

TESIS DE MAESTRÍA

**TRÁNSITO DE CAUDALES A TRAVÉS DE REDES DE DRENAJE UTILIZANDO
REDES NEURONALES ARTIFICIALES.**

**PRESENTADO POR:
IVÁN GERARDO LAGOS CASTRO**

**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

A Dios, quien hizo todo esto posible.

*A mis padres, Gerardo y Blanca, por su incansable apoyo
y a quienes dedico este trabajo.*

*A mi hermana, Andrea, por nuestro inefable amor
fraterno.*

*A mi novia, Nariné, por ser mi compañera, mi motor y mi
guía.*

*A mi entrañable amiga Adriana, por su ayuda, sus
consejos y los buenos momentos.*

*A mi asesor de tesis, Juan Saldarriaga, por creer en mi
trabajo y guiarme en su desarrollo.*

“Can machines think?”... The new form of the problem can be described in terms of a game which we call the “imitation game.”

Alan Turing, 1950

TABLA DE CONTENIDO

TABLA DE CONTENIDO	I
ÍNDICE DE FIGURAS	I
ÍNDICE DE GRÁFICAS	II
ÍNDICE DE FOTOGRAFÍAS	VII
ÍNDICE DE TABLAS	VIII
1 INTRODUCCIÓN	1
1.1 OBJETIVO GENERAL	2
1.2 OBJETIVOS ESPECIFICOS	2
2 CONTEXTUALIZACIÓN Y MARCO TEÓRICO	4
2.1 PROBLEMÁTICA DEL SISTEMA DE DRENAJE URBANO.....	6
2.1.1 Sedimentación y desechos de tamaño considerable.....	6
2.1.2 Estructuras de red	7
2.1.3 Topología.....	8
2.1.4 Fallas estructurales.....	9
3 REDES NEURONALES ARTIFICIALES (ANN)	10
3.1 ENTRENAMIENTO Y APRENDIZAJE	12
3.1.1 Entrenamiento	13
3.1.2 Validación	13
3.1.3 Evaluación o Test	13
3.2 APLICACIÓN PRÁCTICA	13
3.1.4 Medicina	13
3.1.5 Clasificación de Datos	14
3.1.6 Ingeniería.....	15
4 REDES NEURONALES ARTIFICIALES EN MATLAB®	16
4.1 TIPOS DE REDES NEURONALES ARTIFICIALES	16
4.1.1 Ajuste de curvas / Curve Fitting Tool	17

4.1.2	Reconocimiento y clasificación de patrones/Pattern Recognition Tool	17
4.1.3	Agrupación / Clustering	17
4.1.4	Series de tiempo dinámicas / Dynamic Time Series	18
4.2	FUNCIONES DE ENTRENAMIENTO	18
4.1.5	Funciones de entrenamiento supervisadas	18
4.1.6	Funciones de entrenamiento sin supervisión	19
4.1.7	Funciones de entrenamiento de retro propagación con derivadas de Jacobianos	19
4.1.8	Funciones de entrenamiento de retro propagación con derivadas de gradiente	19
5	DESARROLLO Y PREDICCIÓN A TRAVÉS DE LAS ANN	20
5.1	CASO DE ESTUDIO PEQUEÑO CHICÓ	20
5.1.1	DETERMINACIÓN DE CAUDALES PLUVIALES	23
5.1.2	MODELACIÓN HIDRÁULICA DE LA RED	28
5.2	ANÁLISIS DEL REZAGO EN EL TRÁNSITO A TRAVÉS DE LA RED	32
5.1.3	CONSTRUCCIÓN DE LAS REDES NEURONALES ARTIFICIALES (ANNPC)	38
5.1.4	RESULTADOS INICIALES ANNPC	43
5.1.5	VARIACIONES DE HIDROLOGÍA – DURACIÓN Y TQM	65
5.1.6	VARIACIONES DE HIDROLOGÍA - PUNTOS DE INGRESO Y COBERTURA	78
5.3	DESCRIPCIÓN DEL CASO DE ESTUDIO NICOLÁS DE FEDERMÁN	90
5.1.7	MODELACIÓN HIDRAULICA DE LA RED	91
5.1.8	REZAGO EN EL TRÁNSITO A TRAVÉS DE LA RED	91
5.1.9	CONSTRUCCIÓN DE LAS REDES NEURONALES ARTIFICIALES (ANNFED)	92
5.1.10	RESULTADOS INICIALES ANNFED	92
5.1.11	PREDICCIÓN DE EVENTOS	101
5.1.12	REENTRENAMIENTO CON 30 EVENTOS	111

6	METODOLOGÍA PARA EL USO DE ANN	114
7	CONCLUSIONES Y RECOMENDACIONES	118
8	TRABAJOS FUTUROS	120
9	REFERENCIAS BIBLIOGRÁFICAS.....	121

ÍNDICE DE FIGURAS

Figura 3.1 Espacios de entrenamiento, Entradas Vs Salidas.....	10
Figura 3.2 Esquema de una red neuronal artificial (ANN).	12
Figura 3.3 Trazado de células cancerígenas de entrenamiento para ANN (Fuente: Delgado, 1999).....	14
Figura 3.4 Identificación y clasificación de plantas mediante ANN	14
Figura 3.5 Modelo ANFIS FF-BP multicapa para el transporte de sedimentos en alcantarillados (Fuente: Ebtehaj & Bonakdari, 2013)	15
Figura 4.1 Aplicaciones de Redes Neuronales Artificiales.	16
Figura 5.1 Red local y troncal objeto de estudio (Pequeño Chicó).....	20
Figura 5.2 Modelo computacional red Pequeño Chicó.....	29
Figura 5.3 Opciones de cálculo para la modelación.....	29
Figura 5.4 Perfil hidráulico PMI92748 – PMP92951 Evento de Lluvias 6.....	31
Figura 5.5 Esquema de ANN tipo NARX.....	32
Figura 5.6 Esquema de ANN tipo NAR.	32
Figura 5.7 Esquema de ANN tipo Input-Output.....	33
Figura 5.8 Determinación del coeficiente de correlación cruzada.	34
Figura 5.9 Esquema de rezagos para las redes neuronales artificiales.	37
Figura 5.10 Selección de la red neuronal artificial Tipo NARX.	40
Figura 5.11 Importación de datos, Entradas y Objetivos.....	41
Figura 5.12 Selección de porcentaje de uso de datos.....	41
Figura 5.13 Construcción de la arquitectura.....	42
Figura 5.14 Entrenamiento de la red.	42
Figura 5.15 Generación de códigos para modificación.	43
Figura 5.16 Esquemas generales de variación de hidrología – Duración y TQM..	66
Figura 5.17 Interfaz de manejo de datos (<i>nntool</i>).....	67
Figura 5.18 Herramienta para la adaptación de ANN.....	74
Figura 5.19 Orto foto del caso de estudio Pequeño Chicó con localización de sumideros (Nudos amarillos) y pozos de la red (Nudos rojos).	78
Figura 5.20 Cobertura de eventos de lluvia sobre la red Pequeño Chicó.	79
Figura 5.21 Red local y troncal objeto de estudio (Nicolás de Federmán).	91
Figura 6.1 Metodología general para el uso de ANN con series de tiempo dinámicas.....	115

ÍNDICE DE GRÁFICAS

Gráfica 5.1 Hidrogramas evento 9 – Q pico 85% - 90% de Q_0	26
Gráfica 5.2 Hidrogramas evento 6 – Q pico 50% - 55% de Q_0	26
Gráfica 5.3 Eventos de tormenta generados aleatoriamente.	27
Gráfica 5.4 Características generales de las tormentas.	28
Gráfica 5.5 Vano de finalización para eventos de lluvia independientes.	30
Gráfica 5.6 Resultados de modelación de la red caso de estudio – Pequeño Chicó.	31
Gráfica 5.7 Coeficientes de correlación cruzada para los eventos de tormenta.	35
Gráfica 5.8 Coeficientes de correlación serial para los eventos de tormenta.	37
Gráfica 5.9 Hidrogramas predichos por la red neuronal ANNPC1 Vs Modelados en Sewer GEMS.	44
Gráfica 5.10 Hidrogramas predichos por la red neuronal ANNPC2 Vs Modelados en Sewer GEMS.	44
Gráfica 5.11 Hidrogramas predichos por la red neuronal ANNPC3 Vs Modelados en Sewer GEMS.	45
Gráfica 5.12 Hidrogramas predichos por la red neuronal ANNPC4 Vs Modelados en Sewer GEMS.	45
Gráfica 5.13 Hidrogramas predichos por la red neuronal ANNPC5 Vs Modelados en Sewer GEMS.	46
Gráfica 5.14 Hidrogramas predichos por la red neuronal ANNPC6 Vs Modelados en Sewer GEMS.	46
Gráfica 5.15 Hidrogramas predichos por la red neuronal ANNPC7 Vs Modelados en Sewer GEMS.	47
Gráfica 5.16 Hidrogramas predichos por la red neuronal ANNPC8 Vs Modelados en Sewer GEMS.	47
Gráfica 5.17 Hidrogramas predichos por la red neuronal ANNPC9 Vs Modelados en Sewer GEMS.	48
Gráfica 5.18 Hidrogramas predichos por la red neuronal ANNPC10 Vs Modelados en Sewer GEMS.	48
Gráfica 5.19 Hidrogramas predichos por la red neuronal ANNPC11 Vs Modelados en Sewer GEMS.	49
Gráfica 5.20 Hidrogramas predichos por la red neuronal ANNPC12 Vs Modelados en Sewer GEMS.	49
Gráfica 5.21 Hidrogramas predichos por la red neuronal ANNPC13 Vs Modelados en Sewer GEMS.	50

Gráfica 5.22 Hidrogramas predichos por la red neuronal ANNPC14 Vs Modelados en Sewer GEMS.....	50
Gráfica 5.23 Hidrogramas predichos por la red neuronal ANNPC15 Vs Modelados en Sewer GEMS.....	51
Gráfica 5.24 Hidrogramas predichos por la red neuronal ANNPC16 Vs Modelados en Sewer GEMS.....	51
Gráfica 5.25 Hidrogramas predichos por la red neuronal ANNPC17 Vs Modelados en Sewer GEMS.....	52
Gráfica 5.26 Hidrogramas predichos por la red neuronal ANNPC18 Vs Modelados en Sewer GEMS.....	52
Gráfica 5.27 Hidrogramas predichos por la red neuronal ANNPC19 Vs Modelados en Sewer GEMS.....	53
Gráfica 5.28 Hidrogramas predichos por la red neuronal ANNPC20 Vs Modelados en Sewer GEMS.....	53
Gráfica 5.29 Hidrogramas predichos por la red neuronal ANNPC21 Vs Modelados en Sewer GEMS.....	54
Gráfica 5.30 Hidrogramas predichos por la red neuronal ANNPC22 Vs Modelados en Sewer GEMS.....	54
Gráfica 5.31 Hidrogramas predichos por la red neuronal ANNPC23 Vs Modelados en Sewer GEMS.....	55
Gráfica 5.32 Hidrogramas predichos por la red neuronal ANNPC24 Vs Modelados en Sewer GEMS.....	55
Gráfica 5.33 Hidrogramas predichos por la red neuronal ANNPC25 Vs Modelados en Sewer GEMS.....	56
Gráfica 5.34 Hidrogramas predichos por la red neuronal ANNPC26 Vs Modelados en Sewer GEMS.....	56
Gráfica 5.35 Hidrogramas predichos por la red neuronal ANNPC27 Vs Modelados en Sewer GEMS.....	57
Gráfica 5.36 Hidrogramas predichos por la red neuronal ANNPC28 Vs Modelados en Sewer GEMS.....	57
Gráfica 5.37 Hidrogramas predichos por la red neuronal ANNPC29 Vs Modelados en Sewer GEMS.....	58
Gráfica 5.38 Hidrogramas predichos por la red neuronal ANNPC30 Vs Modelados en Sewer GEMS.....	58
Gráfica 5.39 Hidrogramas predichos por la red neuronal ANNPC31 Vs Modelados en Sewer GEMS.....	59

Gráfica 5.40 Hidrogramas predichos por la red neuronal ANNPC32 Vs Modelados en Sewer GEMS.....	59
Gráfica 5.41 Desviaciones estándar de las ANN construidas.	60
Gráfica 5.42 Caudales máximos predichos por las ANN construidas.	61
Gráfica 5.43 Diferencia porcentual del caudal pico máximo predicho.	61
Gráfica 5.44 Desfase temporal del caudal pico máximo de evaluación.	62
Gráfica 5.45 Error cuadrático medio de los caudales predichos.	63
Gráfica 5.46 Error absoluto medio de los caudales predichos.	63
Gráfica 5.47 Correlación Serial Objetivos Vs Salidas.....	64
Gráfica 5.48 Variaciones en los hidrogramas de salida.	69
Gráfica 5.49 Resultados de simulación ANNPC1 y ANNPC6 frente a cambios de duración y TQM.....	70
Gráfica 5.50 Resultados de simulación ANNPC15 y ANNPC16 frente a cambios de duración y TQM.....	71
Gráfica 5.51 Resultados de simulación ANNPC17 y ANNPC21 frente a cambios de duración y TQM.....	71
Gráfica 5.52 Resultados de simulación ANNPC24 y ANNPC31 frente a cambios de duración y TQM.....	72
Gráfica 5.53 Variación del MSE entre las dos evaluaciones.	73
Gráfica 5.54 Variación del R^2 entre las dos evaluaciones.	73
Gráfica 5.55 Variación en la respuesta de la ANNPC17 después de la adaptación.	75
Gráfica 5.56 Variación en la respuesta de la ANNPC24 después de la adaptación.	76
Gráfica 5.57 Evolución del coeficiente R^2 para las redes ANNPC14 y ANNPC27.	77
Gráfica 5.58 Resultados de evaluación ANNPC1 y ANNPC6 frente a cambios en puntos de ingreso y cobertura.	81
Gráfica 5.59 Resultados de evaluación ANNPC15 y ANNPC16 frente a cambios en puntos de ingreso y cobertura.	82
Gráfica 5.60 Resultados de evaluación ANNPC17 y ANNPC21 frente a cambios en puntos de ingreso y cobertura.	83
Gráfica 5.61 Resultados de evaluación ANNPC24 y ANNPC31 frente a cambios en puntos de ingreso y cobertura.	84
Gráfica 5.62 Errores cuadráticos medios de las ANN con cambio en puntos de ingreso y cobertura.....	85
Gráfica 5.63 Coeficientes R^2 de las ANN con cambio en puntos de ingreso y cobertura.	85

Gráfica 5.64 Resultados de evaluación ANNPC1 y ANNPC15 con re entrenamiento de 20 eventos.....	87
Gráfica 5.65 Resultados de evaluación ANNPC17 y ANNPC24 con re entrenamiento de 20 eventos.....	88
Gráfica 5.66 Variación del MSE entre entrenamientos.....	89
Gráfica 5.67 Variación del R ² entre entrenamientos.....	89
Gráfica 5.68 Variación de la diferencia porcentual del caudal máximo.	89
Gráfica 5.69 Hidrogramas predichos por la red neuronal ANNFCED1 Vs Modelados en Sewer GEMS.....	93
Gráfica 5.70 Hidrogramas predichos por la red neuronal ANNFCED1 Vs Modelados en Sewer GEMS.....	93
Gráfica 5.71 Hidrogramas predichos por la red neuronal ANNFCED15 Vs Modelados en Sewer GEMS.	94
Gráfica 5.72 Hidrogramas predichos por la red neuronal ANNFCED16 Vs Modelados en Sewer GEMS.	94
Gráfica 5.73 Hidrogramas predichos por la red neuronal ANNFCED17 Vs Modelados en Sewer GEMS.	95
Gráfica 5.74 Hidrogramas predichos por la red neuronal ANNFCED21 Vs Modelados en Sewer GEMS.	95
Gráfica 5.75 Hidrogramas predichos por la red neuronal ANNFCED24 Vs Modelados en Sewer GEMS.	96
Gráfica 5.76 Hidrogramas predichos por la red neuronal ANNFCED31 Vs Modelados en Sewer GEMS.	96
Gráfica 5.77 Desviaciones estándar de las ANNFCED construidas.	97
Gráfica 5.78 Caudales máximos predichos por las ANNFCED construidas.	98
Gráfica 5.79 Diferencia porcentual del caudal pico máximo predicho por la ANNFCED.....	99
Gráfica 5.80 Desfase temporal del caudal pico máximo de evaluación ANNFCED.	99
Gráfica 5.81 Error cuadrático medio de los caudales predichos por las ANNFCED.	100
Gráfica 5.82 Error absoluto medio de los caudales predichos por las ANNFCED.	100
Gráfica 5.83 Coeficiente R ² Objetivos Vs Salidas.	101
Gráfica 5.84 Resultados de predicción para la ANNFCED1.	103
Gráfica 5.85 Resultados de predicción para la ANNFCED6.	104
Gráfica 5.86 Resultados de predicción para la ANNFCED15.	105
Gráfica 5.87 Resultados de predicción para la ANNFCED16.	106
Gráfica 5.88 Resultados de predicción para la ANNFCED17.	107

Gráfica 5.89 Resultados de predicción para la ANNFED21	108
Gráfica 5.90 Resultados de predicción para la ANNFED24	109
Gráfica 5.91 Resultados de predicción para la ANNFED31	110
Gráfica 5.92 Variación del MSE entre entrenamientos ANNFED31	112
Gráfica 5.93 Variación de la diferencia porcentual del caudal pico ANNFED31 ..	113

ÍNDICE DE FOTOGRAFÍAS

Fotografía 2.1 Tubería de concreto dentro de colector de aguas combinadas.	6
Fotografía 2.2 Colector de aguas combinadas altamente sedimentado.....	7
Fotografía 2.3 Estructura de alivio.....	8
Fotografía 2.4 Falla estructural en un colector combinado.....	9

ÍNDICE DE TABLAS

Tabla 5-1 Características topológicas de la red troncal.....	21
Tabla 5-2 Características topológicas de la red local.....	21
Tabla 5-3 Capacidades a tubo lleno para tramos de inicio de la red de estudio. ..	23
Tabla 5-4 Caudales aleatorios pico de ingreso a la red, entre 90% y 95% de Q ₀ . 24	
Tabla 5-5 Rango de porcentajes de generación de Q's aleatorios pico	25
Tabla 5-6 Características generales de las tormentas	27
Tabla 5-7 Coeficientes de correlación Cruzada Eventos 1-5.	34
Tabla 5-8 Coeficientes de correlación Cruzada Eventos 6-10.....	35
Tabla 5-9 Coeficientes de correlación serial Eventos 1-5.	36
Tabla 5-10 Coeficientes de correlación serial Eventos 6-10.	36
Tabla 5-11 Funciones de entrenamiento utilizadas	38
Tabla 5-12 Redes neuronales artificiales construidas.	39
Tabla 5-13 Pre selección de redes neuronales artificiales.	65
Tabla 5-14 Nuevas características generales de las tormentas.....	66
Tabla 5-15 Evolución de desempeño ANNPC17.....	77
Tabla 5-16 Evolución de desempeño ANNPC24.....	77
Tabla 5-17 Características generales de los eventos de lluvia con cambios en la cobertura.	80
Tabla 5-18 Variación en el desempeño de las ANN respecto al número de eventos para entrenamiento.	90
Tabla 5-19 Redes neuronales artificiales - Case de estudio 2.	92
Tabla 5-20 Eventos generados para la predicción.	102
Tabla 5-21 Eventos adicionales para el entrenamiento.....	112

1 INTRODUCCIÓN

El rápido crecimiento poblacional en las áreas urbanas y la correspondiente densificación de zonas con sistemas de drenaje faltos de capacidad, suponen un reto para la ingeniería moderna. La prolongada vida de operación de los interceptores y colectores actuales, sumados a la falta de mantenimiento y al bajo desempeño de los materiales, han decantado en un crecimiento acelerado de la cantidad de puntos críticos de las redes de drenaje, en donde problemas de sobrecarga y sedimentación generan pérdidas humanas y materiales, estas últimas en ocasiones, irreparables.

Sin embargo, frente al evidente problema que afronta la ingeniería, con respecto a la correcta recolección, transporte y disposición de aguas lluvias, el concepto de integralidad de sistemas ha comenzado a jugar un papel importante en el panorama. El almacenamiento de caudales picos en tanques de retención, las tecnologías verdes, y el control en tiempo real de los sistemas de drenaje, son tan sólo algunos de los conceptos a la vanguardia de un movimiento conceptual en el que la disposición de las aguas lluvias va más allá de una disposición segura y rápida hacia el receptor final. La optimización de los procesos y la aplicación de metodologías que permitan atenuar el impacto de los caudales picos en áreas urbanas, con alto riesgo de afectación, es el nuevo objetivo en la era moderna.

La ingeniería especializada en el drenaje ha optado finalmente por la decisión de afrontar la problemática del drenaje urbano de aguas lluvias de manera global e integral, con tecnologías que minimicen el riesgo inherente de inundación que acarrea la escorrentía superficial. La base conceptual de estas múltiples tecnologías es la de dar manejo al agua lluvia desde el mismo instante en el que cae al terreno, buscando restablecer el proceso hidrológico natural.

Sin embargo, para poder implementar exitosamente estas metodologías, se hace necesario el conocimiento minucioso del comportamiento de las redes de drenaje objeto de estudio, puesto que es este mismo comportamiento el que dicta los lineamientos para la óptima implementación de estas tecnologías. Actualmente, la forma convencional para conocer dicho comportamiento es la modelación computacional; hoy en día existen las herramientas necesarias para simular con gran precisión la operación de un sistema de drenaje sin importar su complejidad; en el mercado y en general en el ámbito práctico se distinguen herramientas de modelación como el programa EPA SWMM, desarrollado por la Agencia de

protección ambiental de los Estados Unidos, o el programa Sewer GEMS desarrollado por la casa estadounidense Bentley. Dichos programas ofrecen una solución confiable y sencilla frente al problema de la modelación de sistemas de redes de drenaje. Sin embargo este tipo de software como cualquier otro de su tipo, exigen además de una considerable cantidad de información topológica, un costoso proceso de calibración para que el programa garantice su desempeño.

Por otro lado, el auge de la Inteligencia Artificial (IA), acompañada del rápido crecimiento computacional, ha brindado herramientas como los algoritmos genéticos, la lógica difusa y las redes neuronales artificiales, las cuales son metodologías inteligentes que han sido aplicadas exitosamente en otros campos de investigación. Este documento realiza un acercamiento práctico al uso de estas herramientas desde una plataforma mundialmente reconocida como lo es el software MatLab®. En el desarrollo investigativo de este documento se realiza una aproximación a la teoría y al método de las redes neuronales artificiales o ANN, por su acrónimo en inglés “Artificial Neural Networks”, se exploran los diferentes tipos de redes neuronales junto con sus funciones de entrenamiento y finalmente se desarrolla todo un proceso de modelación por medio de las ANN, para un caso de estudio real, con el cual se obtienen resultados preliminares sobre el desempeño de las arquitecturas inteligentes construidas y su verdadera aplicabilidad en la práctica de la ingeniería de drenajes.

1.1 OBJETIVO GENERAL

Como objetivo general de esta investigación se espera desarrollar y evaluar el desempeño de un grupo de redes neuronales artificiales, o ANN por su acrónimo en inglés (Artificial Neural Networks), que permitan ser utilizadas en la predicción hidráulica del tránsito de crecientes pluviales a través de redes de drenaje urbano.

1.2 OBJETIVOS ESPECIFICOS

Para lograr este objetivo se plantearon además los siguientes objetivos específicos:

- Determinar cualitativamente y con base en el estado del arte, posibles tipos de redes neuronales artificiales y algoritmos de entrenamiento que en otros fenómenos hidráulicos hayan generado resultados confiables y útiles en el estudio dichos fenómenos.



-
- Construir arquitecturas de inteligencia artificial, a través del software MatLab®, las cuales tras un proceso de entrenamiento permitan simular el fenómeno de tránsito de caudales pluviales a través de una red de drenaje urbano.
 - Evaluar el desempeño de las ANN en la generación de hidrogramas de respuesta frente al tránsito de caudales pluviales en un caso de estudio real.
 - Establecer la utilidad del uso de la herramienta MatLab® para el fenómeno de estudio así como sus limitaciones.
 - Definir preliminarmente lineamientos o recomendaciones útiles, en la construcción de ANN, que permitan al ingeniero moderno un amigable acercamiento a la utilización de herramientas de inteligencia artificial en sus procesos de estimación de caudales de respuesta y posible predicción de los mismos.

2 CONTEXTUALIZACIÓN Y MARCO TEÓRICO

La complejidad de la hidráulica, aun en los fenómenos aparentemente más simples, siempre ha impulsado la necesidad de determinar nuevas metodologías que permitan conocer cada vez más a profundidad el comportamiento físico de los sistemas; el objetivo general parece ser siempre el mismo, y es el de buscar una emulación, sino exacta si muy ajustada a la realidad, además de simplificada, sobre el comportamiento de nuestros sistemas de estudio. Y es en esta búsqueda misma de métodos que permitan simular fenómenos altamente complejos pero que además operen bajo un nivel de sencillez igual de relevante, que la paradoja se convierte en reto.

Afortunadamente, y gracias a la aparición de las computadoras desde la década de los años 60, la ingeniería se ha dotado cada vez más con herramientas computacionales eficientes y rápidas; dichas herramientas a lo largo de su joven, pero rica historia, han abierto las puertas a un conocimiento ilimitado el cual le ha permitido al ingeniero dar solución eficiente y confiable a la gran mayoría de los retos de su entorno. Uno de estos retos en especial, el drenaje urbano, siempre se hace más desafiante conforme pasa el tiempo, pero es hoy en día que la problemática de los sistemas de drenaje urbano parece haber alcanzado un punto crítico, y esto debido primordialmente a la gran densificación de zonas urbanas. Para finales del siglo pasado, casi el 50% de la población mundial vivía en zonas urbanas, habiéndose incrementado esta cantidad en más del 80% desde mediados de los años 60, (J Dolz, 1994). Este alarmante crecimiento poblacional ha sometido progresivamente a los sistemas de drenaje urbano a la captación y transporte de grandes caudales, los cuales son el producto de la gran escorrentía directa derivada de la muy empobrecida capacidad de retención e infiltración de la superficie urbana. Dicho incremento en la captación ha conllevado rápidamente a una obsolescencia del sistema de drenaje existente, exigiendo la toma de medidas definitivas que produzcan un impacto positivo en el desempeño del drenaje urbano. Sin embargo estas medidas implican un correcto conocimiento del sistema estudiado, y es por ello que la modelación de los sistemas juega un papel tan importante en el proceso de diagnóstico y diseño de la red.

En la actualidad, y gracias a los avances tecnológicos, ya existen programas computacionales para la modelación de los sistemas estudiados; sin embargo una

de las grandes limitantes de este tipo de plataformas es la exigente cantidad de información que requieren para realizar sus procesos.

Un programa comúnmente utilizado para estos fines, es el software EPA SWMM desarrollado por la Agencia de Protección Ambiental de los Estados Unidos (EPA), al ser una plataforma gratuita y de libre acceso es una de las herramientas mundialmente más reconocidas y utilizadas en el medio. Sin embargo, aún esta reconocida herramienta requiere datos topológicos mínimos, para generar una corrida exitosa, aunque no confiable. Dichos datos suelen ser:

- Localización espacial de los pozos
- Cotas Rasantes y Fondo
- Longitud de tramos
- Cotas batea de Inicio y Fin
- Diámetros internos
- Rugosidades (n de Manning)
- Conectividad real de la red
- Caudales

Contando con esta información básica, un modelo computacional está en la capacidad de transitar los caudales con ecuaciones físicamente basadas, y arrojar resultados muy aproximados y reales.

Sin embargo, dicho tránsito en la práctica sólo es útil en aquellos casos en los que la red modelada es una red diseñada previa su construcción, para la cual se garantizan con una alta confiabilidad los datos de entrada al modelo. Sin embargo, cuando el problema de la modelación radica en sistemas existentes, como sucede en la mayoría de los casos, la construcción del modelo requiere de un componente de calibración importante, en el que se deben realizar mediciones para ajustar el desempeño del modelo a la realidad.

Desafortunadamente dicho proceso es costoso y demorado, y es allí cuando las ANN empiezan a jugar un papel importante. Siendo metodologías adaptativas e inteligentes, las ANN están en la capacidad de aprender de series de datos históricas lo necesario para predecir las respuestas de un sistema frente a caudales pluviales de entrada. Todo esto sin requerir ninguna de las características listadas previamente para modelos convencionales, inclusive las ANN al operar bajo la información de mediciones reales incluye implícitamente

datos de la red antes desconocidos pero de importancia, de los cuales a continuación se hace una revisión.

2.1 PROBLEMÁTICA DEL SISTEMA DE DRENAJE URBANO

Entendida la problemática de los sistemas de drenaje urbano como consecuencia directa de los procesos de impermeabilización de superficies que se generan a su vez por la densificación en áreas urbanas de alta demanda de recursos hídricos. Es ahora importante conocer dichos factores, ya que estos influyen desfavorablemente en el funcionamiento de las redes de drenaje; además vale la pena mencionar que son estos mismos los que constituyen, en la mayoría de los casos, limitantes importantes aun en los modelos computacionales de simulación más avanzados.

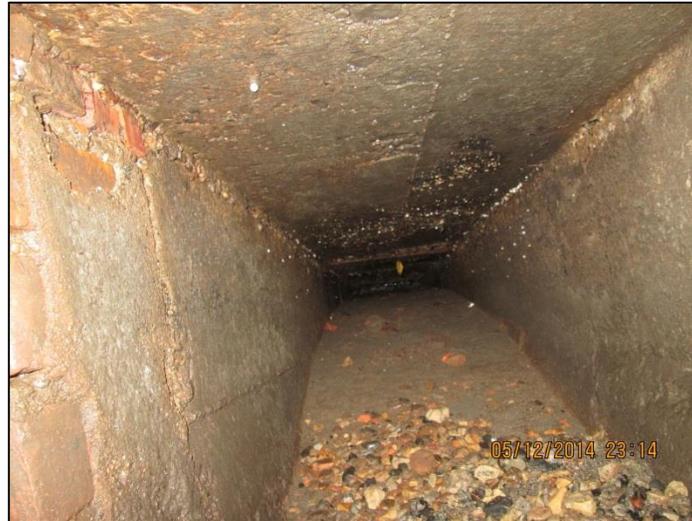
2.1.1 Sedimentación y desechos de tamaño considerable

Entendiéndose para este documento como desechos considerables a aquellos cuerpos sólidos de gran tamaño alojados dentro de la red de drenaje, temporal o permanentemente, que por su envergadura constituyen un obstáculo evidente al flujo natural dentro de la red, Fotografía 2.1,



Fotografía 2.1 Tubería de concreto dentro de colector de aguas combinadas.

y a la sedimentación como el depósito de sólidos de tamaño pequeño que debido a bajas velocidades en la red o a obstáculos dentro de la misma, se acumulan progresivamente en el fondo de los colectores. Fotografía 2.2.



Fotografía 2.2 Colector de aguas combinadas altamente sedimentado.

Como es evidente en la Fotografía 2.1 y la Fotografía 2.2 en las redes de drenaje pueden encontrarse obstáculos que afectan el correcto funcionamiento de estos sistemas; desafortunadamente dichos fenómenos pocas veces pueden ser identificados dentro de la red puesto que demandan un extenuante proceso de catastro e inspección de redes, y de ser hallados, la correcta modelación hidráulica debido a su influencia en el flujo resulta muy compleja.

2.1.2 Estructuras de red

Todo sistema de drenaje, sanitario o pluvial, eventualmente y debido a necesidades topográficas, topológicas y/o hidráulicas, requieren la inclusión de estructuras de soporte para el proceso de tránsito de caudales. Dichas estructuras (alivios, estructuras de disipación de energía, cámaras de caída, desarenadores y sifones, entre otras) incluidas en línea dentro de las redes de drenaje, representan una variable más a la hora de entender la hidráulica que rige el sistema y exige un esfuerzo adicional en el proceso de calibración del modelo. Es por eso que una definición geométrica e hidráulica de dichas estructuras es indispensable.



Fotografía 2.3 Estructura de alivio.

2.1.3 Topología

Otro factor importante a tener cuenta a la hora de la modelación hidráulica y el estudio de los alcantarillados es el conocimiento detallado de la topología, según (Páez, 2010) cambios considerables en factores de calibración como el diámetro y la rugosidad, no afectan significativamente los hidrogramas de respuesta de una red de drenaje como si lo hacen los limnigramas. Sin embargo, si es necesario tener conocimiento detallado de la configuración de los tramos de la red así como la certeza en la inclusión de todos los tramos y áreas de drenaje aportantes al estudio de la red en cuestión. Este hecho nuevamente requiere un esfuerzo operacional, puesto que exige el catastro de redes detallado en el área de estudio, información que en la mayoría de los casos es insuficiente.

Junto a esto se suma la actual necesidad de un método que permita determinar físicamente las pérdidas de energía en cámaras de todo tipo y otras estructuras en donde las condiciones topológicas y de flujo, dificultan el entendimiento de los fenómenos hidráulicos.

2.1.4 Fallas estructurales

Finalmente, otro factor que afecta el desempeño hidráulico de una red de drenaje y por ende su correcta modelación, es la presencia de fallas estructurales en los ductos que componen la red de alcantarillado. Este tipo de fallas, como fisuras o desplazamientos (horizontales y verticales), constituyen una fuente potencial de incertidumbre hidráulica, véase Fotografía 2.4.



Fotografía 2.4 Falla estructural en un colector combinado.

En las grandes redes que conforman el sistema de drenaje de un área urbana, es virtualmente imposible determinar con exactitud todos los puntos de fallas estructurales e irrupción de raíces arbóreas en el sistema, razón misma por la cual la inclusión de dichos datos en un modelo hidráulico computacional, que a su vez tenga la capacidad de simular la influencia de estas fallas en la red, no es posible.

3 REDES NEURONALES ARTIFICIALES (ANN)

Las ANN son el conjunto de algoritmos de aprendizaje y procesamiento automático que constituyen finalmente una arquitectura que posee Inteligencia Artificial, la cual está en la capacidad de aprender y arrojar una predicción automática a fenómenos reales de alta complejidad. Las redes neuronales al igual que los algoritmos genéticos, conforman una estructura inteligente que permite al usuario solucionar problemas mediante la utilización de algoritmos iterativos; estos progresivamente encuentran una solución factible tras explorar inteligentemente un espacio de solución conocido.

En el caso de las ANN el espacio de solución es ingresado enteramente por el diseñador de la arquitectura durante el proceso de entrenamiento. Dicho espacio de solución, debe ser acompañado con su equivalente espacio de entrada, requerimiento indispensable para el aprendizaje de la red.

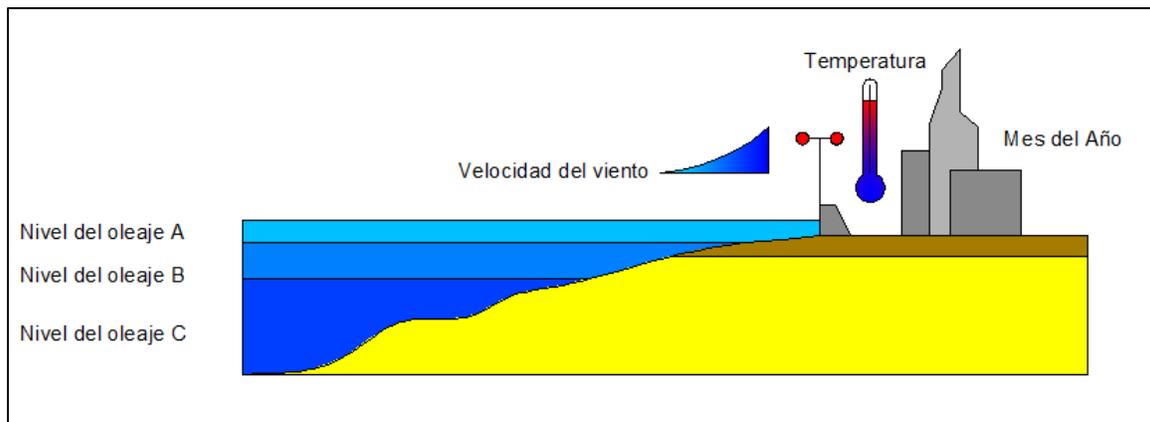


Figura 3.1 Espacios de entrenamiento, Entradas Vs Salidas.

Las ANN reciben su nombre debido a la similitud simplificada que guardan estas con sus homologas biológicas en el cerebro humano. En neurociencia las redes neuronales son estructuras compuestas por conexiones sinápticas organizadas, producto de la interconexión de neuronas; éstas de tipo excitatorio o inhibitorio envían estímulos a través de toda la red generando respuestas cerebrales (Erik R. Kandel, 2001). El funcionamiento e interacción de las neuronas cerebrales es altamente complejo, y los procesos dentro de la actividad cerebral abarcan mucho más que la activación por estímulos y el envío de señales; por esta razón las ANN son tan solo una representación simplificada de sus homologas biológicas.

Una ANN es capaz de dar respuestas automáticamente sólo después de un proceso de entrenamiento, y es este procedimiento el que definirá el rendimiento de la red neuronal. El proceso de entrenamiento consiste en ingresar al modelo inteligente una serie de datos de entrada, compuestos por parejas; el primer componente de entrada debe contener todas las variables de decisión involucradas en un mismo proceso; el segundo componente debe por su parte contener las respuestas reales a dichos procesos condicionada a cada una de las entradas de decisión.

A manera de ejemplo en la Figura 3.1 se ilustra cómo para un conjunto de variables de decisión X , en este caso mes del año, temperatura, y velocidad del viento, se define la variable de respuesta Y : nivel máximo del oleaje. La función de la red neuronal artificial es la de aprender a asociar dicha respuesta en función de las características leídas en el componente de entrada. Según (Solomatine, 2002) el aprendizaje de la máquina depende directamente de la diversidad de los datos de entrenamiento; cuanto más diversos y representativos sean los datos de entrada a la ANN, mejor será el proceso de aprendizaje, aunque advierte también que excederse en la cantidad de datos de entrada puede acarrear un sobre entrenamiento de la ANN.

Prosiguiendo con el ejemplo ilustrado en la Figura 3.1, en la Figura 3.2 se esquematiza el montaje de una red neuronal artificial con dos capas ocultas de 3 y 2 neuronas respectivamente; en esta se ilustra la capa de entrada donde ingresan los valores de las variables, las conexiones entre neuronas de diferentes capas, y la capa de salida, encargada de emitir la respuesta de la red neuronal en función de los impulsos sinápticos de entrada. Cada neurona recibe información de las neuronas de la capa anterior a través de las conexiones sinápticas entre ellas. Recibida la información, la neurona la procesa y emite un impulso hacia la siguiente capa oculta, siempre y cuando dicho impulso supere cierto valor de umbral. El procesamiento neuronal individual consiste en una función β que opera con los valores recibidos por las neuronas de la capa anterior, valores que tienen en sí el valor sináptico de la conexión entre las neuronas; así una neurona siempre dará más importancia a la neurona con mayor peso.

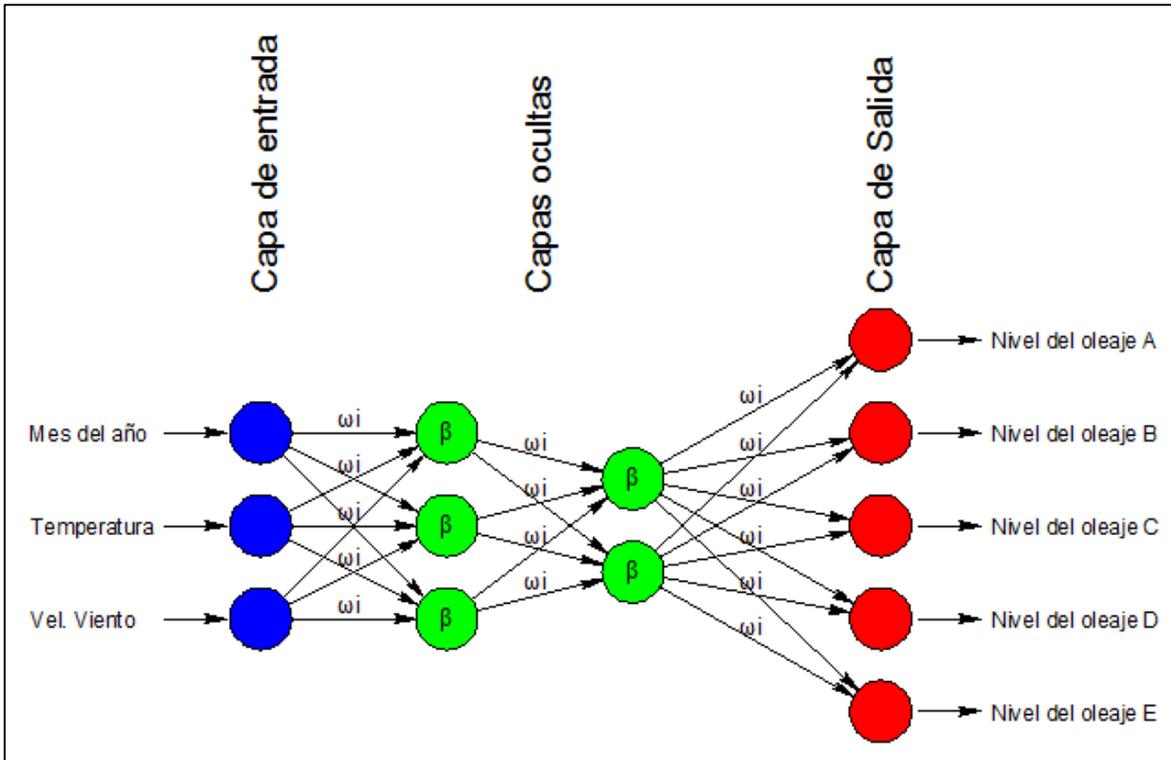


Figura 3.2 Esquema de una red neuronal artificial (ANN).

Una vez procesados los valores y pesos de las capas convergentes a un neurona, esta emite su señal de respuesta hacia las neuronas de la capa oculta siguiente, si la respuesta neuronal supera el valor del umbral la neurona se considera excitatoria, de lo contrario la neurona se considera inhibitoria y no emite señales hacia las capas subsecuente.

3.1 ENTRENAMIENTO Y APRENDIZAJE

El proceso de aprendizaje o entrenamiento consiste en ajustar el valor de los pesos en las conexiones sinápticas así como de los umbrales con el fin de que la ANN arroje como resultados, datos similares a los reales. Dicho ajuste es medido generalmente por una medida de bondad de ajuste, la cual es a su vez la función de optimización de los algoritmos o metodologías encargadas de entrenar la red. En términos generales el estudio de una arquitectura inteligente debe realizarse a través de 2 o 3 grupos de datos, los cuales son porcentajes del total de datos disponibles para construir la ANN. Estos 3 grupos se conocen como:

3.1.1 Entrenamiento

Corresponde a cierto porcentaje de los datos disponibles para la construcción de la red, utilizados por la ANN para minimizar la función de desempeño, generalmente el error cuadrático medio (MSE); dichos valores buscarán ajustar a la red de acuerdo al valor mínimo del error medido.

3.1.2 Validación

Porcentaje de datos utilizados para medir la capacidad de generalización de la ANN, con lo cual el entrenamiento se detiene cuando la generalización de red ha sido optimizada. No todos los algoritmos de entrenamiento permiten este ajuste de las curvas.

3.1.3 Evaluación o Test

Datos utilizados por la red para evaluar su desempeño en respuesta a datos nunca antes procesados en las etapas de entrenamiento o validación. Del grupo de parejas de entrada, la ANN sólo hace uso de las variables de decisión, y evalúa el ajuste de sus resultados respecto a los datos esperados.

3.2 APLICACIÓN PRÁCTICA

Gracias a sus características, las ANN han encontrado campo de acción en diferentes áreas del conocimiento. En la actualidad, el uso más común aunque poco conocido es el de reconocimiento de patrones. A continuación se presentan algunos de los usos registrados en la literatura; estos muestran la versatilidad de las ANN y su gran potencial al encontrarse usos en temas diversos y de alta complejidad.

3.1.4 Medicina

Las ANN de reconocimiento de patrones han sido utilizadas exitosamente en el diagnóstico de radiografías y tomografías, detección de daño cerebral y cardiopatías. El uso de bases de datos de imágenes radiográficas o de tomografías como datos de entrenamiento de redes neuronales han permitido la construcción de arquitecturas inteligentes durante hace más de 30 años. Según (Delgado, 1999) al comparar resultados de una red neuronal diseñada para detectar tempranamente enfermedades oculares la red en cuestión obtuvo un

diagnóstico exitoso en un 87,1%, mayor al diagnóstico de un médico general (79,0%) y cercano al de un médico especialista (92%).



Figura 3.3 Trazado de células cancerígenas de entrenamiento para ANN (Fuente: Delgado, 1999).

En la Figura 3.3 se observa como las imágenes microscópicas de células cancerígenas son convertidas en patrones de fácil lectura para una red neuronal de tal forma que esta sea capaz de arrojar un diagnóstico preliminar y rápido sobre las probabilidades de padecer la enfermedad.

3.1.5 Clasificación de Datos

Uno de los usos más públicos de las redes neuronales artificiales, suele pasar desapercibido. Con el reconocimiento de patrones y la clasificación de datos, muchas redes neuronales artificiales se diseñan con la finalidad de reconocer con éxito la identificación de una persona tras registrar su huella dactilar, su huella ocular, una fotografía de sus facciones o los sonidos de su voz. El uso de las ANN en este campo ha sido ampliamente explotado ya que según Basoqain Olabe (2005) estas ofrecen una solución más adaptable y económica, puesto que las redes neuronales artificiales, luego de su proceso de entrenamiento ya no requieren el almacenamiento de la base de datos de entrada para poder operar y buscar en el espacio de solución la respuesta esperada.

