035	5,92042	15,01370	38,39107	13,76566	99,95%
0,040	3,63528	9,41462	22,78181	8,35311	99,97%
0,045	3,03588	7,38430	181,94375	36,19595	99,87%
0,050	3,89135	8,51126	402,33391	76,62739	99,72%
0,070	1,91737	3,53659	9,97218	3,72346	99,98%
0,090	1,67460	2,63508	26,98906	6,44251	99,96%
0,100	1,36033	1,93455	18,63533	4,59616	99,97%
0,150	0,26091	0,35282	2,29447	0,64717	99,99%
0,200	0,10342	0,09854	10,83091	2,03330	99,98%
0,300	0,05757	0,02715	1,97001	0,39511	99,99%
0,500	0,001883	0,00375	0,37554	0,06955	100,00%

Tabla 5.3 Análisis de sensibilidad mediante la ANN_5 para cambios en el coeficiente de rugosidad – Caso de Estudio 1 – Distribución 1.

Analizando los resultados se observa que el desempeño de la red neuronal evaluada (ANN_5) no presenta una gran variación con respecto a los valores objetivos deseados para diferentes valores de pendiente y coeficiente de rugosidad. Basados en los resultados obtenidos para el Caso de Estudio 1, se puede afirmar que las ANN no son sensibles a variaciones de pendiente o rugosidad, es decir, la respuesta de la red neuronal no se ve afectada.

5.1.4 Otras distribuciones de hidrogramas - Caso de Estudio 1

Para continuar evaluando el desempeño de las redes neuronales artificiales seleccionadas y el grado de acierto de la respuesta proporcionada por estas, en esta etapa se busca determinar cómo afecta la configuración y la distribución de la serie de hidrogramas de entrada la respuesta dada por las redes neuronales o si por el contrario le es indiferente. Para esto, adicional a la serie de hidrogramas evaluada inicialmente para el Caso de Estudio 1, se construyeron dos series de hidrogramas de entrada diferentes entre sí; para lograr esto se cambió la duración, la forma, la magnitud y localización de los picos de los hidrogramas, lo que proporcionó series de hidrogramas diferentes que fueron evaluados para cada una de las cinco arquitecturas de redes neuronales escogidas. Para evitar que las redes neuronales analizadas quedaran sobreentrenadas a causa de una inadecuada escogencia y disposición de los datos de entrada, se evitó que hidrogramas con alturas o picos similares quedaran juntos en un mismo grupo de datos, es decir, entrenamiento, prueba y/o validación. La serie de hidrogramas analizada en principio se denominará Distribución 1, mientas que las otras dos se denominaran Distribución 2 y Distribución 3. En la Gráfica 5.11 se muestran los hidrogramas de entrada y objetivo para la Distribución 2 mientras la Gráfica 5.12 muestra los hidrogramas de entrada y objetivo para la Distribución 3. La forma como se realizó la división de los datos de entrada para cada distribución de hidrogramas se muestra en la Tabla 5.4.

DISTRIBUCIÓN	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
1	60%	49%	33%	22%	19%	20%	18%	32%	47%	100%	100%	100%
2	52%	43%	33%	23%	20%	20%	25%	37%	47%	100%	100%	100%
3	55%	44%	35%	20%	19%	20%	25%	37%	45%	100%	100%	100%

Tabla 5.4 Porcentaje de datos para cada etapa según la distribución de hidrogramas – Caso de Estudio 1.

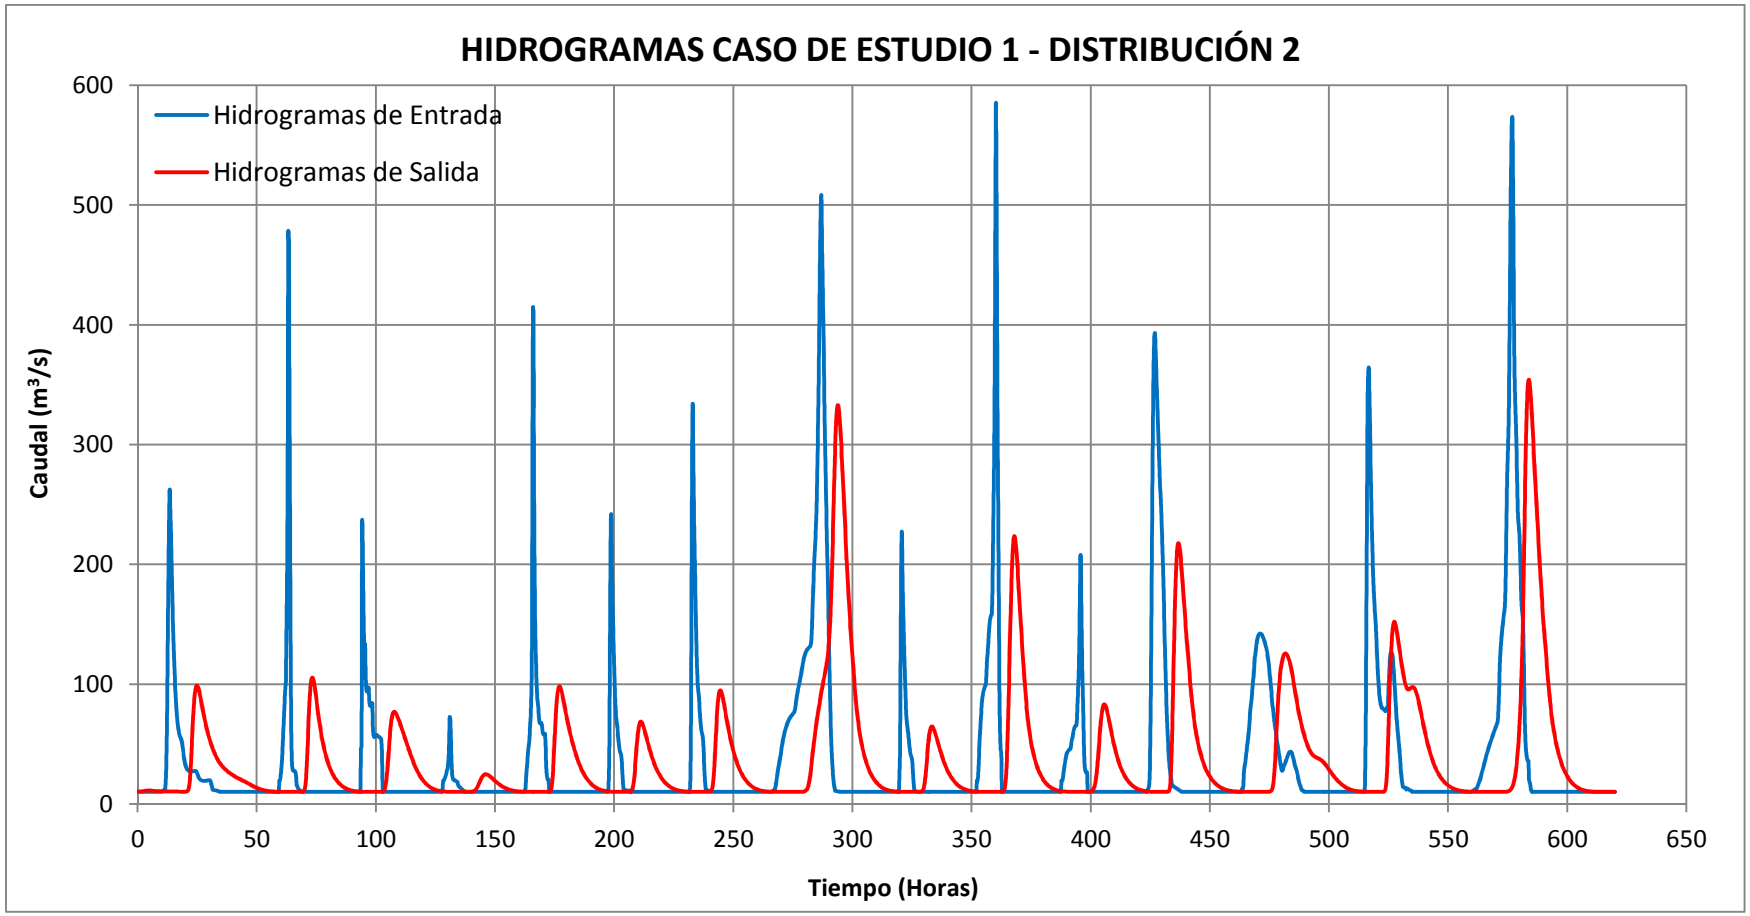

Gráfica 5.11 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 1 - Distribución 2.