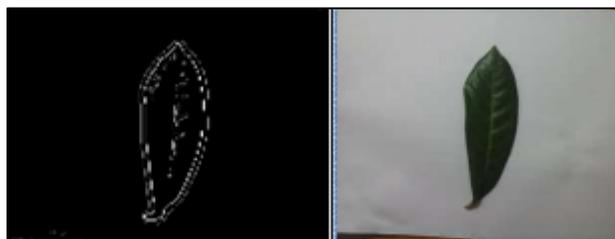


Figura 3.4 Identificación y clasificación de plantas mediante ANN ¹.

¹ Imagen extraída de la red. Disponible en línea: <http://eprints.ucm.es/23444/1/ProyectoFinMaster-PedroPablo.pdf>

3.1.6 Ingeniería

En el campo de la ingeniería también se han registrado gran cantidad de avances y usos de las redes neuronales artificiales destacándose la utilización de redes neuronales para la predicción de crecientes en sistemas pluviales (Dawson, 2006) y la modelación del transporte de sedimentos en sistemas de alcantarillado, Figura 3.5, involucrando características físicas de los cuerpos sólidos y velocidades del flujo (Ebtehaj & Bonakdari, 2013).

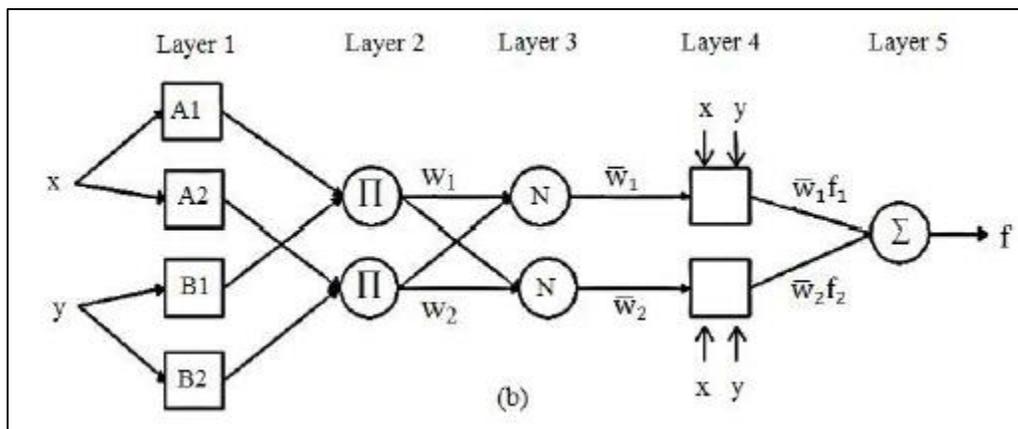


Figura 3.5 Modelo ANFIS FF-BP multicapa para el transporte de sedimentos en alcantarillados (Fuente: Ebtehaj & Bonakdari, 2013)

4 REDES NEURONALES ARTIFICIALES EN MATLAB®

El estado del arte de las ANN ofrece una vasta variedad de recursos en los que se desarrollaron arquitecturas inteligentes utilizando lenguajes de programación independientes; sin embargo en todos ellos el nivel de conocimiento en lenguajes de programación así como de algoritmos de entrenamiento y optimización, exigen habilidades de programación avanzadas que el ingeniero en la práctica, generalmente no posee.

4.1 TIPOS DE REDES NEURONALES ARTIFICIALES

Por otra parte, el software matemático MatLab® (MATrix LABoratory) siendo un programa mundial y altamente reconocido, ofrece una aplicación amigable y compatible con diferentes sistemas operativos, con un lenguaje de programación propio y de fácil aprendizaje. Además cuenta con una serie de aplicaciones de interfaz gráfica dentro de las que se encuentra el Toolbox de Redes Neuronales.

» *nnstart* → *Función de MatLab*

Para el fácil manejo, el software subdivide una serie de redes neuronales en 4 grupos principales, Figura 4.1.

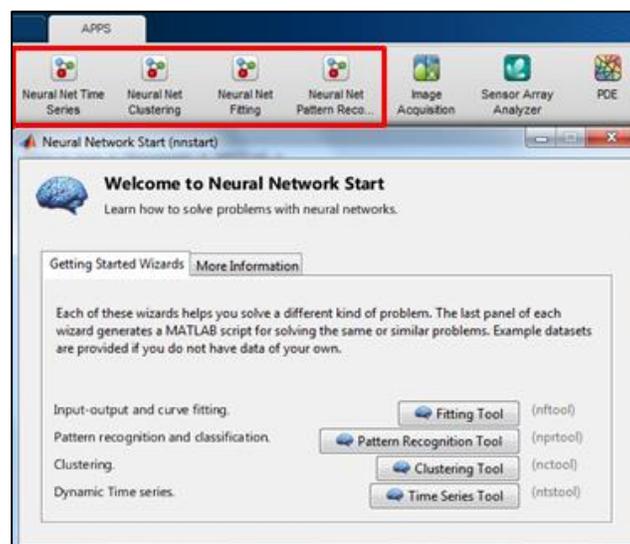


Figura 4.1 Aplicaciones de Redes Neuronales Artificiales.

Esta subdivisión se realiza dependiendo del problema que se quiera resolver. Estos 4 grandes grupos corresponden a:

4.1.1 Ajuste de curvas / Curve Fitting Tool

>> *nftool*

Este tipo de arquitecturas es útil cuando el problema consiste en determinar la relación (lineal o no lineal) entre múltiples variables de decisión y múltiples variables de salida, esto cuando los datos son de tipo estático. Un ejemplo encontrado dentro de la aplicación consiste en una ANN capaz de determinar el torque y las emisiones de óxido nitroso en función del porcentaje de combustible y la velocidad de un motor bajo diferentes condiciones de operación.

4.1.2 Reconocimiento y clasificación de patrones/Pattern Recognition Tool

>> *nprtool*

Las arquitecturas contenidas aquí permiten reconocer múltiples datos de entrada y clasificarlos en categorías específicas definidas en la salida. El ejemplo comúnmente encontrado en la literatura y presente en la herramienta a manera de ejemplo es una red neuronal que permita clasificar tumores como cancerígenos o no, en función de biopsias de muestra con 9 variables de decisión entre las que se cuentan la mitosis, los nucléolos normales y la uniformidad de la forma de la célula.

4.1.3 Agrupación / Clustering

>> *nctool*

Este tipo de ANN permite agrupar series de datos a través de similitudes; utiliza en su capa oculta un mapa de auto organización. A diferencia de los otros tipos de redes, el diseñador únicamente ingresa datos de entrada a la red neuronal, puesto que son características propias de estos datos de entrada los que permiten la clasificación de los mismos. Un ejemplo es una ANN que permite clasificar el iris de las hojas de diversas plantas en 3 diferentes especies, respecto a 4 longitudes propias de cada hoja estudiada.

4.1.4 Series de tiempo dinámicas / Dynamic Time Series

>> *ntstool*

El último grupo de redes neuronales artificiales es aquel que permite resolver problemas no lineales de series de tiempo dinámicas, en el que es posible que datos en un determinado tiempo sean función de datos pasados. Un claro ejemplo de este tipo de ANN, que no está incluido como ejemplo en la herramienta de MatLab®, es la determinación de hidrogramas de salida de un sistema de drenaje, en función de las entradas de caudal a dicho sistema, el cual es precisamente el problema que se busca resolver en esta tesis.

Vale la pena destacar que para el manejo de varias ANN MatLab® también cuenta con una interfaz gráfica de manejo de datos, por fuera de las interfaces expuestas anteriormente. En ella se podrán definir parámetros propios de las redes que en las funciones anteriormente expuestas son definidas por defecto.

>> *nntool*

Debido a que cada tipo de problema contiene un grupo de redes neuronales artificiales recomendadas por el programa, este documento se concentrará exclusivamente en estudiar el desempeño de las arquitecturas inteligentes diseñadas para operar con series de tiempo dinámicas.

4.2 FUNCIONES DE ENTRENAMIENTO

Dentro de las facilidades que posee la herramienta de redes neuronales artificiales, MatLab® ofrece 19 algoritmos de aprendizaje reconocidos y altamente utilizados en la práctica; vale la pena destacar que no todos ellos son válidos para todo tipo de redes neuronales. Razón por la cual el desarrollo investigativo de esta tesis sólo se centró en 4 algoritmos en específico, los cuales se exponen en el numeral 1.1.4. Sin embargo, el software concentra los 19 algoritmos en 4 grupos de acuerdo con sus características. Para el interés del diseñador a continuación se expone un resumen de ellos:

4.1.5 Funciones de entrenamiento supervisadas

No constituyen un algoritmo específico de entrenamiento; los ajustes de pesos y umbrales de las conexiones sinápticas se realizan por métodos de prueba y error,

aleatorios o cíclicos en donde se comparan las salidas de las arquitecturas inteligentes con los objetivos introducidos por el diseñador.

4.1.6 Funciones de entrenamiento sin supervisión

Al igual que las funciones de entrenamiento supervisadas, estas no comprenden un algoritmo específico de aprendizaje, pero los ajustes de pesos y umbrales de las conexiones sinápticas no tienen guía alguna, la red neuronal artificial entrena por medio de reglas de aprendizaje o selección aleatoria de umbrales y pesos.

4.1.7 Funciones de entrenamiento de retro propagación con derivadas de Jacobianos

Se consideran como métodos numéricos de tipo cuasi Newton en el que la función de optimización interpola entre el método Gauss Newton y el método de descenso por gradiente. Se distinguen dos algoritmos, el Levenberg-Marquardt y el de Regulación Bayesiana. Estos algoritmos modificados alteran la diagonal principal de la matriz cuadrada del producto de Jacobianos en las ecuaciones del método Gauss Newton (Universidad Konrad Lorenz, 2009).

4.1.8 Funciones de entrenamiento de retro propagación con derivadas de gradiente

Estos se consideran métodos derivativos dentro de los que se distinguen los algoritmos de gradiente descendente y sus modificaciones. Para estos tipos de entrenamiento los pesos y los umbrales se actualizan en dirección negativa del gradiente de la función de desempeño.

5 DESARROLLO Y PREDICCIÓN A TRAVÉS DE LAS ANN

Con el fin de determinar el desempeño de las ANN, se construyeron una serie de arquitecturas inteligentes las cuales se pusieron a prueba bajo el tránsito de diversos eventos de lluvia generados aleatoriamente. A continuación se presenta el proceso desarrollado para los dos casos de estudio planteados, los dos localizados en la ciudad de Bogotá.

5.1 CASO DE ESTUDIO PEQUEÑO CHICÓ

La primera red escogida para evaluar el desempeño de las ANN, es una red de drenaje pluvial localizada en la ciudad de Bogotá. Los tramos de red estudiados forman parte de la red pluvial de drenaje de la sub cuenca Molinos, la cual se localiza en la zona nororiental de la ciudad, drenando los caudales de aguas lluvias que discurren por la falda de los cerros orientales y por las zonas residenciales presentes en la zona.

La red troncal pluvial de la sub cuenca drena un total de aproximadamente 1600 ha y contiene cerca de 148 tramos de tubería, de los cuales 78 tubos son los analizados en este caso de estudio. En la Figura 5.1 se aprecia la localización espacial de la red local y troncal estudiada.



Figura 5.1 Red local y troncal objeto de estudio (Pequeño Chicó).

Como se puede observar en la imagen anterior, la red objeto de estudio involucra tramos de red tanto troncal, como local, las características de los 16 tramos de red troncal objeto de estudio se muestran en la Tabla 5-1.

Tabla 5-1 Características topológicas de la red troncal.

CÓDIGO	DIAMETRO (m)	LONGITUD (m)	RASANTE INICIAL (m)	BATEA INICIAL (m)	RASANTE FINAL (m)	BATEA FINAL (m)
PLT85747	1.00	101,07	2555,24	2552,37	2554,23	2551,56
PLT85749	1.20	76,03	2554,93	2552,62	2554,51	2552,11
PLT85923	1.40	16,17	2551,49	2548,43	2551,51	2548,43
PLT85750	1.20	86,13	2554,51	2552,08	2554,17	2551,85
PLT85744	1.10	85,28	2555,43	2553,30	2555,31	2553,06
PLT85741	1.00	83,79	2555,82	2553,85	2555,43	2553,59
PLT85748	1.20	14,23	2555,07	2552,69	2554,93	2552,62
PLT85922	1.40	33,19	2551,51	2548,43	2551,53	2548,44
PLT85700	1.00	72,97	2555,23	2552,42	2555,24	2552,39
PLT85941	1.40	81,01	2551,63	2548,52	2551,46	2548,40
PLT85768	1.20	14,14	2554,17	2551,66	2554,23	2551,36
PLT85769	1.40	101,94	2551,71	2548,63	2551,63	2548,52
PLT85940	1.40	59,26	2551,46	2548,43	2551,49	2548,43
PLT85703	1.15	80,39	2555,31	2553,02	2555,07	2552,75
PLT85770	1.40	79,17	2552,04	2548,97	2551,71	2548,65
PLT85771	1.30	90,38	2554,23	2551,24	2554,10	2551,12

Con la intención de estudiar el desempeño de las ANN en un caso de estudio real, también se analizarán un total de 62 tramos de red local, véase Tabla 5-2, afluentes al sistema troncal relacionado en la Tabla 5-1.

Tabla 5-2 Características topológicas de la red local.

CÓDIGO	DIMENSIONES (m)	LONGITUD (m)	RASANTE INICIAL (m)	BATEA INICIAL (m)	RASANTE FINAL (m)	BATEA FINAL (m)
PLT86007	0.30	52,91	2573,97	2572,07	2571,63	2570,19
PLT85641	0.40	93,17	2575,50	2573,25	2569,69	2568,10
PLT85676	0.35	84,96	2570,74	2569,21	2570,03	2568,41
PLT85669	0.85	74,77	2558,82	2556,50	2557,67	2555,31
PLT85619	0.30	59,98	2559,96	2556,62	2558,96	2556,21
PLT85719	0.60	101,44	2565,99	2563,97	2564,49	2561,96

PLT85742	0.50	79,98	2556,42	2555,04	2555,82	2554,22
PLT85992	0.75	55,85	2559,52	2557,15	2558,82	2556,50
PLT85784	0.45	50,68	2576,68	2575,35	2573,21	2572,06
PLT85791	0.75	81,80	2558,73	2556,54	2557,98	2555,57
PLT85905	0.60	94,85	2566,59	2563,60	2564,49	2562,00
PLT85678	0.40	57,84	2573,66	2572,43	2573,86	2571,56
PLT85879	0.60	99,88	2563,79	2561,44	2561,06	2558,66
PLT85737	0.85	87,33	2557,98	2555,55	2557,27	2555,01
PLT85785	0.30	59,44	2575,56	2575,26	2572,96	2570,48
PLT85758	0.75	17,27	2559,04	2556,77	2558,73	2556,58
PLT85917	0.45	9,97	2569,76	2567,89	2569,20	2566,96
PLT85638	0.45	52,45	2572,91	2571,56	2571,63	2570,15
PLT85916	0.60	103,94	2565,91	2564,08	2563,79	2561,41
PLT85621	0.50	14,71	2554,25	2552,38	2554,23	2552,28
PLT85740	0.60	99,69	2569,20	2566,80	2566,59	2563,60
PLT85720	0.75	106,12	2564,49	2561,86	2560,72	2558,76
PLT85636	0.55	87,91	2567,60	2565,86	2565,91	2564,15
PLT85642	0.40	100,03	2569,69	2567,97	2567,60	2565,84
PLT85672	0.90	79,75	2555,33	2553,50	2557,36	2554,50
PLT85675	0.55	91,99	2573,93	2570,89	2570,40	2568,15
PLT85865	0.40	85,62	2561,97	2560,66	2561,06	2559,18
PLT85822	0.30	26,62	2584,17	2578,57	2576,79	2575,45
PLT85620	0.40	8,27	2558,96	2557,46	2558,73	2556,96
PLT85679	0.55	111,15	2573,80	2571,38	2573,93	2570,82
PLT85990	0.75	39,13	2560,72	2558,60	2559,52	2557,23
PLT85674	0.35	95,13	2570,03	2568,38	2566,69	2565,49
PLT85622	0.40	52,03	2554,26	2552,88	2554,25	2552,41
PLT100881	0.30	28,31	2589,76	2588,66	2589,78	2588,63
PLT85670	0.85	24,75	2557,67	2555,29	2557,02	2554,66
PLT100883	0.30	15,43	2589,91	2588,42	2589,98	2588,08
PLT85743	0.40	84,81	2555,27	2553,36	2555,31	2553,17
PLT86003	0.30	29,62	2587,01	2585,48	2585,72	2583,68
PLT85999	0.30	26,91	2587,34	2585,94	2587,01	2585,49
PLT85673	0.90	19,92	2557,36	2552,52	2555,23	2552,43
PLT85745	0.50	96,38	2566,69	2565,41	2565,99	2564,06
PLT85782	0.30	25,55	2585,72	2583,34	2584,51	2580,73
PLT85819	0.40	120,82	2570,93	2568,39	2569,69	2568,13
PLT85640	0.40	85,55	2566,12	2563,67	2565,91	2564,36

PLT85671	0.85	87,60	2557,02	2554,71	2555,33	2553,39
PLT85677	0.30	33,37	2573,46	2571,98	2573,60	2572,43
PLT85786	0.30	49,98	2578,36	2576,12	2576,79	2574,63
PLT85800	0.30	11,02	2555,23	2554,36	2555,33	2554,35
PLT85736	0.30	80,08	2557,54	2555,97	2557,98	2556,30
PLT85809	0.90	9,87	2573,12	2569,79	2572,36	2568,54
PLT85810	0.90	85,08	2570,32	2567,75	2569,26	2565,14
PLT85739	0.60	3,07	2569,20	2566,80	2569,26	2566,59
PLT85820	0.25	36,24	2582,40	2577,05	2575,50	2574,05
PLT100882	0.30	5,83	2589,78	2588,61	2589,91	2588,50
PLT85821	0.40	90,99	2574,86	2574,53	2575,50	2573,49
PLT85639	0.45	69,18	2571,63	2570,06	2569,76	2567,87
PLT100880	0.30	38,89	2589,91	2589,01	2589,76	2588,90
PLT85866	0.75	95,75	2561,06	2558,57	2559,04	2556,77
PLT85738	0.90	99,97	2557,27	2554,98	2555,82	2553,91
PLT85881	0.60	85,78	2570,40	2568,14	2569,20	2566,81
PLT85781	0.30	40,59	2584,51	2580,23	2578,36	2576,19
PLT85637	0.45	16,12	2573,21	2572,00	2572,91	2571,61

5.1.1 DETERMINACIÓN DE CAUDALES PLUVIALES

Los caudales de ingreso al sistema de drenaje se realizarán sólo en los nudos de inicio de la red; estos serán ingresados en forma de hidrogramas de tipo triangular con picos de tormenta para cada pozo en el mismo lapso de tiempo.

Para la determinación de los caudales pluviales de ingreso a la red, se determinan las capacidades a tubo lleno (Q_0) de los tramos iniciales de la red local. Esto con el fin de generar caudales sintéticos aleatorios con base en el valor de los caudales. En la Tabla 5-3 se encuentran dichas capacidades a tubo lleno para los tramos iniciales de la red.

Tabla 5-3 Capacidades a tubo lleno para tramos de inicio de la red de estudio.

Tramo	Q_0 (l/s)	Tramo	Q_0 (l/s)
PLT85820	227.64	PLT85619	93.91
PLT100880	108.42	PLB86093	700.00
PLT85822	445.12	PLT85676	171.00
PLT85800	338.87	PLT85743	143.92
PLT85785	388.59	PLT85865	384.08

PLT86007	222.97	PLT85640	205.08
PLT85999	148.61	PLT85622	240.79
PLT85736	83.06	PLT85757	739.91
PLT85677	147.38	PLT85742	543.17

Una vez obtenidas estas capacidades a tubo lleno, se procede con la conformación de 10 eventos de tormenta para cada uno de los 18 pozos de inicio, para los cuales su pico de tormenta en cada evento independiente corresponde a un rango de porcentajes de la capacidad a tubo lleno.

A manera de ejemplo, para un evento de tormenta en específico se definió que los picos de tormenta de los eventos de lluvia a ingresar en los pozos de inicio correspondían a valores entre el 90% y 95% de los Q_0 . Dichos porcentajes puntuales dentro del rango se generan de forma aleatoria siguiendo una distribución uniforme. Dicho esto, en la Tabla 5-4 se presentan los valores picos generados aleatoriamente en función de las capacidades a tubo lleno de los nudos iniciales, así como los porcentajes generados aleatoriamente.

Tabla 5-4 Caudales aleatorios pico de ingreso a la red, entre 90% y 95% de Q_0

Tramo	Q_0 (l/s)	% Aleatorio	Q Pico (l/s)	Tramo	Q_0 (l/s)	% Aleatorio	Q Pico (l/s)
PLT85820	227.64	0.918	213.98	PLT85619	93.91	0.900	84.55
PLT100880	108.42	0.931	100.95	PLB86093	700.00	0.915	640.15
PLT85822	445.12	0.934	415.53	PLT85676	171.00	0.945	161.57
PLT85800	338.87	0.926	313.96	PLT85743	143.92	0.936	134.75
PLT85785	388.59	0.906	351.90	PLT85865	384.08	0.936	359.37
PLT86007	222.97	0.945	210.61	PLT85640	205.08	0.928	190.24
PLT85999	148.61	0.923	137.21	PLT85622	240.79	0.923	222.26
PLT85736	83.06	0.902	74.88	PLT85757	739.91	0.924	683.43
PLT85677	147.38	0.944	139.09	PLT85742	543.17	0.934	507.13

Debido a que se generaran 10 eventos de tormenta, se estableció que los caudales pico deberían contemplar diferentes estados de operación del sistema, razón por la cual cada evento generará un caudal pico porcentual al Q_0 de entrada, de acuerdo al rango de porcentajes expuestos en la Tabla 5-5.

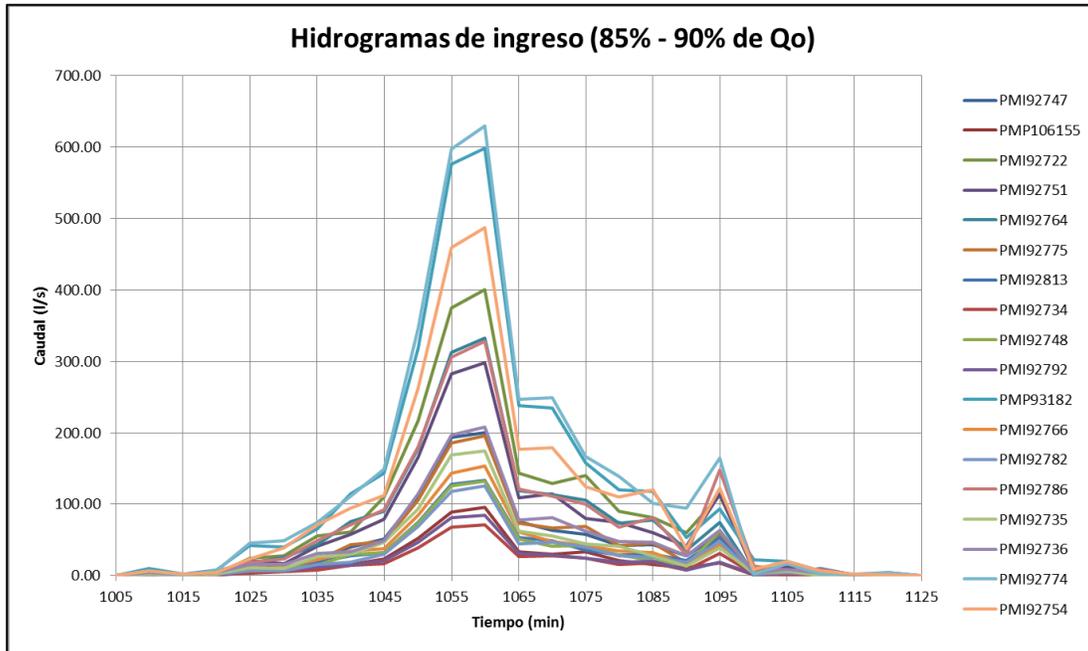
Tabla 5-5 Rango de porcentajes de generación de Q's aleatorios pico

Evento	Porcentajes de generación
1	5% - 10%
2	15% - 20%
3	25% - 30%
4	35% - 40%
5	40% - 45%
6	50% - 55%
7	65% - 70%
8	75% - 80%
9	85% - 90%
10	90% - 95%

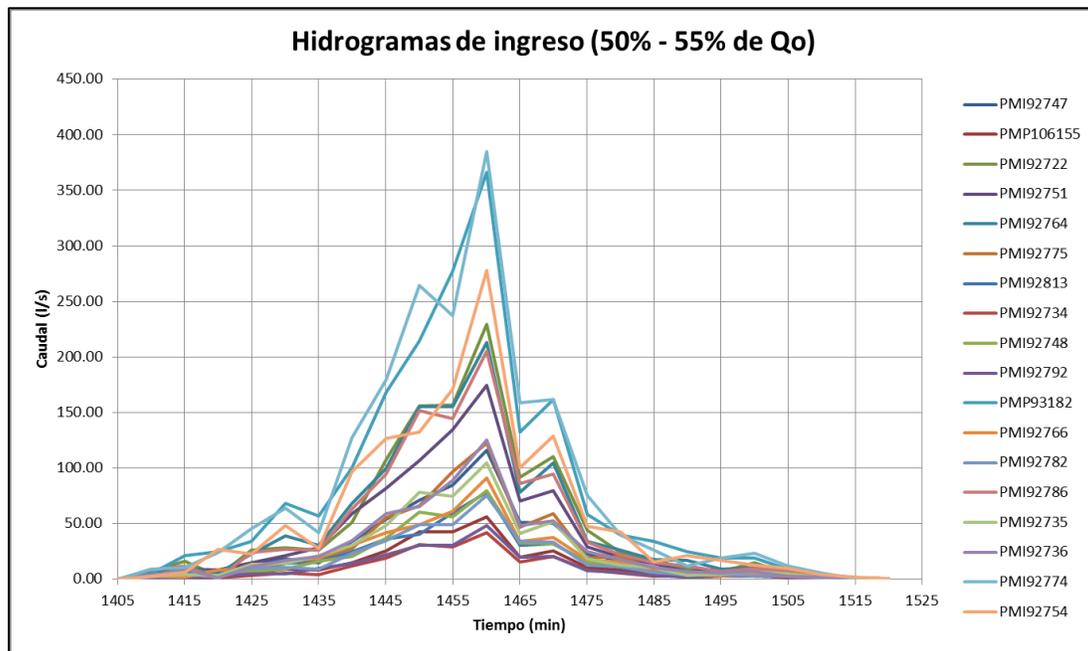
La importancia de la variedad de este rango de caudales y aleatoriedad de los mismos, radica en la necesidad de generar datos de entrada tan variables y diversos que la ANN posea un espacio de aprendizaje lo suficientemente amplio tal que al enfrentarse a datos no conocidos esté en la capacidad de arrojar resultados lo suficientemente confiables.

Una vez definidos los caudales picos de cada evento de tormenta para cada uno de los 18 nodos de ingreso al sistema de drenaje, se procede a generar el resto de la hidrógrafa, igualmente de manera aleatoria. La finalidad de esta generación es la de brindarle a los hidrogramas de entrada aspectos geométricos variables que a su vez incidan en la geometría del hidrograma de descarga. Ingresar geometrías diversas también es necesario para el entrenamiento de la arquitectura inteligente, la diversidad de los datos de entrada así como la función de entrenamiento de la ANN optimizan la generalización de esta última (Morales, 2004).

En la Gráfica 5.1 y la Gráfica 5.2 se ilustran los hidrogramas generados aleatoriamente para dos eventos de lluvia en particular. Allí se puede apreciar la diversidad geométrica de los eventos.

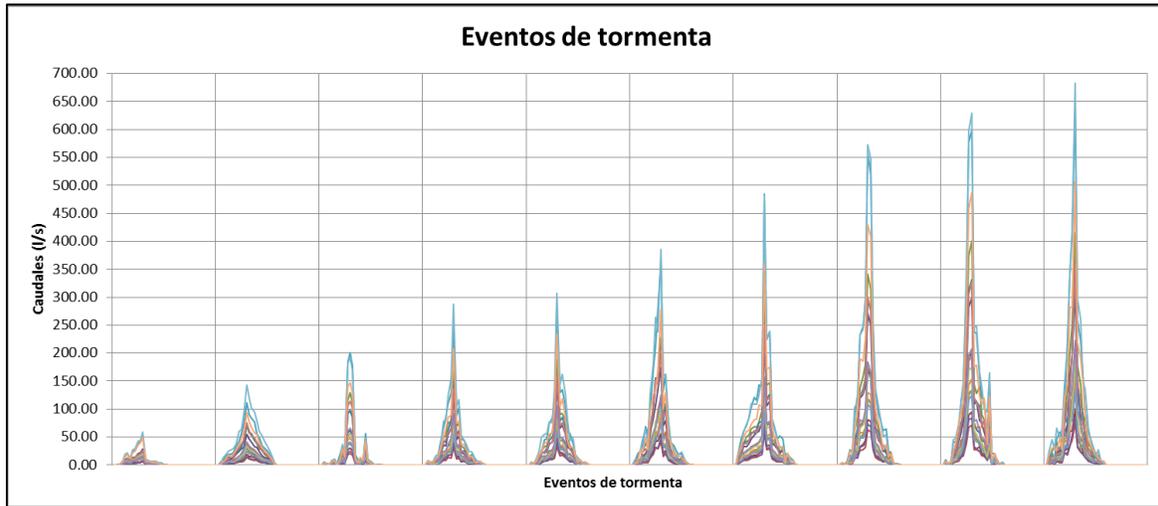


Gráfica 5.1 Hidrogramas evento 9 – Q pico 85% - 90% de Q_o



Gráfica 5.2 Hidrogramas evento 6 – Q pico 50% - 55% de Q_o

Siguiendo este proceso de generación aleatoria, se construyeron para los 10 eventos de tormenta los hidrogramas de entrada para los 18 pozos; en la Gráfica 5.3 se ilustran dichos eventos.



Gráfica 5.3 Eventos de tormenta generados aleatoriamente.

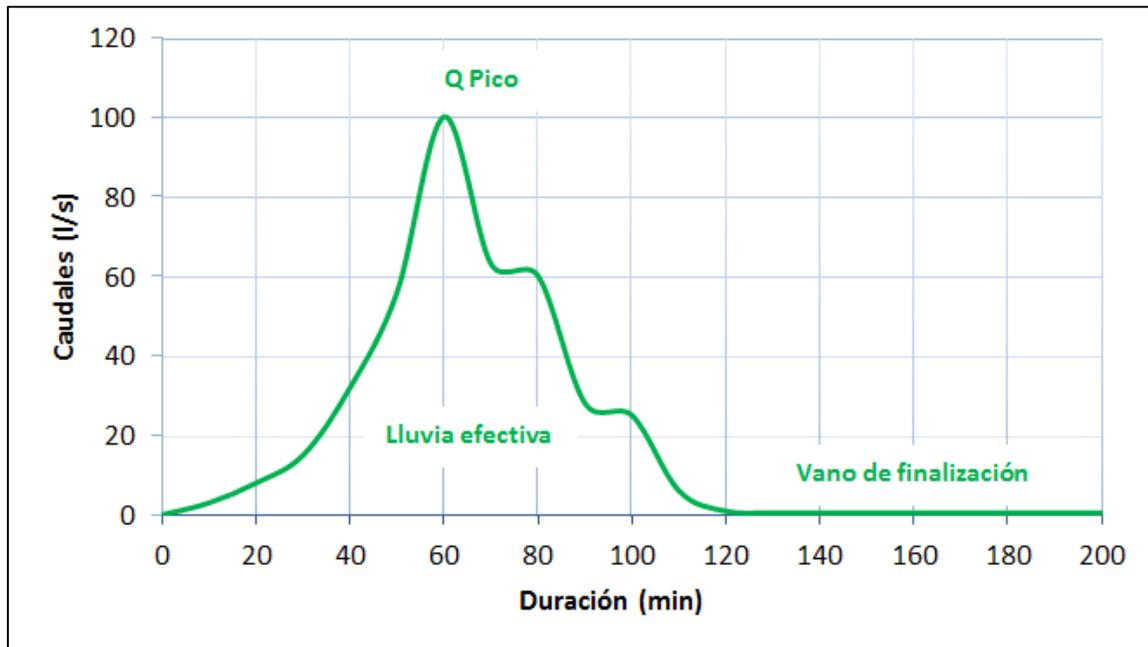
Las características generales, aplicables a los eventos de lluvia son apreciables en la Tabla 5-6 e ilustradas en la Gráfica 5.4.

Tabla 5-6 Características generales de las tormentas

Duración de la lluvia	120 min
Vano de finalización	80 min
Duración evento total	200 min
T para Q máximo (TQM)	60 min
Nudos de Ingreso	18 iniciales

El tiempo del vano de finalización, es el tiempo requerido para que en la modelación hidráulica una vez finalizado un evento de lluvia efectiva, el sistema logre desalojar el caudal recibido sin que este interfiera con el evento siguiente.

Este término se retomará en el capítulo siguiente, concerniente a la modelación hidráulica de la red.



Gráfica 5.4 Características generales de las tormentas.

5.1.2 MODELACIÓN HIDRÁULICA DE LA RED

Una vez determinados todos los caudales de entrada a la red objeto de estudio, el siguiente paso es determinar las salidas asociadas con dichos caudales. Para tal fin se hará uso del software informático Sewer GEMS v8i, el cual es definido por su casa matriz como una multi-plataforma completamente dinámica para la gestión y modelación de sistemas urbanos, sanitarios y combinados (Bentley®, 2014).

Haciendo uso de los datos de la topología de la red objeto de estudio, Tabla 5-1 y Tabla 5-2, se construye el modelo en Sewer GEMS v8i; los resultados dicha construcción se ilustran en la Figura 5.2.

Posteriormente, con las hidrógrafas generadas en el numeral 5.1.1, se realiza la asignación de caudales pluviales para 10 eventos de tormenta en los 18 pozos de inicio de la red.

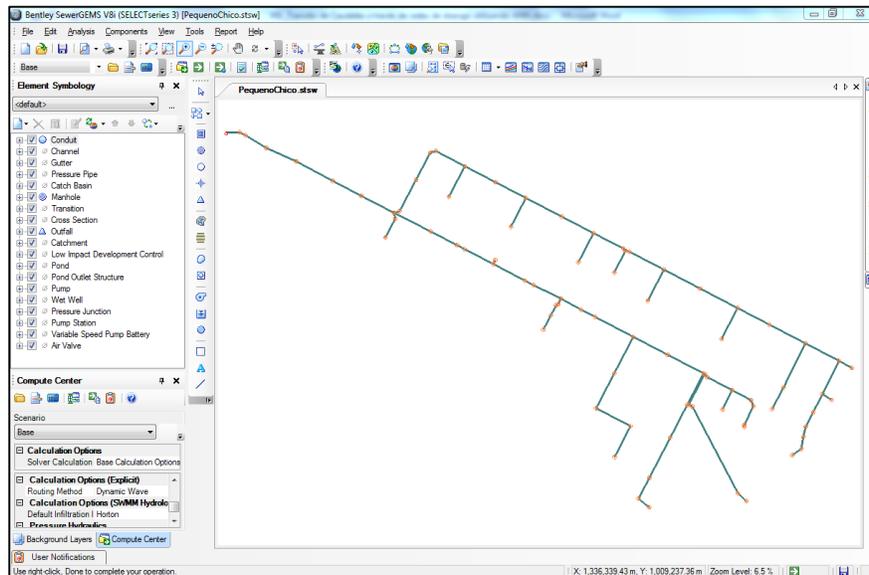


Figura 5.2 Modelo computacional red Pequeño Chicó.

Finalmente, se definen opciones de cálculo, Figura 5.3, para el modelo computacional.

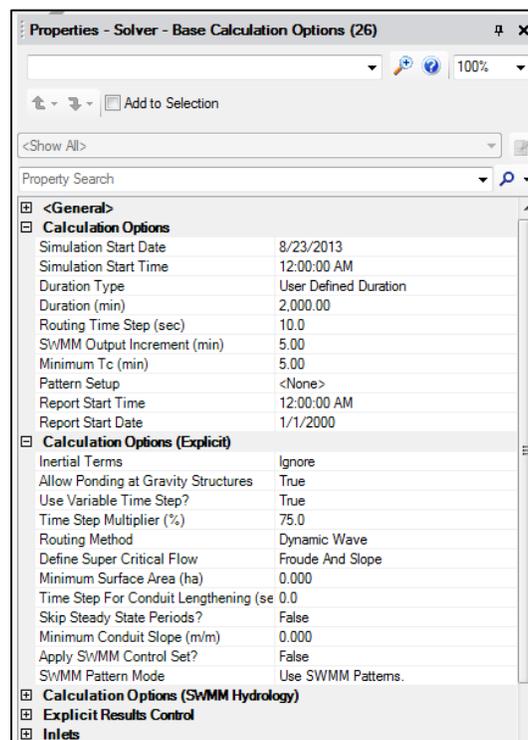
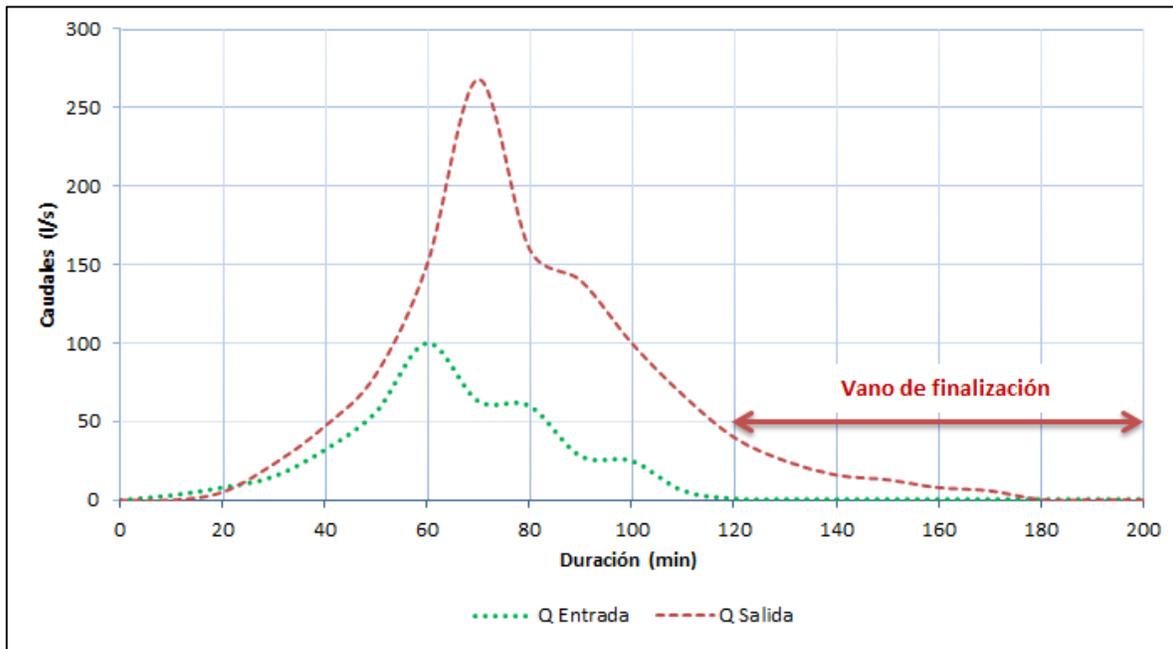


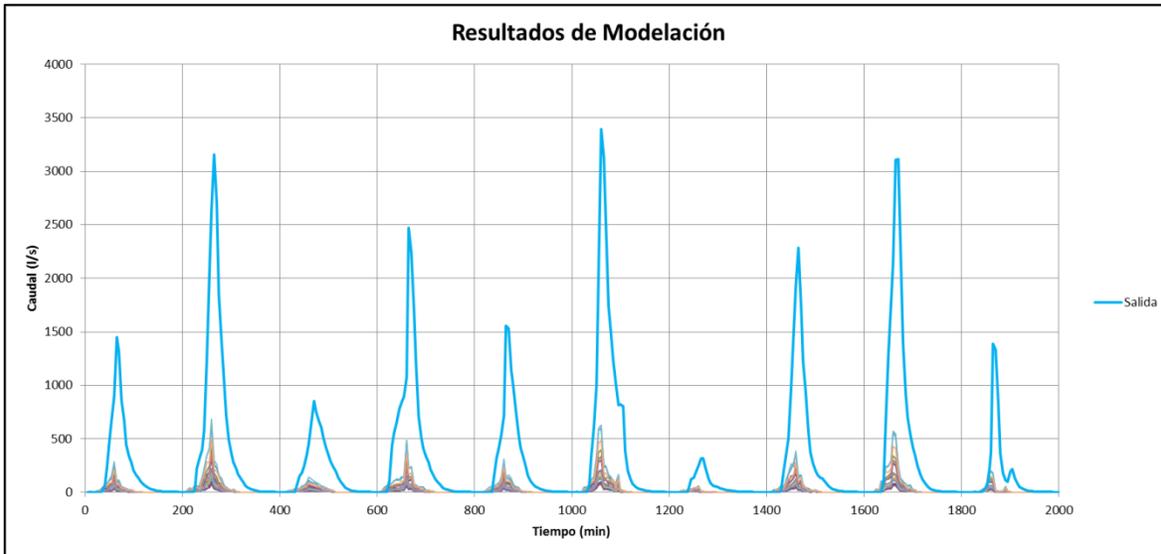
Figura 5.3 Opciones de cálculo para la modelación.

Vale la pena aclarar que después de generada la primera simulación con el modelo en Sewer GEMS v8i, se determinó que la red de drenaje, para los eventos de lluvia efectiva de 120 minutos, requería un tiempo adicional de 80 minutos para transitar completamente la creciente generada por la tormenta inicial, tiempo después del cual podría volver a transitarse un nuevo evento de lluvia independiente del anterior. Este tiempo adicional se define como vano de finalización, Gráfica 5.5.



Gráfica 5.5 Vano de finalización para eventos de lluvia independientes.

En dicho vano de finalización los caudales de ingreso a la red, después de los 120 minutos de lluvia efectiva, son nulos. En la Gráfica 5.6 se ilustran los resultados hidráulicos, obtenidos del modelo, para los 10 eventos de lluvia.



Gráfica 5.6 Resultados de modelación de la red caso de estudio – Pequeño Chicó.

Vale la pena recalcar que entre eventos de tormenta el tiempo es suficientemente largo para considerar que los eventos son independientes, razón por la cual sin importar el orden en que se modelen los caudales de entrada, los resultados a la salida serán siempre los mismos y correspondientes.

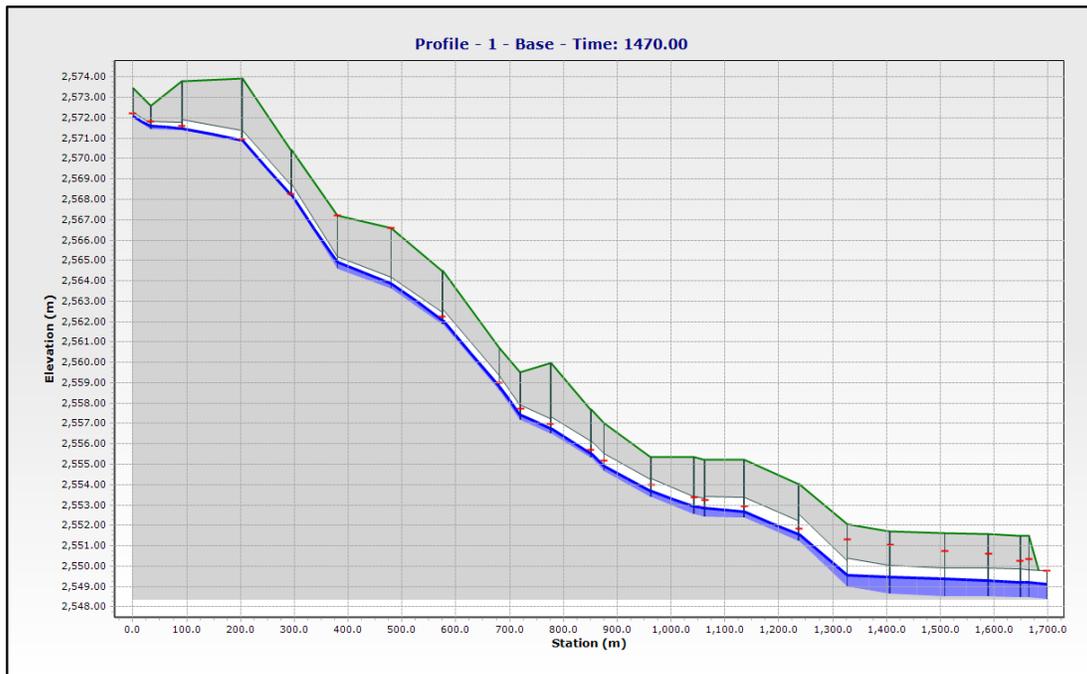


Figura 5.4 Perfil hidráulico PMI92748 – PMP92951 Evento de lluvias 6.

De acuerdo con lo definido en el numeral 5.1.1 los eventos de lluvia generados simulan varios estados de operación de la red, inclusive en aquellos casos en los que la red de drenaje sufre sobrecargas por falta de capacidad. En la Figura 5.4 es apreciable el perfil hidráulico generado por el evento de tormenta 6, definido en el numeral anterior.

5.2 ANÁLISIS DEL REZAGO EN EL TRÁNSITO A TRAVÉS DE LA RED

De acuerdo con la revisión realizada en el numeral 0, sobre los tipos de redes neuronales artificiales con las que cuenta MatLab®, se determinó que las redes de series de tiempo dinámicas son las más acordes al tipo de problema no lineal que presenta el tránsito de caudales.

Sin embargo, este tipo de arquitectura inteligente tiene tres sub grupos que se clasifican según las condiciones del problema que se quiera resolver:

- ANN no lineal, auto regresiva con entradas exógenas (NARX):

Este tipo de ANN predice series de tiempo $y(t)$, dadas series de tiempo $y(t-d)$ y otras series $x(t)$ y $x(t-d)$, (MathWorks Inc, 2013). En la Figura 5.5 se ilustra el esquema utilizado por MatLab® para representar este tipo de arquitecturas.