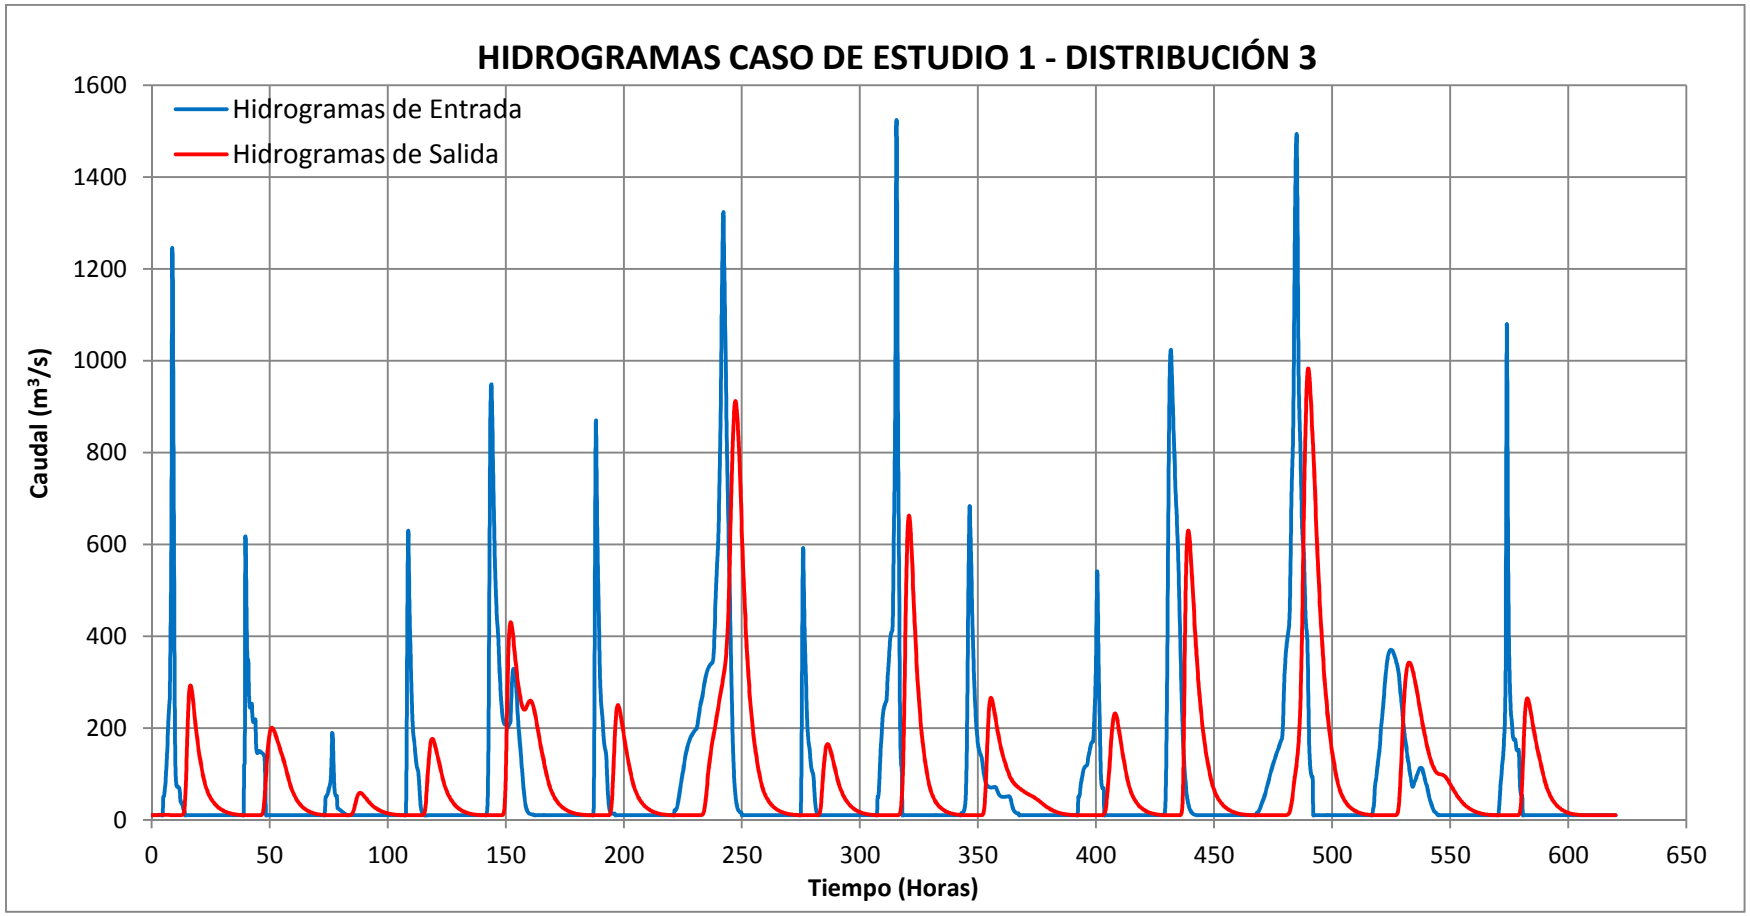

Gráfica 5.12 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 1 - Distribución 3.

Para cada una de las tres series de hidrogramas se varió el porcentaje de datos utilizados para entrenamiento, validación y prueba de las cinco redes neuronales ya seleccionadas como de mejor desempeño (Véase Tabla 5.4). La finalidad de este ejercicio fue la de conocer la forma como varía el desempeño de las redes neuronales a medida que disminuye el porcentaje de datos utilizados para entrenamiento y validación. En la Tabla 5.5 y en la Tabla 5.6 se muestra el desempeño (MSE) y el coeficiente de correlación (R^2) entre los datos esperados y los arrojados por las redes neuronales según la distribución de los datos en las series de hidrogramas.

CASO DE ESTUDIO 1 - MSE $(m^3/s)^2$												
DISTRIBUCIÓN DE HIDROGRÁMAS N°1	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		60%	49%	33%	22%	19%	20%	18%	32%	47%	100%	100%	100%
	ANN_1	3,215	1,891	1,487	8,615	4,383	22,676	31,691	85,755	232,471	9,529	29,201	114,287
	ANN_5	1,995	3,077	2,251	4,762	4,011	71,661	29,568	111,260	392,258	7,567	37,873	199,436
	ANN_18	0,412	0,317	0,189	-	-	-	70,276	101,340	134,023	12,988	32,644	63,091
	ANN_19	0,327	0,356	0,153	-	-	-	55,455	66,682	191,048	10,250	21,580	89,873
	ANN_21	3,837	2,569	1,947	-	-	-	59,870	88,070	79,010	13,923	29,929	38,166
DISTRIBUCIÓN DE HIDROGRÁMAS N°2	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		52%	43%	33%	23%	20%	20%	25%	37%	47%	100%	100%	100%
	ANN_1	0,141	1,985	3,714	0,492	23,290	53,977	0,337	16,891	49,033	0,271	11,761	35,066
	ANN_5	0,394	10,544	0,077	0,385	119,275	26,696	0,981	105,967	22,250	0,539	67,597	15,822
	ANN_18	0,014	0,011	0,017	-	-	-	2,766	2,603	1,903	0,702	0,970	0,904
	ANN_19	0,029	0,013	0,010	-	-	-	4,121	3,577	1,808	1,052	1,332	0,855
	ANN_21	0,155	0,155	0,129	-	-	-	0,319	0,440	0,796	0,196	0,261	0,443
DISTRIBUCIÓN DE HIDROGRÁMAS N°3	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		55%	44%	35%	20%	19%	20%	25%	37%	45%	100%	100%	100%
	ANN_1	2,760	2,869	3,354	6,652	4,810	23,460	2,898	8,021	11,396	3,573	5,144	10,994
	ANN_5	2,529	2,217	1,575	6,771	4,399	60,991	6,235	5,770	55,149	4,304	3,946	37,566
	ANN_18	0,526	0,643	0,427	-	-	-	41,311	39,697	20,286	10,722	15,093	9,364
	ANN_19	0,307	0,286	0,251	-	-	-	42,147	95,584	121,180	10,767	35,546	54,669
	ANN_21	3,831	2,781	3,549	-	-	-	3,721	5,611	5,343	3,803	3,828	4,356

Tabla 5.5 Desempeño para cada una de las redes neuronales según la distribución de la serie de hidrogramas – Caso de Estudio 1.

CASO DE ESTUDIO 1 - R^2 (%)													
DISTRIBUCIÓN DE HIDROGRÁMAS N°1	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		60%	49%	33%	22%	19%	20%	18%	32%	47%	100%	100%	100%
	ANN_1	99,98%	99,99%	99,98%	99,94%	99,97%	99,97%	99,98%	99,85%	99,72%	99,96%	99,89%	99,73%
	ANN_5	99,99%	99,98%	99,97%	99,97%	99,98%	99,75%	99,98%	99,82%	99,44%	99,97%	99,86%	99,46%
	ANN_18	100,00%	100,00%	100,00%	-	-	-	99,90%	99,82%	99,62%	99,95%	99,88%	99,73%
	ANN_19	100,00%	100,00%	100,00%	-	-	-	99,92%	99,83%	99,51%	99,96%	99,90%	99,64%
	ANN_21	99,98%	99,98%	99,98%	-	-	-	99,95%	99,85%	99,82%	99,95%	99,89%	99,85%
DISTRIBUCIÓN DE HIDROGRÁMAS N°2	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		52%	43%	33%	23%	20%	20%	25%	37%	47%	100%	100%	100%
	ANN_1	99,99%	99,64%	99,83%	99,98%	99,63%	98,80%	99,99%	99,55%	98,62%	99,99%	99,59%	98,75%
	ANN_5	99,98%	98,16%	99,99%	99,99%	97,70%	99,44%	99,98%	97,24%	99,47%	99,98%	97,61%	99,50%
	ANN_18	100,00%	100,00%	100,00%	-	-	-	99,94%	99,94%	99,95%	99,97%	99,97%	99,97%
	ANN_19	100,00%	100,00%	100,00%	-	-	-	99,91%	99,93%	99,96%	99,96%	99,96%	99,97%
	ANN_21	99,99%	99,99%	99,99%	-	-	-	99,99%	99,99%	99,98%	99,99%	99,99%	99,99%
DISTRIBUCIÓN DE HIDROGRÁMAS N°3	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		55%	44%	35%	20%	19%	20%	25%	37%	45%	100%	100%	100%
	ANN_1	99,99%	99,99%	99,95%	99,95%	99,97%	99,96%	99,99%	99,97%	99,97%	99,98%	99,98%	99,96%
	ANN_5	99,99%	99,99%	99,98%	99,95%	99,97%	99,86%	99,98%	99,98%	99,78%	99,98%	99,98%	99,83%
	ANN_18	100,00%	100,00%	100,00%	-	-	-	99,87%	99,86%	99,92%	99,95%	99,93%	99,96%
	ANN_19	100,00%	100,00%	100,00%	-	-	-	99,89%	99,66%	99,51%	99,95%	99,84%	99,75%
	ANN_21	99,98%	99,98%	99,98%	-	-	-	99,99%	99,98%	99,98%	99,98%	99,98%	99,98%

Tabla 5.6 Coeficiente de correlación para cada una de las redes neuronales según la distribución de la serie de hidrogramas – Caso de Estudio 1.

De los resultados del análisis mostrado en la Tabla 5.5 y en la Tabla 5.6 se puede afirmar que, a medida que se disminuye el porcentaje de datos utilizados para entrenamiento y validación de una red neuronal, en la mayoría de los casos disminuye la precisión en la estimación de la respuesta en la etapa de prueba por parte de las redes neuronales analizadas; dicho comportamiento se puede apreciar en la forma como decrece el rendimiento (MSE) y el coeficiente de correlación (R^2) de los datos o series de hidrogramas utilizados en la etapa de prueba.

Esta afirmación se aprecia con mayor claridad en la columna que muestra el coeficiente de correlación y el desempeño total de las redes neuronales. Además de lo anterior se puede concluir que la distribución de hidrogramas N°2 es la que muestra la respuesta de las redes neuronales con el error medio cuadrado (MSE) más bajo de las tres, siendo las arquitecturas ANN_5, ANN_18 y ANN_19 las que producen un hidrograma de salida con mayor distorsión para las tres distribuciones si se compara con la salida deseada (*Targets*), con un coeficiente de correlación (R^2) mínimo de 97,24% en la etapa de prueba. Una causa probable del menor desempeño podría ser el hecho de que la serie de hidrogramas en el grupo para entrenamiento y validación no es lo suficientemente variada como para que las redes simulen de forma satisfactoria los hidrogramas de la etapa de prueba.