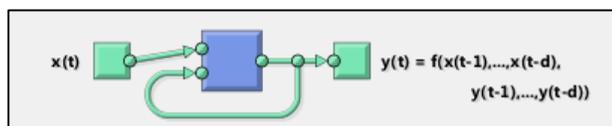


Figura 5.5 Esquema de ANN tipo NARX.

- ANN no lineal, auto regresiva (NAR):

Predice series de tiempo $y(t)$, dadas series de tiempo $y(t-d)$, (MathWorks Inc, 2013).

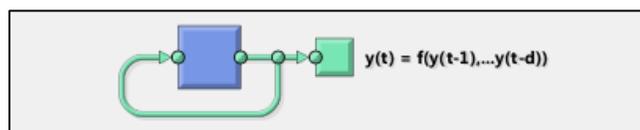


Figura 5.6 Esquema de ANN tipo NAR.

- ANN no lineal, entrada-salida:

Predice series de tiempo $y(t)$, dadas series de tiempo $x(t-d)$. Sin embargo, el software advierte que las redes tipo NARX tienen un mejor desempeño.

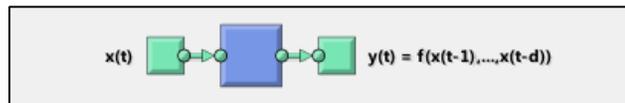


Figura 5.7 Esquema de ANN tipo Input-Output.

Teniendo en cuenta el tipo de fenómeno que se intenta emular por medio de las ANN, se encontró que para series de tiempo con características similares a las que posee un hidrograma o un limnograma, las series tipo NARX o aquellas que son alimentadas por dos fuentes de información, una exógena y una propia, con rezagos en el tiempo, son ideales, esto debido a que permiten ajustar los pesos de la neurona a datos históricos de una misma serie de entrada, (Andreas Kurth, 2008).

Una vez definido el tipo de ANN con la cual se procesaran los datos de la modelación hidráulica de la red, resultado del numeral 5.1.1, ahora se hace necesaria la determinación del valor de la variable “ d ” con la cual la red neuronal podrá predecir los caudales generados en la descarga del colector objeto de estudio, en función de las series de caudales de entrada, y las propias descargas generadas por la ANN; (Elizabeth L. Cavanaugh, 2007).

Para la definición del valor la variable “ d ”, se realizó un análisis estadístico de los datos generados por el modelo computacional construido en Sewer GEMS v8i.

Debido a que la ANN de tipo NARX es alimentada por series de tiempo x y y , se hace necesario determinar el rezago “ d ” para cada una de las dos serie. Para lo cual:

$$dx = \text{Rezago para la serie de tiempo exógena } x$$

$$dy = \text{Rezago para la serie de tiempo propia } y$$

Dichos valores de rezago son dictados por las condiciones de la red de drenaje, por lo que los valores determinados en este capítulo no necesariamente son aplicables a otro tipo de redes.

5.1.2.1 Rezago dx para la serie de tiempo exógena

Se entiende por serie exógena a las series de tiempo independientes, es decir a los hidrogramas de entrada de la red. Para determinar el valor “dx” se calcularán las correlaciones cruzadas entre los datos de entrada y los datos de salida.

Debido a que los datos de entrada vienen en 18 series de tiempo, el coeficiente de correlación cruzada se determinará entre las salidas en la descarga y una serie de tiempo de entrada generada a partir del promedio ponderado de las entradas en los pozos (véase Figura 5.8).

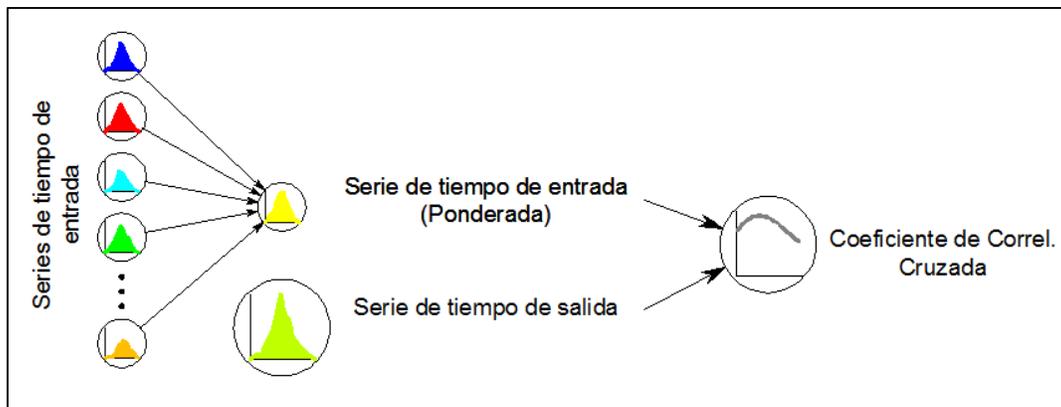


Figura 5.8 Determinación del coeficiente de correlación cruzada.

Determinando el coeficiente de correlación cruzada para los 10 eventos de manera independiente, con rezagos de 0 a 5 saltos en el tiempo (0 – 25 min), se obtienen los resultados de la Tabla 5-7 y la Tabla 5-8.

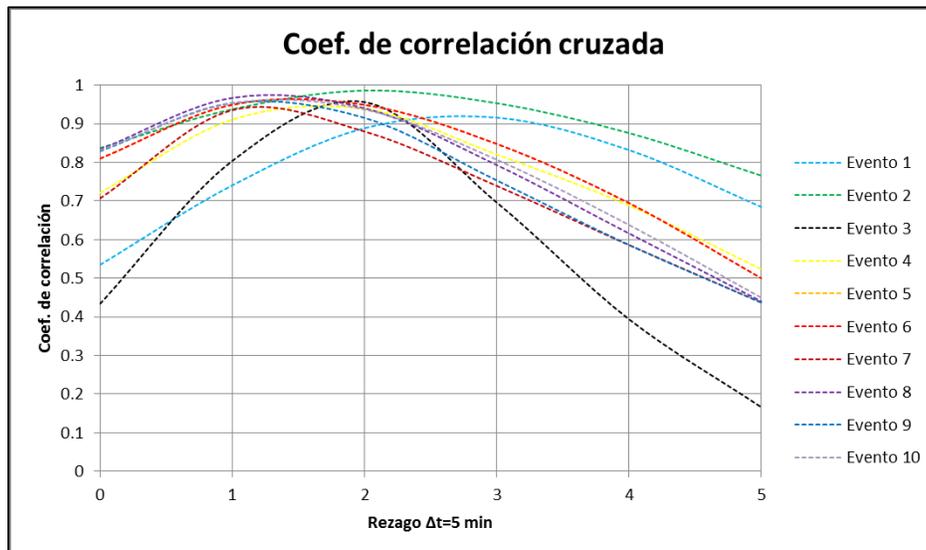
Tabla 5-7 Coeficientes de correlación Cruzada Eventos 1-5.

Rezago	Evento 1	Evento 2	Evento 3	Evento 4	Evento 5
	Coeficientes de Correlación Cruzada				
0	0.535	0.837	0.434	0.722	0.732
1	0.741	0.938	0.804	0.911	0.925
2	0.889	0.986	0.956	0.939	0.935
3	0.916	0.953	0.696	0.821	0.811
4	0.832	0.876	0.394	0.689	0.700
5	0.685	0.766	0.166	0.524	0.554

Tabla 5-8 Coeficientes de correlación Cruzada Eventos 6-10.

Rezagó	Evento 6	Evento 7	Evento 8	Evento 9	Evento 10
	Coeficientes de Correlación Cruzada				
0	0.810	0.707	0.834	0.829	0.832
1	0.949	0.935	0.967	0.954	0.953
2	0.949	0.880	0.941	0.915	0.937
3	0.848	0.739	0.793	0.753	0.807
4	0.695	0.586	0.616	0.586	0.638
5	0.500	0.437	0.441	0.437	0.450

En la Gráfica 5.7 se puede observar el desarrollo de los coeficientes de correlación cruzada contenidos en las tablas anteriores. Allí se evidencia como los más altos coeficientes se presentan principalmente en los rezagos de tiempo 1 y 2 (5 – 10 min). Esto quiere decir que las series de tiempo de salida tienen una alta correlación respecto a datos de entrada históricos hasta 10 minutos antes del evento de descarga.


Gráfica 5.7 Coeficientes de correlación cruzada para los eventos de tormenta.

Por esta razón se determina que el valor de “ dx ” es 2. De esta manera y teniendo en cuenta el esquema de operación de la Figura 5.5, se concluye que la red neuronal artificial operará con los valores de la serie de tiempo $x(t - 1)$ y $x(t - 2)$, rezagos de más alta correlación, según lo anteriormente expuesto.

5.1.2.2 Rezago dy para la serie de tiempo endógena

Por serie de tiempo propia, o endógena, se entiende como el hidrograma de salida en la descarga de la red de drenaje. Para determinar el valor de “ dy ” se calculará el coeficiente de correlación serial, o de auto correlación, con rezagos de 0 a 5 saltos en el tiempo.

Determinando el coeficiente de correlación serial para los 10 eventos de manera independiente, con rezagos de 0 a 5 saltos en el tiempo (0 – 25 min), se obtienen los resultados de la Tabla 5-9 y la Tabla 5-10.

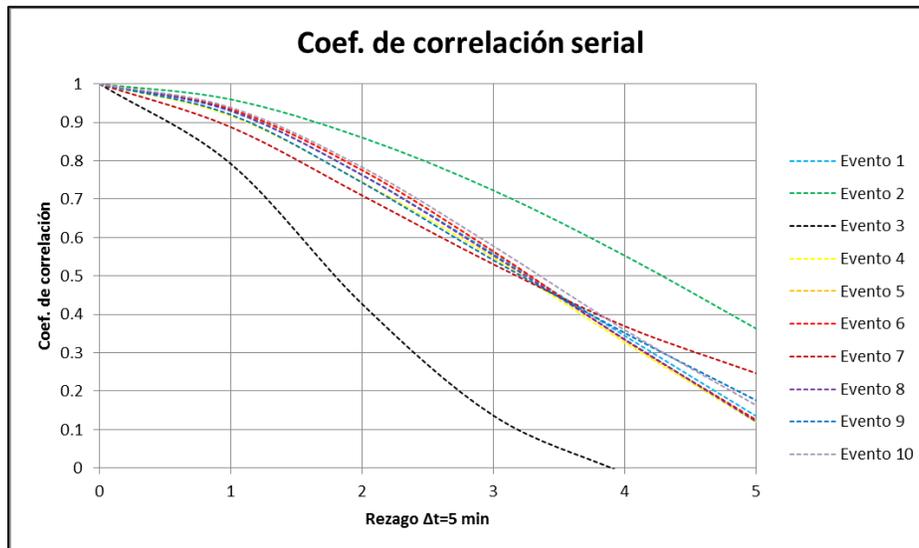
Tabla 5-9 Coeficientes de correlación serial Eventos 1-5.

Rezago	Evento 1	Evento 2	Evento 3	Evento 4	Evento 5
	Coeficientes de Correlación Serial				
0	1.000	1.000	1.000	1.000	1.000
1	0.929	0.960	0.792	0.917	0.911
2	0.763	0.860	0.427	0.745	0.754
3	0.557	0.723	0.136	0.547	0.588
4	0.344	0.553	-0.015	0.327	0.402
5	0.135	0.363	-0.073	0.120	0.206

Tabla 5-10 Coeficientes de correlación serial Eventos 6-10.

Rezago	Evento 6	Evento 7	Evento 8	Evento 9	Evento 10
	Coeficientes de Correlación Serial				
0	1.000	1.000	1.000	1.000	1.000
1	0.934	0.888	0.930	0.920	0.938
2	0.775	0.710	0.763	0.743	0.783
3	0.564	0.530	0.553	0.541	0.578
4	0.333	0.369	0.335	0.352	0.359
5	0.125	0.247	0.121	0.176	0.163

En la Gráfica 5.8 se ilustran los datos contenidos en las tablas anteriores.



Gráfica 5.8 Coeficientes de correlación serial para los eventos de tormenta.

De acuerdo con los resultados obtenidos se determina que el valor “ Δy ” es 1, puesto que es justamente este rezago el único que en la mayoría de los casos genera un coeficiente de correlación serial superior al 90%. Por lo tanto se concluye que la ANN operará con los valores de la serie de tiempo $y(t - 1)$, rezagos de más alta correlación, según lo anteriormente expuesto.

Finalmente, el esquema definitivo general por el que las ANN operarán los datos de los fenómenos se ilustra en la Figura 5.9.

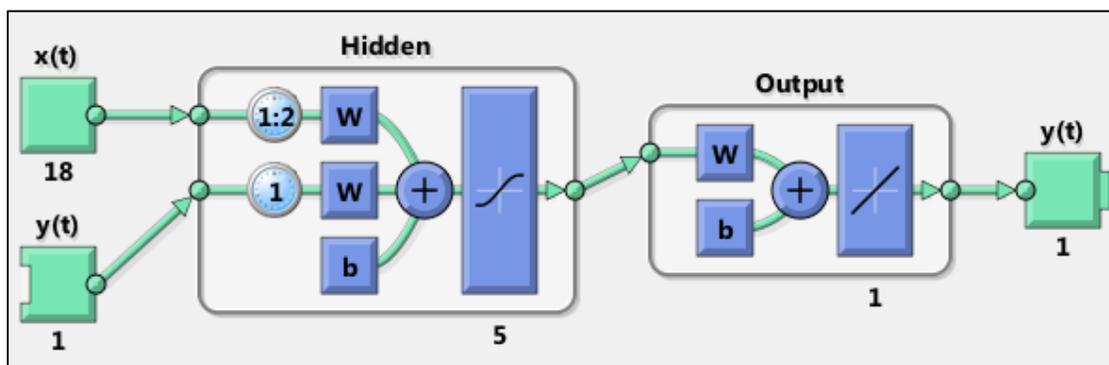


Figura 5.9 Esquema de rezagos para las redes neuronales artificiales.

5.1.3 CONSTRUCCIÓN DE LAS REDES NEURONALES ARTIFICIALES (ANNPC)

Con base en las conclusiones del capítulo anterior, se procede finalmente con la construcción de las ANN. Con el fin de determinar lineamientos o metodologías para futuras referencias, se construyen 32 ANN cada una de estas con características propias. Las variables de las estructuras inteligentes se fijan en esta investigación, en 3 parámetros de gran importancia; estos parámetros son:

5.1.3.1 Función de entrenamiento/Training Function

Se utilizarán exclusivamente 4 funciones de entrenamiento para llevar a cabo el aprendizaje de las ANN; dichos algoritmos son aquellos que según referencias en el campo han sido utilizados para la predicción de descargas de un alivio (Andreas Kurth, 2008), modelación y control de sistemas de alcantarillados (Xiangfei Li, 2011) y otros usos de las redes neuronales (Michael Bruen, 2006).

Estas funciones de entrenamiento se encuentran dentro del grupo de funciones de entrenamiento de MatLab®. Dichas funciones se presentan en la Tabla 5-11.

Tabla 5-11 Funciones de entrenamiento utilizadas

Función De Entrenamiento	Algoritmo	Tipo de Función
TRAINLM	Retro propagación de Levenberg - Marquardt	Función de entrenamiento de retro propagación con derivada de Jacobianos
TRAINRP	Retro propagación resiliente	Función de entrenamiento de retro propagación con derivadas de gradiente
TRAIPOSS	Método de la secante paso a paso	
TRAINGDA	Descenso por gradiente con tasa de aprendizaje adaptativa	

5.1.3.2 Número de capas ocultas / Hidden Layers

Pese a que en la literatura se han encontrado buenos resultados utilizando diversas configuraciones y cantidad de capas ocultas, no ha sido posible fijar una metodología puntual para determinar el número adecuado de estas. Aunque si se especifica que su uso es recomendable cuando el número de neuronas es

demasiado grande (José R. Hilera, 2000) y resulta más conveniente separar su número en 2 o más capas ocultas. Teniendo en cuenta lo anteriormente expuesto, las arquitecturas aquí evaluadas tendrán entre 2 y 3 capas ocultas.

5.1.3.3 Número de neuronas por capa / Hidden Nodes per layer

De manera análoga al número de capas ocultas, no existen registros uniformes sobre la cantidad de neuronas por capa, adecuadas para que la ANN tenga un buen desempeño. Sin embargo, si es reconocido ampliamente en el campo el uso de pocas neuronas (Andreas Kurth, 2008), aunque el término “pocas” tampoco da mayores indicios sobre una cantidad aproximada. Por esta razón en esta investigación se evaluará el desempeño de las ANN con arreglos de 5 a 20 neuronas por arquitectura.

Definidos los 3 parámetros de control, en la Tabla 5-12 se presenta el listado de las ANN a crear, cada una de estas con sus características propias.

Tabla 5-12 Redes neuronales artificiales construidas.

ANN's Pequeño Chicó			
	Training Function	Hidden Layers	Nodes
ANNPC1	TRAINLM	1	5
ANNPC2	TRAINLM	1	10
ANNPC3	TRAINLM	1	15
ANNPC4	TRAINLM	1	20
ANNPC5	TRAINLM	2	2,3
ANNPC6	TRAINLM	2	5,5
ANNPC7	TRAINLM	2	10,5
ANNPC8	TRAINLM	2	10,10
ANNPC9	TRAINRP	1	5
ANNPC10	TRAINRP	1	10
ANNPC11	TRAINRP	1	15
ANNPC12	TRAINRP	1	20
ANNPC13	TRAINRP	2	2,3
ANNPC14	TRAINRP	2	5,5
ANNPC15	TRAINRP	2	10,5
ANNPC16	TRAINRP	2	10,10
ANNPC17	TRAINOSS	1	5
ANNPC18	TRAINOSS	1	10
ANNPC19	TRAINOSS	1	15
ANNPC20	TRAINOSS	1	20

ANNPC21	TRAINOSS	2	2,3
ANNPC22	TRAINOSS	2	5,5
ANNPC23	TRAINOSS	2	10,5
ANNPC24	TRAINOSS	2	10,10
ANNPC25	TRAIINGDA	1	5
ANNPC26	TRAIINGDA	1	10
ANNPC27	TRAIINGDA	1	15
ANNPC28	TRAIINGDA	1	20
ANNPC29	TRAIINGDA	2	2,3
ANNPC30	TRAIINGDA	2	5,5
ANNPC31	TRAIINGDA	2	10,5
ANNPC32	TRAIINGDA	2	10,10

5.1.3.4 Construcción de redes en MatLab

Cada una de estas ANN fue construida haciendo uso de la función `>> nnstart`, a continuación se presenta paso a paso el proceso de construcción:

- Ingreso a la herramienta utilizando la función `>> nnstart`.
- Selección de la red neuronal artificial tipo NARX:

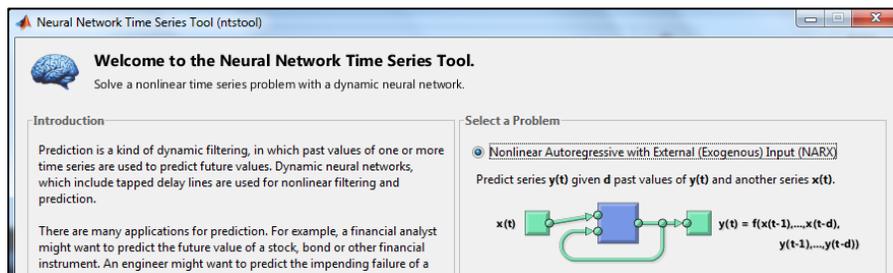


Figura 5.10 Selección de la red neuronal artificial Tipo NARX.

- Importar las matrices de series de tiempo x y y desde el espacio de trabajo, “Workspace”:

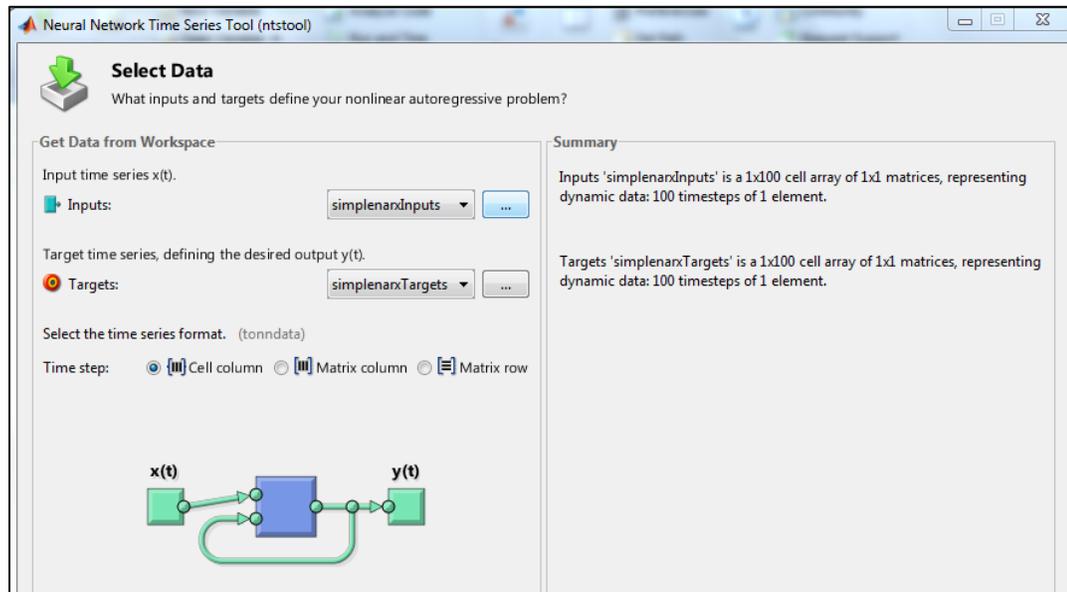


Figura 5.11 Importación de datos, Entradas y Objetivos.

- Seleccionar los porcentajes de los datos de ingresados, destinados para los procesos de entrenamiento, validación y evaluación.

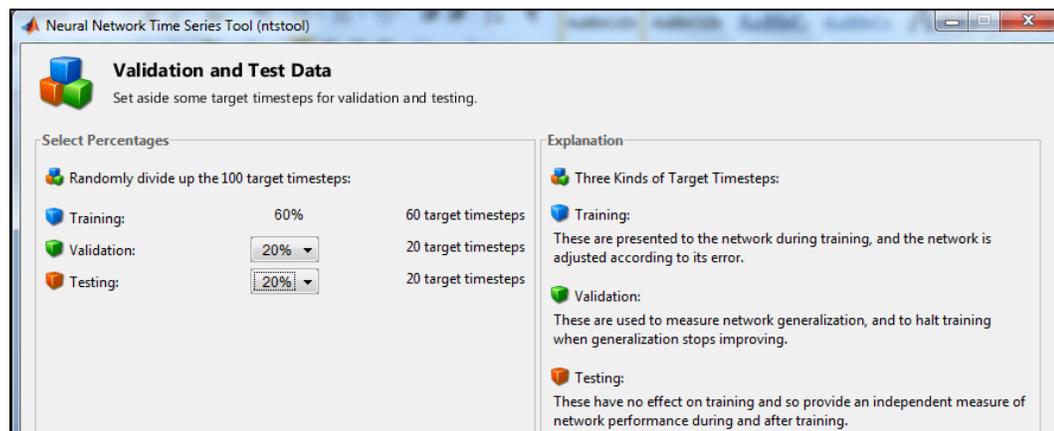


Figura 5.12 Selección de porcentaje de uso de datos.

Por defecto la herramienta selecciona el tipo de división de datos “Random”.

- Seleccionar el número de neuronas de la capa oculta, y el valor de rezago “d”:

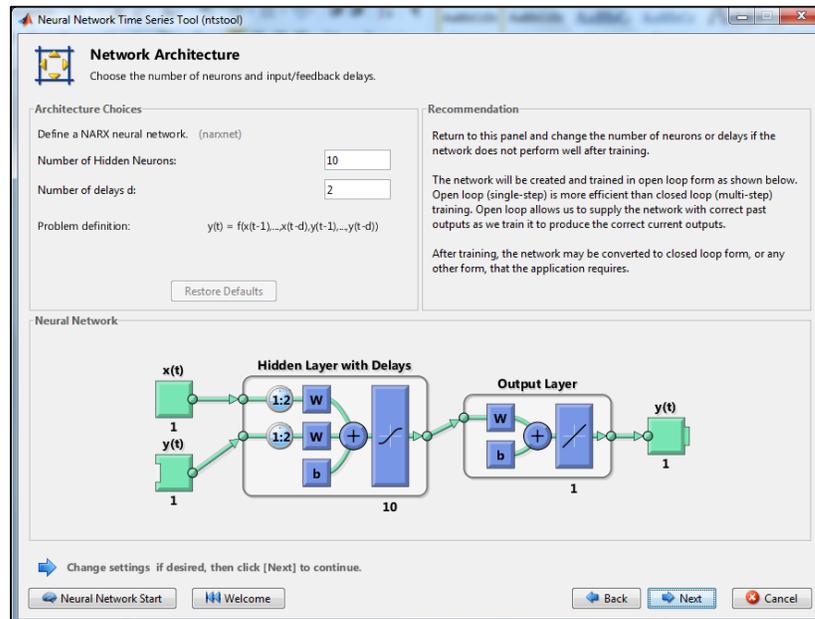


Figura 5.13 Construcción de la arquitectura.

Por defecto la herramienta selecciona una sola capa oculta, y el valor de rezago “ d ” lo asimila igual para la serie de tiempo x como para la serie de tiempo y .

- Entrenar la red:

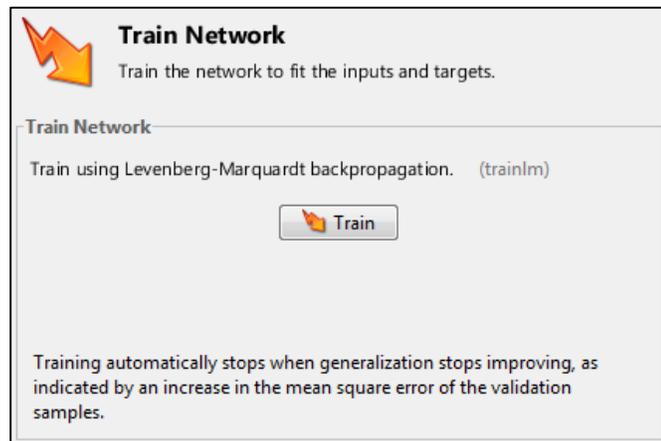


Figura 5.14 Entrenamiento de la red.

- Generar el código avanzado de la red neuronal creada para realizar las modificaciones requeridas, de acuerdo con las necesidades del diseñador de la red.

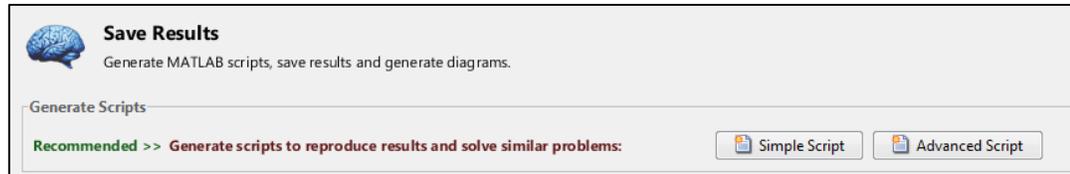


Figura 5.15 Generación de códigos para modificación.

- Evaluar la red para las series de tiempo de entrada.

5.1.4 RESULTADOS INICIALES ANNPC

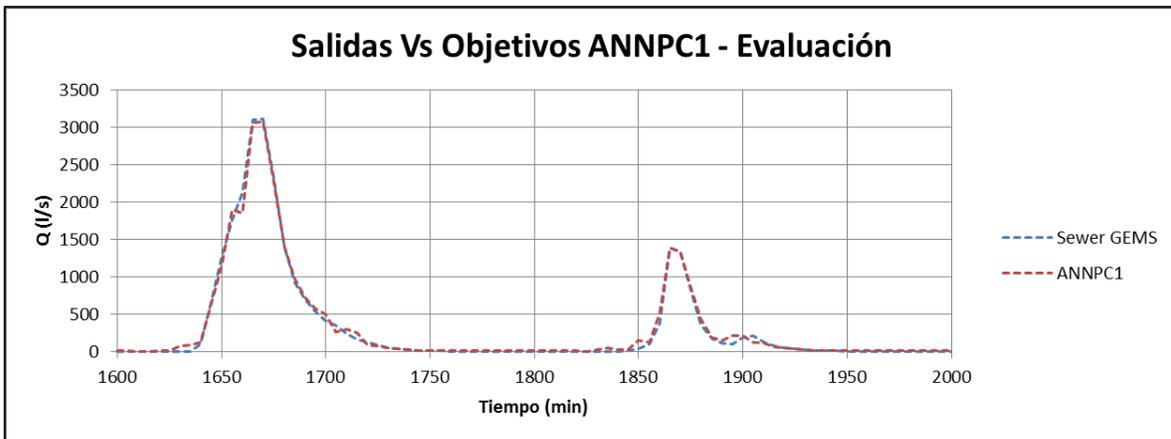
Una vez construidas las ANN definidas en el numeral anterior, con las consideraciones de cada caso, se generan los resultados de entrenamiento y evaluación de la ANN, entendiendo como “entrenamiento” para este caso los procesos de entrenamiento y validación, según el tipo de función de entrenamiento.

Para poder realizar una comparación cuantitativa sobre el desempeño de las ANN, para los mismos datos de entradas y las mismas necesidades de predicción, se definen una serie de medidas de ajuste e indicadores que permiten realizar una comparación directa de los resultados obtenidos; dichas medidas son:

- Desviación Estándar
- Q Máximo
- Diferencia Porcentual del Caudal Máximo predicho
- Desfase temporal del pico
- Error Cuadrático Medio / Mean Squared Error (MSE)
- Error Absoluto Medio / Mean Absolute Error (MAE)
- Coeficiente de correlación serial R

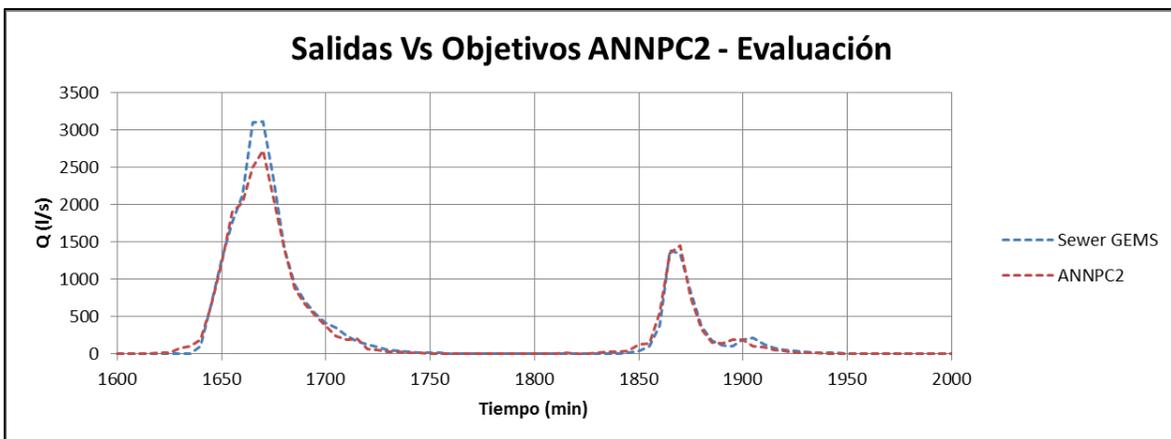
5.1.4.1 Redes ANNPC entrenadas con TRAINLM

Realizado el entrenamiento del primer grupo de 8 ANN, a continuación se presenta los resultados gráficos de cada una de ellas, y una calificación netamente cualitativa sobre su desempeño en el proceso de generalización.



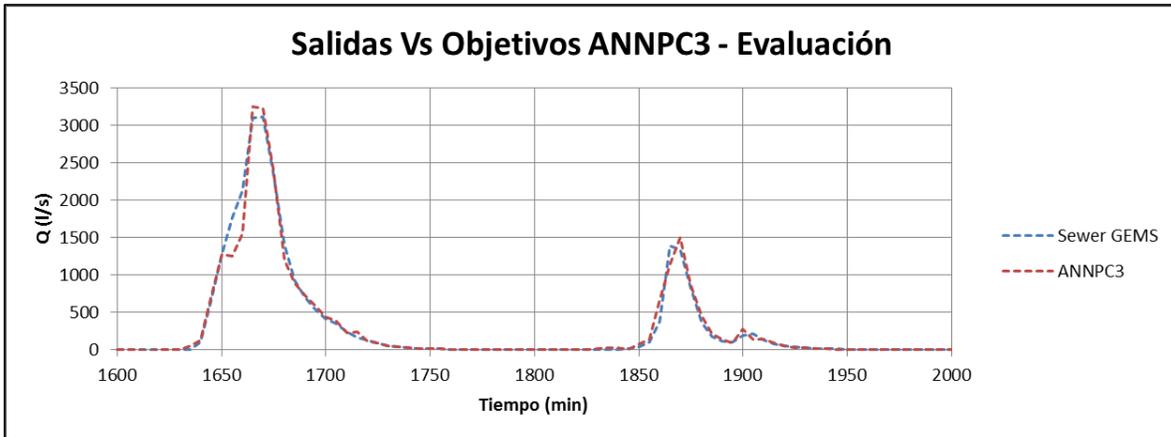
Gráfica 5.9 Hidrogramas predichos por la red neuronal ANNPC1 Vs Modelados en Sewer GEMS.

La red ANNPC1 gráficamente presenta un muy buen desempeño ajustándose a los datos observados en la modelación de la red en el Software Sewer GEMS. Se considera que la capacidad de generalización de esta red neuronal artificial es: Alta.



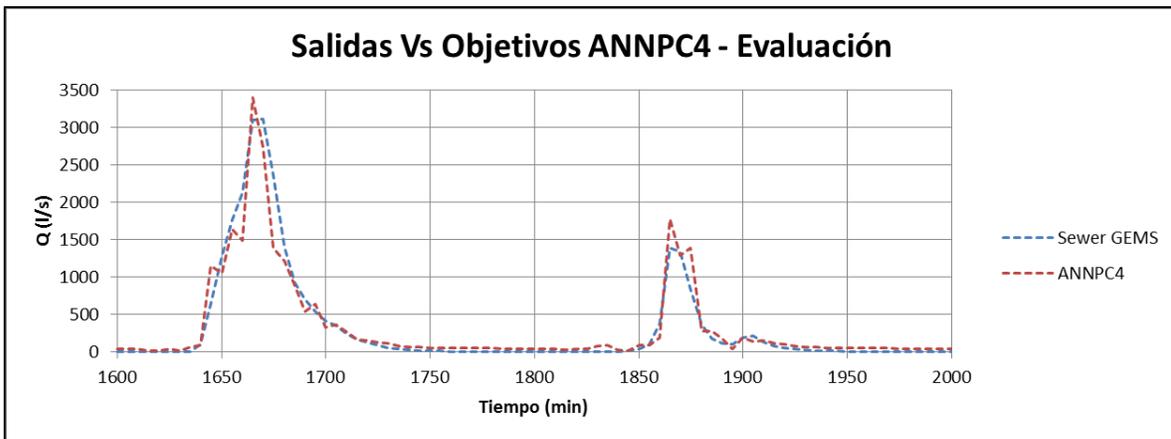
Gráfica 5.10 Hidrogramas predichos por la red neuronal ANNPC2 Vs Modelados en Sewer GEMS.

La red ANNPC2 presenta un buen desempeño prediciendo los datos de evaluación para el segundo pico, sin embargo no lo hace tan bien para el caudal pico más grande. Como puede observarse la red se ajusta muy bien hasta un valor cercano a los 2000 l/s pero finalmente sub valora los datos del pico máximo. Se califica su capacidad de generalización como: Media Baja.



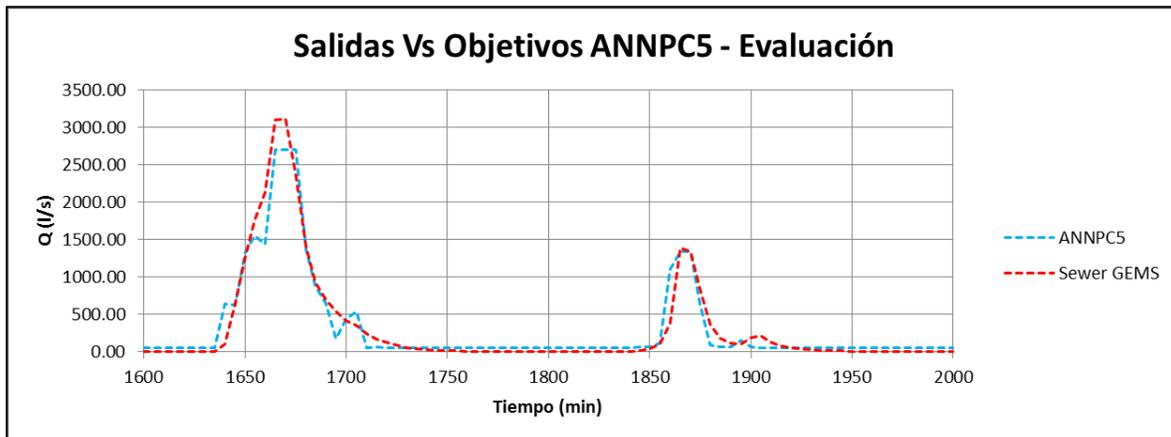
Gráfica 5.11 Hidrogramas predichos por la red neuronal ANNPC3 Vs Modelados en Sewer GEMS.

Esta red por otra parte, se ajusta aceptablemente a los hidrogramas modelados, sin embargo la ANNPC3 sobrevalora en ambos casos los caudales picos predichos. Se califica su generalización como: Media.



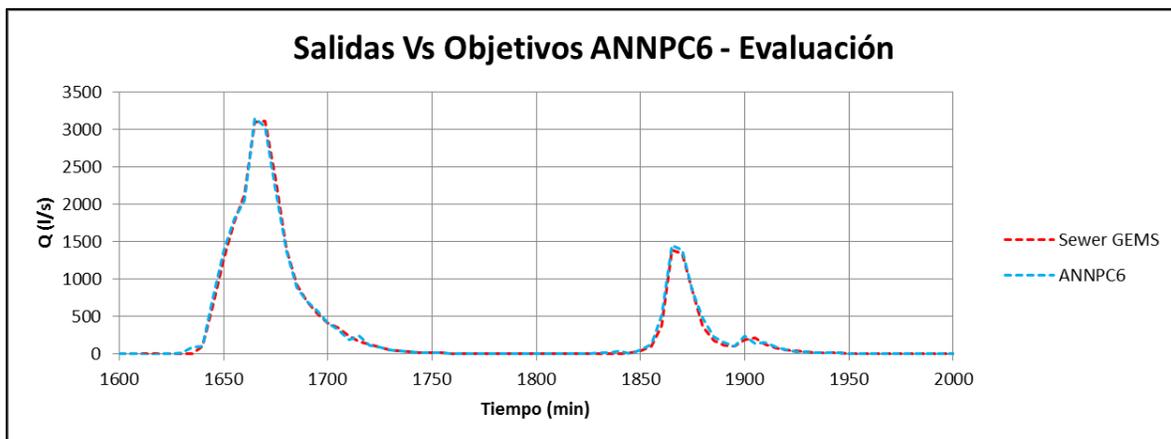
Gráfica 5.12 Hidrogramas predichos por la red neuronal ANNPC4 Vs Modelados en Sewer GEMS.

La red ANNPC4, Gráfica 5.13, presenta un pobre desempeño; ni siquiera en los caudales más bajos del hidrograma logra ajustarse con suficiencia; sobrevalora los caudales picos y además genera ruido en el proceso de ajuste. Su bajo rendimiento podría deberse a un sobre entrenamiento de la red o a un excesivo número de neuronas. Su generalización: Baja.



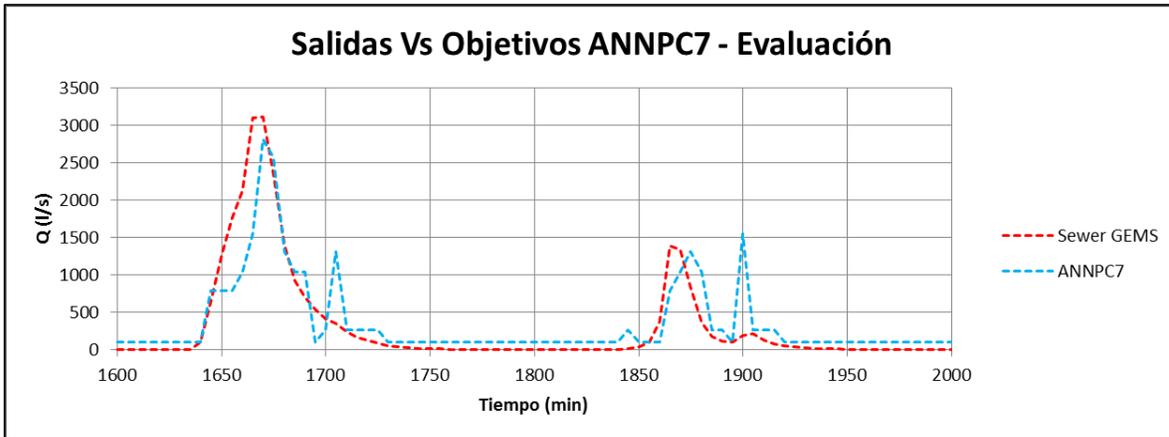
Gráfica 5.13 Hidrogramas predichos por la red neuronal ANNPC5 Vs Modelados en Sewer GEMS.

De manera similar a la ANNPC4, la ANNPC5 de la Gráfica 5.14 no se ajusta adecuadamente a los datos modelados; presenta ruido en las gráficas y subvaloración de los caudales picos. Capacidad de generalización: Baja.



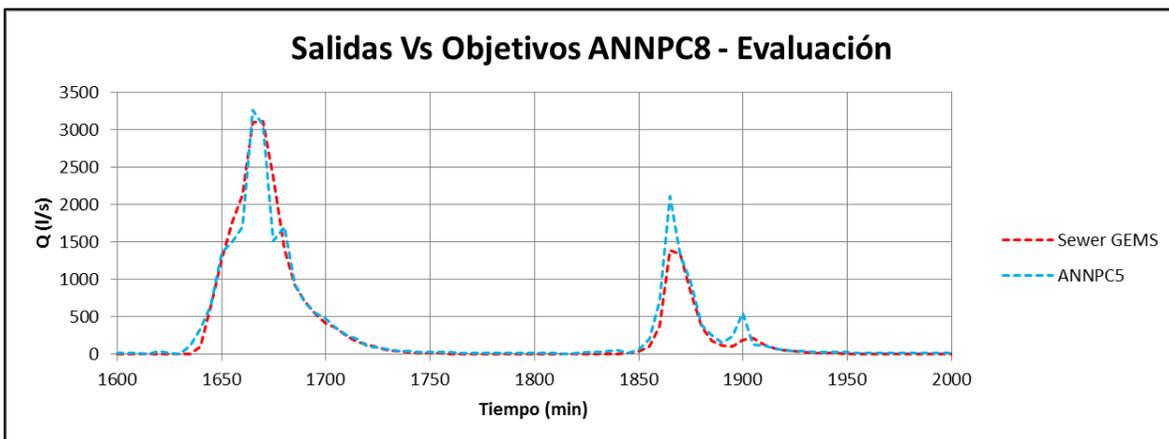
Gráfica 5.14 Hidrogramas predichos por la red neuronal ANNPC6 Vs Modelados en Sewer GEMS.

En un desempeño similar al observado con la ANNPC1, la ANNPC6 predice muy bien los caudales generados en la descarga, tanto para el caudal pico más grande como para el menor, inclusive logra definir con gran detalle la forma achatada de los picos y el pequeño pico generado cerca de la finalización del segundo evento de lluvia. Su capacidad de generalización: Alta.



Gráfica 5.15 Hidrogramas predichos por la red neuronal ANNPC7 Vs Modelados en Sewer GEMS.

Contrario a los resultados obtenidos en la anterior arquitectura inteligente, la ANNPC7 predice caudales de descarga con mucho ruido; para los dos eventos de tormenta de la evaluación esta genera un segundo pico de caudal con geometría similar, esto se puede atribuir a un sobre entrenamiento de la red a datos específicos en los que la tormenta genera un segundo pico. Su generalización: Muy Baja.

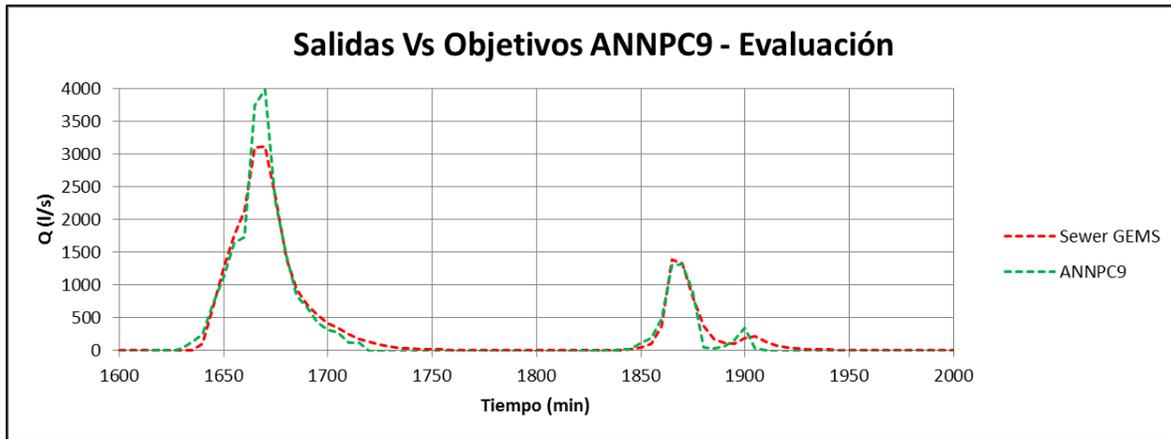


Gráfica 5.16 Hidrogramas predichos por la red neuronal ANNPC8 Vs Modelados en Sewer GEMS.