En el ANEXO A se muestran los resultados de las simulaciones realizadas en la etapa de prueba y los errores de las redes neuronales evaluadas para las Distribuciones 1, 2 y 3. En las gráficas del anexo se puede apreciar que la mayor dificultad para las redes neuronales del Caso de Estudio 1 se presenta cuando estas requieren simular hidrogramas con picos altos.

5.2 CASO DE ESTUDIO 2

Como se mencionó en el Capítulo 4, el Caso de Estudio 2 es un hidrosistema conformado por un cauce principal y dos afluentes (Véase Figura 4.4). Para el montaje del modelo en MATLAB®, esta condición indica una ANN de 3 entradas, siendo estas, los hidrogramas de los dos afluentes y de la entrada al tramo de estudio y 1 salida, que en este caso es el hidrograma en la descarga del tramo principal.

Para este caso de estudio los análisis realizados son similares a los del Caso de Estudio 1, salvo que en este no se evaluó el comportamiento de las 84 ANN mencionadas en la Tabla 4.2, sino que se consideró para análisis únicamente las redes neuronales ya definidas como de mejor desempeño (ANN_1, ANN_5, ANN_18, ANN_19 y ANN_21). El análisis de sensibilidad a cambios de pendiente y rugosidad también se omitió, pues en el Caso de Estudio 1 se concluyó que la respuesta de las redes neuronales artificiales no se ve afectada por el cambio de dichas variables.

Igual que para el Caso de Estudio 1, en este también se generaron 3 series de hidrogramas diferentes, la Distribución 1 se refiere a la condición inicial de análisis, mientras que las Distribuciones 2 y 3, son variaciones de esta en cuanto a la localización, altura de los picos, duración y forma de los hidrogramas de entrada. La Gráfica 5.13, Gráfica 5.14 y la Gráfica 5.15 muestran las series de hidrogramas para cada una de las 3 distribuciones. La forma como se realizó la división de los datos de entrada para cada serie de hidrogramas se muestra en la Tabla 5.7.

DISTRIBUCIÓN	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
1	63%	50%	37%	15%	19%	19%	22%	31%	44%	100%	100%	100%
2	58%	48%	37%	18%	22%	18%	24%	30%	45%	100%	100%	100%
3	58%	51%	36%	18%	18%	15%	24%	31%	49%	100%	100%	100%

Tabla 5.7 Porcentaje de datos para cada etapa según la distribución de hidrogramas – Caso de Estudio 2.

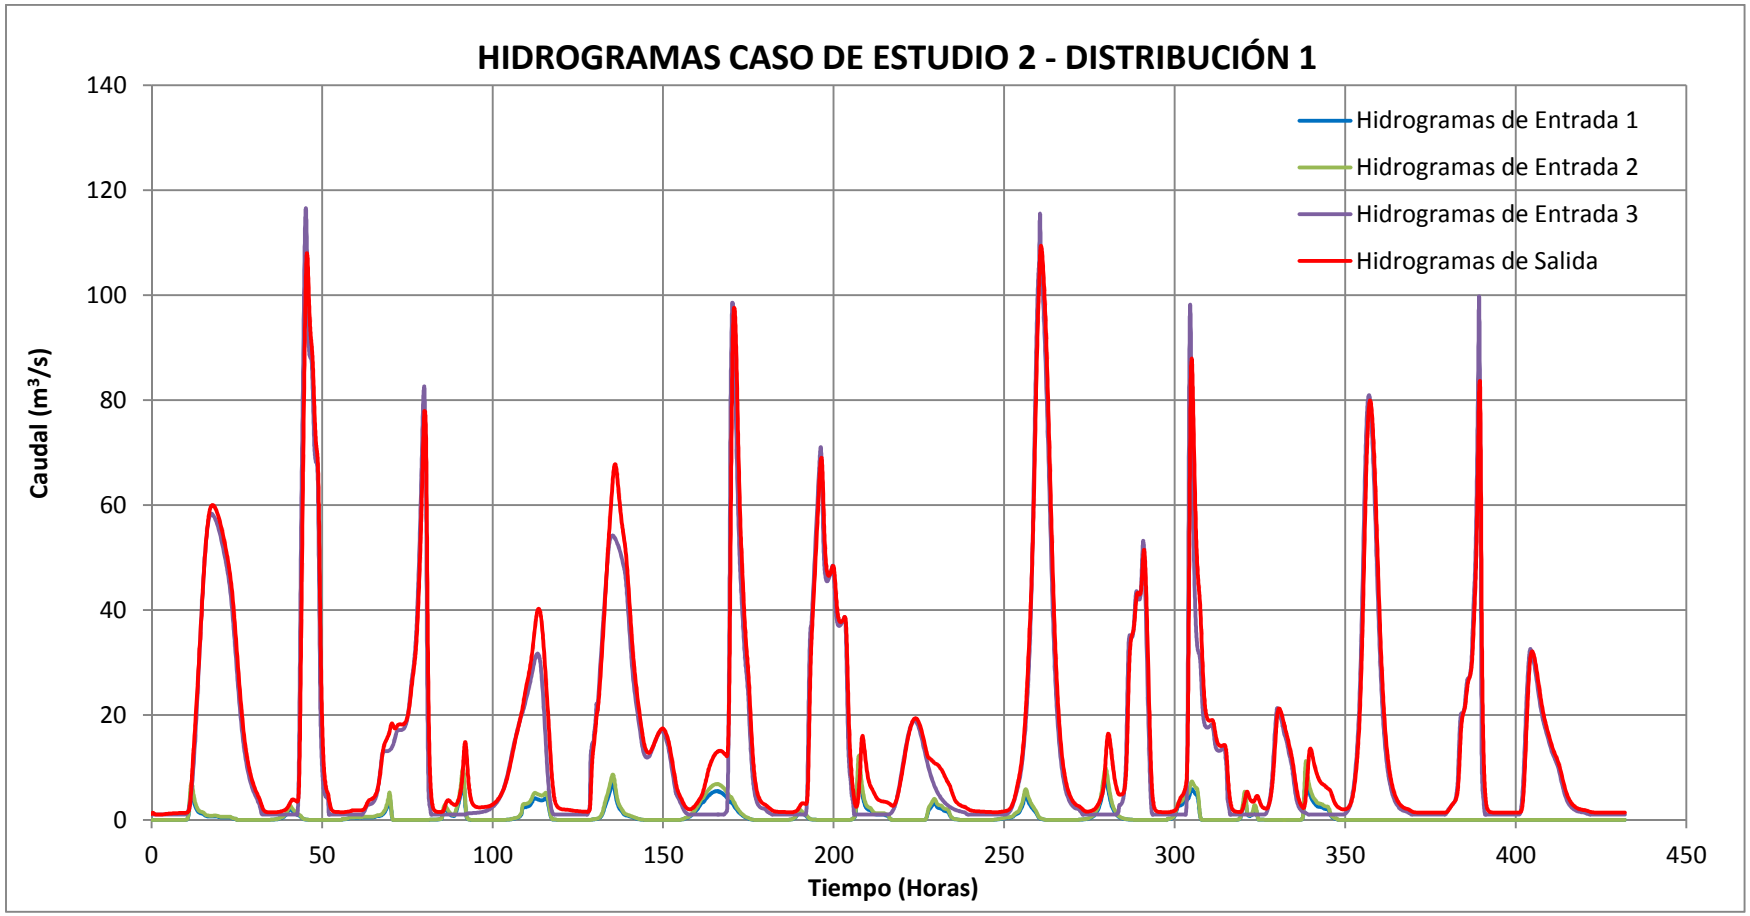

Gráfica 5.13 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 2 – Distribución 1.

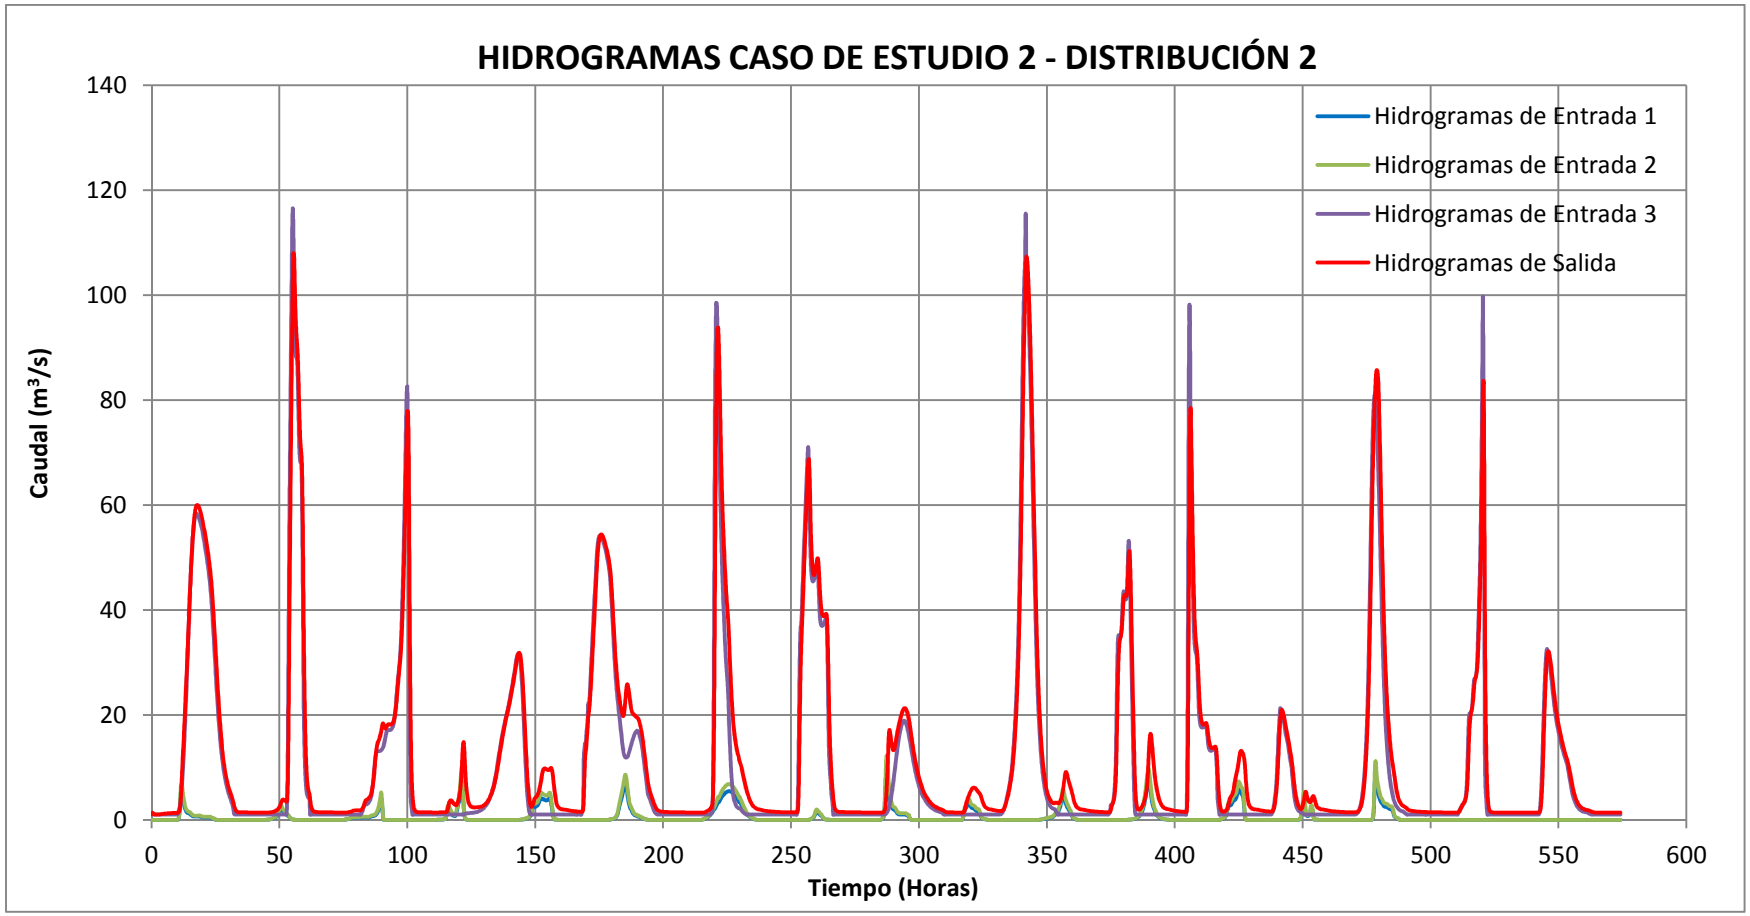

Gráfica 5.14 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 2 – Distribución 2.

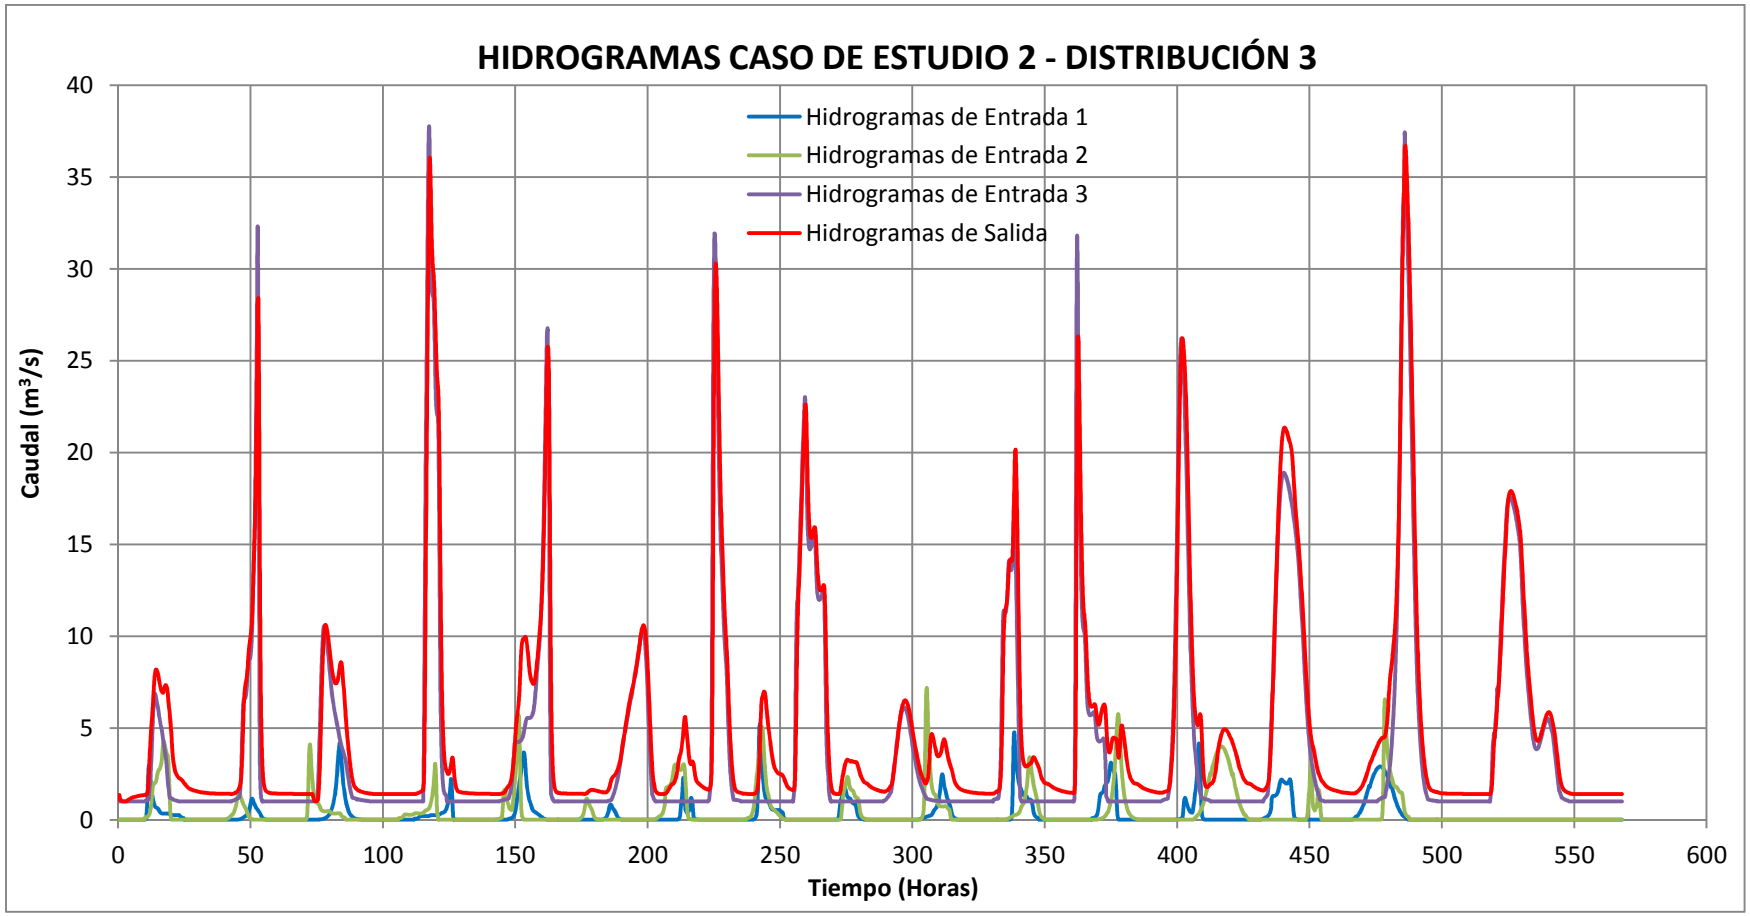

Gráfica 5.15 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 2 – Distribución 3.

Para cada una de las tres distribuciones de hidrogramas, como se mencionó anteriormente, se varió el porcentaje de datos utilizados para entrenamiento, validación y prueba. En la Tabla 5.8 y en la Tabla 5.9 se muestra el desempeño (MSE) y el coeficiente de correlación (R^2) entre los datos esperados y los arrojados por las redes neuronales. Igual que para el Caso de Estudio 1, se puede afirmar que, a medida que se disminuye el porcentaje de datos utilizados para entrenamiento y validación de una red neuronal, en la mayoría de los casos disminuye la precisión en la estimación de la respuesta en la etapa de prueba por parte de las redes neuronales analizadas; esta afirmación se aprecia con mayor claridad en la columna que muestra el coeficiente de correlación y el desempeño total de las redes neuronales, donde el MSE aumenta y el coeficiente de correlación disminuye.

Además de lo anterior se puede concluir que la distribución de hidrogramas N°3 es la que muestra la respuesta de las redes neuronales con el error medio cuadrado (MSE) más bajo de las tres, siendo las arquitecturas ANN_18 y ANN_19 las que producen un hidrograma de salida con mayor distorsión para las tres distribuciones si se compara con la salida deseada (*Targets*), con un coeficiente de correlación (R^2) mínimo de 94,65% en la etapa de prueba.

En el ANEXO B se muestran los resultados de las simulaciones realizadas en la etapa de prueba y los errores de las redes neuronales evaluadas para las Distribuciones 1, 2 y 3. Igual que para el Caso de Estudio 1, la respuesta de las redes neuronales en este caso presentan las mayores distorsiones al momento de simular los picos de los hidrogramas, pues estos se desarrollan en poco tiempo y para valores de caudal altos.