Finalmente, la ANNPC8, logra ajustarse aceptablemente en cierto momentos de la tormenta; sin embargo para los dos eventos de evaluación la arquitectura inteligente sobre valora los caudales pico. Capacidad de generalización: Media baja.

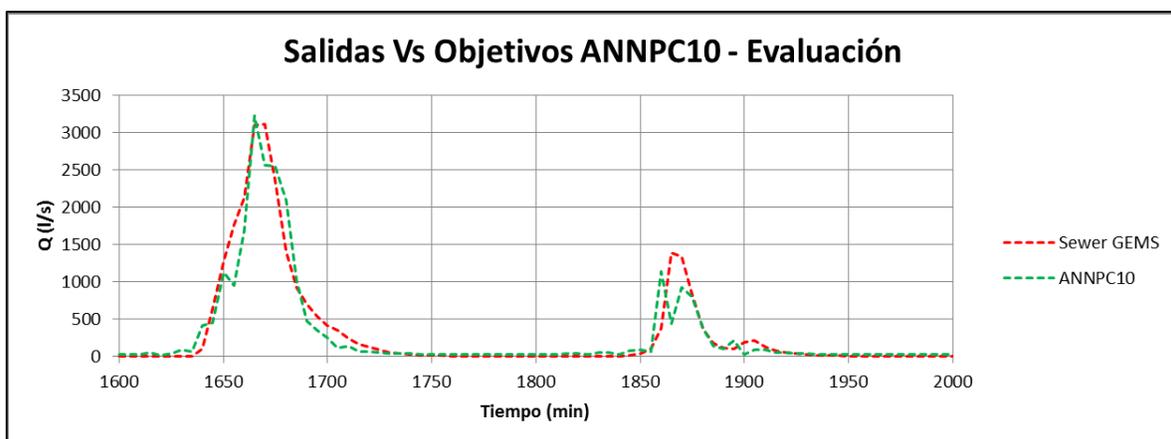
5.1.4.2 Redes ANNPC entrenadas con TRAINRP

Prosiguiendo con la evaluación del segundo grupo de 8 redes neuronales entrenadas con el algoritmo de retro propagación resiliente a continuación se presentan los resultados obtenidos para los mismos caudales evaluados en la sección anterior.



Gráfica 5.17 Hidrogramas predichos por la red neuronal ANNPC9 Vs Modelados en Sewer GEMS.

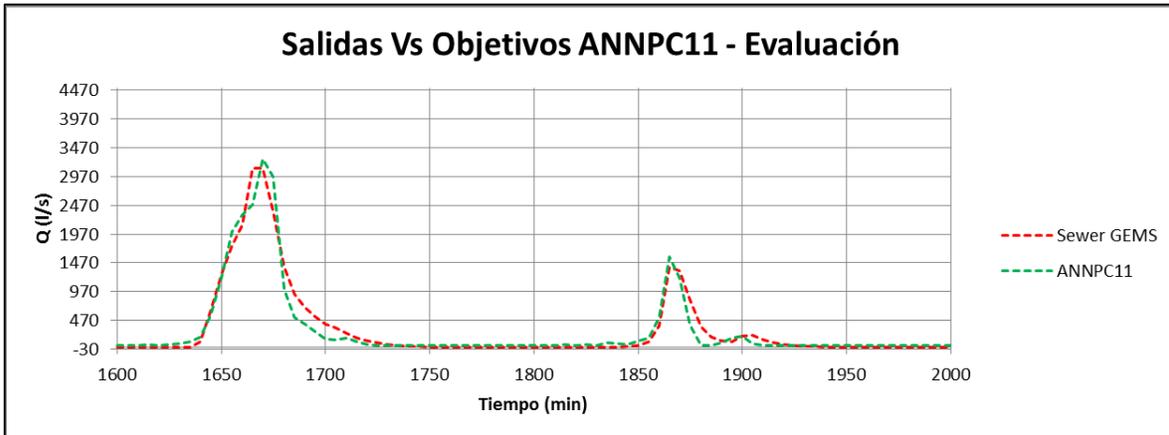
La ANNPC9, Gráfica 5.18, se ajusta a los datos observados aceptablemente a lo largo de los dos hidrogramas de descarga de la red; sin embargo para el caudal pico máximo su desempeño decae dramáticamente. Su desempeño en cuanto a la generalización: Bajo.



Gráfica 5.18 Hidrogramas predichos por la red neuronal ANNPC10 Vs Modelados en Sewer GEMS.

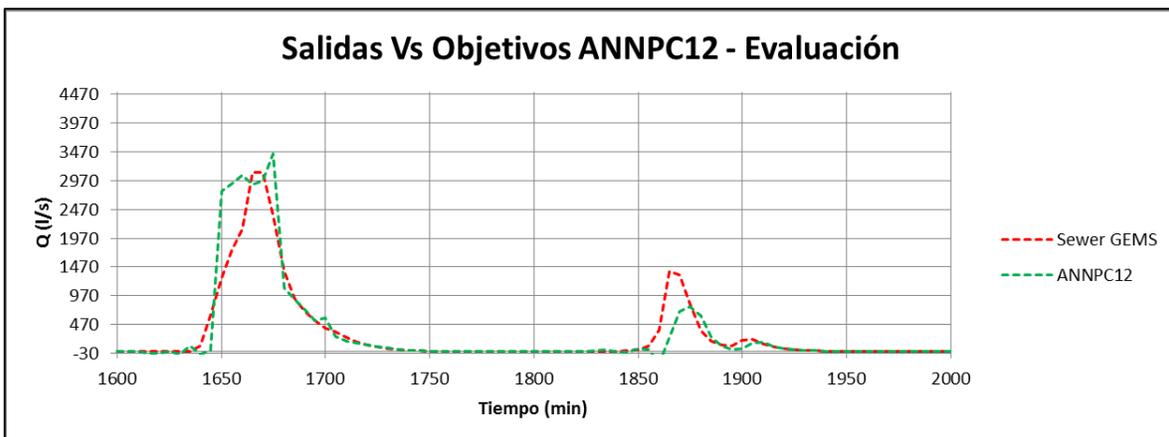
La ANNPC10 presente un desempeño aún más pobre comparado con la ANNPC9; la ANN genera ruido en los datos, y en el caso del segundo caudal pico

genera dos picos ambos con valores sub valorados respecto al pico observado en el modelo de Ser GEMS. Su generalización: Baja.



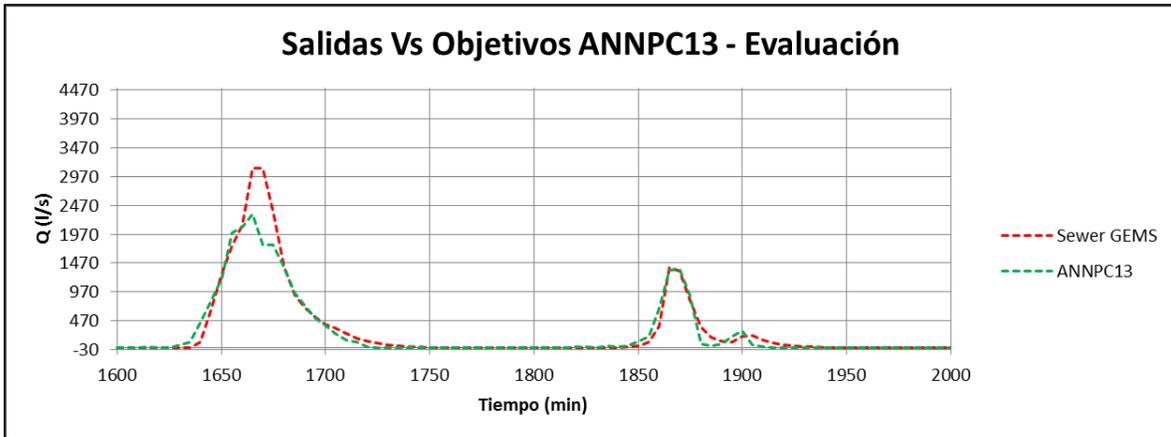
Gráfica 5.19 Hidrogramas predichos por la red neuronal ANNPC11 Vs Modelados en Sewer GEMS.

Por otra parte, la ANNPC11 parece tener un desempeño más aceptable; y aunque no se ajusta con suficiencia a los datos observados, si es la red entrenada con este algoritmo que presenta mejores resultados. Generalización: Media baja.



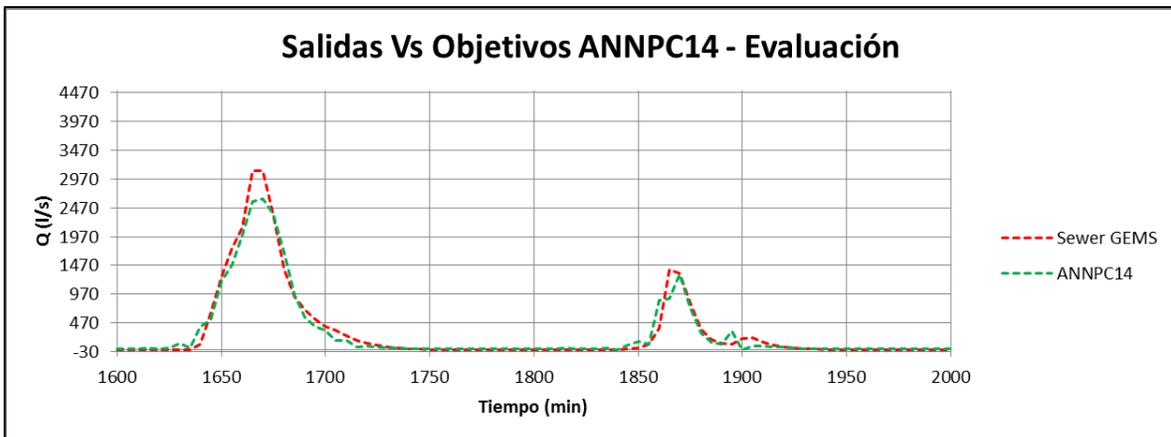
Gráfica 5.20 Hidrogramas predichos por la red neuronal ANNPC12 Vs Modelados en Sewer GEMS.

Los hidrogramas generados por la ANNPC12, Gráfica 5.21, presenta un muy bajo ajuste. Para el pico máximo sobrevalora el caudal y lo localiza tiempo después del real, y para el mínimo lo subvalora localizándolo nuevamente varios minutos después de lo esperado. Generalización: Muy baja.



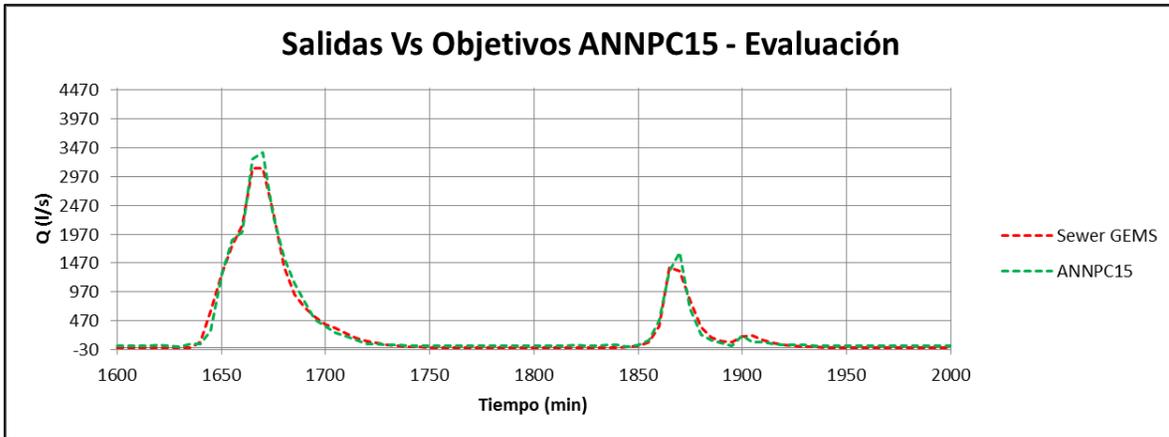
Gráfica 5.21 Hidrogramas predichos por la red neuronal ANNPC13 Vs Modelados en Sewer GEMS.

Preliminarmente la inclusión de una capa oculta adicional, no parece generar mejora alguna en redes entrenadas con este algoritmo; únicamente parece ajustarse aceptablemente al caudal pico mínimo. Su capacidad de generalización: Media baja.



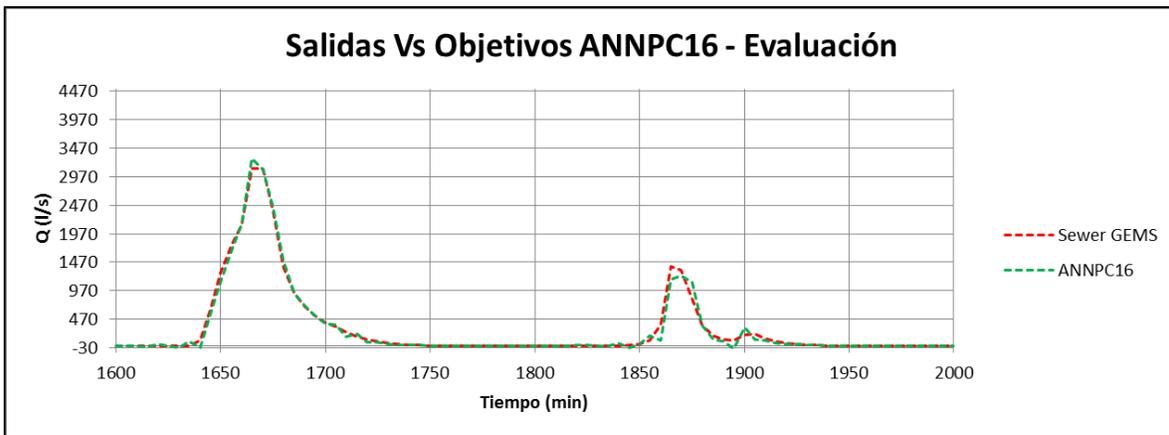
Gráfica 5.22 Hidrogramas predichos por la red neuronal ANNPC14 Vs Modelados en Sewer GEMS.

Contrario a los anteriores resultados, obtenidos con este algoritmo de entrenamiento, la ANNPC14 muestra una mejora en cuanto a su desempeño, pese a que sub valora los caudales picos la generalización mejora. Capacidad de generalización: Media.



Gráfica 5.23 Hidrogramas predichos por la red neuronal ANNPC15 Vs Modelados en Sewer GEMS.

Mejorando aún más el ajuste de los valores predichos por la red, la ANNPC15 finalmente estima un hidrograma en la descarga sobresaliente, aunque aún subvalora los caudales picos máximos. Su capacidad de generalización: Media alta.

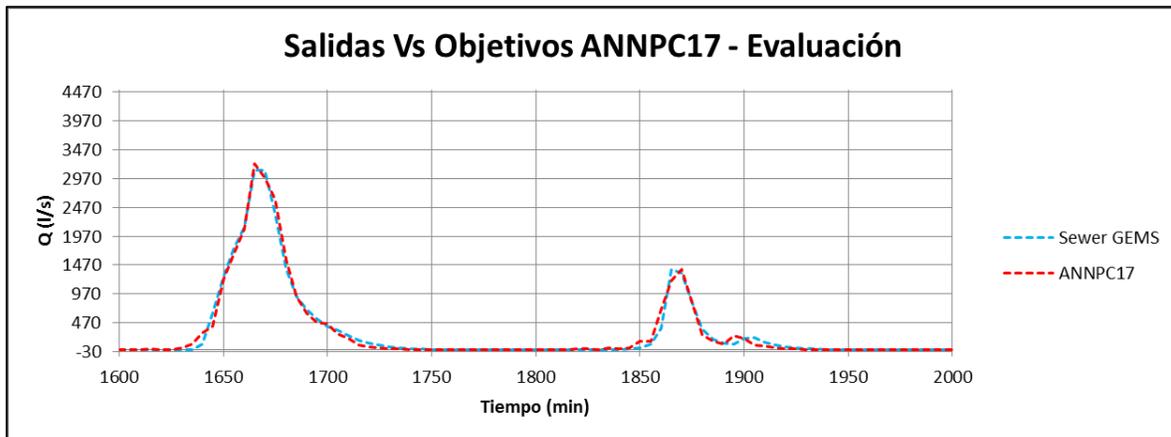


Gráfica 5.24 Hidrogramas predichos por la red neuronal ANNPC16 Vs Modelados en Sewer GEMS.

Finalmente, y de manera similar a los resultados obtenidos en la anterior ANN, la ANNPC16 predice hidrogramas de manera más ajustada a los reales; los caudales picos son más próximos y para el evento máximo su generalización es casi perfecta. Capacidad de generalización: Alta.

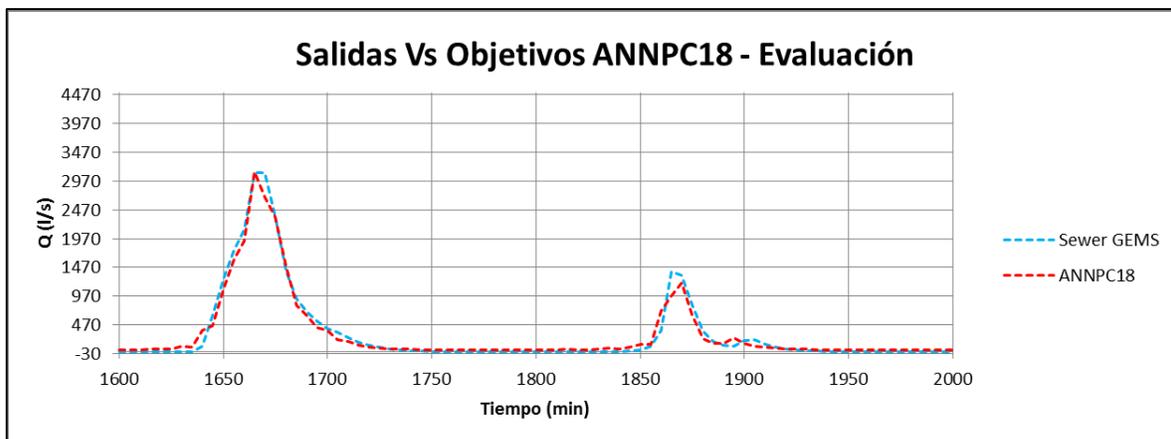
5.1.4.3 Redes ANNPC entrenadas con TRAINOSS

Prosiguiendo con las redes entrenadas con el método de la secante, a continuación se presentan los resultados gráficos obtenidos:



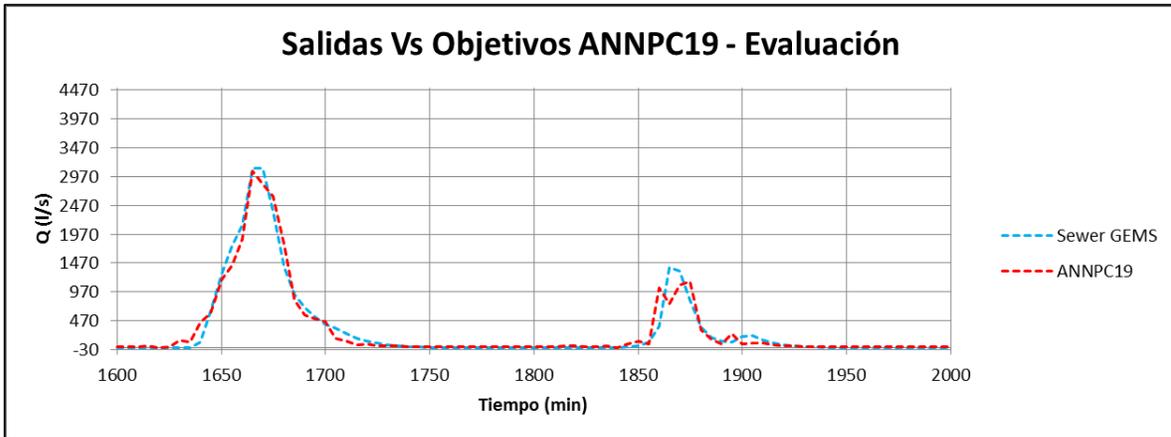
Gráfica 5.25 Hidrogramas predichos por la red neuronal ANNPC17 Vs Modelados en Sewer GEMS

La red neuronal artificial ANNPC17 presenta un buen desempeño prediciendo los caudales generados en la descarga, al igual que con el algoritmo de Levenberg – Marquardt; este algoritmo parece necesitar de pocas neuronas para obtener un buen desempeño. Capacidad de generalización: Alta.



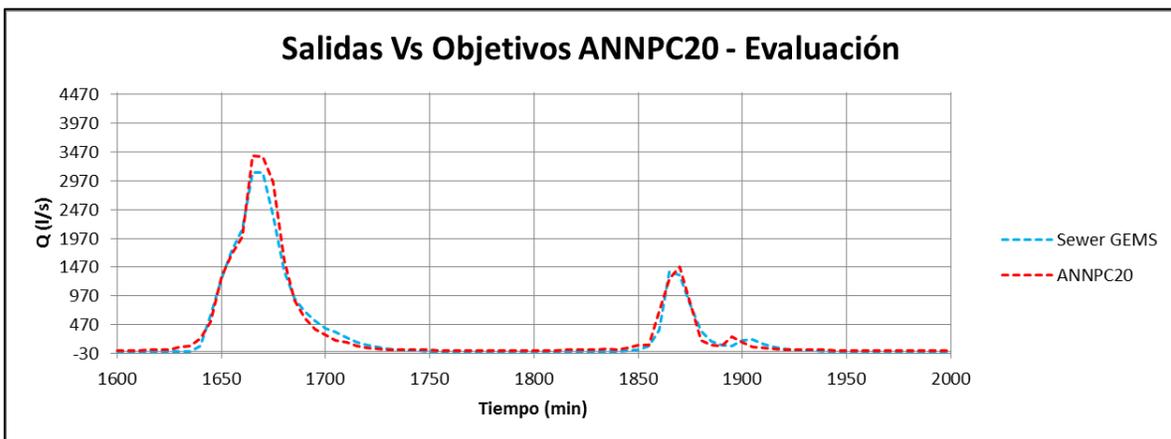
Gráfica 5.26 Hidrogramas predichos por la red neuronal ANNPC18 Vs Modelados en Sewer GEMS.

La ANNPC18, Gráfica 5.27, no tiene un ajuste tan óptimo como el de su predecesora; sin embargo la forma de los hidrogramas generados si se asemejan a la ANNPC17. Capacidad de generalización: Media alta.



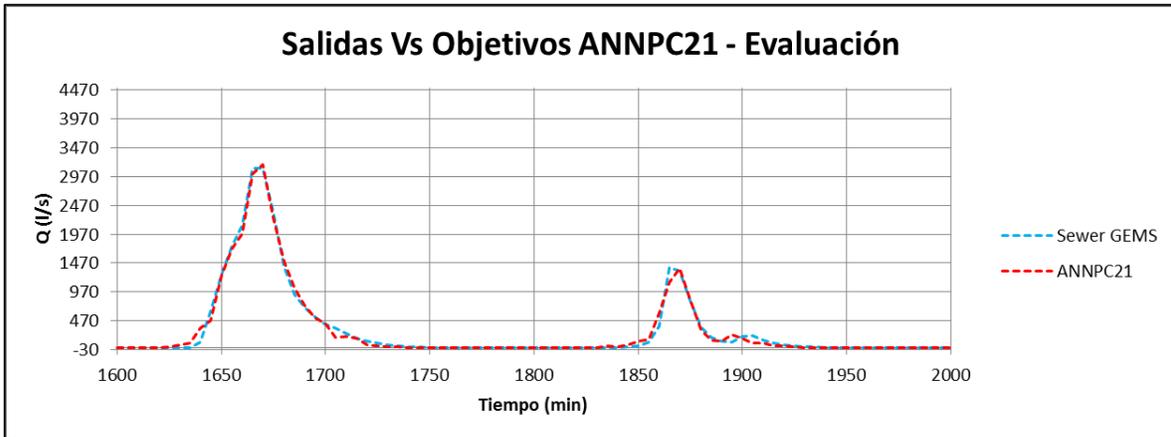
Gráfica 5.27 Hidrogramas predichos por la red neuronal ANNPC19 Vs Modelados en Sewer GEMS.

Con 15 neuronas en la capa oculta, la ANNPC19 presenta un ajuste muy pobre comparado con sus predecesoras de 5 y 10 neuronas en una capa oculta. En el pico de caudal máximo menor se presenta ruido similar al encontrado en la ANNPC10 entrenada con TRAINRP, de 10 neuronas en una capa oculta. Capacidad de generalización: Baja.



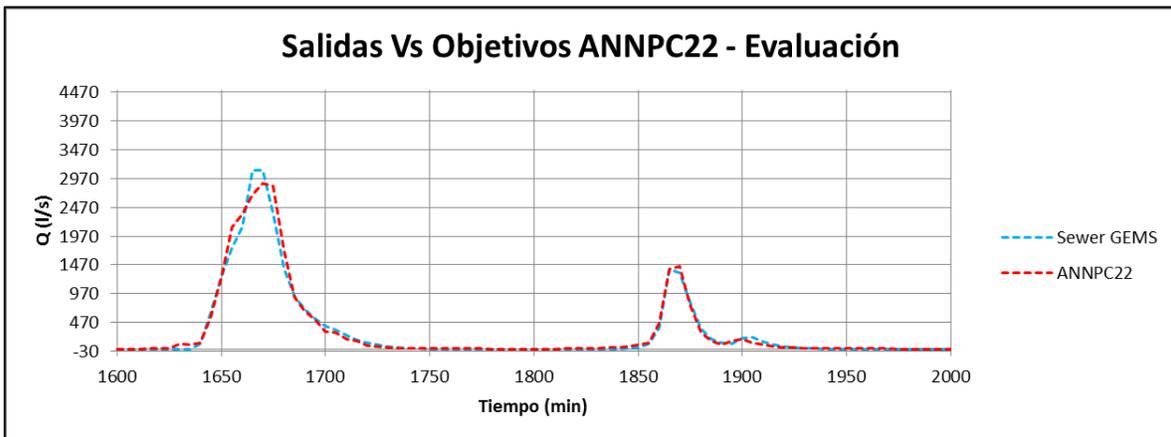
Gráfica 5.28 Hidrogramas predichos por la red neuronal ANNPC20 Vs Modelados en Sewer GEMS.

Para una red neuronal entrenada con el método de la secante y 20 neuronas en una única capa oculta, el ajuste de la predicción a los datos observados es aceptable a lo largo del hidrograma de creciente; sin embargo para ambos eventos de tormenta la arquitectura inteligente no logra reproducir correctamente los caudales picos, y los sobrevalora. Su capacidad de generalización: Media baja.



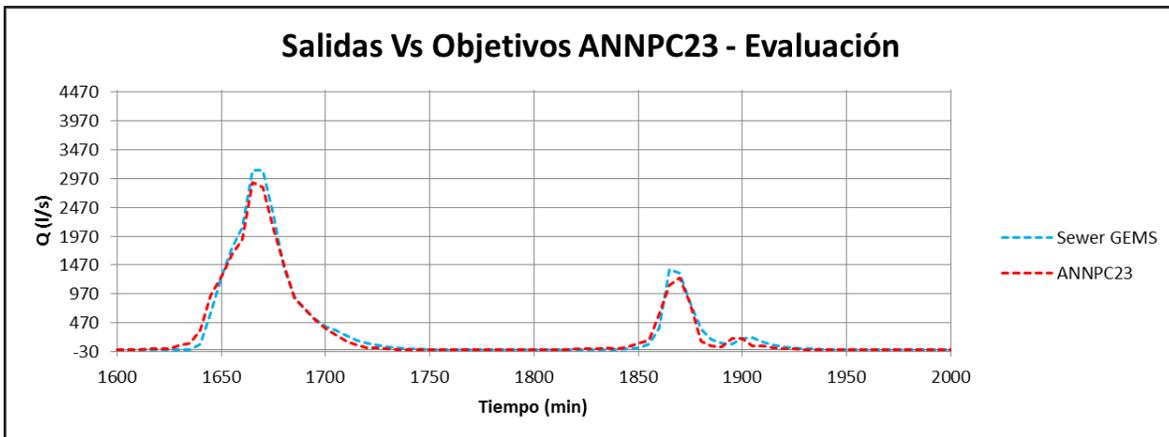
Gráfica 5.29 Hidrogramas predichos por la red neuronal ANNPC21 Vs Modelados en Sewer GEMS.

Similarmente a los resultados obtenidos en la ANNPC17 de 5 neuronas en una capa oculta, la ANNPC21, Gráfica 5.30, con 5 neuronas igualmente pero con un arreglo en dos capas ocultas el ajuste es muy bueno. Requerirá de una medida cuantitativa para determinar el mejor desempeño entre estas dos redes. Pero preliminarmente puede aseverarse que un bajo conteo de neuronas genera resultados considerablemente buenos. Capacidad de generalización: Alta.



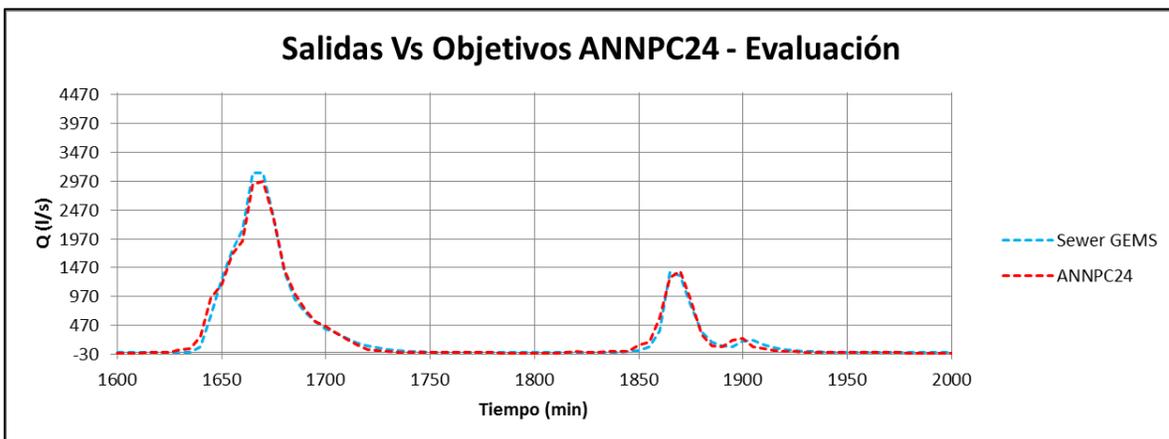
Gráfica 5.30 Hidrogramas predichos por la red neuronal ANNPC22 Vs Modelados en Sewer GEMS.

Una vez más para este algoritmo de entrenamiento, un incremento en el número de neuronas parece haber disminuido el desempeño de la ANN, aunque el ajuste general parece aceptable, los caudales picos del evento máximo son nuevamente sub valorados. Capacidad de generalización: Media baja.



Gráfica 5.31 Hidrogramas predichos por la red neuronal ANNPC23 Vs Modelados en Sewer GEMS.

Realizando una comparación con su semejante, ANNPC19, cuyos conteos de neuronas son iguales, pero en arreglos de capas diferentes. La ANNPC23, Gráfica 5.32, presenta un ajuste mucho mejor. Sin embargo aunque la generalización se ve mejorada, los caudales pico aún son subvalorados. Capacidad de generalización: Media baja.

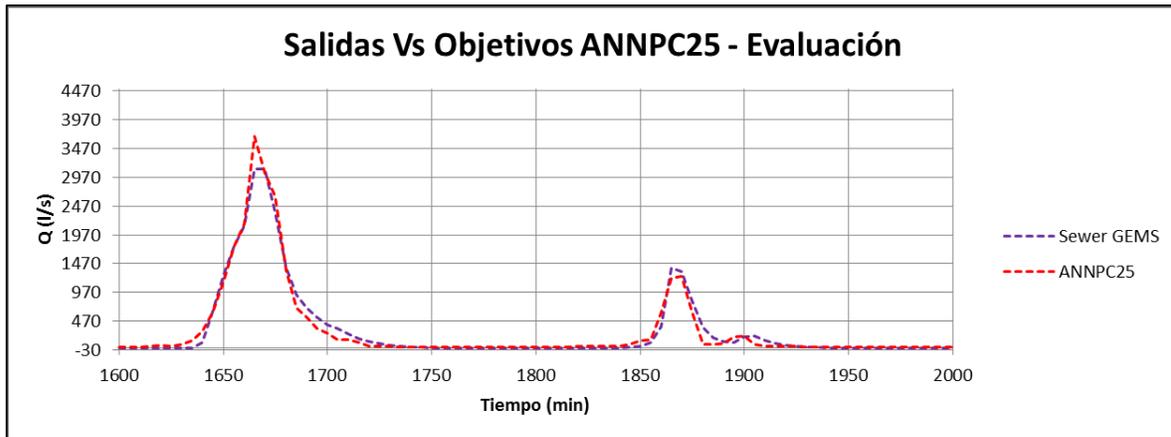


Gráfica 5.32 Hidrogramas predichos por la red neuronal ANNPC24 Vs Modelados en Sewer GEMS.

Finalmente, la ANNPC24 predice hidrogramas en la descarga de la red de drenaje bastante ajustados a los esperados además reproduce el pequeño pico generado en la finalización del segundo evento de tormenta; aunque para el evento máximo subvalora de nuevo el caudal pico. Su capacidad de generalización: Media.

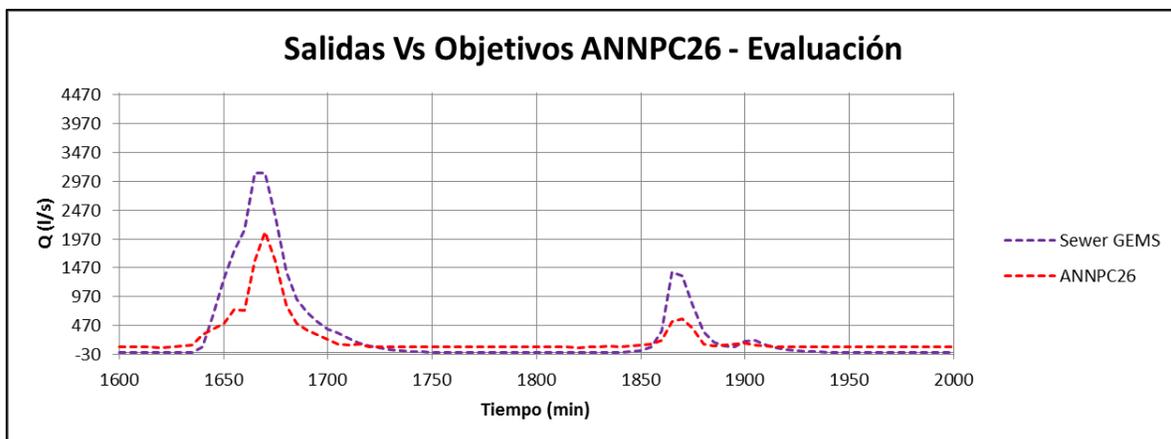
5.1.4.4 Redes ANNPC entrenadas con TRAIINGDA

Para finalizar con los resultados gráficos de las ANN, a continuación se presentan las hidrogramas predichas por el último grupo de redes neuronales artificiales.



Gráfica 5.33 Hidrogramas predichos por la red neuronal ANNPC25 Vs Modelados en Sewer GEMS.

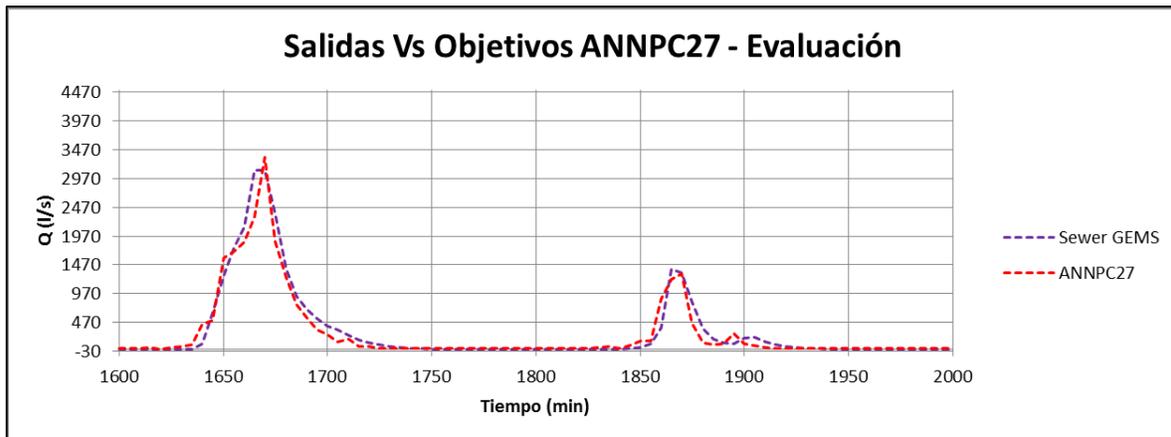
El ajuste de la ANNPC25, de 5 neuronas y 1 sola capa, parece aceptable salvo por el hecho de que en el evento de caudales máximos el caudal es sobrevalorado hasta cerca de 500 l/s por encima del caudal pico real. En contraposición el caudal pico del evento de lluvia menor, se ve subvalorado. Capacidad de generalización de la ANN: Medio bajo.



Gráfica 5.34 Hidrogramas predichos por la red neuronal ANNPC26 Vs Modelados en Sewer GEMS.

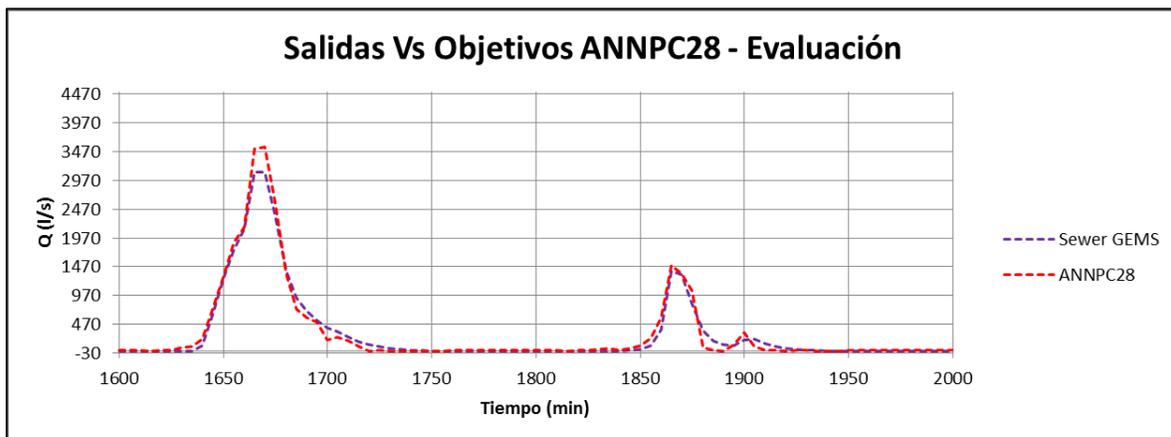
Con un arreglo de 10 neuronas en una sola capa oculta, el desempeño de la ANNPC26 es muy pobre. Subvalora los valores máximos del hidrograma de

salida, y en proximidades a los ceros sobrevalora los caudales más pequeños del evento. Su capacidad de generalización: Muy baja.



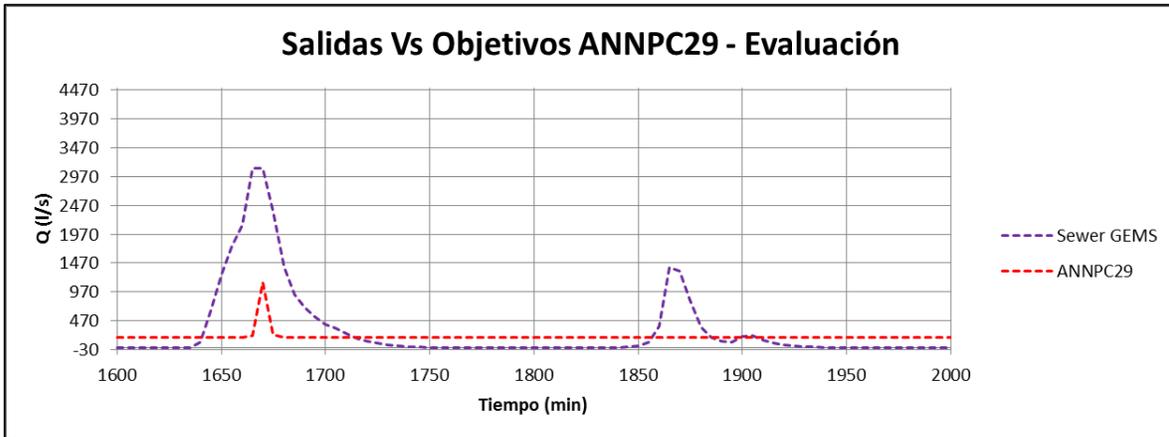
Gráfica 5.35 Hidrogramas predichos por la red neuronal ANNPC27 Vs Modelados en Sewer GEMS.

El desempeño de la ANNPC27, comparado con su antecesora con un conteo de 10 neuronas, parece mejorar. Sin embargo es la ANNPC25, con conteo más bajo de neuronas, la que sigue presentando el mejor desempeño. Capacidad de generalización: Media baja.



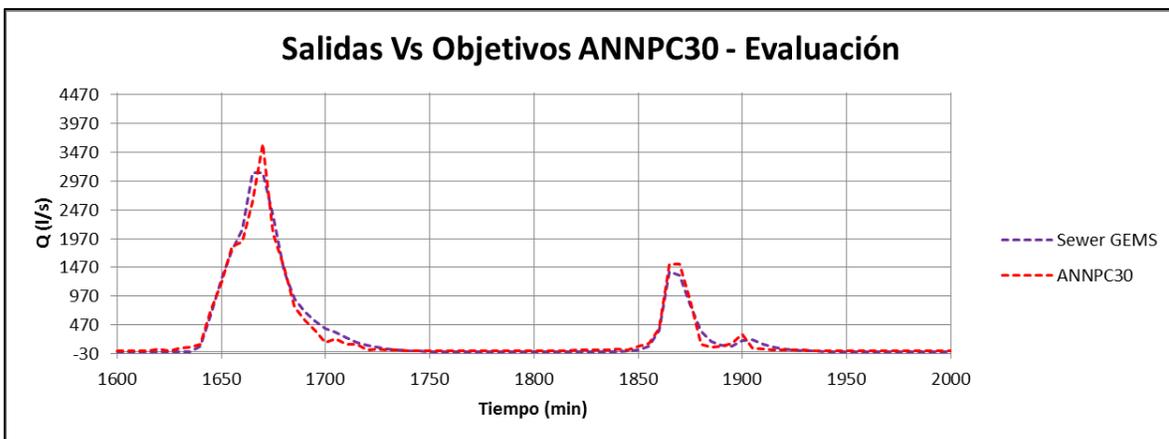
Gráfica 5.36 Hidrogramas predichos por la red neuronal ANNPC28 Vs Modelados en Sewer GEMS.

Un mayor conteo de neuronas en una capa oculta no parece mejorar notoriamente el desempeño de las redes entrenadas mediante este algoritmo. Parece generalizada una tendencia a sobrevalorar los caudales pico del máximo evento. Salvo en el caso de la ANNPC26. Capacidad de generalización: Media abaja.



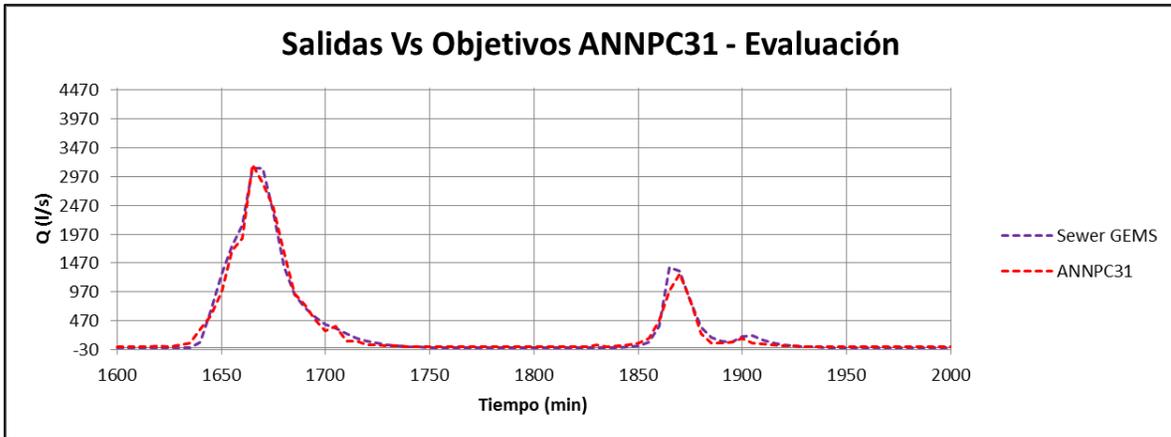
Gráfica 5.37 Hidrogramas predichos por la red neuronal ANNPC29 Vs Modelados en Sewer GEMS.

La ANNPC29, con un arreglo de 5 neuronas en 2 capas ocultas tiene un desempeño nulo, los resultados de la predicción para los hidrogramas de salida no guardan relación alguna con los objetivos. El bajo desempeño puede deberse a un mal proceso de entrenamiento. Capacidad de generalización: Muy baja.