CASO DE ESTUDIO 2 - MSE $(m^3/s)^2$												
	RED	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
	NEURONAL	63%	50%	37%	15%	19%	19%	22%	31%	44%	100%	100%	100%
DISTRIBUCIÓN DE HIDROGRÁMAS N°1	ANN_1	0,272	0,306	0,214	0,435	0,204	0,271	0,837	0,717	0,416	0,420	0,414	0,314
	ANN_5	0,285	0,325	0,326	0,416	0,144	0,239	0,843	0,652	0,606	0,427	0,391	0,433
	ANN_18	0,070	0,123	0,045	-	-	-	1,044	1,010	4,684	0,284	0,397	2,086
	ANN_19	0,035	0,046	0,022	-	-	-	2,662	6,136	2,985	0,612	1,932	1,326
	ANN_21	0,267	0,204	0,199	-	-	-	0,686	0,783	2,432	0,358	0,383	1,181
	RED	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
	NEURONAL	58%	48%	37%	18%	22%	18%	24%	30%	45%	100%	100%	100%
DISTRIBUCIÓN DE HIDROGRÁMAS N°2	ANN_1	0,189	0,146	0,256	0,322	0,136	0,347	0,586	0,437	0,539	0,308	0,232	0,400
	ANN_5	0,185	0,235	0,243	0,328	0,160	0,272	0,588	2,185	2,529	0,308	0,804	1,277
	ANN_18	0,100	0,067	0,039	-	-	-	0,774	9,771	3,309	0,244	2,964	1,510
	ANN_19	0,066	0,034	0,021	-	-	-	1,779	14,755	7,557	0,465	4,443	3,412
	ANN_21	0,240	0,177	0,127	-	-	-	0,452	0,559	0,706	0,248	0,292	0,387
	RED	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
	NEURONAL	58%	51%	36%	18%	18%	15%	24%	31%	49%	100%	100%	100%
DISTRIBUCIÓN DE HIDROGRÁMAS N°3	ANN_1	0,016	0,026	0,041	0,035	0,024	0,071	0,021	0,033	0,089	0,020	0,028	0,069
	ANN_5	0,039	0,032	0,043	0,025	0,032	0,036	0,030	0,024	0,030	0,034	0,029	0,036
	ANN_18	0,006	0,006	0,003	-	-	-	0,040	0,153	0,364	0,014	0,052	0,180
	ANN_19	0,002	0,002	0,002	-	-	-	0,226	1,048	0,526	0,056	0,326	0,258
	ANN_21	0,018	0,028	0,019	-	-	-	0,010	0,020	0,017	0,016	0,025	0,018

Tabla 5.8 Desempeño para cada una de las redes neuronales según la distribución de la serie de hidrogramas – Caso de Estudio 2.

CASO DE ESTUDIO 2 - R^2 (%)													
	RED	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
	NEURONAL	63%	50%	37%	15%	19%	19%	22%	31%	44%	100%	100%	100%
DISTRIBUCIÓN DE HIDROGRÁMAS N°1	ANN_1	99,95%	99,94%	99,96%	99,88%	99,96%	99,94%	99,74%	99,77%	99,90%	99,91%	99,91%	99,93%
	ANN_5	99,95%	99,93%	99,93%	99,86%	99,97%	99,94%	99,72%	99,79%	99,86%	99,90%	99,91%	99,90%
	ANN_18	99,99%	99,98%	99,99%	-	-	-	99,66%	99,67%	98,93%	99,94%	99,91%	99,53%
	ANN_19	99,99%	99,99%	100,00%	-	-	-	99,12%	98,18%	99,32%	99,86%	99,58%	99,70%
	ANN_21	99,94%	99,96%	99,96%	-	-	-	99,77%	99,75%	99,45%	99,92%	99,91%	99,74%
	RED	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
	NEURONAL	58%	48%	37%	18%	22%	18%	24%	30%	45%	100%	100%	100%
DISTRIBUCIÓN DE HIDROGRÁMAS N°2	ANN_1	99,95%	99,97%	99,94%	99,93%	99,96%	99,91%	99,77%	99,83%	99,84%	99,91%	99,94%	99,89%
	ANN_5	99,95%	99,94%	99,94%	99,93%	99,96%	99,93%	99,78%	99,33%	99,35%	99,92%	99,79%	99,67%
	ANN_18	99,98%	99,99%	99,99%	-	-	-	99,75%	96,21%	99,03%	99,93%	99,18%	99,58%
	ANN_19	99,99%	99,99%	99,99%	-	-	-	99,33%	94,65%	97,79%	99,87%	98,79%	99,06%
	ANN_21	99,95%	99,96%	99,97%	-	-	-	99,83%	99,79%	99,79%	99,93%	99,92%	99,89%
	RED	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
	NEURONAL	58%	51%	36%	18%	18%	15%	24%	31%	49%	100%	100%	100%
DISTRIBUCIÓN DE HIDROGRÁMAS N°3	ANN_1	99,95%	99,92%	99,87%	99,90%	99,86%	99,83%	99,96%	99,96%	99,79%	99,95%	99,93%	99,81%
	ANN_5	99,87%	99,90%	99,86%	99,92%	99,83%	99,91%	99,95%	99,95%	99,92%	99,91%	99,92%	99,90%
	ANN_18	99,98%	99,98%	99,99%	-	-	-	99,93%	99,80%	99,08%	99,96%	99,88%	99,51%
	ANN_19	99,99%	99,99%	100,00%	-	-	-	99,58%	97,95%	98,73%	99,85%	99,10%	99,31%
	ANN_21	99,94%	99,90%	99,94%	-	-	-	99,98%	99,96%	99,96%	99,96%	99,93%	99,95%

Tabla 5.9 Coeficiente de correlación para cada una de las redes neuronales según la distribución de la serie de hidrogramas – Caso de Estudio 2.

5.3 CASO DE ESTUDIO 3

El Caso de Estudio 3 es un hidrosistema conformado por un cauce principal y un tributario (Véase Figura 4.6). Para el montaje del modelo en MATLAB®, esta condición indica que se debe configurar una ANN de 2 entradas, siendo estas, las series de hidrogramas del cauce tributario y del cauce principal y 1 salida que corresponde a la serie de hidrogramas en la descarga del tramo principal. Para este caso de estudio los análisis realizados son similares a los descritos paras los demás casos, es decir, se consideró para análisis únicamente las redes neuronales ANN_1, ANN_5, ANN_18, ANN_19 y ANN_21. Al igual que en los dos casos anteriores se generaron 3 series de hidrogramas, donde, la Distribución 1 hace referencia a la condición inicial de estudio, mientras que las Distribuciones 2 y 3, son variaciones de esta en cuanto a la localización, altura de los picos, duración y forma de los hidrogramas de entrada. La Gráfica 5.16, Gráfica 5.17 y Gráfica 5.18, muestran las series de hidrogramas de entrada y salida para cada una de las 3 distribuciones. La forma como se realizó la división de los datos de entrada para cada distribución de hidrogramas se muestra en la Tabla 5.10.

DISTRIBUCIÓN	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
1	64%	50%	36%	16%	19%	21%	20%	31%	43%	100%	100%	100%
2	62%	50%	38%	17%	18%	18%	21%	32%	44%	100%	100%	100%
3	60%	48%	35%	17%	17%	19%	23%	35%	46%	100%	100%	100%

Tabla 5.10 Porcentaje de datos para cada etapa según la distribución de hidrogramas – Caso de Estudio 3.

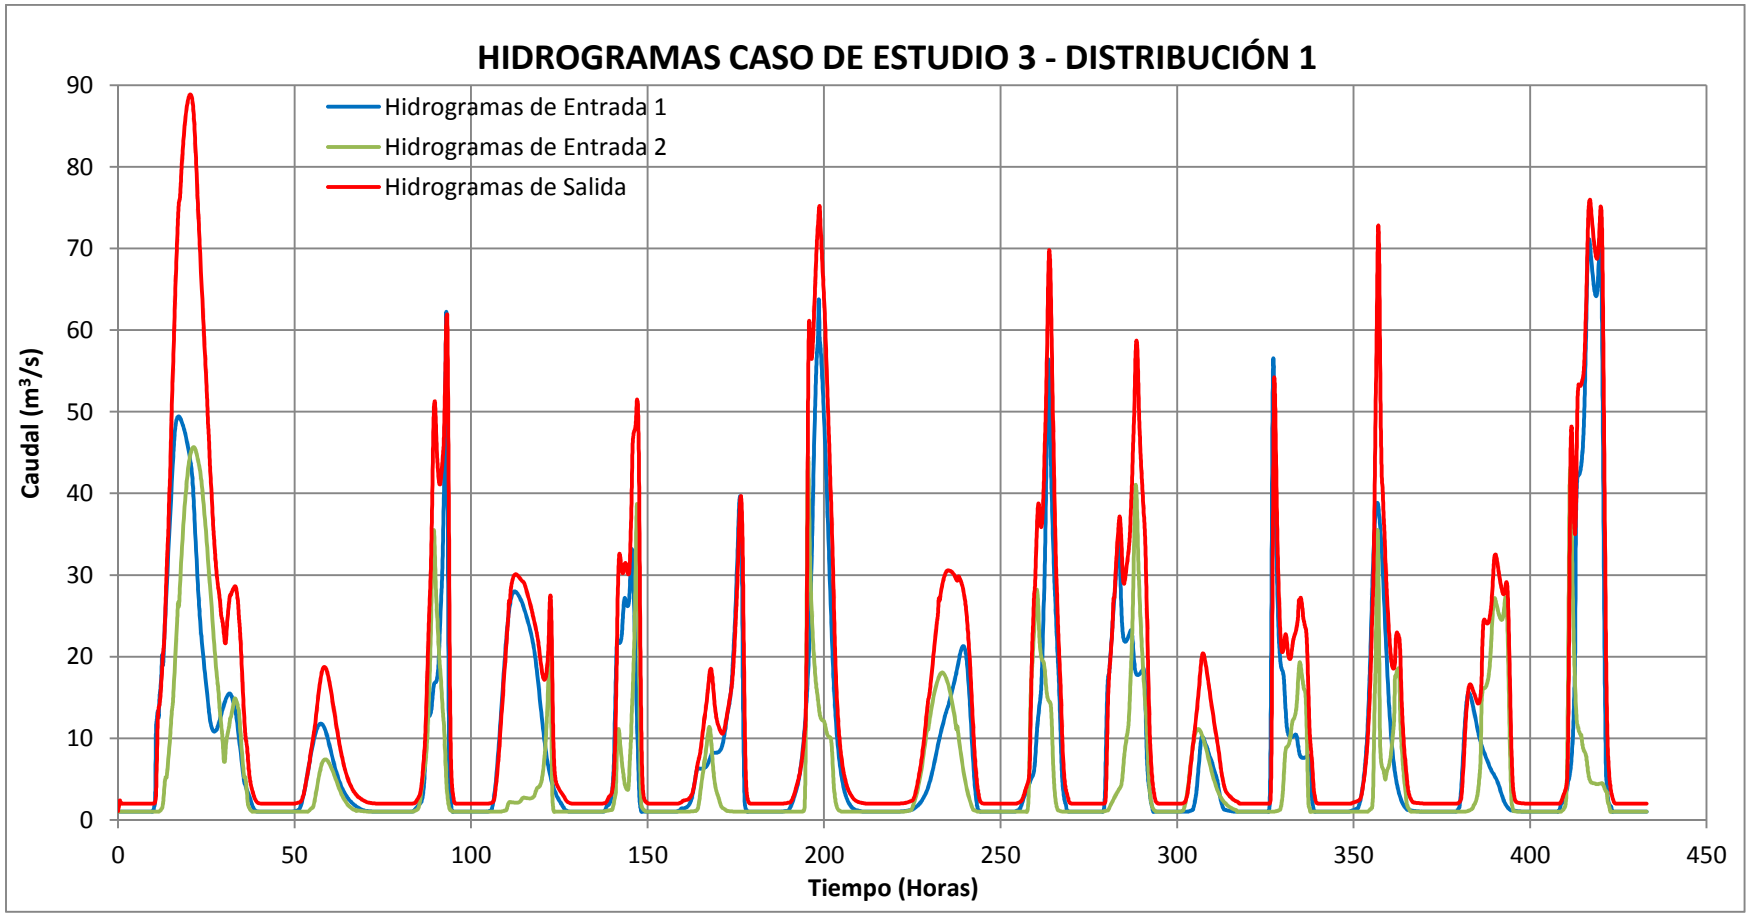

Gráfica 5.16 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 3 – Distribución 1.

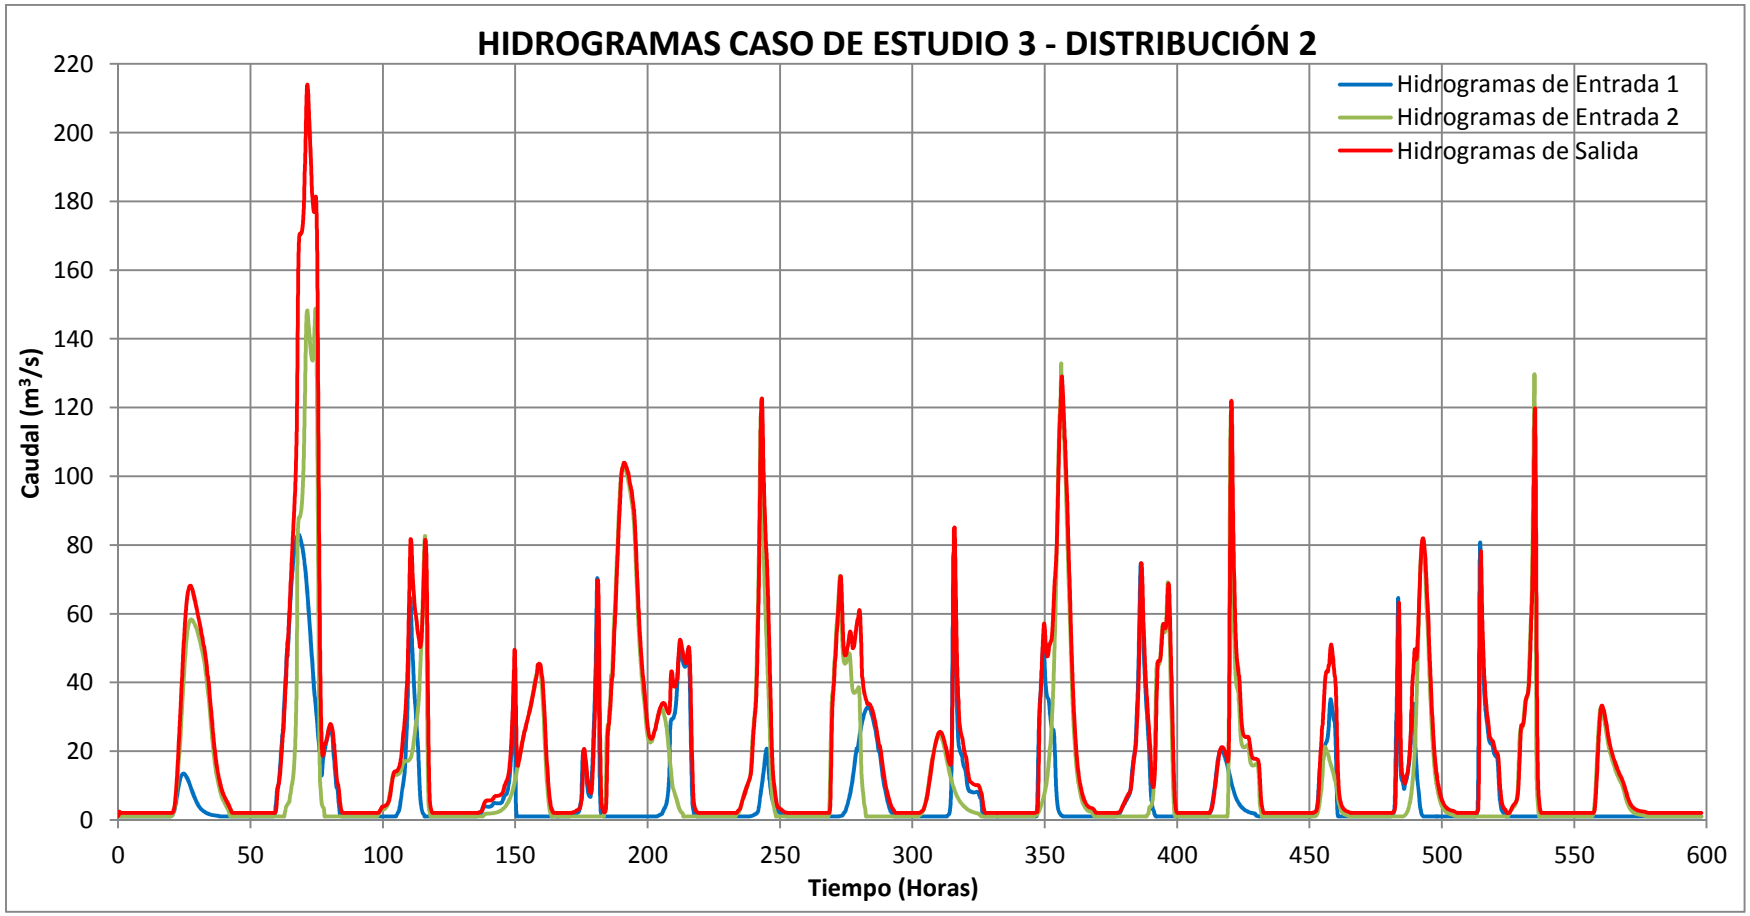

Gráfica 5.17 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 3 – Distribución 2.

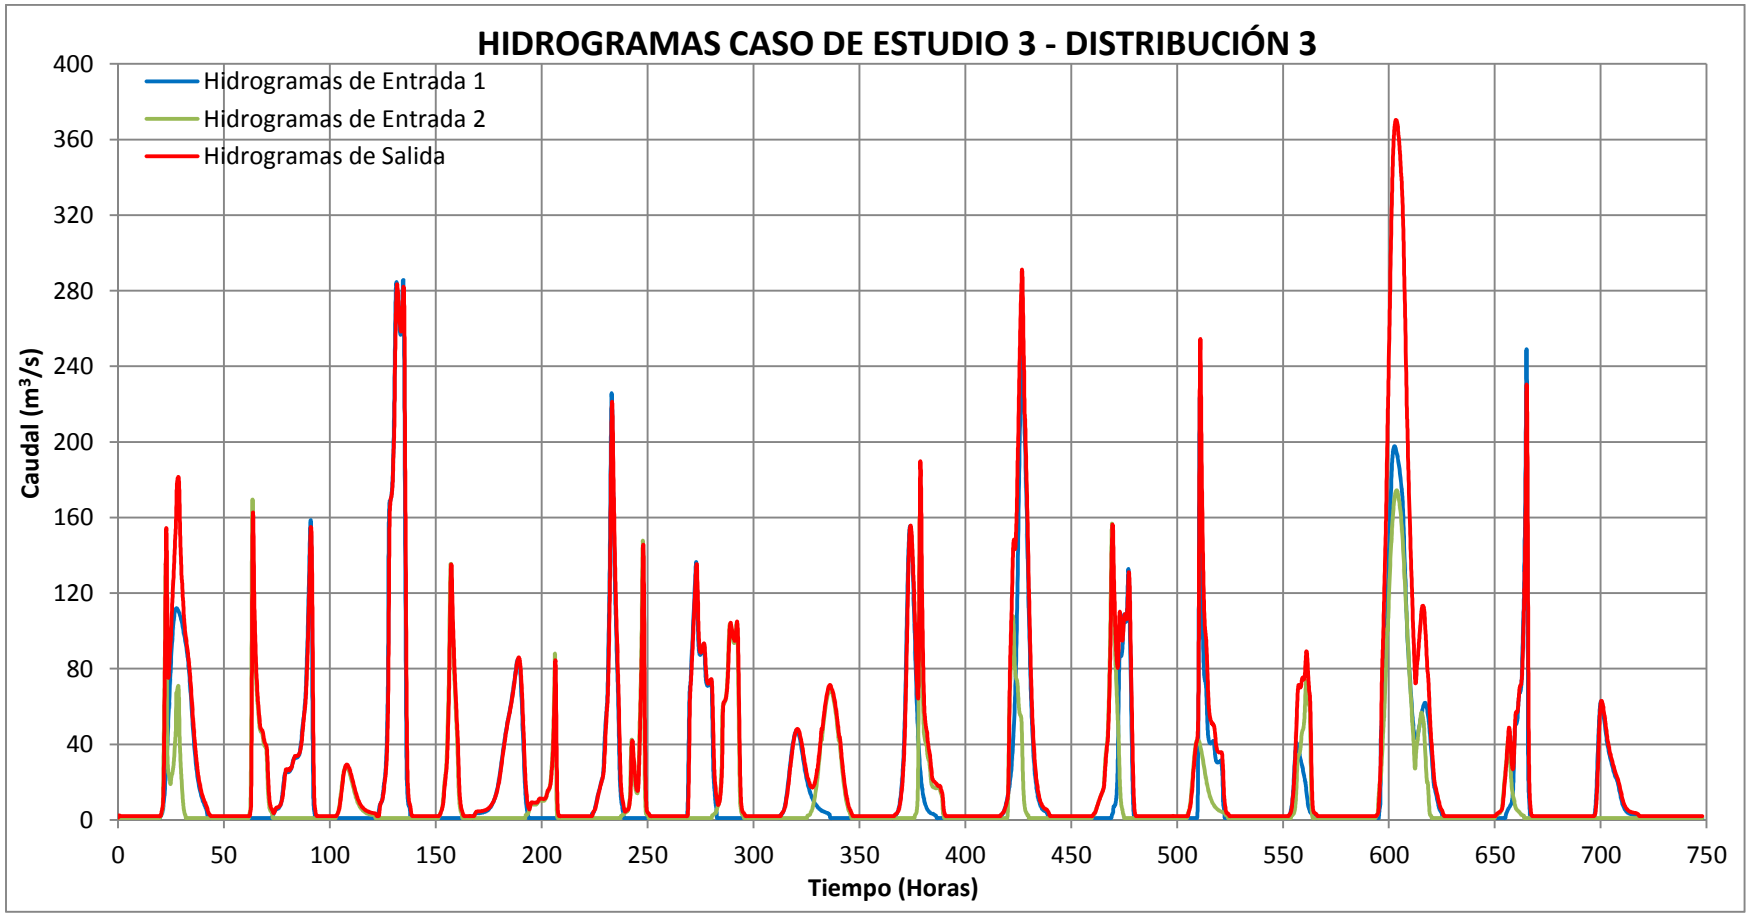

Gráfica 5.18 Hidrogramas de entrada y salida obtenidos con HEC-RAS – Caso de Estudio 3 – Distribución 3.