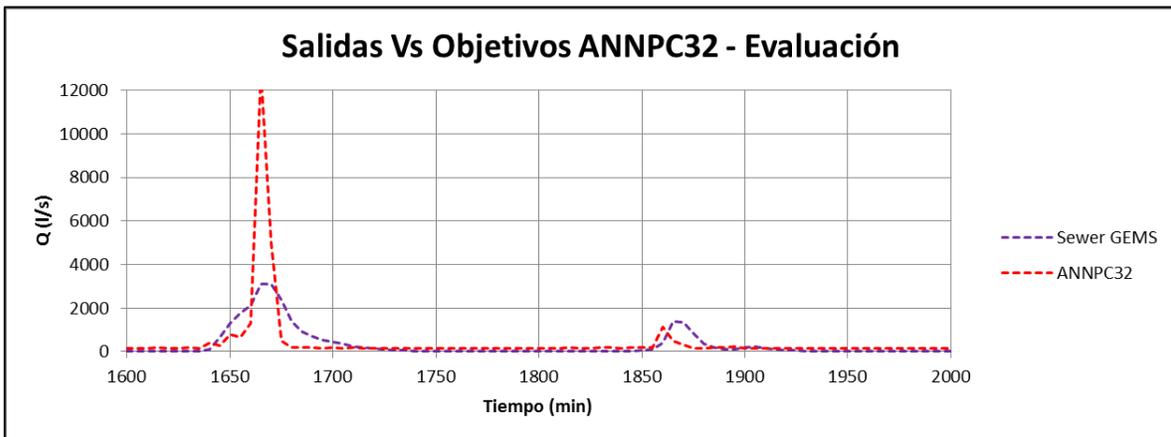
Gráfica 5.38 Hidrogramas predichos por la red neuronal ANNPC30 Vs Modelados en Sewer GEMS.

Comparada con su semejante (ANNPC26), la inclusión de una segunda capa oculta parece mejorar el desempeño de la ANNPC30. Sin embargo una vez más es notorio la tendencia de las redes a sobrevalorar el caudal pico del evento máximo. Capacidad de generalización: Media baja.



Gráfica 5.39 Hidrogramas predichos por la red neuronal ANNPC31 Vs Modelados en Sewer GEMS.

Con un arreglo de 2 capas ocultas y 15 neuronas, la ANNPC31 es la única ANN entrenada con el algoritmo del gradiente, con un desempeño sobresaliente. Los caudales picos, pese a que no reproducen fielmente la geometría si se aproximan a los valores reales esperados. La red no genera ruido y se ajusta considerablemente bien a la geometría general de las hidrógrafas. Su capacidad de generalización: Alta.



Gráfica 5.40 Hidrogramas predichos por la red neuronal ANNPC32 Vs Modelados en Sewer GEMS.

Finalmente, la última red neuronal evaluada, la ANNPC32, presenta una vez más un desempeño nulo, comparable solo con los resultados de la ANNPC29; la geometría generada y los valores de caudal para los picos distan mucho de los valores reales. Su capacidad de generalización: Muy baja.

5.1.4.5 Consolidación de resultados y análisis

Teniendo en cuenta los resultados expuestos en el anterior numeral, a continuación se presenta un análisis detallado sobre el desempeño de las arquitecturas inteligentes, evaluadas con respecto a los indicadores y medidas de bondad de ajuste definidas al comienzo del numeral 5.1.4.

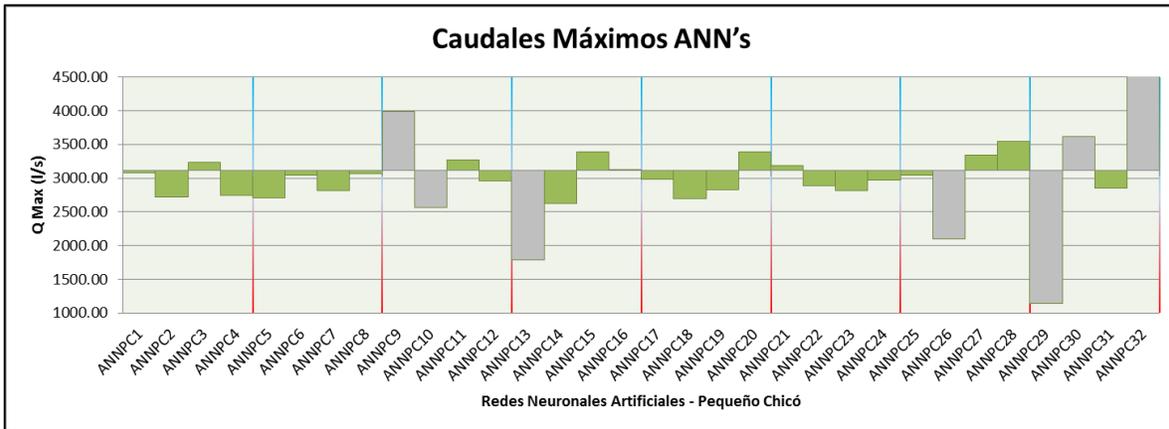
5.1.4.5.1 Desviaciones estándar



Gráfica 5.41 Desviaciones estándar de las ANN construidas.

Aunque no es un indicador del correcto ajuste de los resultados de la ANN a los valores esperados, al comparar las desviaciones estándar de los dos eventos de lluvia predichos por las ANN con las modeladas en Sewer GEMS v8i, si se obtiene una comparación preliminar y cuantitativa de la medida estadística, para la cual un valor muy distante, $|\sigma_{Sewer} - \sigma_{ANNi}| > 100$, con respecto al esperado, $\sigma_{Sewer} = 666.87$, indicará que los hidrogramas predichos poseen una configuración evidentemente distorsionada respecto a los objetivos esperados, razón por la cual valores estadísticos como la media y la desviación, son tan diferentes. Como se puede apreciar en la Gráfica 5.41, 6 redes neuronales exceden este valor de 100 y en especial 3 se destacan por su bajo desempeño, ANNPC26, ANNPC29 y ANNPC32. Con respecto a sus respectivos resultados gráficos, Gráfica 5.34, Gráfica 5.37 y Gráfica 5.40, se encuentra cómo este indicador descalifica inmediatamente el uso de estas 3 arquitecturas inteligentes.

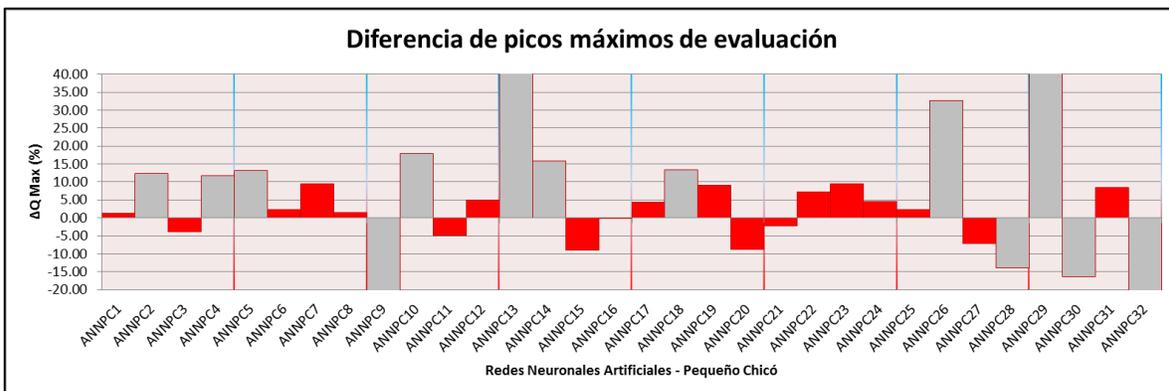
5.1.4.5.2 Caudales Máximos



Gráfica 5.42 Caudales máximos predichos por las ANN construidas.

Realizando una comparación respecto a los caudales pico generados para el evento máximo, se obtienen los resultados contenidos en la Gráfica 5.42; allí se distinguen aquellas arquitecturas que predicen valores excesivos del caudal. Ya descartadas las redes neuronales del numeral anterior, el indicador de caudales máximos, hace evidente una subvaloración considerable para la ANNPC10, y una sobrevaloración de este mismo, para las redes ANNPC9 y ANNPC30; todas estas anteriores con diferencias por el exceso y por el defecto, mayores a 500 l/s respecto al caudal pico máximo real.

5.1.4.5.3 Diferencia Porcentual de Picos Máximos



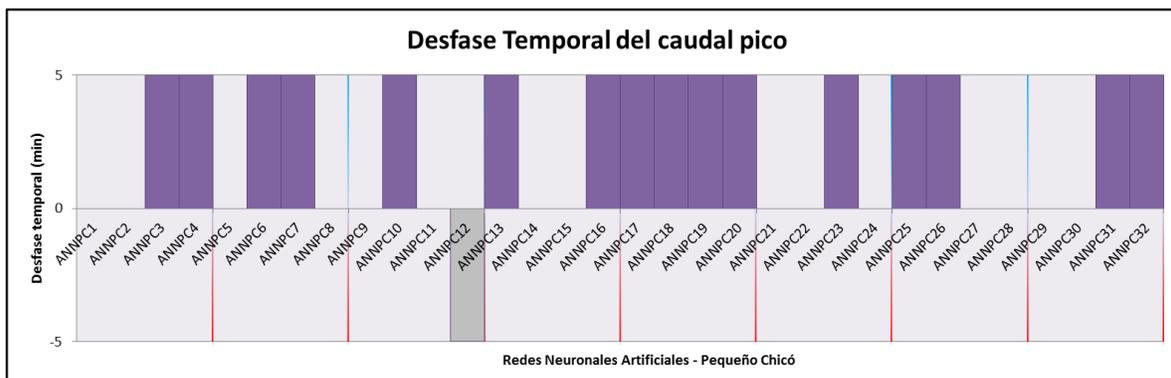
Gráfica 5.43 Diferencia porcentual del caudal pico máximo predicho.

Pese a que en la Gráfica 5.42 son evidentes las más grandes diferencias de caudales respecto al real, el indicador de diferencia porcentual permite realizar una comparación más rigurosa respecto al valor esperado. Al realizar dicha comparación se confirma el mal desempeño de las redes ANNPC9, ANNPC10 y ANNPC30, para las cuales la variación absoluta porcentual excede el 10%.

$$\left| \frac{Q_{Sewer} - Q_{ANNi}}{Q_{Sewer}} \right| = \text{Variación Absoluta Porcentual}$$

Además de las redes desaprobadas por los indicadores anteriores, por el criterio del 10% en la variación porcentual de caudales picos, se suman las redes ANNPC2, ANNPC4, ANNPC5, ANNPC14, ANNPC18 y ANNPC28.

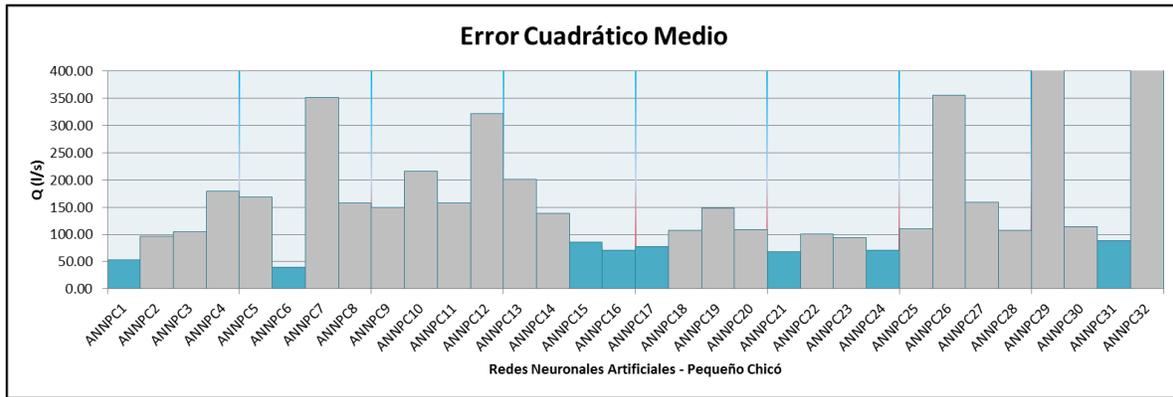
5.1.4.5.4 Desfase Temporal del caudal pico



Gráfica 5.44 Desfase temporal del caudal pico máximo de evaluación.

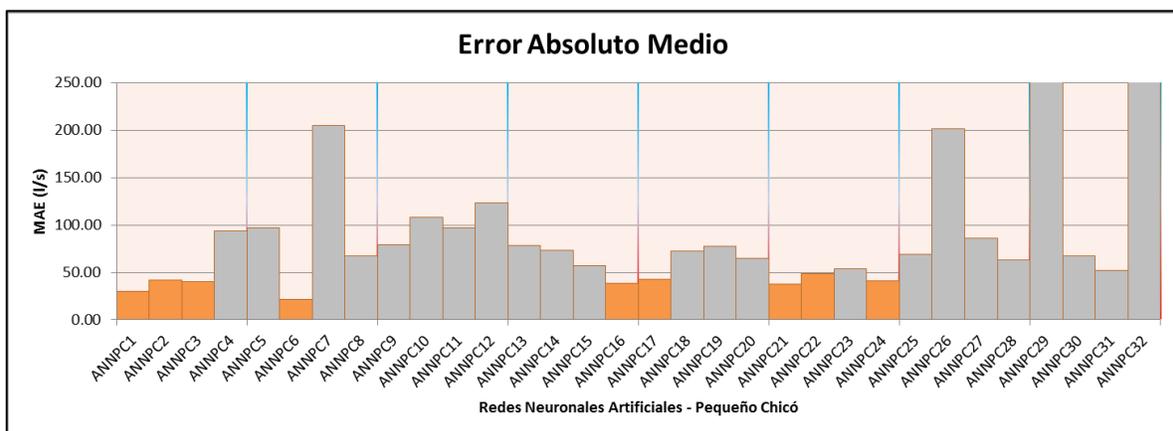
Como último indicador de caudales se analizará el desfase temporal de generación del caudal pico. Para evaluar el desempeño de las redes neuronales se partirá del hecho de que las únicas predicciones desfavorables son aquellas tardías. En la Gráfica 5.44 se puede observar como cerca de la mitad de las ANN ubican al caudal pico del evento en la descarga, 5 minutos antes que el real, cerca del otro 50% de las redes lo localiza en el mismo lapso de tiempo, y sólo la ANNPC12 lo localiza 5 minutos más tarde de lo esperado.

5.1.4.5.5 Error Cuadrático y Error Absoluto Medios



Gráfica 5.45 Error cuadrático medio de los caudales predichos.

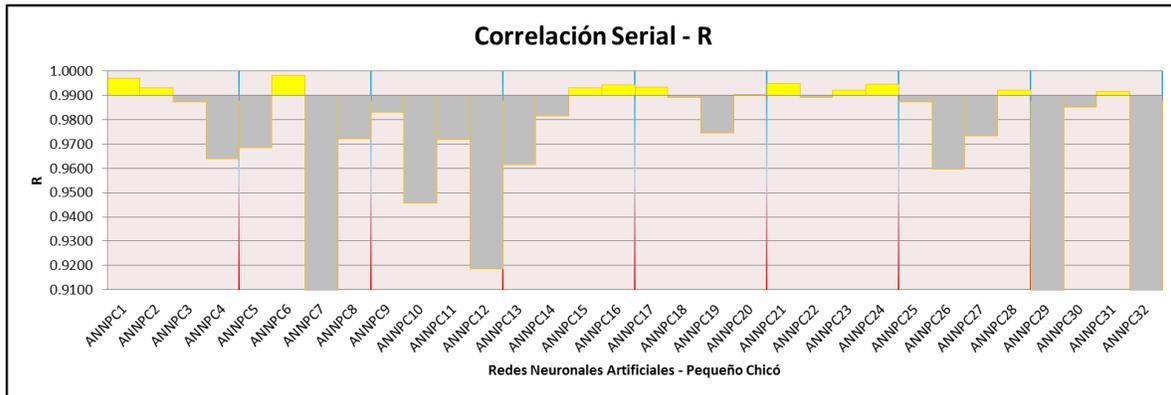
En la Gráfica 5.45 se puede observar el desempeño de las ANN respecto al error cuadrático medio, medida de ajuste que permite medir de manera más rigurosa el ajuste de las predicciones a los datos esperados. Sin embargo resulta difícil determinar un valor máximo hasta el cual definir como sobresaliente el desempeño de la red neuronal. En este punto se hace necesaria una comparación a la par con los resultados gráficos anteriormente expuestos. Dicha revisión evidenció que redes con un $MSE > 90 l/s$ cualitativamente fueron calificadas con una capacidad de generalización media baja o inferior.



Gráfica 5.46 Error absoluto medio de los caudales predichos.

Realizando un proceso similar pero con un corte en el $MAE > 50 l/s$ se obtienen los resultados de la Gráfica 5.46.

5.1.4.5.6 Correlación Serial - R



Gráfica 5.47 Correlación Serial Objetivos Vs Salidas.

Como última prueba de bondad de ajuste, se evaluó el coeficiente de correlación serial de rezago cero, entre los hidrogramas modelados y predichos por las ANN. Definiendo un valor de corte de 0.99 desde el cual una ANN cualitativa y cuantitativamente estaría en la capacidad de predecir caudales de descarga con un alto nivel de exactitud, se obtienen los resultados contenidos en la Gráfica 5.47.

5.1.4.6 Selección de ANNPC's sobresalientes

A continuación se presenta el resultado de la evaluación de las ANN creadas. Se seleccionaron las redes neuronales que avanzan a la siguiente etapa de evaluación, la cual se realizará con series de entrada con características de duración y caudales picos totalmente diferentes.

Tabla 5-13 Pre selección de redes neuronales artificiales.

Código	CRITERIOS DE SELECCIÓN							AVANZA?
	Desviación Estandar	Caudal Máximo	Diferencia Porcentual de Q Max	Desfase Temporal del Pico Q Max	MSE	MAE	R	
ANNPC1								SI
ANNPC2			No Cumple		No Cumple			NO
ANNPC3					No Cumple		No Cumple	NO
ANNPC4			No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC5			No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC6								SI
ANNPC7	No Cumple				No Cumple	No Cumple	No Cumple	NO
ANNPC8					No Cumple	No Cumple	No Cumple	NO
ANNPC9		No Cumple	No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC10		No Cumple	No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC11					No Cumple	No Cumple	No Cumple	NO
ANNPC12	No Cumple			No Cumple	No Cumple	No Cumple	No Cumple	NO
ANNPC13	No Cumple	No Cumple	No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC14			No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC15						No Cumple		SI
ANNPC16								SI
ANNPC17								SI
ANNPC18			No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC19					No Cumple	No Cumple	No Cumple	NO
ANNPC20					No Cumple	No Cumple		NO
ANNPC21								SI
ANNPC22					No Cumple		No Cumple	NO
ANNPC23					No Cumple	No Cumple		NO
ANNPC24								SI
ANNPC25					No Cumple	No Cumple	No Cumple	NO
ANNPC26	No Cumple	No Cumple	No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC27					No Cumple	No Cumple	No Cumple	NO
ANNPC28			No Cumple		No Cumple	No Cumple		NO
ANNPC29	No Cumple	No Cumple	No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC30		No Cumple	No Cumple		No Cumple	No Cumple	No Cumple	NO
ANNPC31						No Cumple		SI
ANNPC32	No Cumple	No Cumple	No Cumple		No Cumple	No Cumple	No Cumple	NO

5.1.5 VARIACIONES DE HIDROLOGÍA – DURACIÓN Y TQM

Pese a que los resultados obtenidos en la primera evaluación de las ANN arrojaron resultados favorables para 8 arquitecturas, vale la pena resaltar que los hidrogramas de entrenamiento fueron generados con geometrías y caudales pico variables que permitieran simular diferentes condiciones de operación del sistema. Sin embargo estos hidrogramas, como se mencionó en el numeral 5, siempre guardaron similitud en otras características propias de un evento de tormenta

como lo son la duración y el tiempo en el que se presenta el caudal pico. En este numeral y los dos numerales siguientes se complejizará el problema del tránsito de caudales a través de la red de drenaje. Lo anterior se logrará realizando variaciones en la hidrología de manera tal que la evaluación de las ANN pueda llevarse a un caso teórico más acorde con la realidad.

Con el fin de evaluar el desempeño de las mejores ocho ANN obtenidas en el numeral anterior, frente a series de entrada diferentes a las de entrenamiento incluyendo variaciones en la duración y en el tiempo al caudal máximo (TQM), Figura 5.16, se generaron 10 nuevos eventos de tormenta para ser simulados por las ANN.

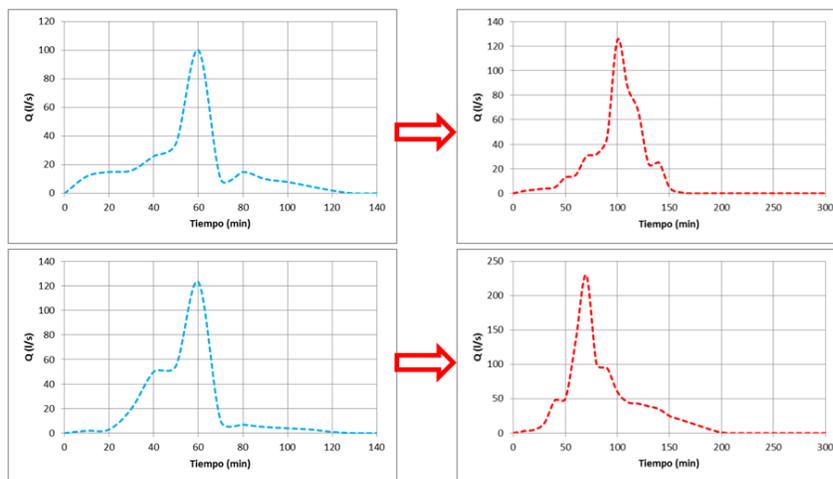


Figura 5.16 Esquemas generales de variación de hidrología – Duración y TQM.

Una vez definidos los 10 nuevos eventos de tormenta se procedió a realizar la modelación hidráulica en Sewer GEMS v8i con las mismas opciones de cálculo hidráulico ilustradas en la Figura 5.3. Dicha modelación arrojó que debido a las variaciones de duración y TQM de los nuevos eventos el vano de finalización debería ajustarse respecto a cada evento de tormenta. De acuerdo con lo anterior, en la Tabla 5-14 se registran las características generales utilizadas para esta nueva etapa del estudio.

Tabla 5-14 Nuevas características generales de las tormentas.

Duración de la lluvia	30 min - 150 min
Vano de finalización	100 min - 220 min
Duración evento total	250 min

T para Q máximo (TQM)	20 min - 75 min
Nudos de Ingreso	18 iniciales

Estas características pueden ser comparadas con las definidas para el proceso de entrenamiento registradas en la Tabla 5-6 del numeral 5.

Aunque el tránsito de los nuevos caudales se realiza a lo largo de la misma red de estudio, fue necesaria la verificación del rezago en el tránsito de la red, determinando así que la variación en los caudales de ingreso al sistema no induce un cambio en los rezagos definidos en el numeral 5.2, por lo cual las arquitecturas inteligentes son aplicables para la simulación de los nuevos eventos de tormenta.

Una vez definidas las parejas de entrada al sistema se procedió a realizar la simulación de los caudales con la ayuda de la función \gg *nntool*. Véase Figura 5.17 Interfaz de manejo de datos (*nntool*).

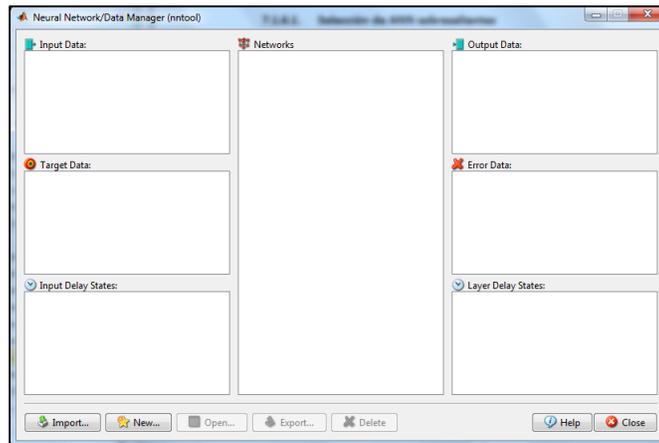


Figura 5.17 Interfaz de manejo de datos (*nntool*).

Para la simulación de las ANN se requiere contar, dentro del espacio de trabajo de MatLab, con las siguientes variables:

- Matriz $m \times n$ datos de entrada / *Input Data*, que contiene el(los) evento(s) de tormenta de ingreso a la red. Siendo m el número de pozos de ingreso y n la duración total de los eventos.
- Matriz $a \times b$ datos de salida / *Target Data*, que contiene el(los) hidrograma(s) de salida en los puntos de interés de la red. Para este caso

la descarga de la red en un punto conocido. Siendo a el número de pozos de salida y b la duración total de los eventos.

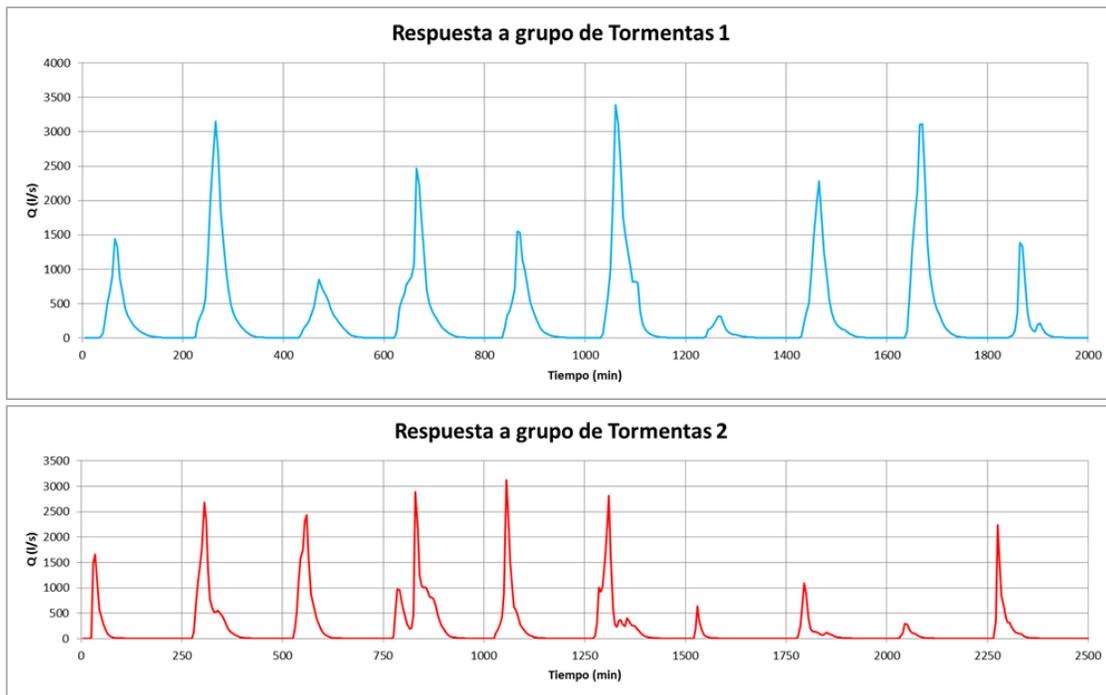
- Red neuronal artificial con la arquitectura definida según el diseñador / *Network*, obtenida del proceso descrito en el Numeral 5.1.3.4.
- Estados de rezago de entrada / *Input Delay States* vector generado por la interfaz, que contiene una transformación de los rezagos de entrada.

Desde la interfaz de manejo se importan las variables, y se procede a simular la red neuronal artificial. Vale la pena mencionar que los datos de salida son solo utilizados para que el programa compare la simulación generada por la ANN y los datos esperados.

5.1.5.1 Resultados de la simulación

Debido a que los caudales de simulación poseen características diferentes respecto a los caudales utilizados para el entrenamiento se espera que el desempeño de las ANN se vea afectado negativamente, pues ninguna arquitectura en su proceso de entrenamiento registro hidrogramas con duraciones y TQM variables. Sin embargo se espera determinar la sensibilidad del desempeño de las ANN frente a cambios drásticos en la hidrología, sin el reentrenamiento o adaptación debidos.

En la Gráfica 5.48 se ilustra la variación en los hidrogramas de salida esperados; allí se evidencia de primera mano lo anteriormente expuesto. Las ANN deberán generar series de salida semejantes a las rojas, estando entrenada para generar series de salida como las azules.

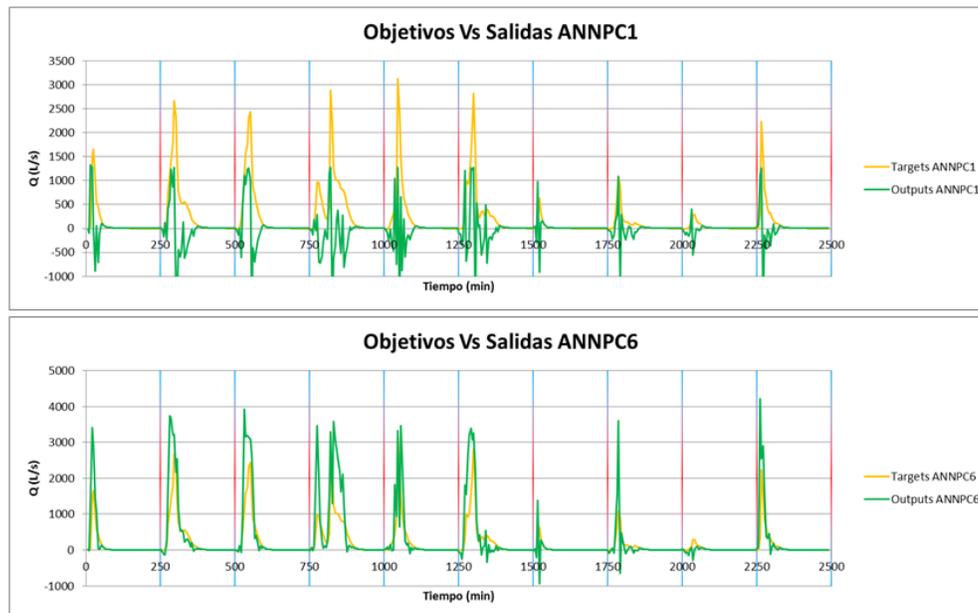


Gráfica 5.48 Variaciones en los hidrogramas de salida.

A continuación se presentan los hidrogramas de respuesta de las ocho mejores ANN definidas en el Numeral 5.1.4.5.6 en comparación con los hidrogramas esperados.

5.1.5.1.1 ANNPC1 y ANNPC6 variación de duración y TQM

Para el caso de la ANNPC1 se observa como la ANN generó salidas con mucho ruido y, salvo en los eventos de tormenta cuyos picos no superan los 500 L/s, logró registrar un caudal similar al esperado. Sin embargo los resultados no son útiles en ningún caso. Dicho resultado concuerda con la información registrada en la literatura y permite evidenciar la importancia de un proceso de entrenamiento riguroso que incluya parejas de entrada tan diversas como puedan presentar en la realidad.



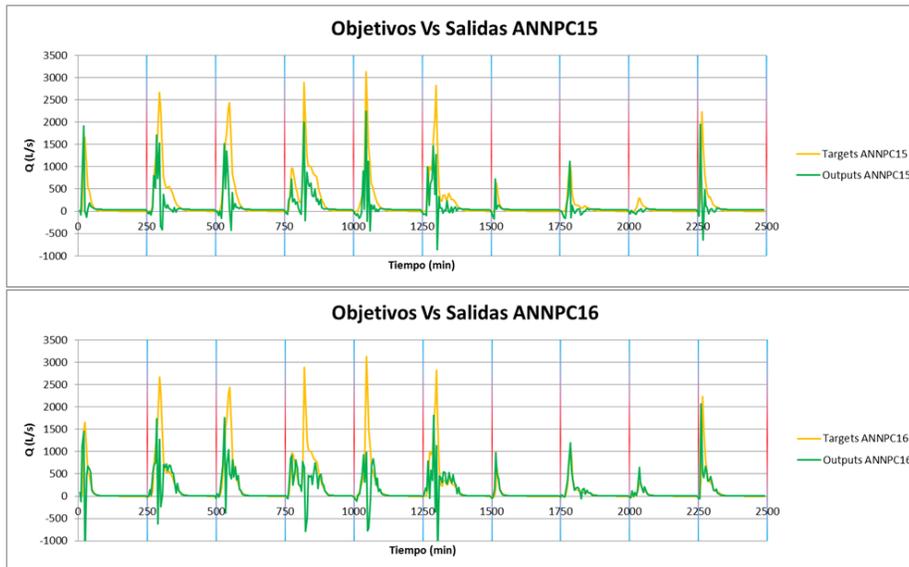
Gráfica 5.49 Resultados de simulación ANNPC1 y ANNPC6 frente a cambios de duración y TQM.

Por otro lado la ANNPC6 aunque continúa registrando un bajo desempeño, la red neuronal artificial generó hidrogramas con un mejor ajuste que la ANNPC1 intentando simular la geometría esperada.

5.1.5.1.2 ANNPC15 y ANNPC16 variación de duración y TQM

Similar a los resultados obtenidos con ANNPC1, la ANNPC15 generó muy pobres hidrogramas de salida, subvalorando en la mayoría de los casos el caudal del caudal pico. Por otra parte los resultados de la ANNPC16 aunque no son tan ajustados a los registrados por la ANNPC6 visualmente sí parecen tener un mejor desempeño que la ANNPC15.

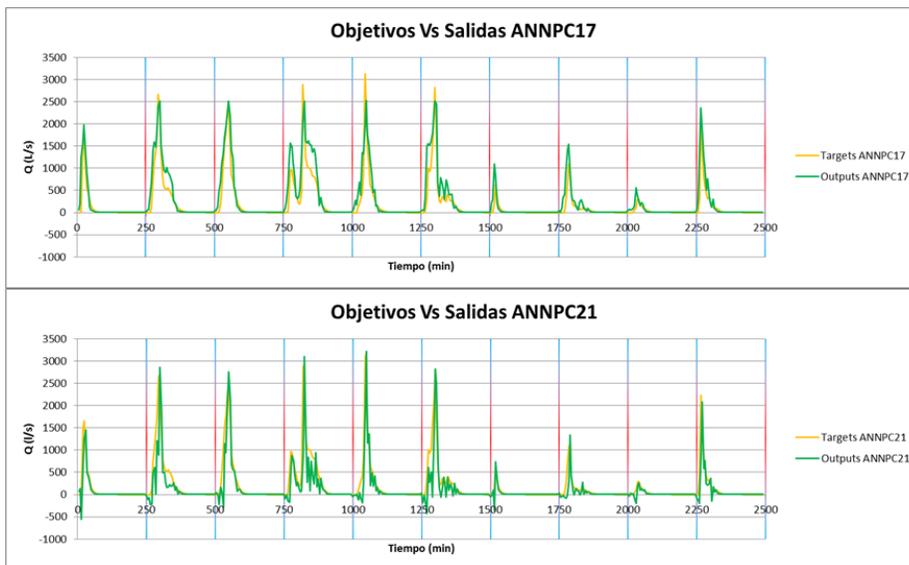
Es importante también recalcar que el mejor desempeño registrado por la ANNPC16 está asociado nuevamente con los eventos de tormenta con caudales pico muy inferiores a los mayores registrados.



Gráfica 5.50 Resultados de simulación ANNPC15 y ANNPC16 frente a cambios de duración y TQM.

5.1.5.1.3 ANNPC17 y ANNPC21 variación de duración y TQM

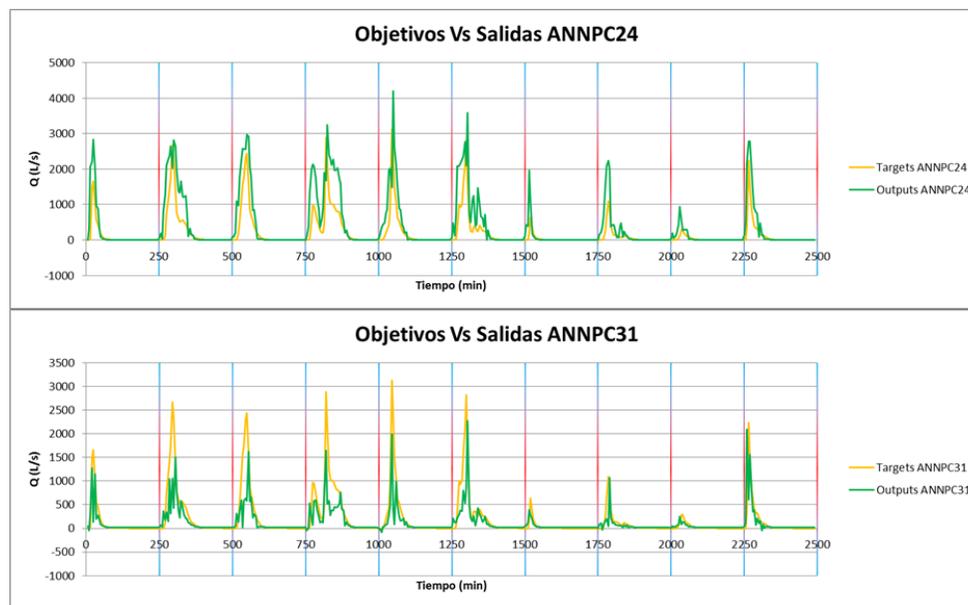
En el caso de la ANNPC21 el desempeño no se vio tan afectado aunque los hidrogramas de salida siguen presentando mucho ruido.



Gráfica 5.51 Resultados de simulación ANNPC17 y ANNPC21 frente a cambios de duración y TQM.

Por otra parte, los resultados de la ANNPC17 resultan muy positivos; si bien la geometría de los hidrogramas de resultado no es fiel a los datos esperados, sí es evidente un mejor ajuste respecto a todas las ANN analizadas hasta el momento. Lo que en principio indica que la arquitectura a pesar de la limitación en los datos de entrenamiento, es capaz de simular con cierto grado de suficiencia hidrogramas desconocidos por ella.

5.1.5.1.4 ANNPC24 y ANNPC31 variación de duración y TQM



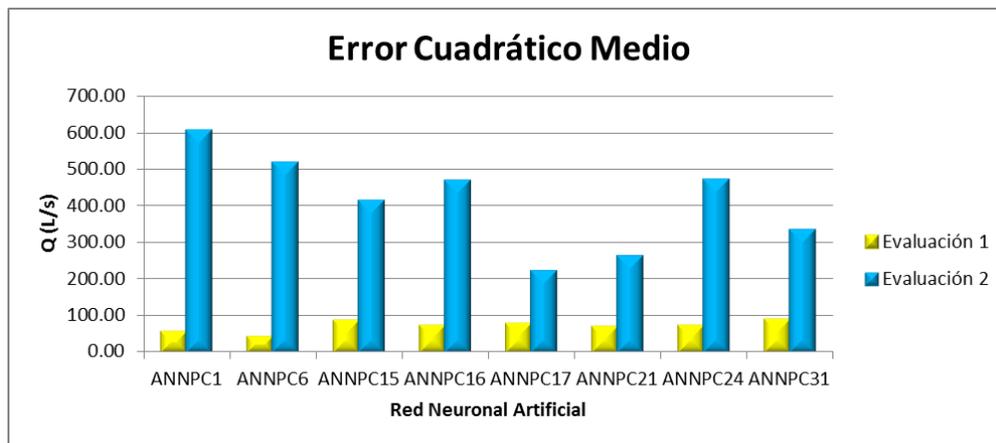
Gráfica 5.52 Resultados de simulación ANNPC24 y ANNPC31 frente a cambios de duración y TQM.

En el caso de las redes ANNPC24 y ANNPC31 las series de salida generadas una no presentan tanto ruido, presente en otras arquitecturas, y aunque la reproducción de la geometría del hidrograma no es adecuada, sí es posible evidenciar como la red tiene una tendencia a simular los datos esperados, aunque falla en la definición de caudales mínimos y máximos.

Lo anterior se evidencia más claramente en los resultados obtenidos por la ANNPC24 para la tormenta 4, en donde la red para los resultados atípicos de un evento con 2 picos de caudal, genera una serie que emula el resultado esperado aunque sin la exactitud deseada.

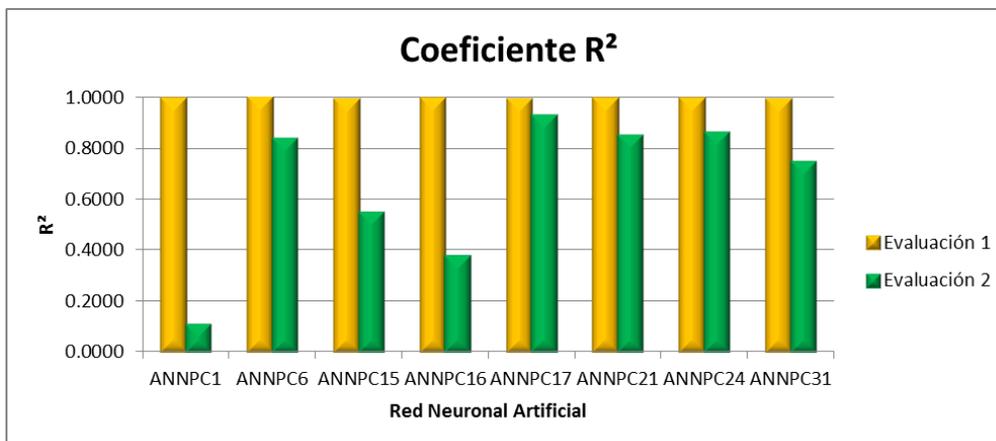
5.1.5.1.5 Comparación de resultados

A continuación se presenta la comparación de resultados obtenidos para las ocho redes neuronales artificiales comparativamente entre la evaluación inicial y la simulación anteriormente analizada.



Gráfica 5.53 Variación del MSE entre las dos evaluaciones.

Como se mencionó al inicio del numeral, se esperaba que el desempeño de las ANN se viera afectado negativamente, en la Gráfica 5.53 se ilustra el gran impacto que tuvo el cambio drástico de la hidrología. Sin embargo debido a que las series de salida utilizadas para calcular el MSE son diferentes, una medida de desempeño más adecuada para la comparación sería el coeficiente R^2 . (Véase Gráfica 5.54.)



Gráfica 5.54 Variación del R² entre las dos evaluaciones.

En la Gráfica 5.54 es fácil apreciar las redes neuronales que más se vieron afectadas frente al cambio de hidrología en los valores de entrada, siendo las más afectadas la ANNPC1, ANNPC16 y ANNPC15. Por otro lado y concordante con el análisis cualitativo de los numerales anteriores, las redes ANNPC17, ANNPC24 y ANNPC21 fueron aquellas que pese a los cambios hidrológicos mantuvieron un desempeño aceptable.

Sin embargo pese a los resultados hasta el momento obtenidos, resulta conveniente explorar una de las cualidades de las ANN. Al ser arquitecturas inteligentes con algoritmos de aprendizaje definidos, la adaptabilidad de una red es una característica útil cuando las condiciones a simular cambian en la vida real.

Cuando el desempeño de una red neuronal se ve afectado por variaciones naturales o artificiales en la relación de los datos de entrada y salida del fenómeno que se esté simulando, la red neuronal tiene la posibilidad de adaptarse a los cambios si tiene acceso a nuevas parejas de entradas y salidas con las que poder ajustar sus pesos sinápticos.

Para explorar los alcances de la adaptación de una ANN, se reevaluará el desempeño de las dos arquitecturas cuyo desempeño se vio afectado en menor medida: ANNPC17 y ANNPC24.

5.1.5.2 Adaptación de las ANN frente a cambios hidrológicos

Para la adaptación de las arquitecturas solo son necesarias nuevas parejas de entrada que representen diversamente los cambios generados en el fenómeno estudiado. Con la ayuda de la misma interfaz de MatLab utilizada para la simulación de los nuevos eventos de tormenta se puede adaptar (\gg *adapt*) la red neuronal con base en nuevas parejas de entrada y salida.

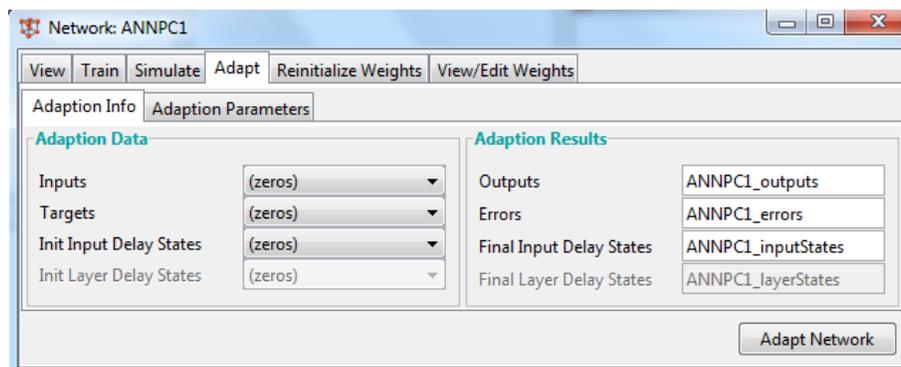
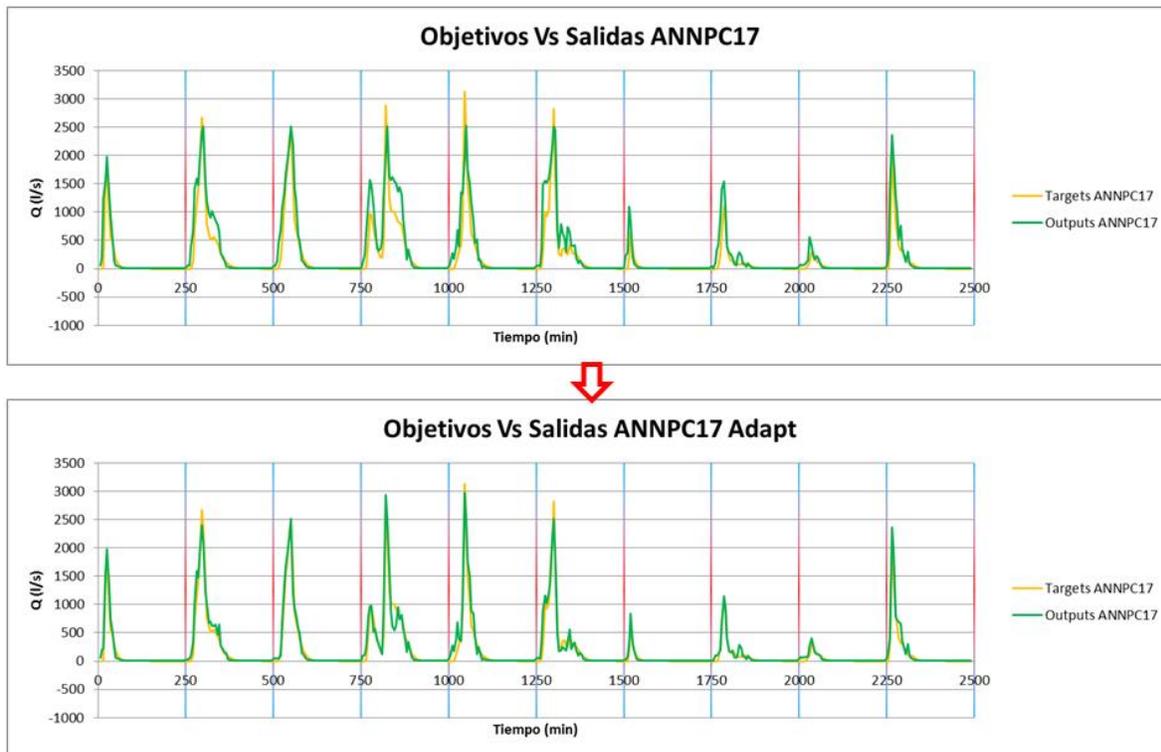


Figura 5.18 Herramienta para la adaptación de ANN.

Una vez realizado el proceso de adaptación de la red, con un conjunto diferente de diez eventos de tormenta con características variables como las expuestas en la Tabla 5-14, se procedió a simular nuevamente los diez eventos de tormenta utilizados para evaluar el desempeño de las redes neuronales artificiales en el Numeral 1.1.6.

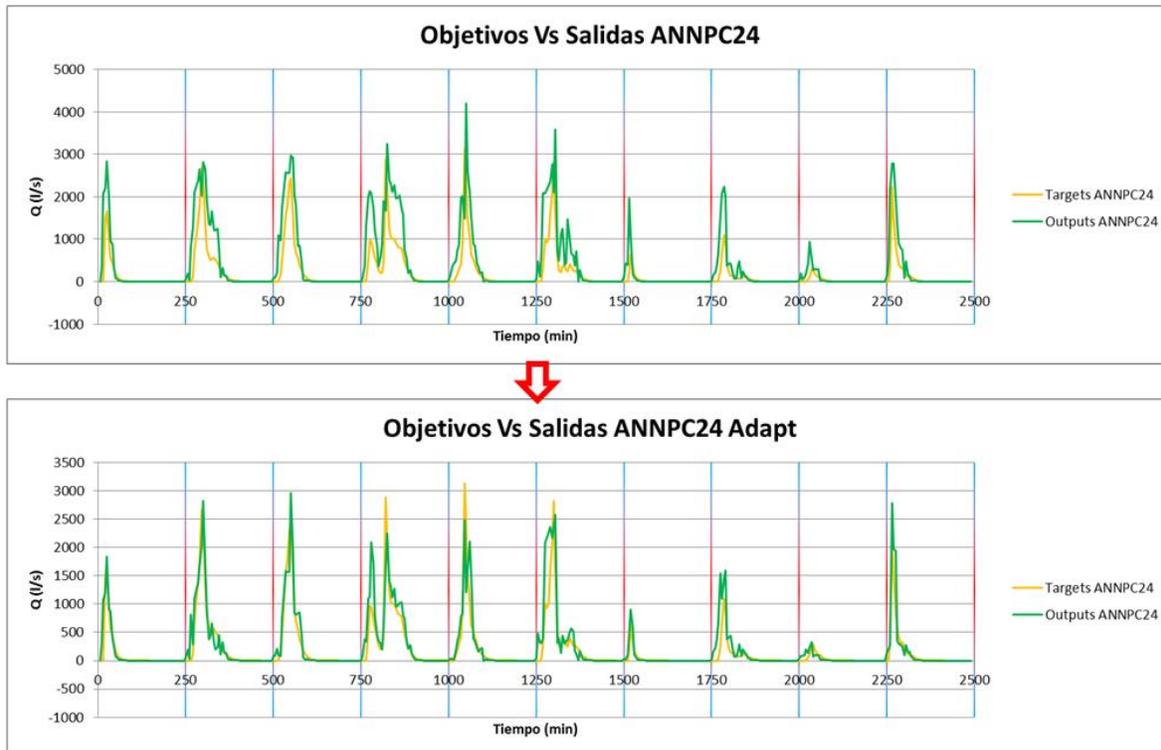


Gráfica 5.55 Variación en la respuesta de la ANNPC17 después de la adaptación.

En la Gráfica 5.55 se puede observar la nueva serie de hidrogramas generadas por la red ANNPC17. A primera vista ya es evidente que la adaptación de la arquitectura mejoró el desempeño notablemente. Para los 10 eventos de tormenta simulados es evidente una mejoría en la geometría de los hidrogramas en la descarga de la red. Aunque aún es posible apreciar algunas zonas donde la red neuronal artificial no se ajusta fielmente a los datos esperados generando ruido.

Dicho comportamiento puede ser atribuido a la cantidad de hidrogramas utilizados para la adaptación de la red. Esto plantea una limitante para el uso práctico de las ANN para casos como el estudiado, puesto que pone de manifiesto una demanda considerable de datos para la adaptación, que en muchos casos no se encuentran disponibles por la falta de instrumentación que pueda existir en la realidad.

Por otra parte, en la Gráfica 5.56 se ilustran los resultados de la ANNPC24 después del proceso de adaptación.



Gráfica 5.56 Variación en la respuesta de la ANNPC24 después de la adaptación.

Una vez más se hace evidente la mejoría en la predicción de hidrogramas para la red estudiada. Y aunque no parece ser una aproximación igual de rigurosa a la obtenida con la ANNPC17 si es posible concluir que la adaptación como característica de las ANN es una herramienta invaluable para mantener vigentes las arquitecturas inteligentes ya diseñadas.

En la Tabla 5-15 y la Tabla 5-16 se relaciona la evolución del desempeño de las dos redes neuronales analizadas así como la mejoría en su desempeño, medido por los indicadores Error Cuadrático Medio (MSE), Error Absoluto Medio (MAE) y el coeficiente R^2 .

Tabla 5-15 Evolución de desempeño ANNPC17.

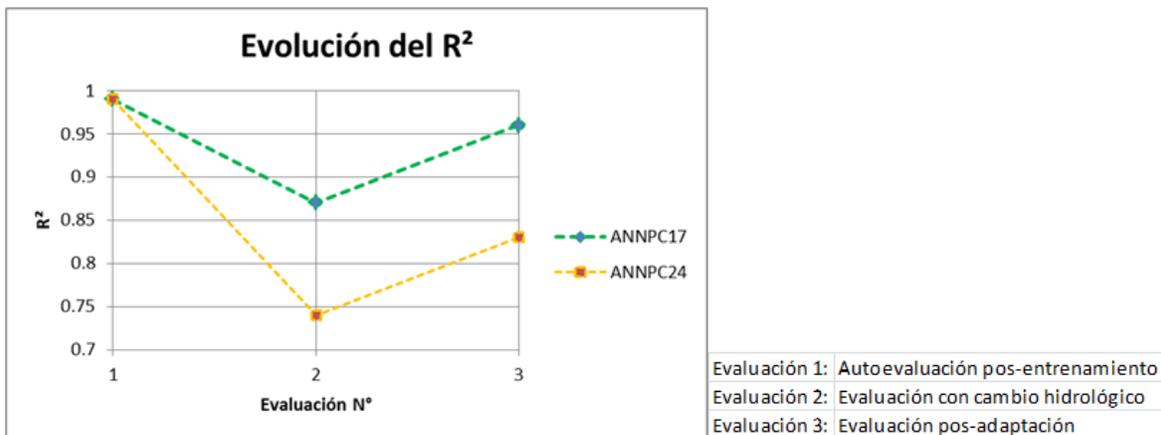
Evolución de desempeño ANNPC17						
B. AJUSTE	Evaluación 1		Evaluación 2		Evaluación 3	
MSE	77.11	l/s	223.66	l/s	102.41	l/s
MAE	43.21	l/s	101.13	l/s	48.45	l/s
R ²	0.99		0.87		0.96	

En ambas tablas es posible evidenciar la evolución positiva que tuvo el desempeño de las ANN después del proceso de adaptación.

Tabla 5-16 Evolución de desempeño ANNPC24.

Evolución de desempeño ANNPC24						
B. AJUSTE	Evaluación 1		Evaluación 2		Evaluación 3	
MSE	70.63	l/s	472.34	l/s	229.4	l/s
MAE	41.04	l/s	223.94	l/s	94.3	l/s
R ²	0.99		0.74		0.83	

Sin embargo, como se ilustra en la Gráfica 5.57, dicho desempeño no logró ser mejorado hasta su punto óptimo alcanzado en una primera evaluación.


Gráfica 5.57 Evolución del coeficiente R² para las redes ANNPC14 y ANNPC27.

En conclusión, la adaptación es tan útil como lo permita la disponibilidad de datos que describan el comportamiento variable del fenómeno estudiado.

5.1.6 VARIACIONES DE HIDROLOGÍA - PUNTOS DE INGRESO Y COBERTURA

Al igual que en el Numeral 5.1.5 el objetivo en esta etapa es complejizar el fenómeno para determinar la viabilidad de las redes neuronales artificiales en un caso de estudio más próximo a la realidad. Por tal razón en este numeral se determinará si la construcción de ocho nuevas redes neuronales, que poseerán la arquitectura de las mejores ocho definidas en el Numeral 5.1.4.5.6, pero entrenadas con un total de 50 hidrogramas de entrada, tiene un buen desempeño simulando el tránsito de crecientes a través de la red de estudio.

Inicialmente las ANN procesaban la información proveniente de 18 nudos de la red localizados en los puntos de inicio del sistema de drenaje; sin embargo en la realidad el sistema de drenaje pluvial recibe hidrogramas a lo largo de todo su recorrido.



Figura 5.19 Orto foto del caso de estudio Pequeño Chicó con localización de sumideros (Nudos amarillos) y pozos de la red (Nudos rojos).

Por lo tanto en esta etapa del estudio se realizará una aproximación más a la realidad y se generarán eventos de tormenta diversos para cada uno de los 50 nudos que registran ingreso de caudal vía conexión de sumideros en el trazado urbano. Además para simular diferentes escenarios dentro del área de estudio los

diez eventos de tormenta fueron subdivididos según su cobertura sobre la red. Así finalmente se obtendría la siguiente distribución:

- 3 eventos de lluvia tendrán una cobertura sobre el 100% del área de estudio.
- 2 eventos de lluvia cubrirán sólo el 75% del área de estudio, dejando el 25% sobrante seco.
- 3 eventos de lluvia caerán sobre el 50% del área de estudio (25 pozos).
- 2 eventos de lluvia se concentraran en el 25% del área de estudio.

En la Figura 5.20, se ilustra la cobertura sobre la red de estudio.

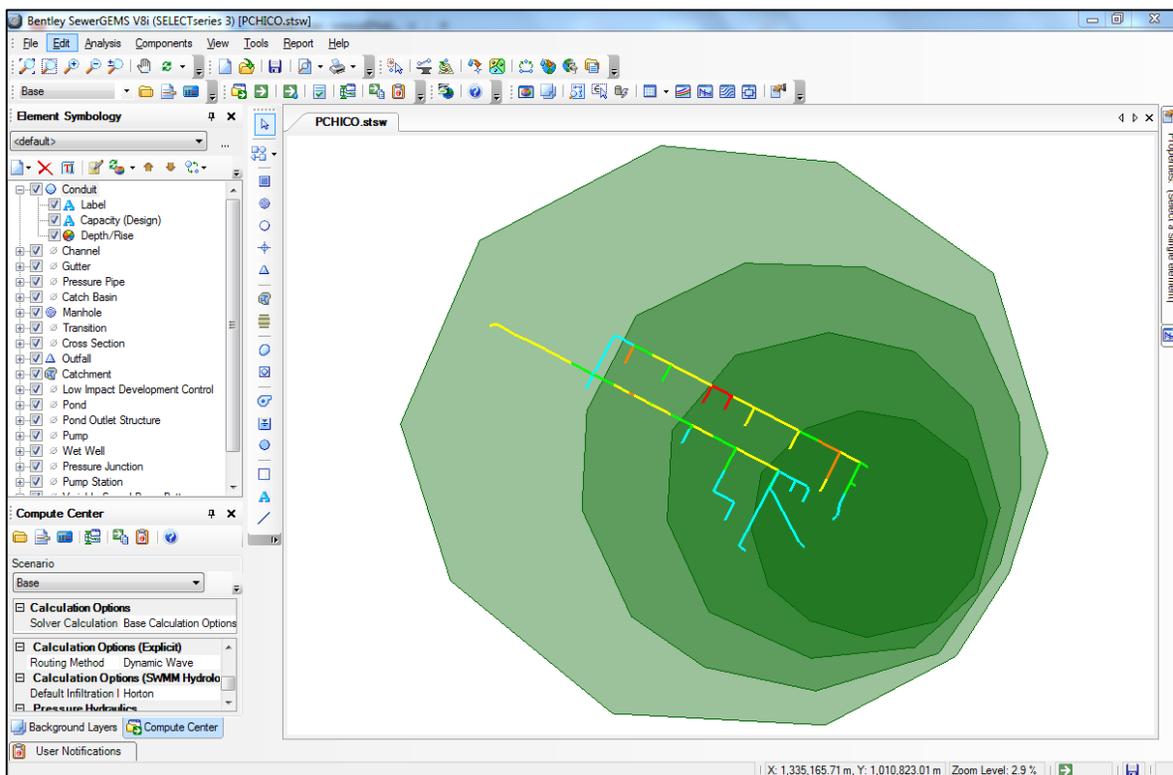


Figura 5.20 Cobertura de eventos de lluvia sobre la red Pequeño Chicó.

De esta manera se definieron nuevamente características cada vez más diversas en el fenómeno de estudio, haciendo más compleja así la simulación del tránsito de caudales a través de la red. En la Tabla 5-17 se encuentran relacionadas las características que definen el fenómeno del tránsito de caudales.

Tabla 5-17 Características generales de los eventos de lluvia con cambios en la cobertura.

Duración de la lluvia	30 min - 150 min
Vano de finalización	100 min - 220 min
Duración evento total	250 min
T para Q máximo (TQM)	20 min - 75 min
Nudos de Ingreso	12 - 50

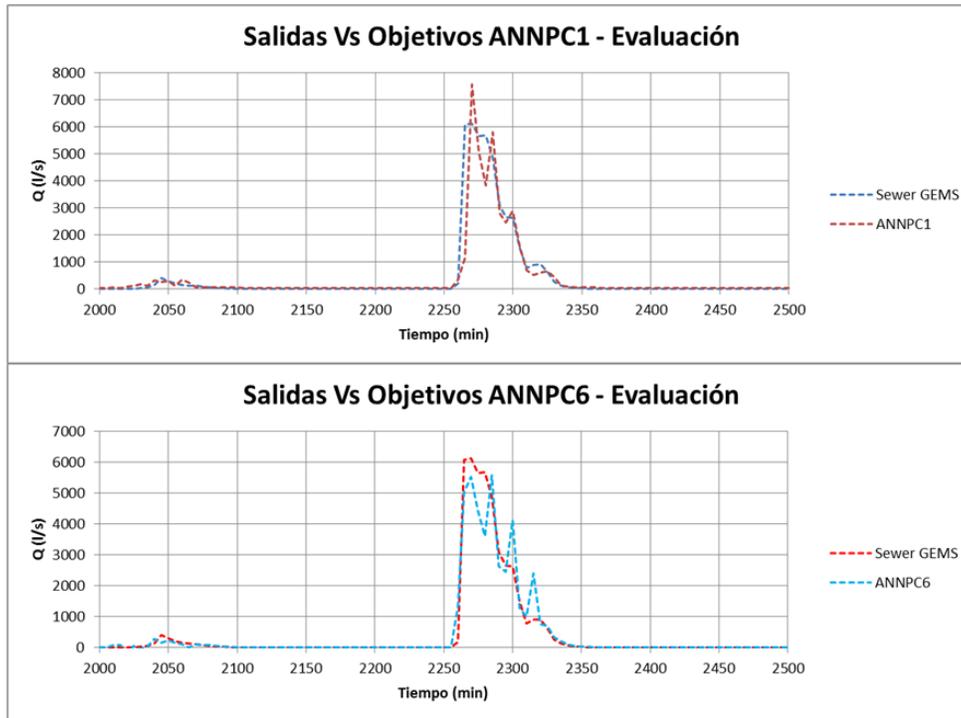
5.1.6.1 Resultados iniciales

Una vez definidas las características generales de los 10 eventos de tormenta se procedió una vez más a generar las parejas de entrada y salida, para el entrenamiento de las redes, a través de la simulación de los diferentes eventos de tormenta en el modelo computacional de Sewer GEMS v8i. Definidas dichas parejas se procedió con el entrenamiento de las redes y posterior evaluación inicial de su desempeño.

5.1.6.1.1 ANNPC1 y ANNPC6 variación de puntos de ingreso y cobertura

Los resultados de la evaluación inicial de estas dos redes son similares. En ambos casos las ANN generaron hidrogramas con múltiples picos en el evento de tormenta con el caudal máximo más alto. Aunque el desarrollo del evento simulado cumple con la duración - de 2250 min a 2350 min para la tormenta máxima – la red no logró simular aceptablemente el valor del caudal pico.

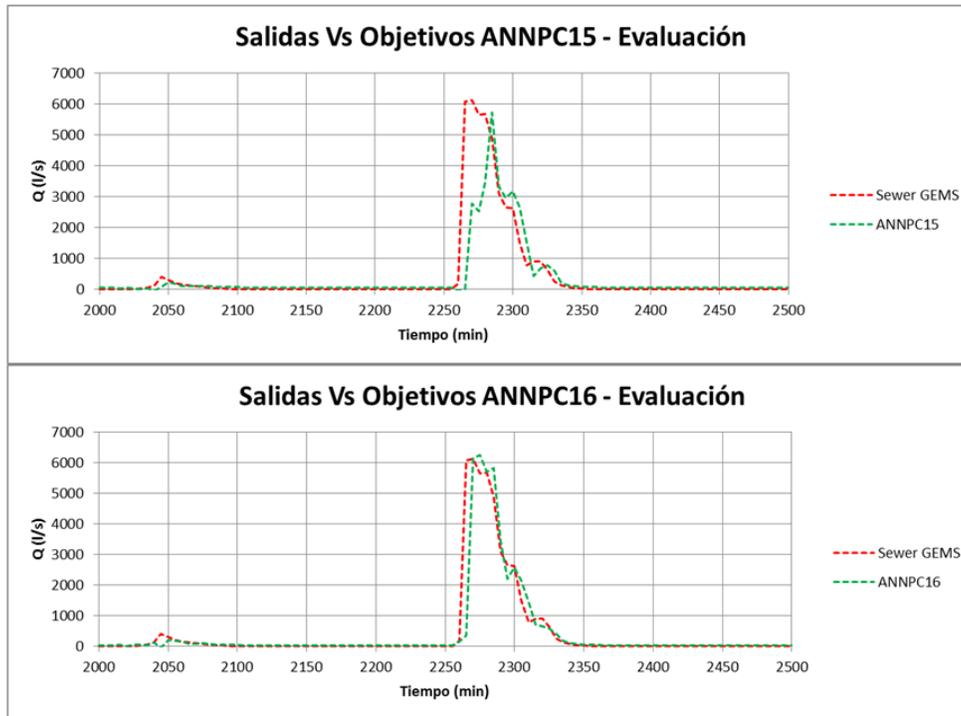
De manera análoga el evento desarrollado entre los minutos 2000 y 2250 tampoco fue simulado de manera correcta. El bajo desempeño puede atribuirse a un ineficiente proceso de entrenamiento.



Gráfica 5.58 Resultados de evaluación ANNPC1 y ANNPC6 frente a cambios en puntos de ingreso y cobertura.

5.1.6.1.2 ANNPC15 y ANNPC16 variación de puntos de ingreso y cobertura

Para las redes ANNPC15 y ANNPC16, ambas entrenadas con el algoritmo de propagación resiliente, con dos capas ocultas y una diferencia de 5 neuronas en la segunda capa, los resultados son cualitativamente mejores que los obtenidos en las ANN anteriores. En el caso de la ANNPC15 la generación de picos múltiples se redujo; sin embargo se observa un desfase temporal en toda la serie de caudales.



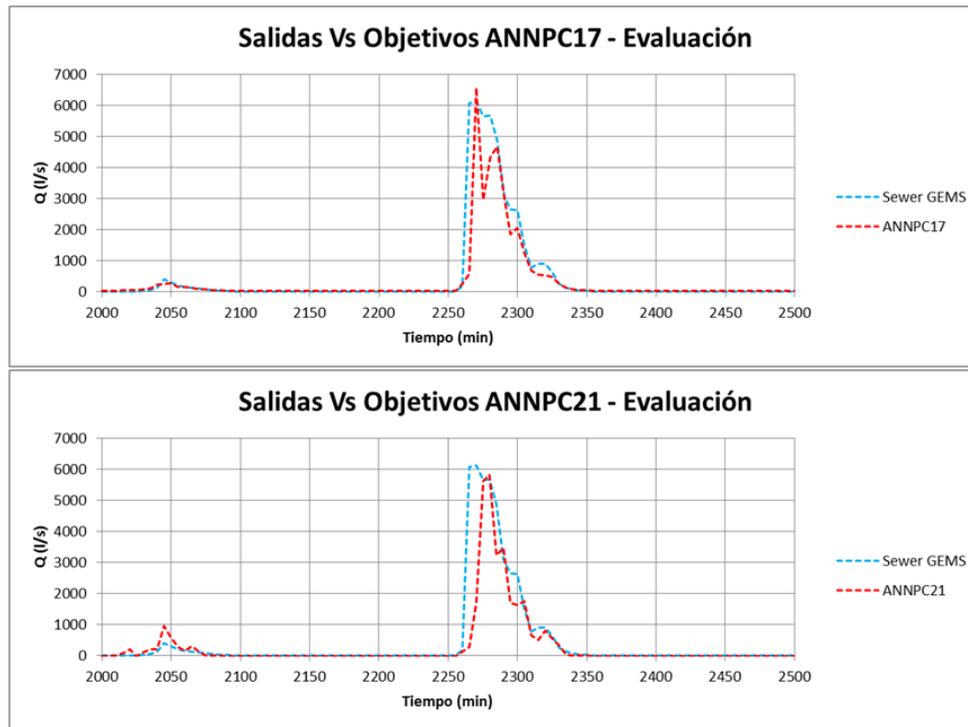
Gráfica 5.59 Resultados de evaluación ANNPC15 y ANNPC16 frente a cambios en puntos de ingreso y cobertura.

Por otra parte, la ANNPC16 con 5 neuronas más en la segunda capa oculta muestra un desempeño aceptable en la simulación del evento máximo. Pese a tener un desfase temporal la geometría del hidrograma se ajusta mucho mejor a la esperada. Sin embargo para el evento mínimo la simulación no fue lo suficientemente buena. Teniendo en cuenta que estas redes neuronales fueron entrenadas con el mismo conjunto con el que fueron entrenadas las redes ANNPC1 y ANNPC6, podría suponerse que los algoritmos de propagación resiliente requerirían en principio una menor cantidad de datos de entrenamiento para obtener un desempeño aceptable.

5.1.6.1.3 ANNPC17 y ANNPC21 variación de puntos de ingreso y cobertura

El resultado de las redes ANNPC17 y ANNPC21, similar a lo obtenido para las redes ANNPC1 y ANNPC6, muestra el desarrollo de múltiples picos para el evento máximo. Para este caso las dos redes fueron entrenadas con el método de la secante paso a paso, y con el mismo número de neuronas (5) pero distribuidas de manera diferente (Tabla 5-12), sin embargo la diferencia en la arquitectura para

estos dos casos no parece representar un cambio significativo en los resultados generados por las redes neuronales artificiales.



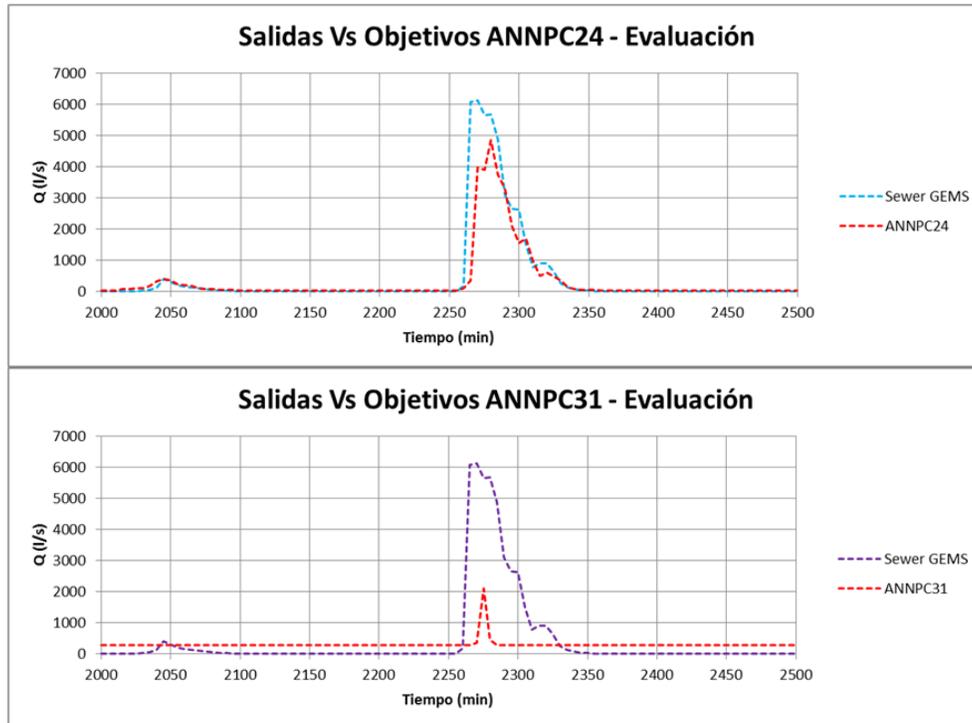
Gráfica 5.60 Resultados de evaluación ANNPC17 y ANNPC21 frente a cambios en puntos de ingreso y cobertura.

En la simulación de los dos eventos de evaluación las dos ANN tuvieron un pobre desempeño; una vez más el bajo desempeño de las redes neuronales puede deberse a un pobre proceso de entrenamiento. Debido a que los datos de entrada han sido progresivamente diversificados respecto a los evaluados en el Numeral 5.1.4, posiblemente diez eventos para el entrenamiento no sea una cantidad suficiente para representar la diferentes combinaciones de características de las lluvias registradas en la Tabla 5-17 Características generales de los eventos de lluvia con cambios en la cobertura.

5.1.6.1.4 ANNPC24 y ANNPC31 variación de puntos de ingreso y cobertura

Finalmente para las ANN ANNPC24 y ANNPC31 los resultados obtenidos tampoco son satisfactorios. En primer lugar la red ANNPC24 entrenada con el método de la secante paso a paso, al igual que las dos redes anteriores, pero con

un total de veinte neuronas separadas equitativamente en dos capas ocultas, generó hidrogramas apenas parecidos a los esperados. Sin embargo un hecho que llama la atención es que comparando los resultados de las redes ANNPC17, ANNPC21 y ANNPC24 parece haber una tendencia a suprimir la generación de picos múltiples en un mismo evento cuanto mayor sea el número de neuronas.



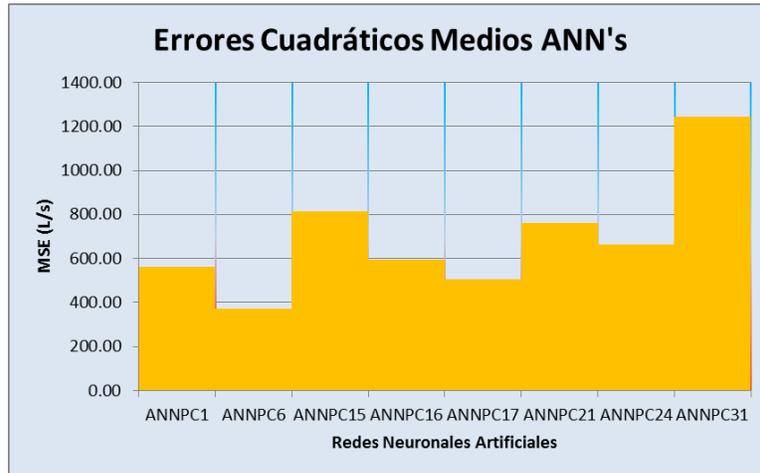
Gráfica 5.61 Resultados de evaluación ANNPC24 y ANNPC31 frente a cambios en puntos de ingreso y cobertura.

Por otra parte la red ANNPC31, única red de estudio entrenada con el algoritmo de descenso por gradiente con tasa de aprendizaje adaptativa, presentó resultados completamente atípicos, comparables únicamente con los obtenidos con la red ANNPC29 en la evaluación inicial del estudio previo a las modificaciones hidrológicas, (Gráfica 5.37).

5.1.6.1.5 Análisis de resultados

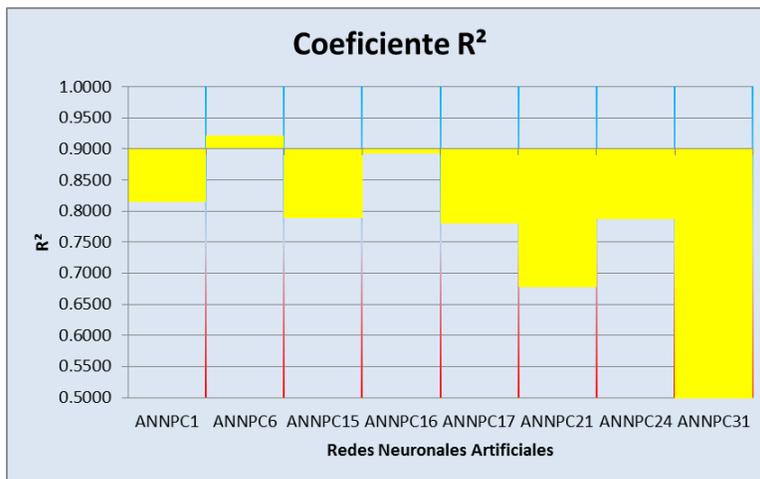
Determinando los valores del MSE y el coeficiente R^2 para determinar cuantitativamente el desempeño de las ANN frente a fenómenos de lluvia diversos y de características variables temporal y espacialmente se encontró que las redes

neuronales tuvieron por lo general un muy bajo desempeño. En la Gráfica 5.62 es posible evidenciar como todas las redes tienen errores cuadráticos medios muy elevados.



Gráfica 5.62 Errores cuadráticos medios de las ANN con cambio en puntos de ingreso y cobertura.

Por otra parte, el coeficiente R^2 registra que de las ocho ANN estudiadas, solo la red ANNPC16 superó la frontera del 0.9, hecho que concuerda con lo observado en el numeral 5.1.6.1.2.



Gráfica 5.63 Coeficientes R^2 de las ANN con cambio en puntos de ingreso y cobertura.

Debido a que el desempeño de todas las redes se vio tan negativamente afectado, la hipótesis sobre que el conjunto de entrenamiento fue insuficiente para obtener buenos resultados, tiene sustento. Por tal motivo como parte de esta etapa de

estudio se explorará la posibilidad de obtener mejores resultados ampliando el conjunto de datos de entrenamiento, para confirmar así que un mayor espacio de entrenamiento compensa la variabilidad de las características de cada evento de lluvia.

En el Numeral 5.1.5.2 se estudiaron los efectos de la adaptación en redes con un buen desempeño inicial pero que frente a variaciones propias del fenómeno requirieron una actualización. En este caso, debido a que el desempeño de las redes es en principio deficiente, la adaptación es desvirtuada, por lo que para esta etapa del estudio se evaluará el efecto de un reentrenamiento completo de las arquitecturas.

5.1.6.2 Reentrenamiento con veinte eventos de tormenta

Para realizar un reentrenamiento de las redes neuronales se optó por generar veinte eventos de tormenta con las características definidas en la Tabla 5-17. De esta manera las redes neuronales tendrán un espacio de entrenamiento más amplio con el que se espera obtener mejores resultados, y tener así una sensibilidad del desempeño de las ANN frente a la cantidad de datos de entrenamiento.

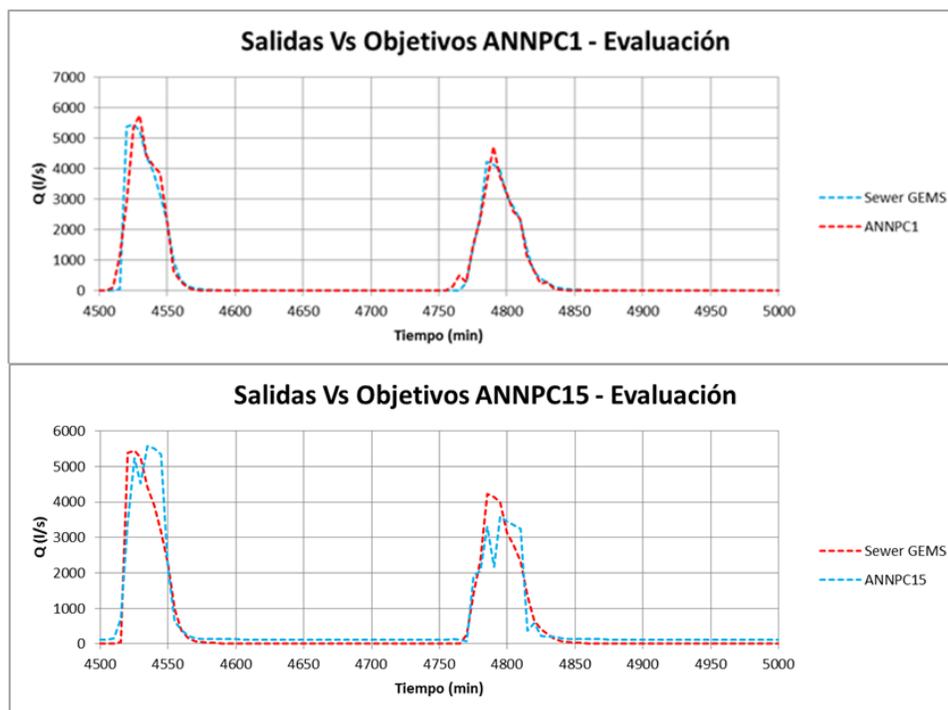
Una vez más para simular diferentes escenarios dentro del área de estudio los veinte eventos de tormenta fueron subdivididos según su cobertura sobre la red. Así finalmente se obtendría la siguiente distribución:

- 5 eventos de lluvia tendrán una cobertura sobre el 100% del área de estudio.
- 5 eventos de lluvia cubrirán sólo el 75% del área de estudio, dejando el 25% sobrante seco.
- 5 eventos de lluvia caerán sobre el 50% del área de estudio (25 pozos).
- 5 eventos de lluvia se concentraran en el 25% del área de estudio.

Para ilustrar los resultados generales de la nueva evaluación a continuación se presentaran los resultados gráficos de las redes ANNPC1, ANNPC15, ANNPC17 y ANNPC24. Los resultados de las demás ANN se obvian por considerarse semejantes a los a continuación expuestos.

5.1.6.2.1 ANNPC1 y ANNPC15 con re entrenamiento de 20 eventos

Pese a que los caudales de evaluación difieren respecto a los usados en el Numeral 1.1.7, en la Gráfica 5.64 podemos observar que las redes ANNPC1 y ANNPC15 efectivamente tuvieron una mejoría en la simulación de los caudales. La generalización de las gráficas de resultado en comparación con las esperadas es mucho mejor, aunque aún se presentan algunas insuficiencias en la ANNPC15.



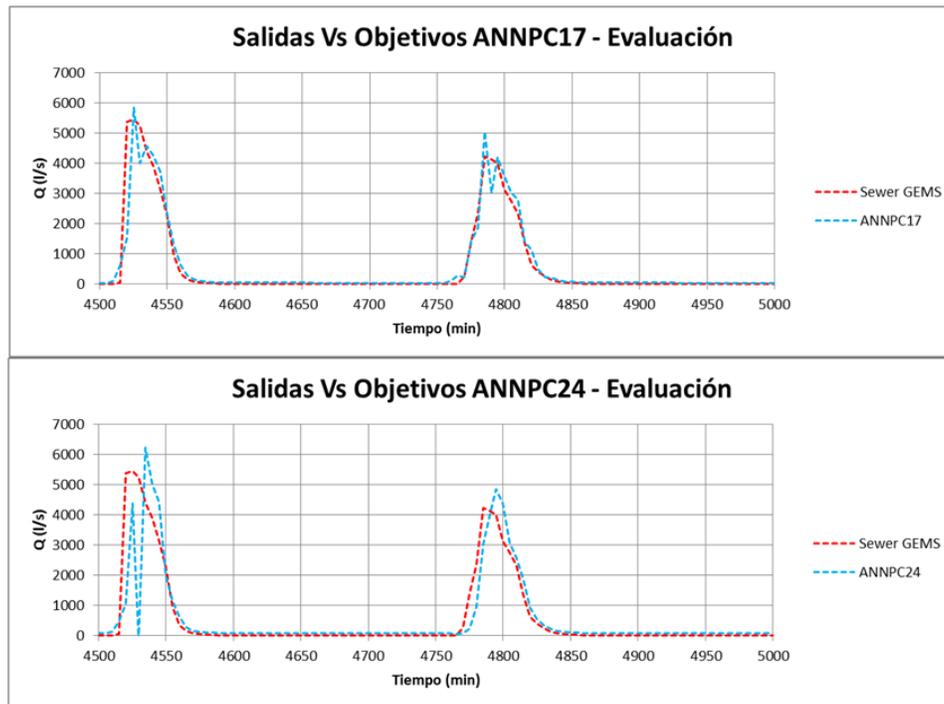
Gráfica 5.64 Resultados de evaluación ANNPC1 y ANNPC15 con re entrenamiento de 20 eventos.

Sin embargo el desempeño no parece ser del todo óptimo; las falencias en el desempeño pueden deberse nuevamente a insuficiencias en el proceso de entrenamiento, bien sea por un fenómeno de sobre entrenamiento o por falta de un espectro de caudales más amplio con el que la red pueda aprender a diferenciar mejor las características propias de cada serie de caudales.

5.1.6.2.2 ANNPC17 y ANNPC24 con re entrenamiento de 20 eventos

Comparativamente con los resultados obtenidos en las anteriores ANN, las redes ANNPC17 y ANNPC24 generaron hidrogramas de salida con una mejora notable.

Aunque aún persiste presencia de picos múltiples la tendencia a la mejora en su desempeño respecto al número de datos de entrenamiento es indudable.



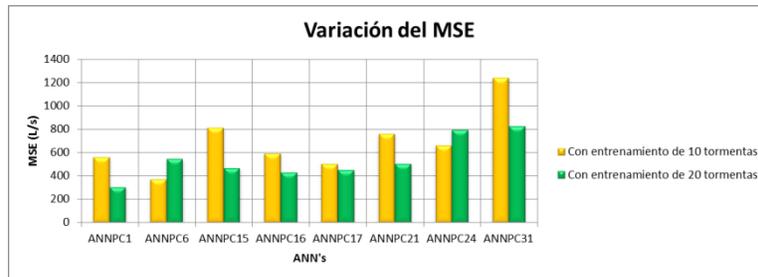
Gráfica 5.65 Resultados de evaluación ANNPC17 y ANNPC24 con re entrenamiento de 20 eventos.

En la Gráfica 5.65 se puede observar sin embargo que la ANNPC17 fue la red cuyo rendimiento se vio mejorado en mayor magnitud. Mientras que los resultados de la ANNPC24 registraron un valor atípico en el primer evento de tormentas.

5.1.6.2.3 Comparación de resultados

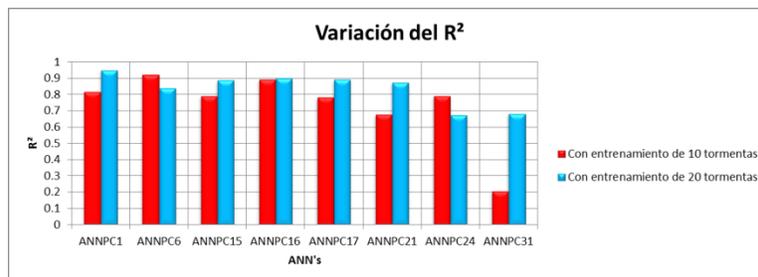
Aunque los eventos de evaluación no fueron los mismos para los entrenamientos de diez y veinte eventos el desempeño se compara en función del MSE, el R^2 y la variación porcentual del caudal pico respecto al esperado.

A continuación se presentan los resultados obtenidos para las ocho ANN comparativamente entre la evaluación inicial y la evaluación realizada posterior al proceso de reentrenamiento.



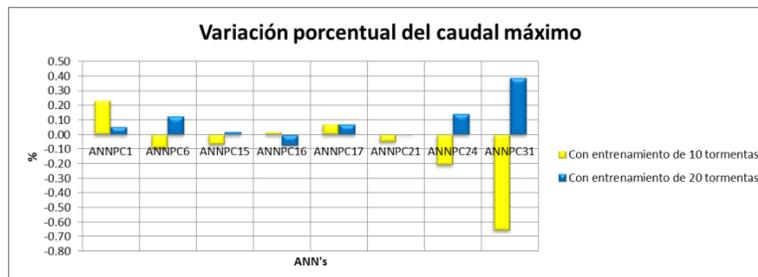
Gráfica 5.66 Variación del MSE entre entrenamientos.

En la Gráfica 5.66 se observa como un incremento en el espacio de entrenamiento de las redes neuronales tuvo un efecto positivo en seis de las ocho ANN's estudiadas. Pese a que gráficamente los resultados no son totalmente satisfactorios, si es evidente que la solución al problema de generalización se encuentra en el número de parejas utilizadas para el entrenamiento.



Gráfica 5.67 Variación del R² entre entrenamientos.

Comparativamente el valor del coeficiente R² también se vio positivamente afectado en seis de las ocho ANN's estudiadas; sin embargo estas no concuerdan con las seis redes que vieron mejorado su valor de MSE con el re entrenamiento.



Gráfica 5.68 Variación de la diferencia porcentual del caudal máximo.

Finalmente, respecto a la diferencia porcentual entre el valor simulado y el esperado, se encuentra que los resultados son similares, en seis de los ocho

casos la diferencia porcentual se vio reducida. Y en los dos casos donde hubo un incremento en la diferencia porcentual por el exceso o por el defecto, sólo uno se salió del rango del 10 % (ANNPC6).

En la Tabla 5-18 se relacionan los datos para cada una de las ocho ANN's evaluadas.

Tabla 5-18 Variación en el desempeño de las ANN respecto al número de eventos para entrenamiento.

	MSE (L/s)			R ²			Dif. Q Pico (%)	
	10	20		10	20		10	20
ANNPC1	562.18	307.65	ANNPC1	0.8151	0.9488	ANNPC1	23	6
ANNPC6	372.55	544.75	ANNPC6	0.9212	0.8395	ANNPC6	-9	13
ANNPC15	813.27	469.72	ANNPC15	0.7885	0.8863	ANNPC15	7	2
ANNPC16	594.54	431.85	ANNPC16	0.8927	0.9003	ANNPC16	2	-7
ANNPC17	505.86	453.15	ANNPC17	0.7801	0.8891	ANNPC17	7	7
ANNPC21	762.08	505.21	ANNPC21	0.6774	0.8714	ANNPC21	-5	0
ANNPC24	664.61	795.15	ANNPC24	0.7881	0.6725	ANNPC24	-1	5
ANNPC31	1242.36	828.73	ANNPC31	0.2052	0.6789	ANNPC31	-5	9

5.3 DESCRIPCIÓN DEL CASO DE ESTUDIO NICOLÁS DE FEDERMÁN

Con el fin de evaluar en un segundo caso de estudio las ANN, se escogió la red de drenaje pluvial del barrio Nicolás de Federmán. La red forma parte del sistema de drenaje de la subcuenca del CAN, la cual se localiza en el centro de la ciudad, aguas debajo de la cuenca del río Arzobispo.

En la Figura 5.21 se ilustra en planta la zona de estudio seleccionada. Los nudos amarillos representan los sumideros en la zona y los nudos rojos los pozos de la red de drenaje.

La red de drenaje de estudio cuenta con un total de 7 tramos de red troncal con una sección tipo box culvert, y 45 tramos de red local. Posee 51 pozos en total de los cuales a 23 se les asignarán caudales pluviales.



Figura 5.21 Red local y troncal objeto de estudio (Nicolás de Federmán).

De manera análoga con el proceso desarrollado para el caso Pequeño Chicó se definieron 20 eventos de tormenta con las características descritas en la Tabla 5-17.

5.1.7 MODELACIÓN HIDRAULICA DE LA RED

Al igual que en el caso de Pequeño Chicó, la modelación numérica de los caudales permitió determinar que para las variaciones múltiples de los eventos de tormenta, una duración total de eventos de 250 minutos es suficiente para que los vanos de finalización correspondientes, garanticen una independencia en los eventos.

5.1.8 REZAGO EN EL TRÁNSITO A TRAVÉS DE LA RED

Posteriormente al proceso de simulación y siguiendo la misma metodología planteada en el Numeral 5.2 para el caso de estudio anterior, se determinan los rezagos en el tránsito a través de la red, obteniendo que el valor óptimo para la serie de tiempo exógena es $dx = 2$ y para la serie de tiempo endógena, o propia, de $dy = 1$.

5.1.9 CONSTRUCCIÓN DE LAS REDES NEURONALES ARTIFICIALES (ANNFED)

A diferencia del proceso seguido en el modelo anterior, en esta etapa de estudio serán ocho las redes neuronales a construir y evaluar. La arquitectura propia de dichas redes será la misma de aquellas redes neuronales cuyo desempeño resultó aceptable para el caso de estudio anterior (Véase Numeral 5.1.4.5.6).

Con el fin de facilitar la comparación directa al lector de los resultados entre los dos casos de estudio, las ANN's construidas tendrán el mismo código numérico que sus homólogas del caso Pequeño Chicó.