En la Tabla 5.11 y en la Tabla 5.12 se muestra el desempeño (MSE) y el coeficiente de correlación (R^2) entre los datos esperados y los arrojados por las redes neuronales; se observa que a medida que se disminuye el porcentaje de datos utilizados para entrenamiento y validación de una red neuronal decrece la precisión en la estimación de la respuesta en la etapa de prueba por parte de las redes neuronales analizadas. Dicho comportamiento se puede apreciar en la forma como aumenta el error medio cuadrado (MSE) y en la disminución del coeficiente de correlación (R^2) de los datos o series de hidrogramas utilizados en la etapa de prueba.

Además de lo anterior se puede concluir que la distribución de hidrogramas N°2 es la que muestra la respuesta de las redes neuronales con el error medio cuadrado (MSE) más bajo de las tres, siendo las arquitecturas ANN_18 y ANN_19 junto con la ANN_5 en la Distribución 3 las que producen un hidrograma de salida con mayor distorsión para las tres distribuciones si se compara con la salida deseada (*Targets*), con un coeficiente de correlación (R^2) de 98,11% en la etapa de prueba. Una causa probable del menor desempeño podría ser la irregularidad en la forma de los hidrogramas de salida, pues para este caso de estudio, todos tienen una configuración diferente y con picos altos y de corta duración.

El ANEXO C muestra los resultados de las simulaciones realizadas en la etapa de prueba y los errores de las redes neuronales evaluadas para las Distribuciones de Hidrogramas 1, 2 y 3. En las gráficas del anexo se puede apreciar que la mayor dificultad para las redes neuronales del Caso de Estudio 3 se presenta cuando estas requieren simular hidrogramas con picos altos y con formas irregulares.

CASO DE ESTUDIO 3 - MSE $(m^3/s)^2$												
DISTRIBUCIÓN DE HIDROGRÁMAS N°1	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		64%	50%	36%	16%	19%	21%	20%	31%	43%	100%	100%	100%
	ANN_1	0,055	0,051	0,072	0,084	0,049	0,104	0,139	0,154	0,680	0,076	0,083	0,340
	ANN_5	0,073	0,063	0,092	0,080	0,046	0,082	0,288	0,153	0,223	0,117	0,088	0,146
	ANN_18	0,026	0,019	0,013	-	-	-	1,928	3,344	3,885	0,406	1,050	1,678
	ANN_19	0,011	0,015	0,008	-	-	-	6,853	6,366	4,055	1,380	1,984	1,748
	ANN_21	0,057	0,059	0,059	-	-	-	0,098	0,117	0,103	0,065	0,077	0,078
DISTRIBUCIÓN DE HIDROGRÁMAS N°2	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		62%	50%	38%	17%	18%	18%	21%	32%	44%	100%	100%	100%
	ANN_1	0,245	0,239	0,254	0,498	0,298	0,394	0,489	0,454	0,790	0,339	0,318	0,515
	ANN_5	0,348	0,399	0,421	0,302	0,291	0,229	0,728	0,512	0,448	0,420	0,416	0,398
	ANN_18	0,083	0,086	0,082	-	-	-	0,252	0,826	0,694	0,119	0,323	0,352
	ANN_19	0,067	0,071	0,045	-	-	-	0,351	1,126	3,023	0,126	0,409	1,355
	ANN_21	0,282	0,202	0,187	-	-	-	2,455	2,733	0,719	0,739	1,012	0,421
DISTRIBUCIÓN DE HIDROGRÁMAS N°3	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		60%	48%	35%	17%	17%	19%	23%	35%	46%	100%	100%	100%
	ANN_1	1,598	1,714	1,704	1,299	1,798	0,537	5,630	6,320	11,135	2,476	3,341	5,821
	ANN_5	1,986	1,557	1,874	1,013	2,547	0,407	65,271	32,650	41,859	16,387	12,608	19,988
	ANN_18	0,525	0,508	0,417	-	-	-	42,870	152,971	24,075	10,271	53,870	11,300
	ANN_19	0,304	0,208	0,198	-	-	-	48,863	96,653	58,207	11,480	33,963	26,882
	ANN_21	1,336	1,005	0,943	-	-	-	14,963	11,128	4,007	4,473	4,548	2,352

Tabla 5.11 Desempeño para cada una de las redes neuronales según la distribución de la serie de hidrogramas – Caso de Estudio 3.

CASO DE ESTUDIO 3 - R^2 (%)													
DISTRIBUCIÓN DE HIDROGRÁMAS N°1	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		64%	50%	36%	16%	19%	21%	20%	31%	43%	100%	100%	100%
	ANN_1	99,99%	99,99%	99,98%	99,96%	99,98%	99,96%	99,97%	99,95%	99,82%	99,98%	99,98%	99,91%
	ANN_5	99,98%	99,98%	99,98%	99,96%	99,98%	99,97%	99,94%	99,95%	99,94%	99,97%	99,98%	99,96%
	ANN_18	99,99%	99,99%	100,00%	-	-	-	99,63%	99,21%	99,00%	99,89%	99,72%	99,55%
	ANN_19	100,00%	100,00%	100,00%	-	-	-	98,39%	98,48%	98,80%	99,61%	99,47%	99,51%
	ANN_21	99,98%	99,98%	99,98%	-	-	-	99,98%	99,96%	99,97%	99,98%	99,98%	99,98%
DISTRIBUCIÓN DE HIDROGRÁMAS N°2	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		62%	50%	38%	17%	18%	18%	21%	32%	44%	100%	100%	100%
	ANN_1	99,98%	99,98%	99,98%	99,89%	99,96%	99,93%	99,88%	99,90%	99,86%	99,96%	99,97%	99,95%
	ANN_5	99,97%	99,97%	99,97%	99,93%	99,96%	99,96%	99,82%	99,88%	99,92%	99,96%	99,96%	99,96%
	ANN_18	99,99%	99,99%	99,99%	-	-	-	99,94%	99,80%	99,88%	99,99%	99,97%	99,96%
	ANN_19	99,99%	99,99%	100,00%	-	-	-	99,91%	99,72%	99,47%	99,99%	99,96%	99,86%
	ANN_21	99,97%	99,98%	99,98%	-	-	-	99,44%	99,32%	99,87%	99,92%	99,89%	99,96%
DISTRIBUCIÓN DE HIDROGRÁMAS N°3	RED NEURONAL	ENTRENAMIENTO			VALIDACIÓN			PRUEBA			TOTAL		
		60%	48%	35%	17%	17%	19%	23%	35%	46%	100%	100%	100%
	ANN_1	99,94%	99,93%	99,94%	99,92%	99,95%	99,97%	99,93%	99,91%	99,77%	99,93%	99,91%	99,84%
	ANN_5	99,93%	99,93%	99,93%	99,94%	99,94%	99,97%	99,54%	99,67%	99,54%	99,61%	99,71%	99,57%
	ANN_18	99,98%	99,98%	99,98%	-	-	-	99,29%	98,11%	99,71%	99,69%	98,66%	99,76%
	ANN_19	99,99%	99,99%	99,99%	-	-	-	99,31%	98,57%	98,75%	99,67%	99,12%	99,21%
	ANN_21	99,95%	99,96%	99,96%	-	-	-	99,87%	99,84%	99,93%	99,88%	99,88%	99,94%

Tabla 5.12 Coeficiente de correlación para cada una de las redes neuronales según la distribución de la serie de hidrogramas – Caso de Estudio 3.

6. ANÁLISIS DE COSTOS

Una de las premisas planteadas al inicio de la investigación para definir la viabilidad de utilizar las ANN como método alterno para realizar el tránsito de crecientes en un canal o cauce determinado además de la precisión en la estimación de las series de hidrogramas objetivo, fue la posibilidad de reducir los costos operacionales entre utilizar ANN u otro método alterno. Entre los insumos que se requieren para desarrollar estas metodologías se pueden listar: obtención de secciones batimétricas (Trabajo de campo), las cuales requieren una gran inversión de dinero y tiempo, análisis hidrológicos, análisis hidráulico y el montaje del modelo digital, ya sea con algún software de diseño (HEC-RAS en este caso) o utilizando ANN.

Para el análisis de costos de esta investigación no fue posible obtener la información monetaria de las actividades, materiales y procesos requeridos para el Caso de Estudio 3, por lo que el análisis solo se realizó para los Casos de Estudio 1 y 2. Debido a que los costos de las actividades no están referidos a la fecha actual sino a la fecha de realización de las mismas, los costos se manejarán en dólares utilizando como tasa de cambio el promedio de la cotización de esta moneda durante el desarrollo de las actividades. A continuación se muestra el gasto de dinero y tiempo que requieren las actividades necesarias para realizar el tránsito de crecientes en un canal a través de la metodología tradicional y utilizando ANN.

6.1 CASO DE ESTUDIO 1

- **Trabajos de Campo**
  - Batimetrías: 18 Secciones – 40 días
  - Costos Batimetría (Unidad): $ 2´320.000 o US 1.268
  - Costo Total Batimetrías: $ 41´760.000 o US 22.820
- **Trabajos de Oficina**
  - Montaje de modelo digital: 15 días
  - Costo personal / día: $ 100.000 o US 54,65
  - Costo total montaje de modelo digital: $ 1´500.000 o US 819,68
- **Montaje de redes neuronales artificiales (ANN)**

- Montaje de ANN: 5 días
- Costo personal / día: $ 100.000 o US 54,65
- Costo total montaje de ANN: $ 500.000 o US 273,23

- **Registros hidrológicos o de caudales**
  - Análisis hidrológico: 5 a 10 días
  - Costo personal /día: $ 100.000 o US 54,65
  - Información disponible por el IDEAM u otras entidades de forma libre.
  - Entrega de información IDEAM: 3 a 10 días

Promedio dólar mes, Marzo - Mayo 2013: $ 1.829,99

6.2 CASO DE ESTUDIO 2

- **Trabajos De Campo**
  - Batimetrías: 40 Secciones – 15 días
  - Costos promedio batimetría (Unidad): $ 750.000 o US 425,71
  - Costo total batimetrías: $ 30´000.000 o US 17.028,52
- **Trabajos de Oficina**
  - Montaje de modelo digital: 7 días
  - Costo personal /día: $ 100.000 o US 56,76
  - Costo total montaje de modelo digital: $ 700.000 o US 397,33
- **Montaje de redes neuronales artificiales (ANN)**
  - Montaje de ANN: 5 días
  - Costo personal /día: $ 100.000 o US 56,76
  - Costo total montaje de ANN: $ 500.000 o US 283,81
- **Registros hidrológicos o de caudales**
  - Análisis hidrológico: 5 días

- Costo personal /día: $ 100.000 o US 56,76
- Información disponible por el IDEAM u otras entidades de forma libre.
- Entrega de información 3 a 10 días

Promedio dólar mes, Julio 2011: $ 1.761,75

Analizando la información anterior se aprecia que la actividad que demanda mayor gasto de tiempo y dinero es la consecución de la información topológica del cauce (Secciones batimétricas) la cual no es requerida para el montaje de una red neuronal, lo que le da una ventaja a estas sobre los métodos tradicionales. El ahorro en tiempo por cuenta de esta actividad, para el Caso de Estudio 1 es del orden de 40 días y para el Caso de Estudio 2 del orden de 15 días, mientras que el ahorro en dinero es de aproximadamente 22.800 dólares para el Caso de Estudio 1 y de aproximadamente 17.000 dólares para el Caso de Estudio 2.

A demás de esto, se destaca que el tiempo de montaje y calibración del modelo digital de un cauce es un poco mayor que el que se requiere para seleccionar y entrenar una determinada red neuronal. Una característica que diferencia las redes neuronales de los métodos tradicionales es el hecho de que el adecuado funcionamiento de estas se ve influenciado por la cantidad de información de entrada con la que se cuente, es decir, entre mayor sea el rango de información o registros con el que se cuente la respuesta proporcionadas por la redes neuronales tendrá una probabilidad mucho mayor de ajustarse adecuadamente a la realidad o a la respuesta deseada.

De acuerdo con los costos de las actividades definidos anteriormente, para el Caso de Estudio 1, el ahorro en dinero sería del orden de 23.360,00 dólares y en tiempo del orden de unos 50 días, mientras que para el Caso de Estudio 2 el ahorro en dinero sería del orden de 17.140,00 dólares y en tiempo del orden de unos 17días.

7. CONCLUSIONES Y RECOMENDACIONES

- Al realizar la búsqueda bibliográfica se nota que a nivel local en el campo de los Hidrosistemas las investigaciones son pocas y solo se encuentran algunas aplicaciones a nivel general y en redes húmedas.

- Como lo indica el material bibliográfico proporcionado por MATLAB®, se pudo corroborar que las redes neuronales que utilizan el algoritmo de entrenamiento de Levenberg-Marquardt y además de estas, las que utilizan el algoritmo de Bayesian Regularization son la que muestran un mejor desempeño considerando como parámetros de evaluación el error medio cuadrado (MSE) y el coeficiente de correlación (R^2). Para un análisis rápido se podría partir de estos algoritmos de entrenamiento, pero se deberá verificar para cada caso de estudio particular si proporcionan el mejor desempeño.

- En cuanto a la investigación se observó que para un mayor número de neuronas combinado con un mayor número de capas ocultas, la generalización de las redes neuronales es menos acertada.

- Para un coeficiente de correlación (R^2) superior al 98.5% las redes neuronales muestran una muy buena generalización en los datos de salida en la etapa de prueba.

- Las arquitecturas de las cinco redes neuronales con mejor desempeño, ANN_1, ANN_5, ANN_18, ANN_19 y ANN_21, fueron las utilizadas como base para el tránsito de crecientes en cada uno de los tres casos de estudio. La ANN_1 y ANN_5 utilizan el algoritmo de Levenberg-Marquardt mientras que las demás arquitecturas utilizan el algoritmo de Bayesian Regularization.

- Realizado un análisis de sensibilidad al Caso de Estudio 1, se observó que el desempeño de las redes neuronales no se ve afectado en gran medida por variaciones en el coeficiente de rugosidad (n de Manning) o en la pendiente de fondo del cauce, razón por la cual se puede afirmar en primera instancia que las redes neuronales no son sensibles a la variación de dichos parámetros.

- Las redes neuronales analizadas en los Casos de Estudio 1, 2 y 3 muestran algún grado de dificultad para lograr una buena generalización o ajuste en hidrogramas de la serie con picos altos y de corta duración. Para lograr un mejor ajuste en la respuesta de la red neuronal se podría aumentar el tamaño de la serie de datos de entrada incluyendo aún más hidrogramas con formas y tamaños diversos.

- En la mayoría de casos analizados, a medida que se disminuye el porcentaje de datos de entrenamiento de la serie de hidrogramas, se observa una reducción en el coeficiente de correlación en la etapa de prueba entre los datos esperados y los simulados con las redes neuronales artificiales. Para esta investigación el porcentaje de datos para entrenamiento, validación y prueba de los tres casos de estudio en la distribución 1 se ubicaron en los siguientes rangos de datos.
  - Entrenamiento: 60% - 64% de los datos.
  - Validación: 15% - 22% de los datos.
  - Prueba: 18% - 22% de los datos.

- En cuanto al Error Medio Cuadrado de los datos simulados con las redes neuronales (MSE), en la mayoría de los casos este aumenta a medida que se disminuye el porcentaje de datos de entrenamiento de la serie de hidrogramas. Se podría recomendar mantenerse en el orden de porcentaje de datos dado, aunque lo ideal sería estimar la distribución adecuada para cada caso de estudio particular.

- Para las distintas distribuciones de hidrogramas de los tres casos de estudio analizados se obtuvo un Coeficiente de Correlación total variable entre los datos esperados y los obtenidos con las redes neuronales artificiales en el rango mostrado a continuación:

  Caso de Estudio 1: 99,46% – 99,99%
  Caso de Estudio 2: 98,79% – 99,96%
  Caso de Estudio 3: 98,66% – 99,99%

- Las redes neuronales por la naturaleza de los datos que requieren para ejecutar un análisis determinado permiten reducir el tiempo de ejecución del tránsito de una creciente, ya que no requiere toma de información en campo como secciones batimétricas ni el montaje y calibración de un

modelo digital. Estos procesos son los que mayor tiempo y recursos requieren en el desarrollo de un adecuado tránsito de crecientes.

- En cuanto a los costos de análisis, las redes neuronales requieren una menor cantidad de recursos; estas solo necesitan registros históricos de precipitación o caudales en los sitios de análisis sin considerar la geometría o morfología del cauce estudiado. De acuerdo con los costos de las actividades definidos en el Capítulo 6, para el Caso de Estudio 1, el ahorro en dinero sería del orden de 23.360,00 dólares y en tiempo del orden de unos 50 días, mientras que para el Caso de Estudio 2 el ahorro en dinero sería del orden de 17.140,00 dólares y en tiempo del orden de unos 17días.

- A diferencia de un tránsito normal, para obtener un mejor desempeño en el tránsito de una creciente utilizando ANN, se requieren de un registro de datos históricos amplio para evitar que al presentarse datos por fuera de un rango determinado la red neuronal presente inconvenientes en cuanto a la estimación o predicción de la información y además para evitar que estas se sobreentrenen por la presencia de datos muy parecidos.

8. BIBLIOGRAFÍA

CAMPOLO, M., SOLDATI, A., & ANDREUSSI, P. (2003). Artificial neural network approach to flood forecasting in the River Arno. *Hydrological Sciences–Journal–des Sciences Hydrologiques*, 19.

DIBIKE, Y., & SOLOMATINE, D. (2001). *River Flow Forecasting Using Artificial Neural Networks. 7 Páginas.* Netherlands.

HILERA, J., & MARTÍNEZ, V. (2000). *REDES NEURONALES ARTIFICIALES. Fundamentos, modelos y aplicaciones.* México D.F.: EDITORIAL ALFAOMEGA S.A.

IZAURIETA, F., & SAAVEDRA, C. (n.d.). Redes Neuronales Artificiales. Concepción, Chile: Departamento de Física, Universidad de Concepción.

MOLINA AGUILAR, J. P., & APARICIO, J. (2006). *Tránsito de avenidas en cauces mediante redes neuronales artificiales .* México.

MORALES V., J. (2004). Tránsito de crecientes en sistemas de alcantarillado utilizando redes neuronales artificiales (RNA). Bogotá, Colombia: Universidad de Los Andes.

OBREGÓN, N., FRAGALA, F., & PRADA, L. (n.d.). Redes neuronales artificiales en hidroinformátiSeminario Internacional La Hidroinformática en la Gestión Integrada de los Recursos Hídricos. Cali, Colombia: Universidad del Valle/Instituto CINARA.

PARTAL, T. (2009). River flow forecasting using different artificial neural network algorithms and wavelet transform. *NRC Research Press*, 15.

SHAMSELDIN, A. (2010). Artificial neural network model for river flow forecasting in a developing country. *Journal of Hydroinformatics*, 14.

SIVANANDAM, S., SUMATHI, S., & DEEPA, S. (2006). *Introduction to neural networks using MATLAB 6.0.* New Delhi: McGraw-Hill.

www.histologiaub.blogspot.com. (n.d.). Retrieved 11 17, 2014, from https://www.google.com.co/search?q=neurona&client=firefox-a&hs=wO&rls=org.mozilla:es-ES:official&channel=sb&source=lnms&tbm=isch&sa=X&ei=o0d1VISuEIG

qggSA14O4Cg&ved=0CAgQ_AUoAQ&biw=1366&bih=639#facrc=_&imgdii=_&imgrc=qa7tgqlMHlTyNM%253A%3BTgKwYYz52x2ohM%3B

9. ANEXOS