En la Tabla 5-19 se registran las ocho redes neuronales construidas para el segundo caso de estudio así como sus respectivas arquitecturas. La construcción de las arquitecturas se realizó siguiendo la metodología planteada en el Numeral 5.1.3.4.

Tabla 5-19 Redes neuronales artificiales - Case de estudio 2.

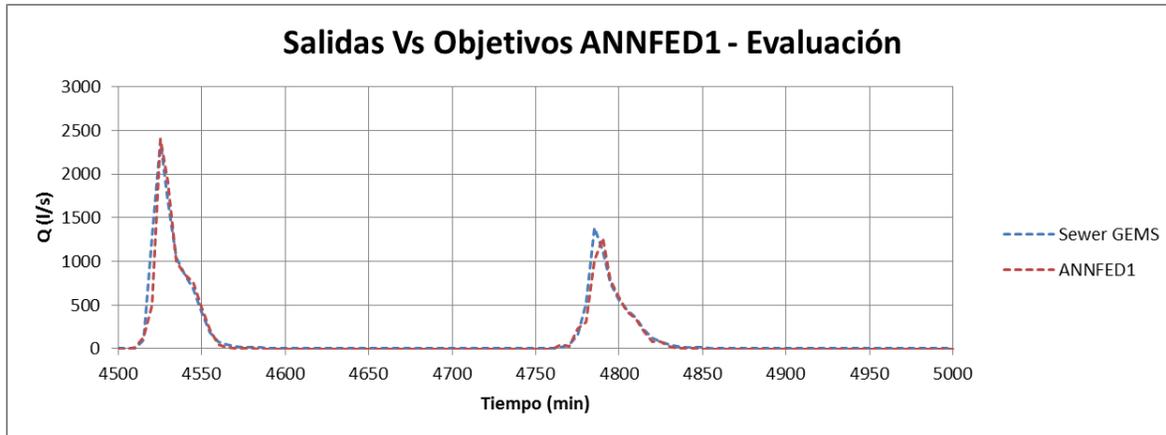
ANN Nicolás de Federmán			
Training Function		Hidden Layers	Nodes
ANNFED1	TRAINLM	1	5
ANNFED6	TRAINLM	2	5,5
ANNFED15	TRAINRP	2	10,5
ANNFED16	TRAINRP	2	10,10
ANNFED17	TRAIPOSS	1	5
ANNFED21	TRAIPOSS	2	2,3
ANNFED24	TRAIPOSS	2	10,10
ANNFED31	TRAINGDA	2	10,5

5.1.10 RESULTADOS INICIALES ANNFED

Con el fin de poder realizar una comparación cuantitativa sobre el desempeño de las ANN entre sí, y el respectivo desempeño de las mismas arquitecturas en comparación con el primer caso de estudio, se definió el mismo conjunto de medidas de ajuste e indicadores, descritas en el Numeral 5.1.4, que permiten realizar una comparación directa de los resultados obtenidos.

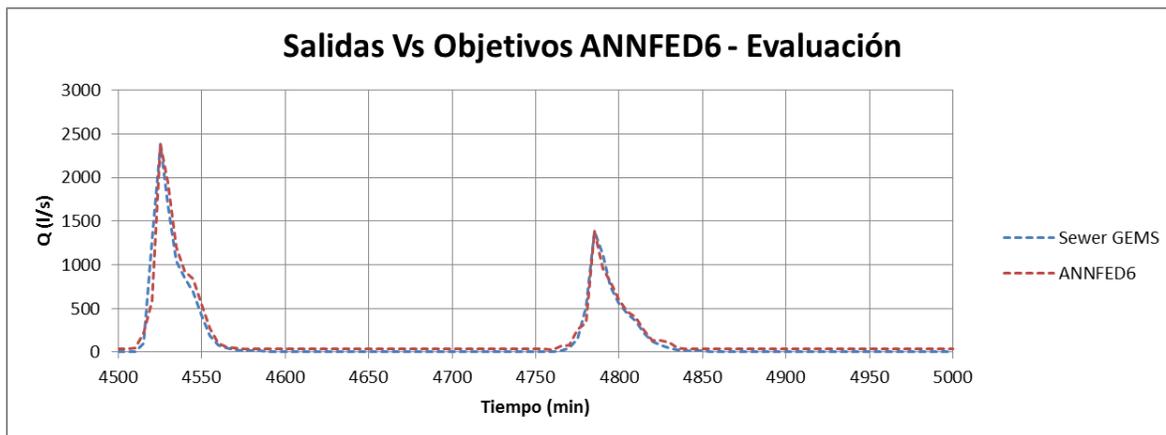
5.1.10.1 Redes ANNFED entrenadas con TRAINLM

De manera similar a su análoga ANNPC1, la ANNFED1 registra un buen desempeño en la evaluación, simulando dos eventos de lluvia con buena generalización. La ANNFED1 se confirma como una red neuronal artificial con resultados consistentes en las evaluaciones iniciales de la red.



Gráfica 5.69 Hidrogramas predichos por la red neuronal ANNFED1 Vs Modelados en Sewer GEMS.

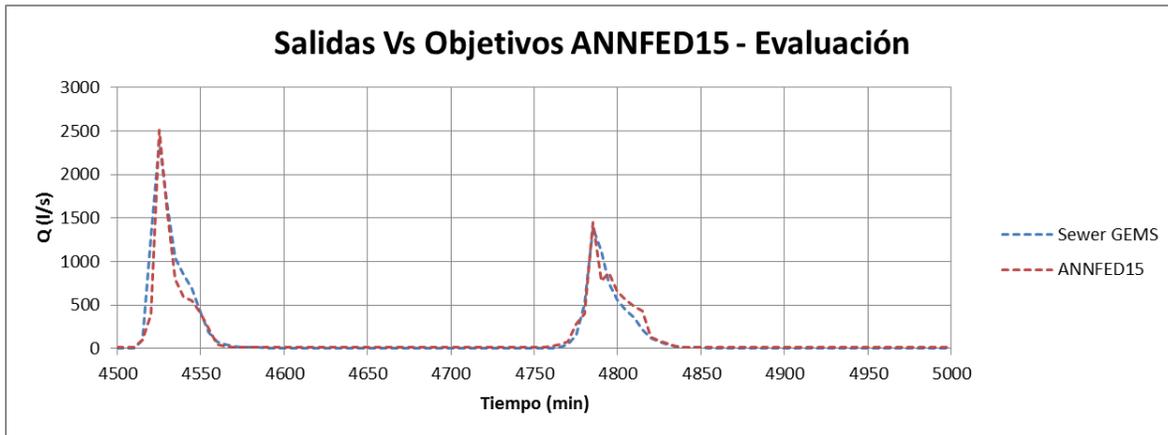
Un caso similar ocurre con la ANNFED6, siendo una red entrenada con el mismo algoritmo que la ANNFED1. La red muestra un muy buen desempeño en cuanto a generalización y simulación de caudales picos. Al igual que la red neuronal anterior, la arquitectura de 10 neuronas distribuidas equitativamente en 2 capas ocultas se constituye como un candidato consistente en los resultados preliminares de evaluación.



Gráfica 5.70 Hidrogramas predichos por la red neuronal ANNFED1 Vs Modelados en Sewer GEMS.

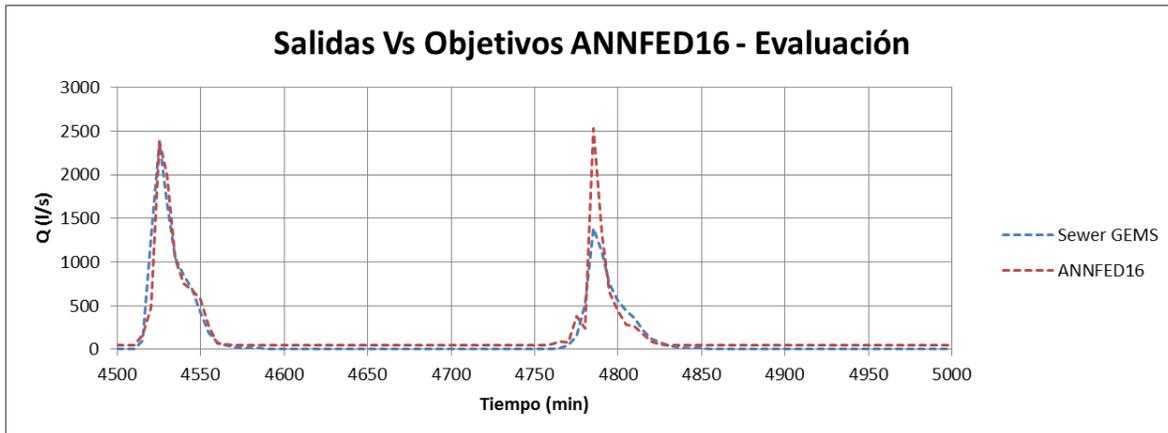
5.1.10.2 Redes ANNFED entrenadas con TRAINRP

El resultado obtenido por la ANNFED15 pese a no ser tan sobresaliente como los de las redes entrenadas con el algoritmo de Levenberg – Marquardt, si son ejemplo de un desempeño aceptable. Aunque no reproduce con suficiencia la geometría general del evento, visualmente si se aproxima a lo esperado en cuanto a duración y caudales máximos. (Comparar con la Gráfica 5.23).



Gráfica 5.71 Hidrogramas predichos por la red neuronal ANNFED15 Vs Modelados en Sewer GEMS.

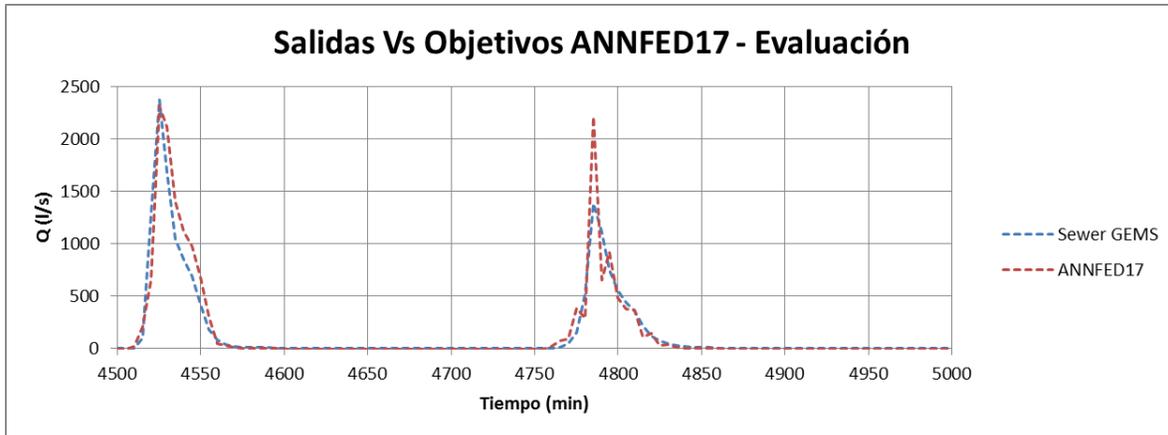
Para el caso de la ANNFED16 se encuentra que el buen desempeño se restringe a tan solo uno de los dos eventos de evaluación. Pese a que la simulación del primer evento es satisfactoria, para el segundo - cuyo caudal pico es menor que el primero – la simulación genera una sobreestimación del caudal máximo.



Gráfica 5.72 Hidrogramas predichos por la red neuronal ANNFED16 Vs Modelados en Sewer GEMS.

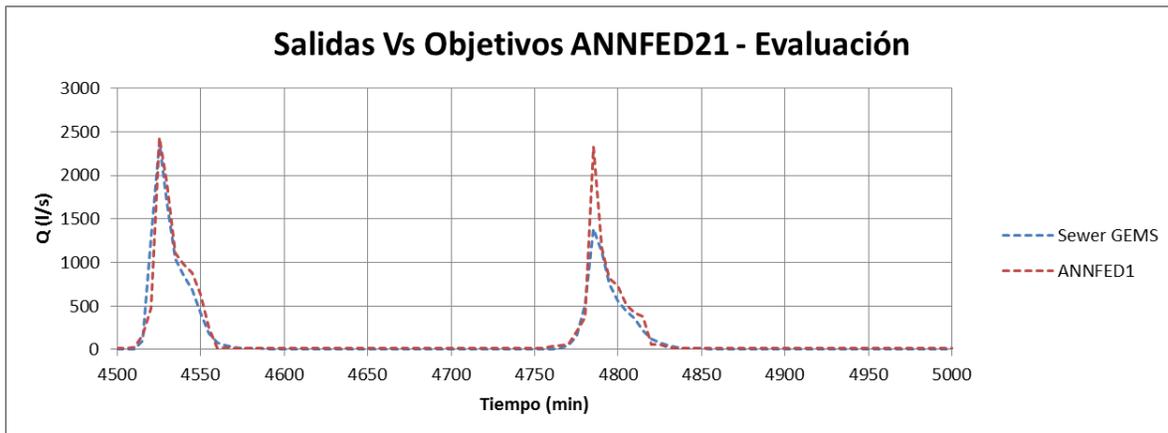
5.1.10.3 Redes ANNFED entrenadas con TRAINOSS

En discordancia con los resultados obtenidos por su homóloga, la ANNFED17 presenta problemas en la simulación. Aunque reproduce con limitada exactitud el hidrograma para el primer evento, falla en la simulación del segundo, generando incluso múltiples picos de caudal para el evento.



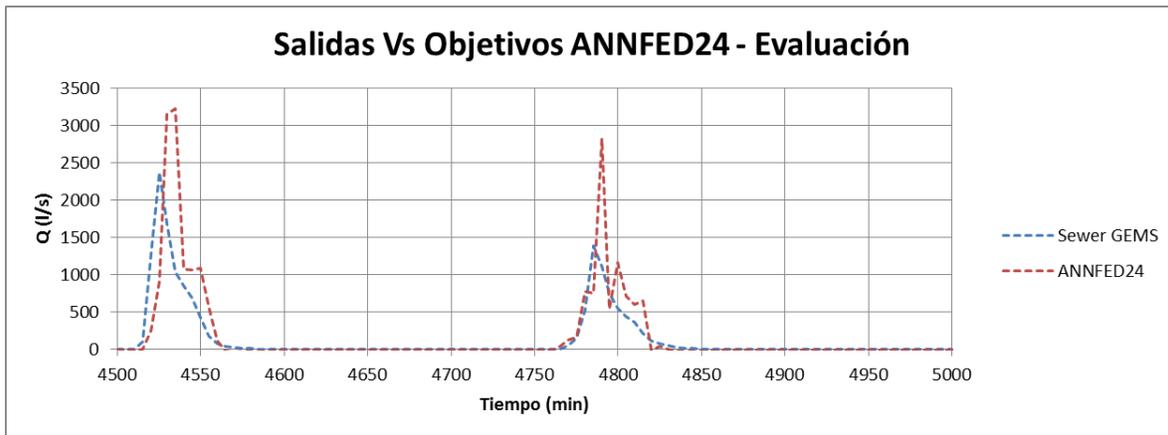
Gráfica 5.73 Hidrogramas predichos por la red neuronal ANNFED17 Vs Modelados en Sewer GEMS.

Caso similar se presenta en los resultados de la ANNFED21, siendo arquitecturas con el mismo número de neuronas, pero con configuraciones diferentes, el resultado es parecido. La simulación del primer evento parece idéntica, mientras que en el segundo la ANNFED21 mejora la generalización suprimiendo los picos múltiples.



Gráfica 5.74 Hidrogramas predichos por la red neuronal ANNFED21 Vs Modelados en Sewer GEMS.

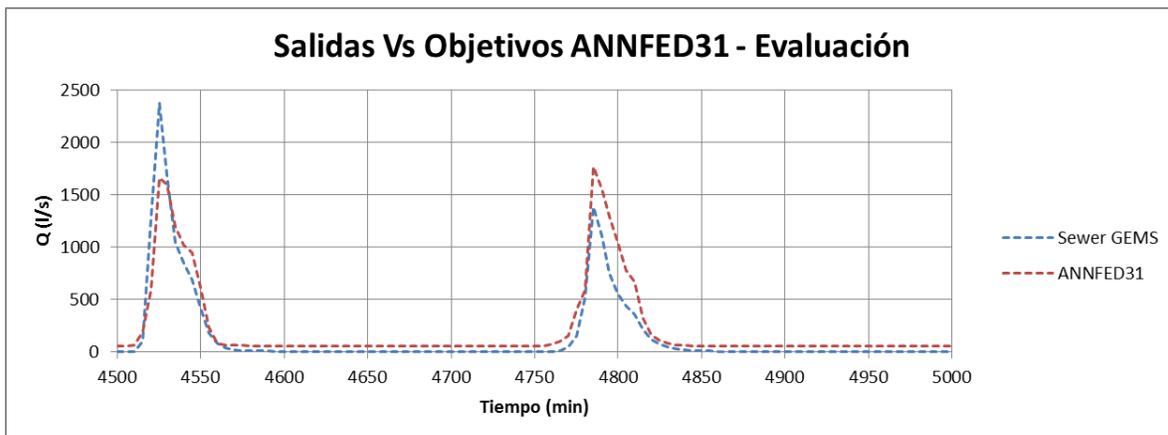
Contrario a los resultados obtenidos para esta arquitectura en el anterior caso de estudio, la ANNED24 fue la red que peor desempeño tuvo a la hora de simular los dos eventos de evaluación inicial. Entrenada con el mismo algoritmo que las redes ANNED17 y ANNED21, la mayor cantidad de neuronas en esta arquitectura parece no haber tenido efecto positivo alguno en el desempeño de la red.



Gráfica 5.75 Hidrogramas predichos por la red neuronal ANNED24 Vs Modelados en Sewer GEMS.

5.1.10.4 Redes ANNED entrenadas con TRAINGDA

Finalmente, los resultados de las ANNED31, entrenada con el método del descenso por gradiente con tasa de aprendizaje adaptativa, confirmarían que la red ANNED31 no es una arquitectura confiable debido a su bajo desempeño generalizado en las múltiples evaluaciones realizadas.



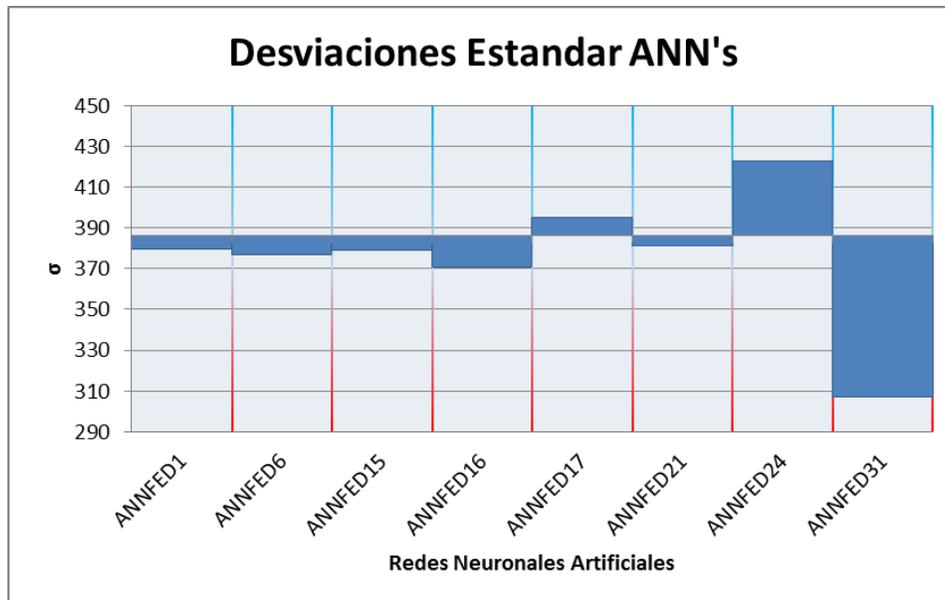
Gráfica 5.76 Hidrogramas predichos por la red neuronal ANNED31 Vs Modelados en Sewer GEMS.

5.1.10.5 Consolidación de resultados y análisis

Teniendo en cuenta los resultados expuestos en el anterior numeral, a continuación se presenta un análisis sobre el desempeño de las arquitecturas inteligentes, evaluadas con respecto a los indicadores y medidas de bondad de ajuste definidas al comienzo del Numeral 5.1.4.

5.1.10.5.1 Desviaciones estándar

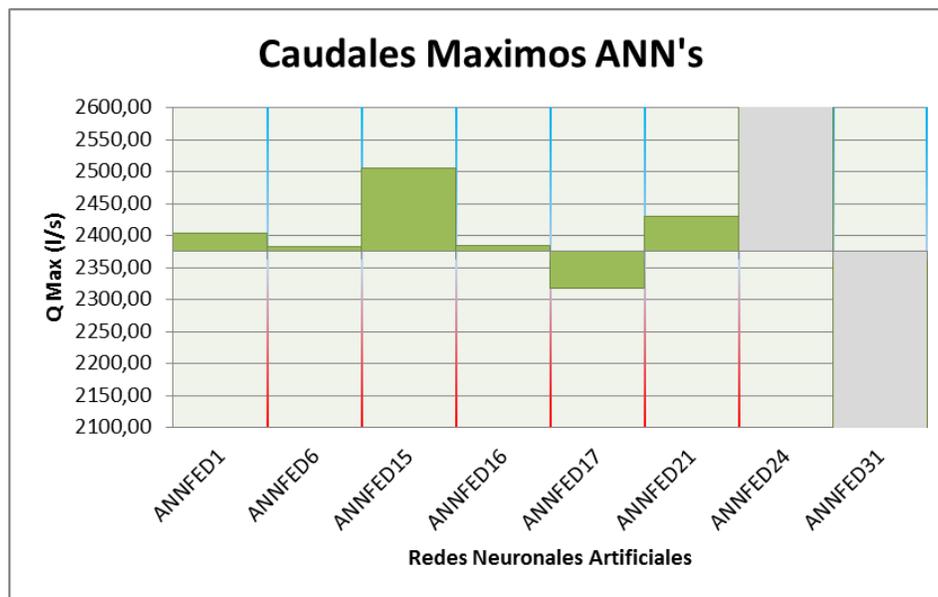
De manera análoga con el análisis realizado en el Numeral 5.1.4.5.1 a las redes del caso Pequeño Chicó se comparan las desviaciones estándar de los eventos de lluvia predichos por las redes neuronales artificiales con las modeladas en Sewer GEMS v8i. Realizando una comparación cuantitativa de la medida estadística, para la cual un valor muy distante, $|\sigma_{Sewer} - \sigma_{ANNi}| > 100$, con respecto al esperado, $\sigma_{Sewer} = 386.53$, indicará que los hidrogramas predichos poseen una configuración evidentemente distorsionada respecto a los objetivos esperados. Sin embargo como se puede apreciar en la Gráfica 5.77 ninguna red neuronal incumple el criterio.



Gráfica 5.77 Desviaciones estándar de las ANNFED construidas.

5.1.10.5.2 Caudales máximos

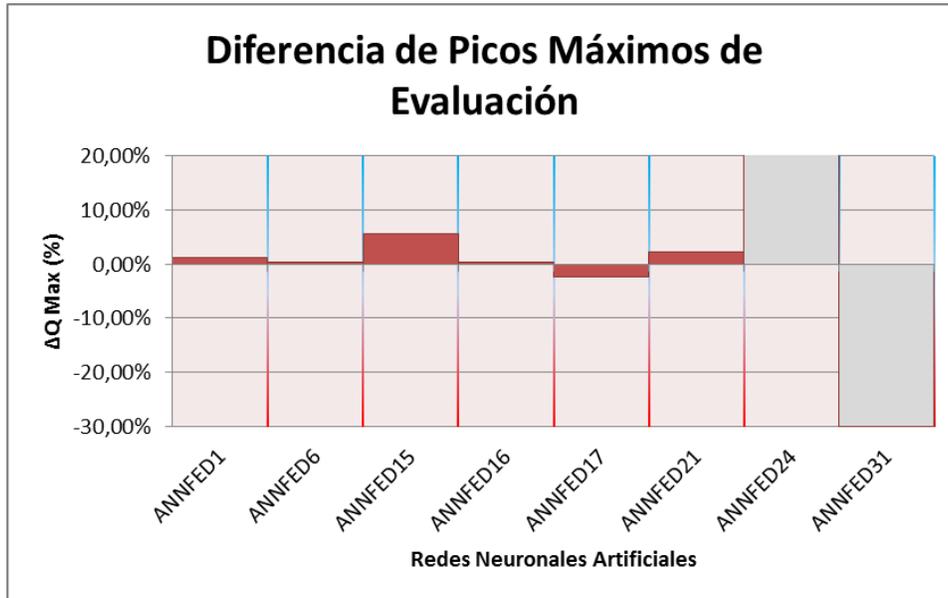
Al realizar la comparación absoluta entre el caudal simulado por la ANN y el caudal máximo esperado para el primer evento de lluvia, el cual visualmente resulta ser el más favorable, se encuentra que solo las redes ANN FED24 y ANN FED31 estiman de una manera exagerada el caudal pico. Vale la pena mencionar que no se hace la comparación para el segundo evento puesto que visualmente se considera que es más riguroso evaluar el desempeño de la red en aquel caso en el que se presenta un mejor desempeño. La invalidación de la red por casos más evidentes como el segundo evento de tormenta se realizará con un criterio más comprensivo como el MSE o coeficiente R^2 .



Gráfica 5.78 Caudales máximos predichos por las ANN FED construidas.

5.1.10.5.3 Diferencia porcentual de picos máximos

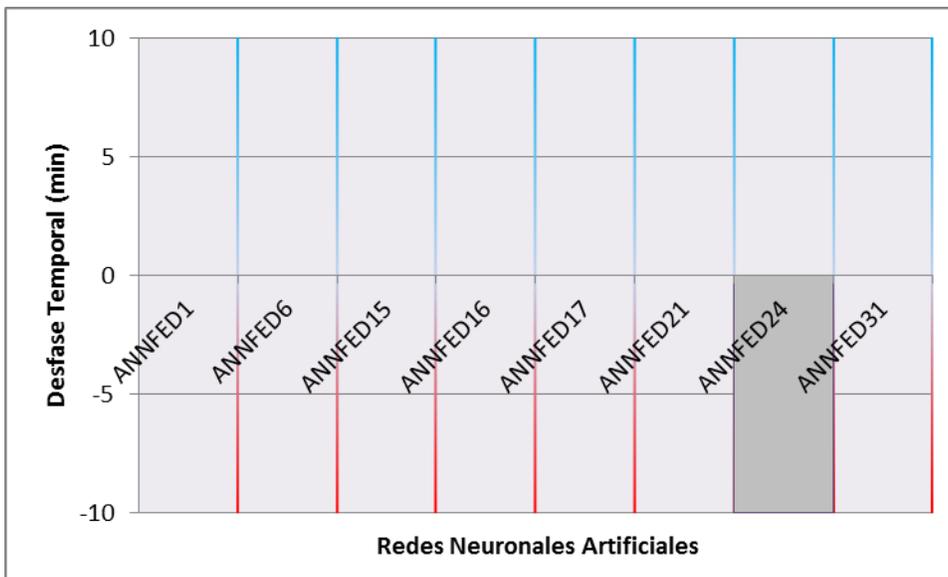
Por otra parte, realizando una comparación porcentual de los caudales pico predichos en el primer evento de lluvias, se encuentra consistentemente que las redes ANN FED24 y ANN FED31 no simulan de manera suficiente los caudales pico, superando una diferencia porcentual entre el valor observado y el esperado de más del 10%.



Gráfica 5.79 Diferencia porcentual del caudal pico máximo predicho por la ANN FED.

5.1.10.5.4 Desfase temporal del caudal pico

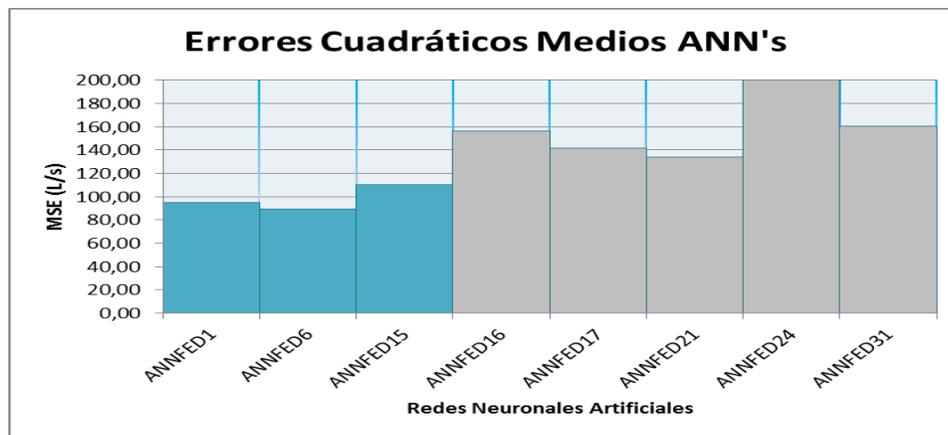
Respecto al desfase temporal en la predicción del caudal pico se encontró que la red ANNFED24 es la única que en alguno de los dos eventos de evaluación predijo el caudal máximo con un retraso de 10 minutos.



Gráfica 5.80 Desfase temporal del caudal pico máximo de evaluación ANN FED.

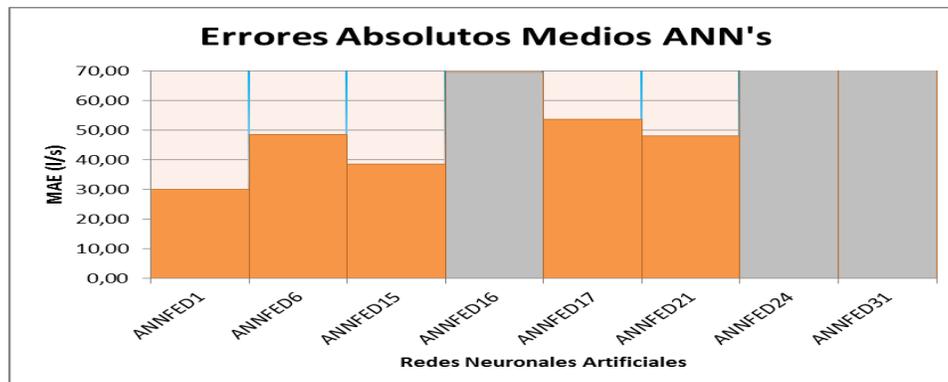
5.1.10.5.5 Error Cuadrático y Error Absoluto Medios

En la Gráfica 5.81 se puede observar el desempeño de las ANN's con respecto al MSE, como valor de corte; para este caso se seleccionó un valor de 120 L/s, descalificándose por este criterio 5 de las 8 ANN's. Además en ella se puede evidenciar como las redes ANNFED16, ANNFED17 y ANNFED24 finalmente son descalificadas por su pobre desempeño a la hora de simular el segundo evento de tormenta.



Gráfica 5.81 Error cuadrático medio de los caudales predichos por las ANNFED.

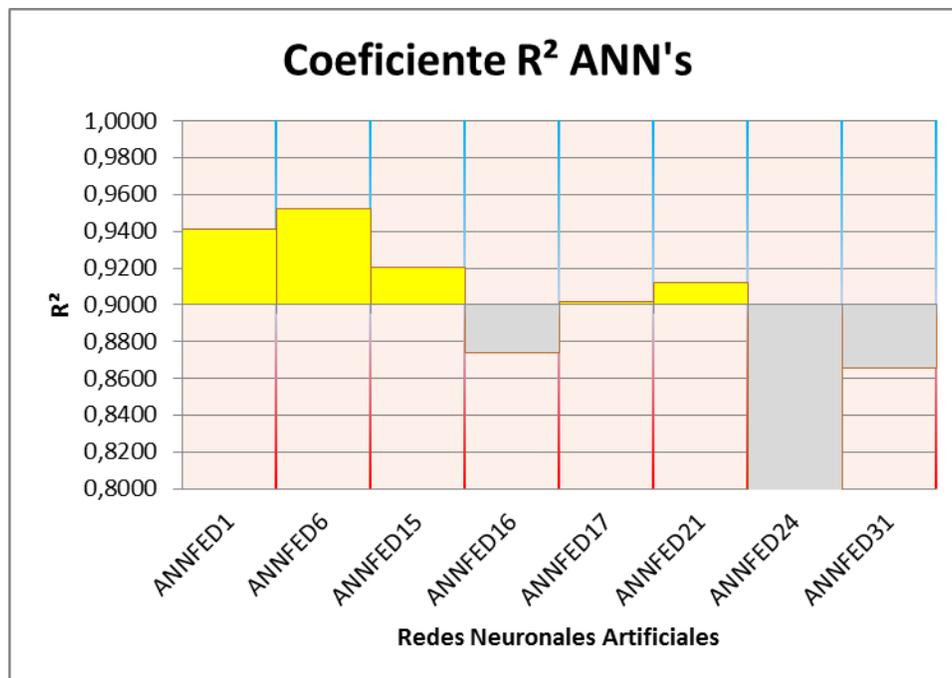
Por otra parte al realizar la comparación con los errores absolutos medios se encuentra que en concordancia con otros criterios ya expuestos las tres primeras redes continúan teniendo un buen rendimiento en todo aspecto, frente a los dos eventos de tormenta utilizados para la evaluación.



Gráfica 5.82 Error absoluto medio de los caudales predichos por las ANNFED.

5.1.10.5.6 Coeficiente R^2

Finalmente la determinación del coeficiente R^2 nos permite corroborar que las primeras 3 redes tienen el mejor desempeño sobre las demás, además ratifica a la ANN FED24 y la ANN FED31 como las redes con más bajo desempeño. Sin embargo otras redes como la ANN FED17 y la ANN FED21, pese a fallar a otros criterios, al ser evaluadas desde el coeficiente R^2 muestran un desempeño aceptable.



Gráfica 5.83 Coeficiente R^2 Objetivos Vs Salidas.

5.1.11 PREDICCIÓN DE EVENTOS

De acuerdo con el análisis previo las redes ANN FED1, ANN FED6 y ANN FED15 tuvieron un buen desempeño según los resultados de la primera evaluación. Cada una de estas redes cumplió cada uno de los criterios y medidas de evaluación. Sin embargo, vale la pena mencionar que para las redes ANN FED16, ANN FED17 y ANN FED21 pese a no cumplir con todos los criterios, estas sí registraron un buen desempeño para el primer evento de predicción, (véase Gráfica 5.72, Gráfica 5.73 y Gráfica 5.74 respectivamente). Por esta razón en esta etapa del estudio se predecirán 20 eventos de tormenta diversos con cada una de las ANN para

determinar si el buen desempeño evaluado por las redes es consistente frente a otros eventos de tormenta o si por el contrario existen limitaciones en el uso de las redes.

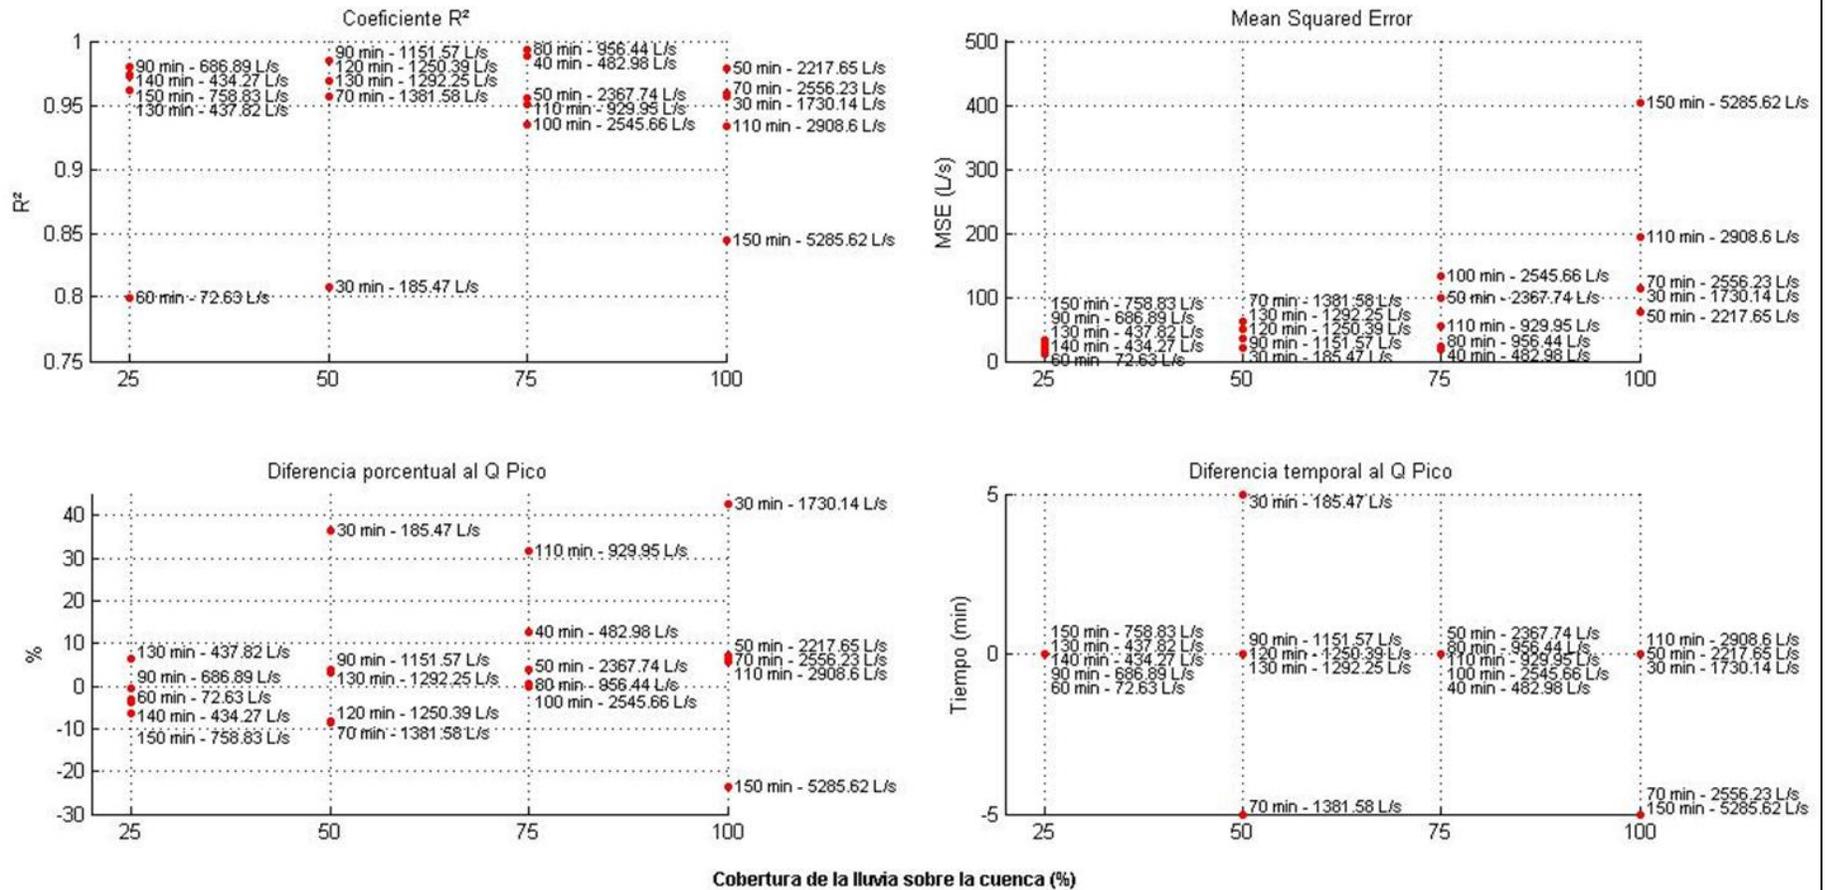
En la Tabla 5-20 se relacionan las características de los 20 eventos a predecir, el valor del caudal máximo (Q Pico) corresponde al valor máximo en el hidrograma de descarga, valor que debe ser predicho por las ANN's.

Tabla 5-20 Eventos generados para la predicción.

Evento	Duración (min)	Q.Pico (L/s)	% Cobertura
1	50	2217.65	100%
2	120	1250.39	50%
3	90	686.89	25%
4	150	5285.62	100%
5	70	2556.23	100%
6	130	1292.25	50%
7	30	185.47	50%
8	110	929.95	75%
9	60	72.63	25%
10	100	2545.66	75%
11	40	482.98	75%
12	80	956.44	75%
13	140	434.27	25%
14	130	437.82	25%
15	30	1730.14	100%
16	150	758.83	25%
17	90	1151.57	50%
18	110	2908.6	100%
19	50	2367.74	75%
20	70	1381.58	50%

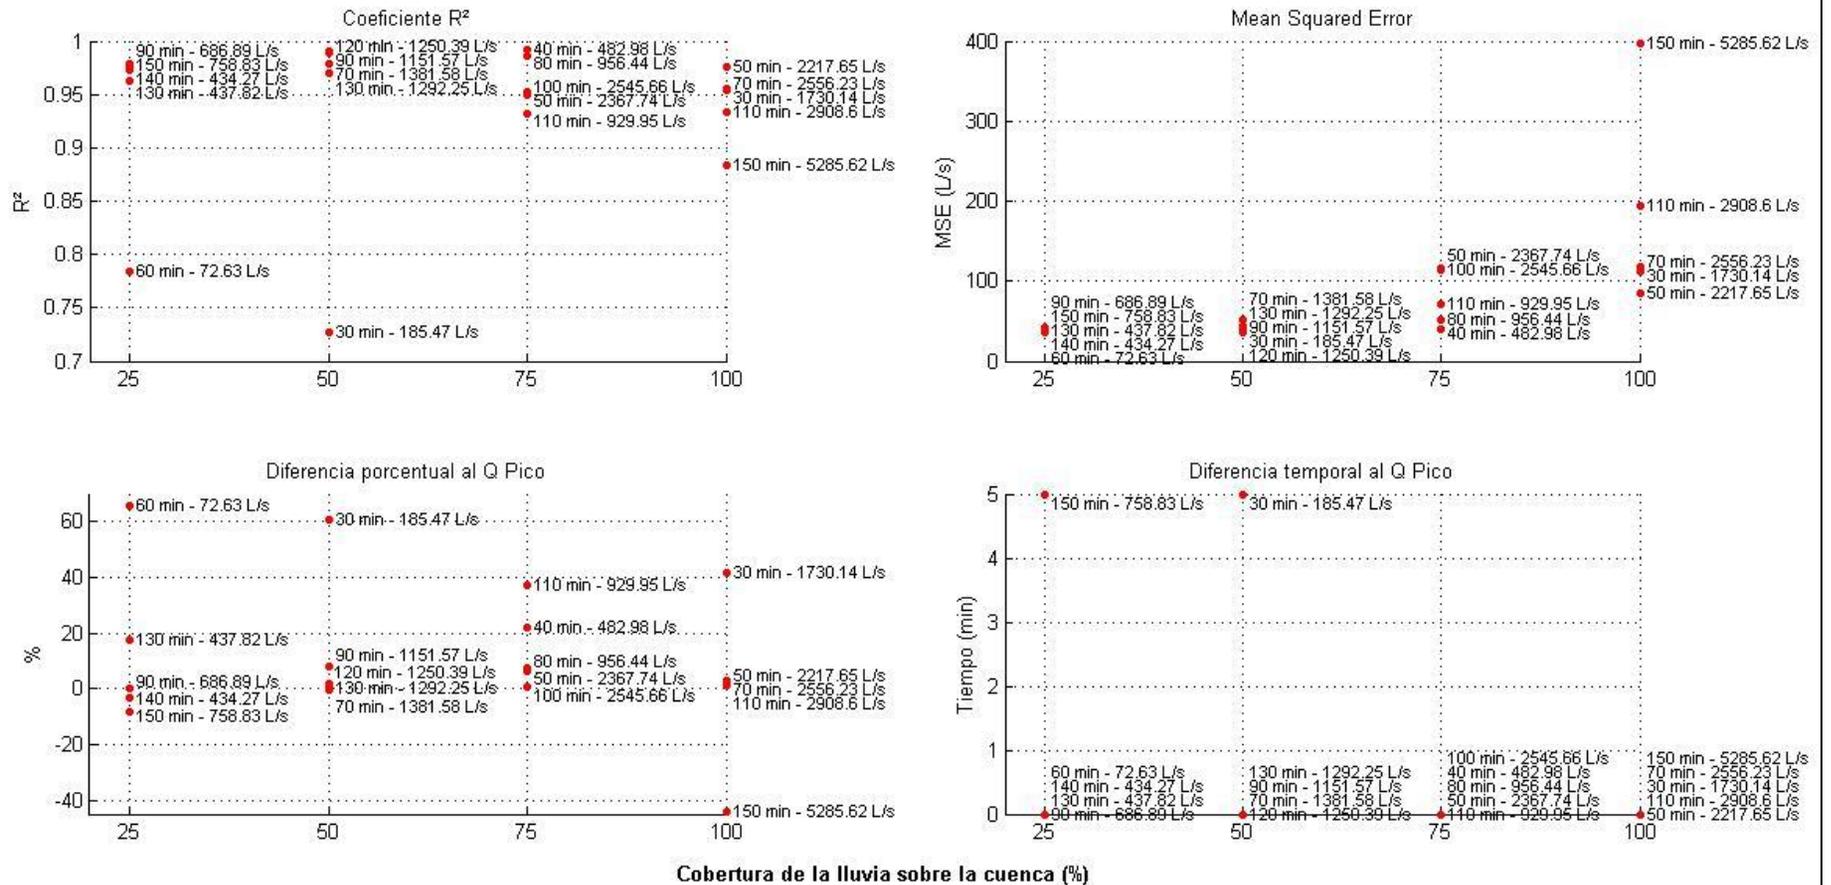
En las gráficas siguientes se encuentran los resultados para cada una de las ANN FED según los criterios que mejor representan la generalización de una red neuronal y la exactitud en la predicción de caudales máximos. Los valores del coeficiente R^2 y del MSE hablan de la generalización de la red; cuanto más altos o más bajos sean estos valores respectivamente, mejor será el ajuste de la predicción con relación al hidrograma esperado. Para el R^2 un valor mínimo de 0.9 garantiza una generalización detallada de la geometría del hidrograma, hecho sustentado con valores de MSE inferiores a 120 L/s. Sin embargo el incumplimiento de estos criterios no constituye descalificación directa, pues valores próximos al límite aun así pueden ser predicciones aceptables, por lo que el resultado de estos criterios debe complementarse con el análisis de caudales máximos. Por otra parte las diferencias porcentuales y temporales del caudal pico hablan de las condiciones hidráulicas para el evento máximo, valor de vital importancia a la hora de tratar con redes de drenaje. Una diferencia porcentual superior al 10 % se considera inadmisibles, mientras que una diferencia temporal negativa no es recomendable, puesto que esto indicaría que la red predijo la ocurrencia del caudal máximo x minutos más tarde que la ocurrencia real.

Desempeño ANN FED1



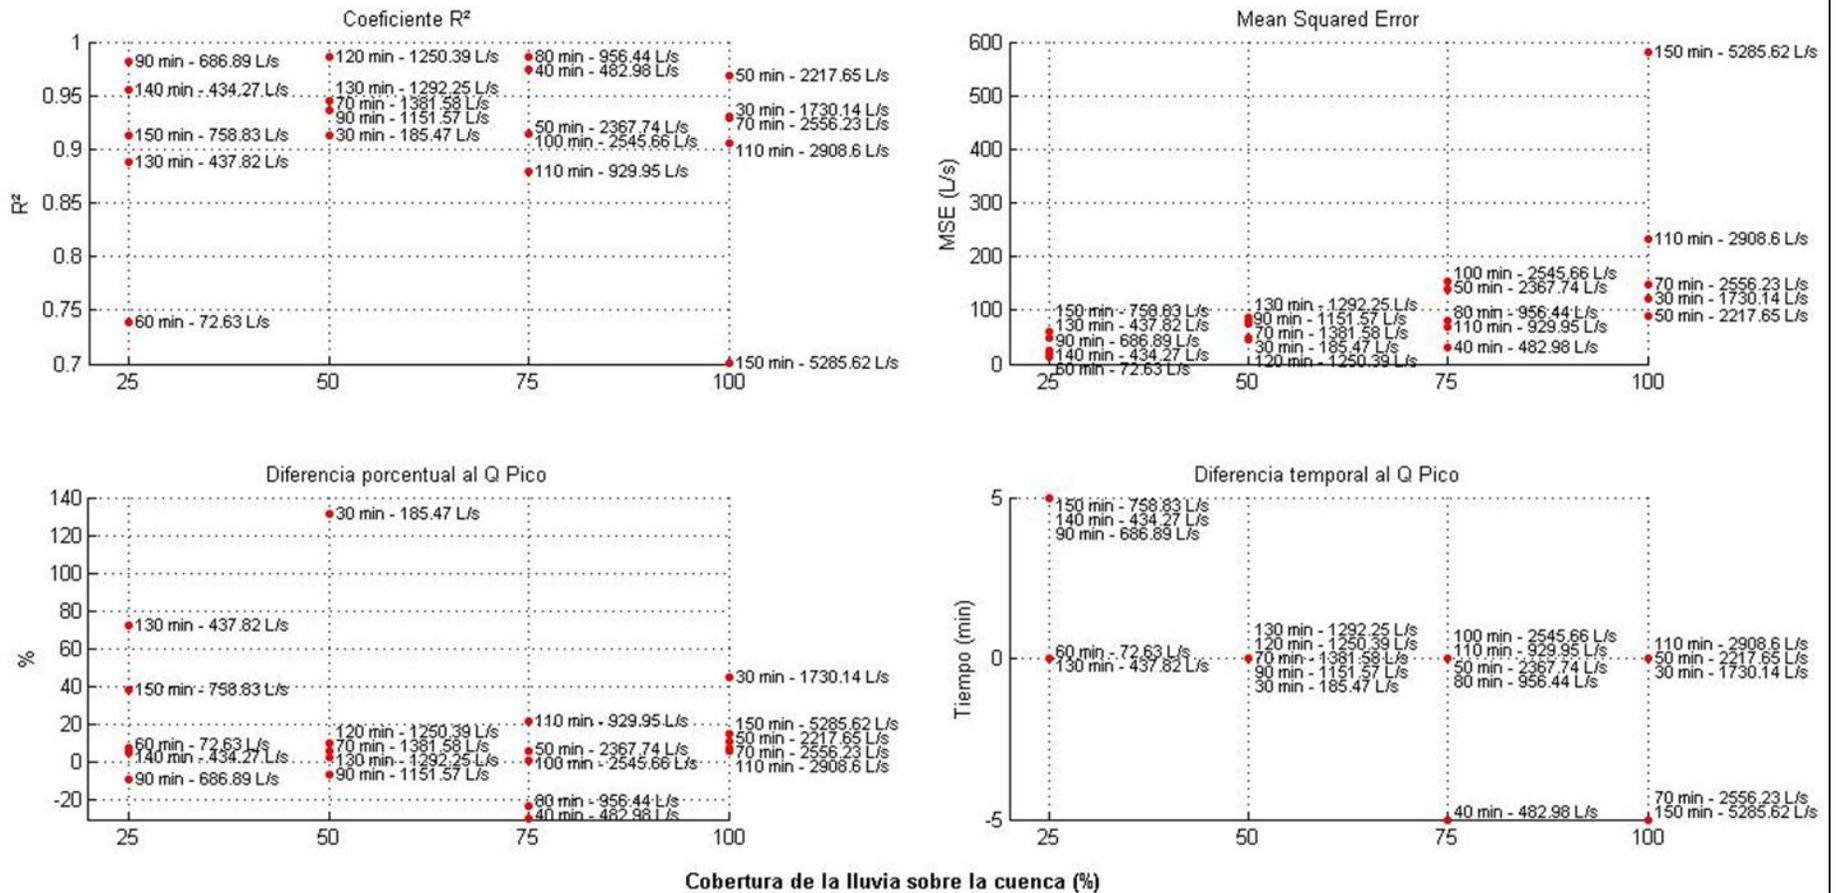
Gráfica 5.84 Resultados de predicción para la ANN FED1.

Desempeño ANN FED6



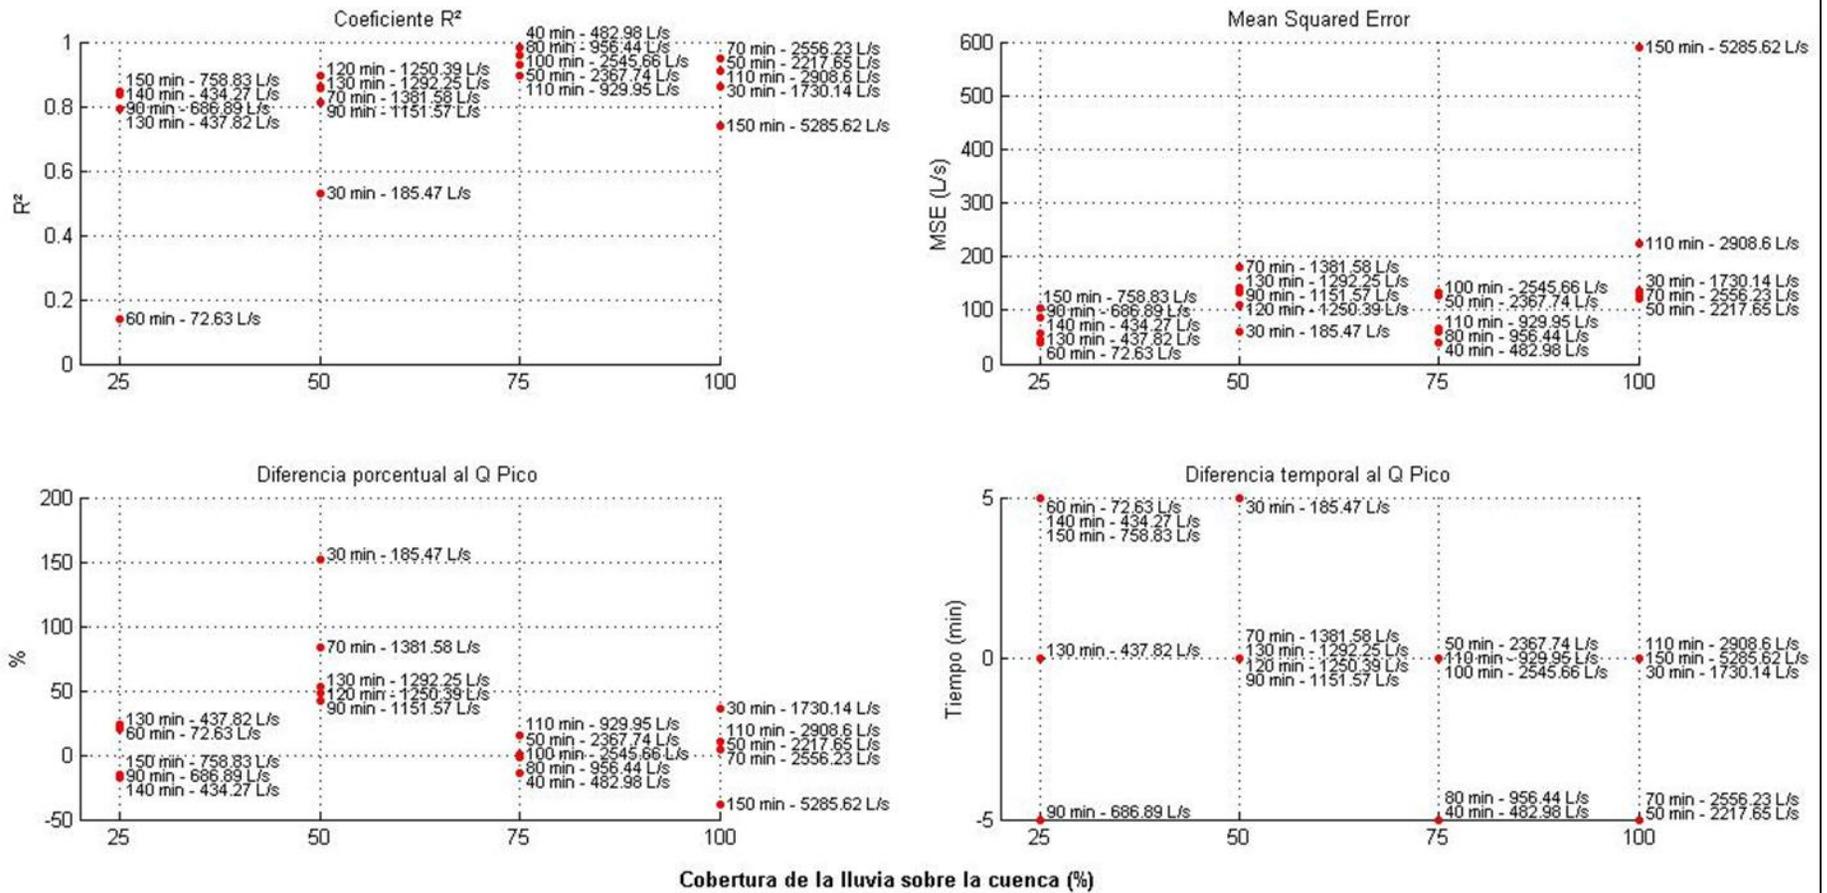
Gráfica 5.85 Resultados de predicción para la ANN FED6.

Desempeño ANNFD15



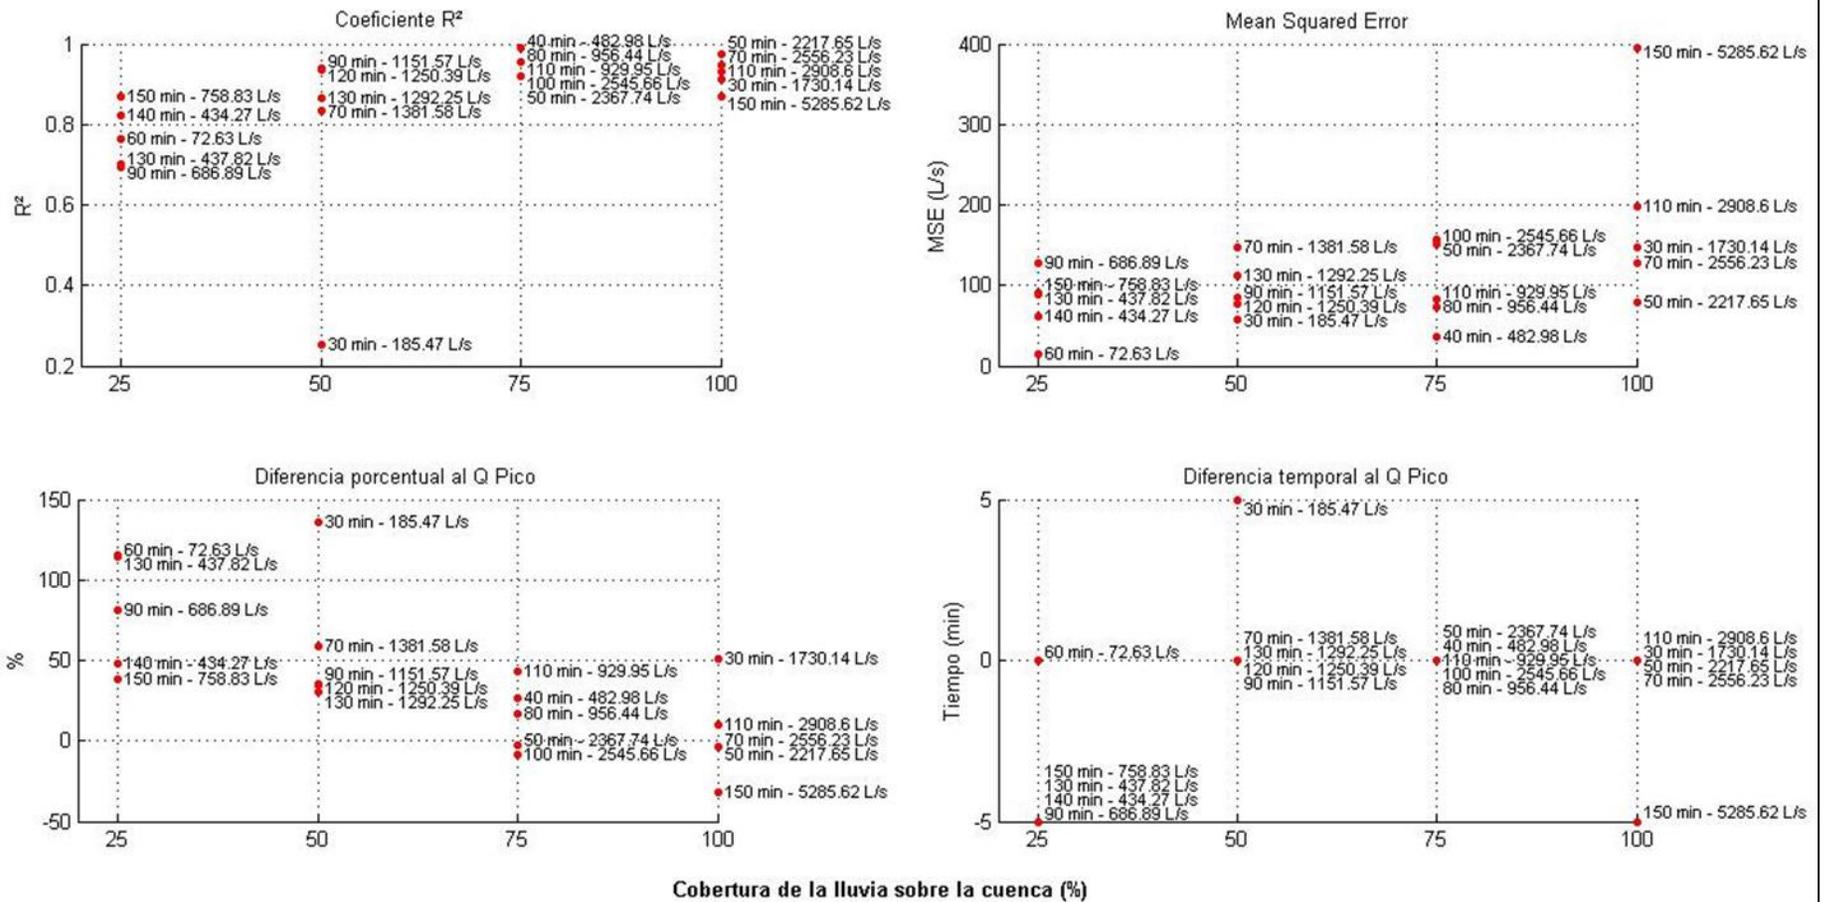
Gráfica 5.86 Resultados de predicción para la ANNFD15.

Desempeño ANNFD16



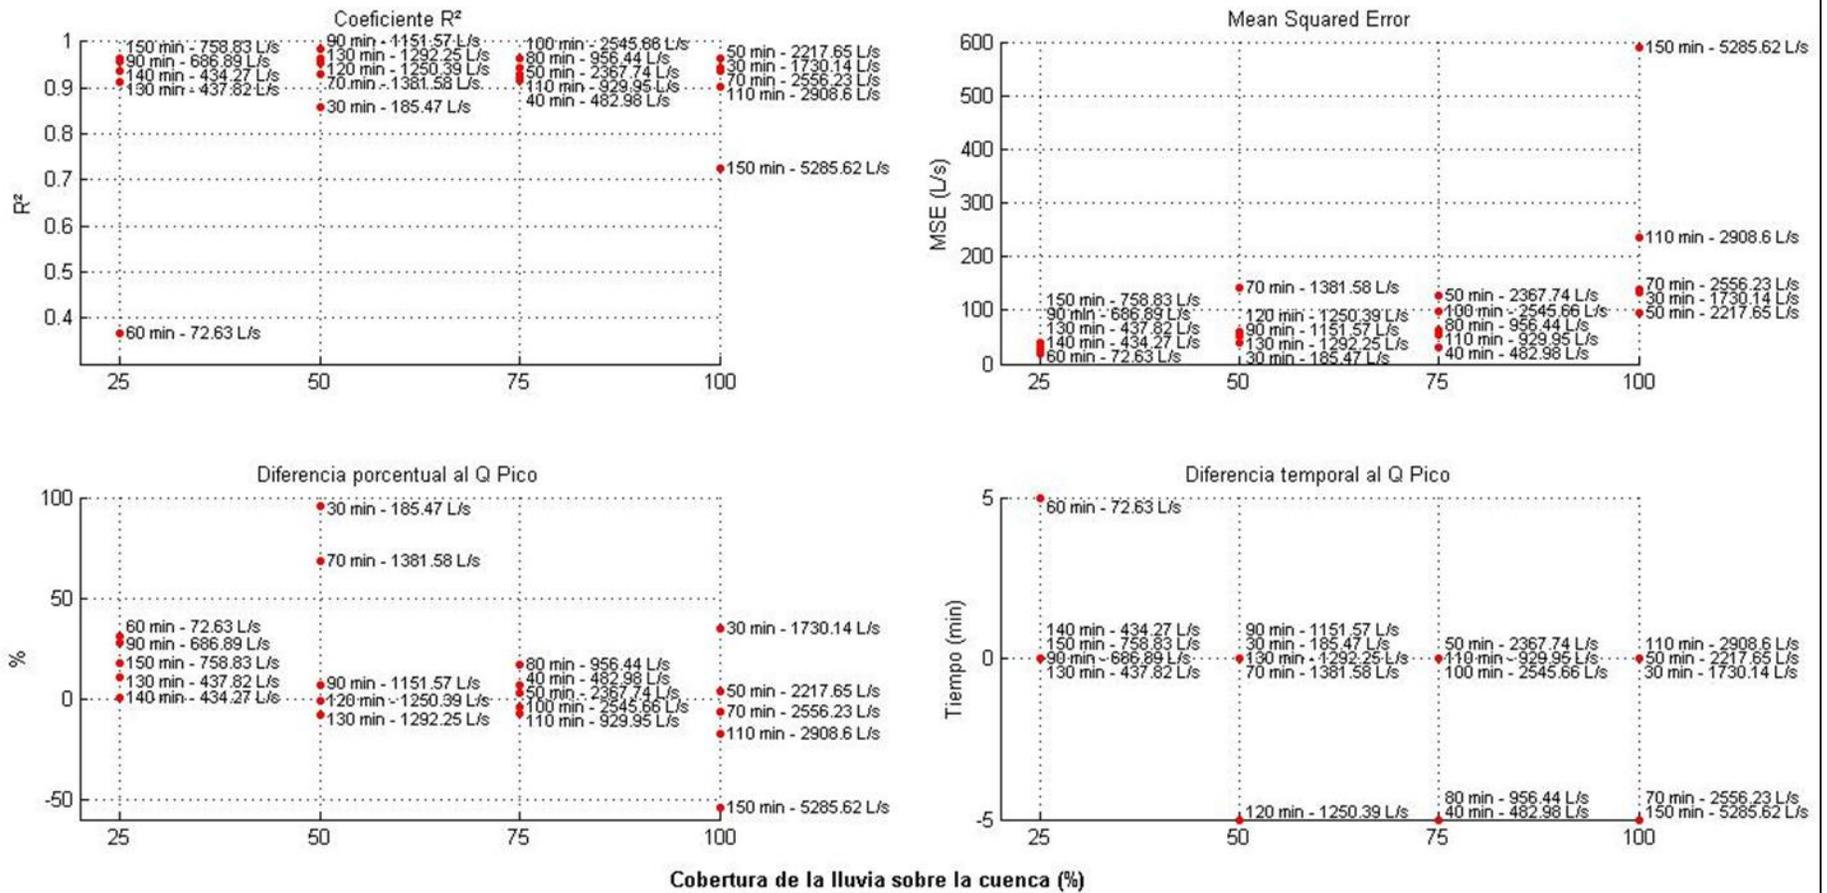
Gráfica 5.87 Resultados de predicción para la ANNFD16.

Desempeño ANNFD17



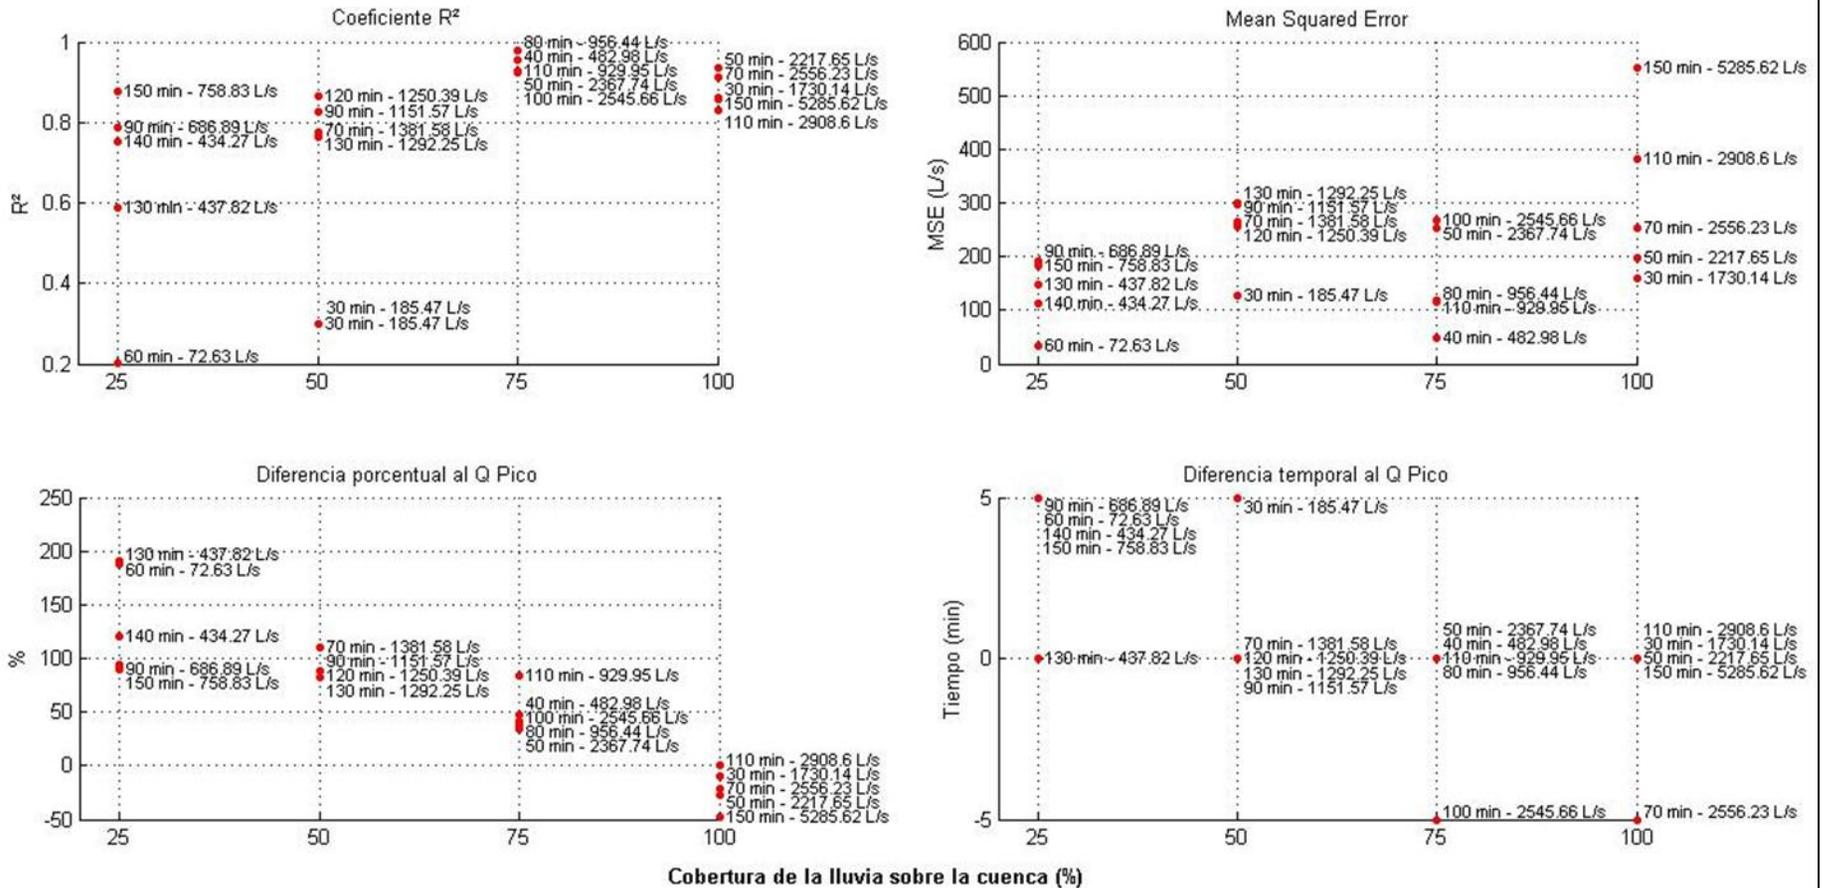
Gráfica 5.88 Resultados de predicción para la ANNFD17.

Desempeño ANNFD21



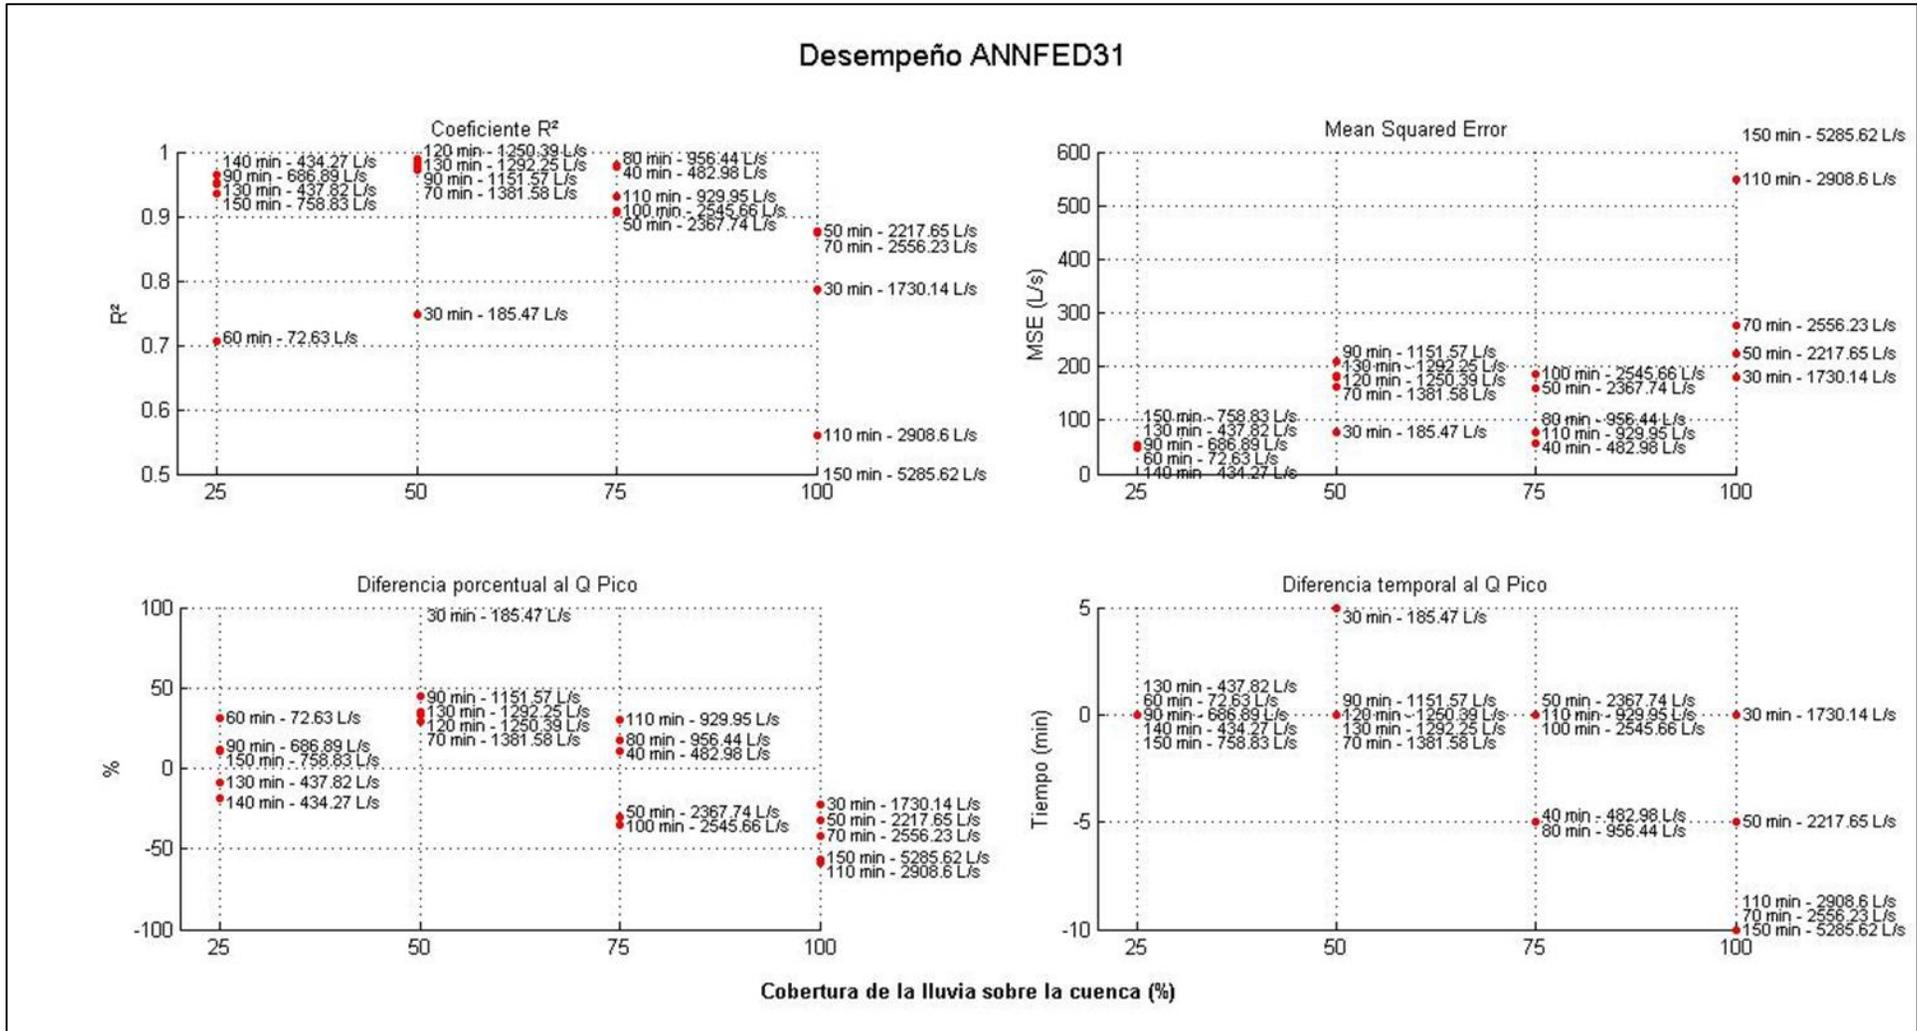
Gráfica 5.89 Resultados de predicción para la ANNFD21.

Desempeño ANNFD24



Gráfica 5.90 Resultados de predicción para la ANNFD24.

Desempeño ANNED31



Gráfica 5.91 Resultados de predicción para la ANNED31.

5.1.11.1 Análisis de Resultados

Realizando una evaluación del desempeño de cada una de las ANN y su desempeño frente a criterios de generalización y exactitud en la predicción de caudales pico se determinó que:

- Las redes entrenadas con el algoritmo de Levenberg – Marquardt fueron las que tuvieron un mejor desempeño, con una efectividad en la generalización del 85% con base en el R^2 . Sin embargo en la predicción del caudal pico se encontró que la efectividad se redujo al 75% generando caudales pico con una diferencia porcentual superior al 10% respecto a los valores esperados.
- Si identificó de manera general que los eventos 4, 7 y 9 fueron eventos de tormenta cuyas predicciones presentaron el más bajo desempeño de generalización para todas las redes neuronales artificiales. Vale la pena aclarar que estos eventos corresponden a los eventos extremos de predicción, siendo estos el evento máximo registrado y los dos eventos mínimos respectivamente (Véase Tabla 5-20).
- Los resultados permitieron identificar una tendencia clara en el desempeño de las redes respecto al MSE; realizando una comparación de los resultados de la Gráfica 5.84 a la Gráfica 5.91 se puede observar como el desempeño disminuye cuanto mayor es la cobertura del evento sobre la cuenca, es decir cuanto mayor es la cantidad de datos que tiene que procesar la arquitectura inteligente.
- Consistentemente con los resultados iniciales de las redes ANNFED24 y ANNFED31 se confirmó que estas son las redes con el más bajo desempeño.

5.1.12 REENTRENAMIENTO CON 30 EVENTOS

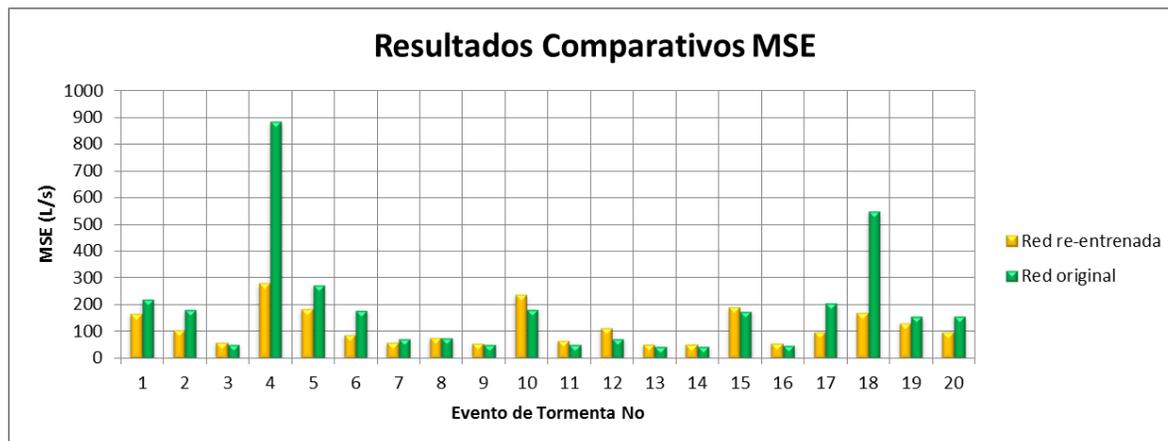
Con base en los resultados de la evaluación inicial del Numeral 5.1.10.5 y los resultados de predicción del numeral anterior, se puede llegar a la conclusión que pese a que existen redes con un desempeño satisfactorio para múltiples eventos de tormenta, en la mayoría de casos no fue posible lograr un resultado óptimo para cada evento predicho. Frente a esta problemática en esta etapa del estudio se intenta determinar una vez más si al ampliar el espacio de entrenamiento se pueden subsanar las falencias para aquellos eventos que no se predicen con cierto grado de confiabilidad.

Para ello se tomó como ejemplo la red neuronal ANNFED31, siendo esta la red con el más bajo desempeño. Realizando el reentrenamiento de las redes con un conjunto de 30 eventos de tormenta, 20 de ellos con las características de la Tabla 5-20 y 10 adicionales con las características de la Tabla 5-21, se espera complementar el espacio de entrenamiento y obtener una mejor efectividad en la predicción de los mismos 20 eventos evaluados en el numeral anterior.

Tabla 5-21 Eventos adicionales para el entrenamiento.

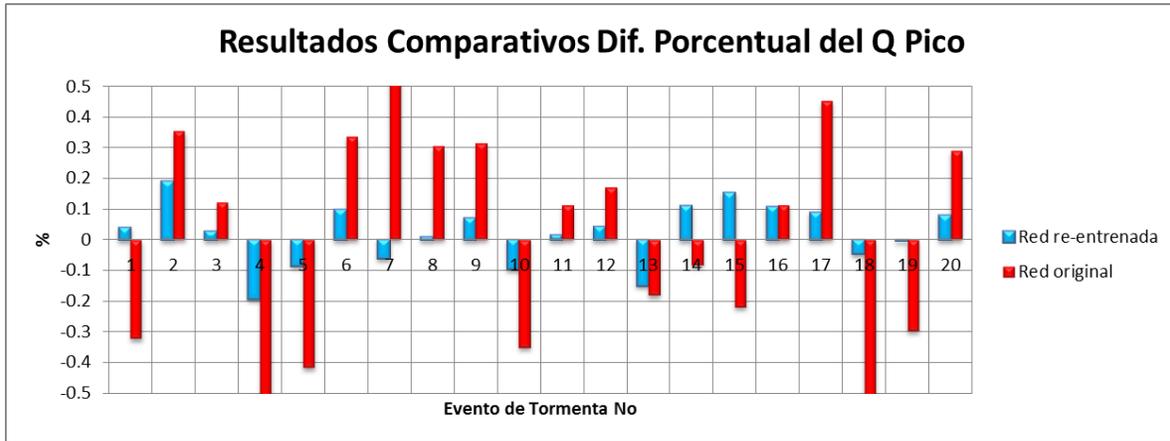
Evento	Duración (min)	Q Pico (L/s)	% Cobertura
21	60	4859.72	100%
22	120	1647.88	50%
23	140	566.27	25%
24	80	2696.13	100%
25	100	129.68	25%
26	40	1016.64	50%
27	160	2714.15	75%
28	160	628.11	50%
29	80	2474.21	100%
30	30	2548.75	75%

Realizado todo el reentrenamiento y una vez predichos los mismos eventos de tormenta del numeral 5.1.11 se obtuvo, como se puede observar en la Gráfica 5.92, una mejora considerable respecto a los valores del MSE.



Gráfica 5.92 Variación del MSE entre entrenamientos ANNFED31.

Por otra parte, respecto a la diferencia porcentual al caudal pico la mejora en el desempeño es notoria. En la Gráfica 5.93 se puede observar como la exactitud en la predicción puntual del caudal máximo se vio altamente mejorada.



Gráfica 5.93 Variación de la diferencia porcentual del caudal pico ANNFED31.

6 METODOLOGÍA PARA EL USO DE ANN

Con la intención de que este trabajo marque un punto de inicio en la investigación rigurosa de la aplicabilidad de las ANNS's en la ingeniería hidráulica, este capítulo propone una metodología general para el desarrollo y aplicación de las ANN en casos de estudio con series de tiempo dinámicas. Basado en el estado del arte, en los avances investigativos y en los resultados obtenidos, se construyó la metodología general de la Figura 6.1 con la que espero estimular el emprendimiento de trabajos futuros ofreciendo un punto de partida válido para cualquier tipo de estudio.

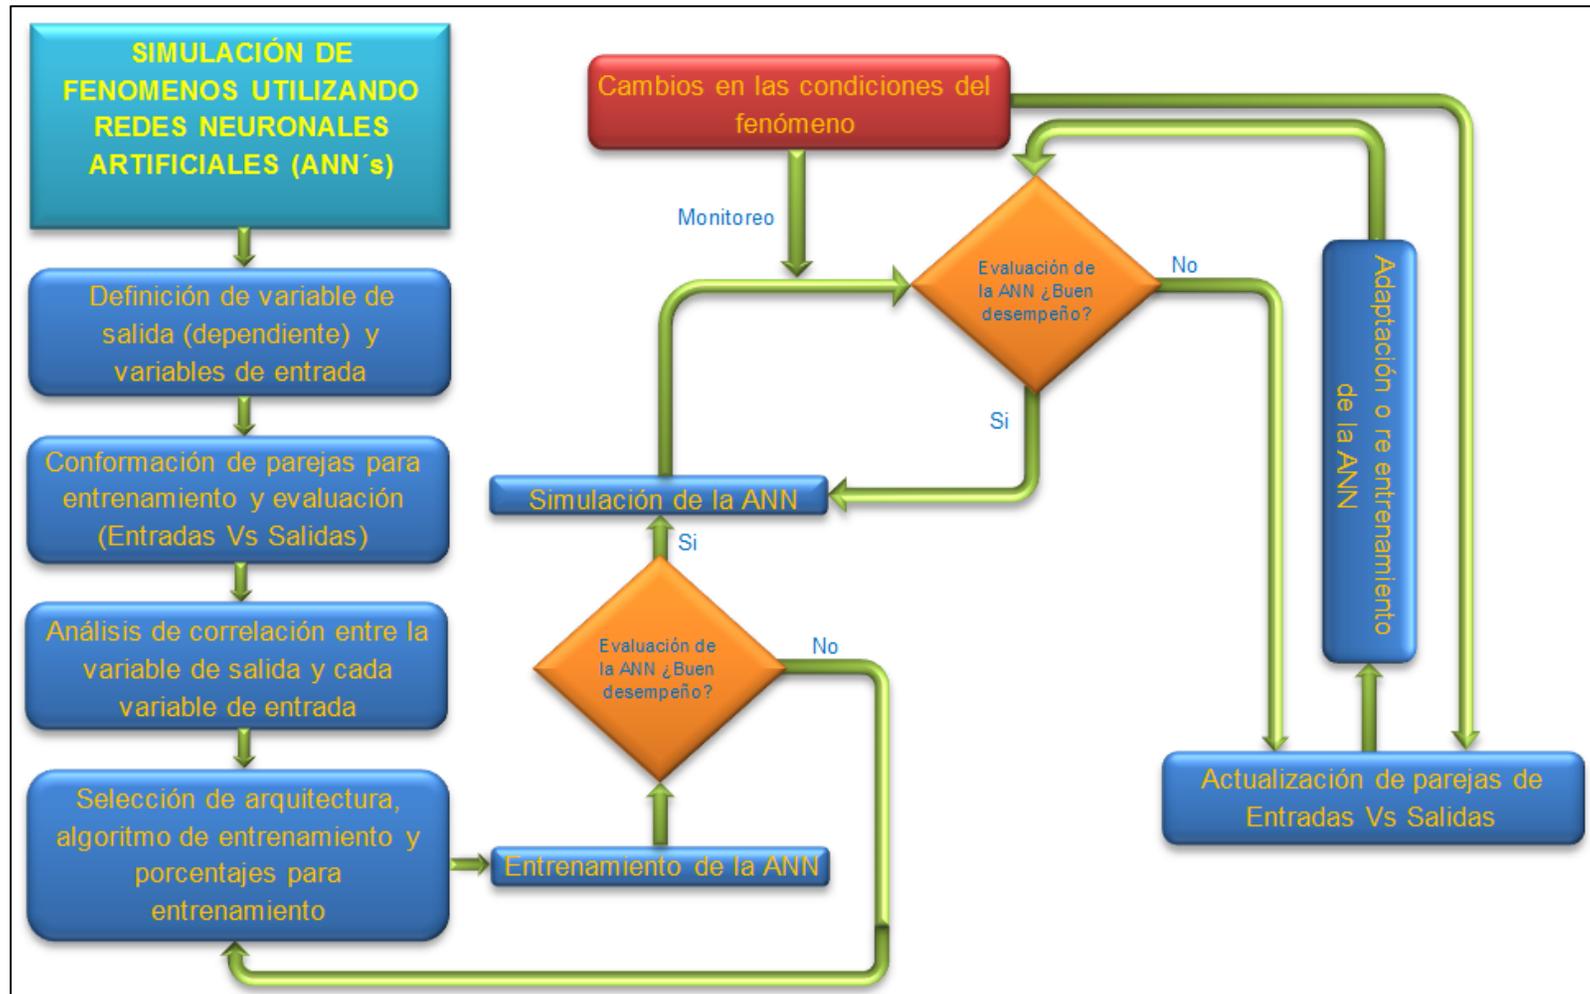


Figura 6.1 Metodología general para el uso de ANN con series de tiempo dinámicas.

A continuación se presenta una profundización paso a paso de la metodología planteada y su equivalente en el desarrollo de esta tesis.

- Definición de variable de salida y variables de entrada: Este proceso parte del conocimiento avanzado del fenómeno que se quiere predecir así como de las variables independientes sobre las que se quiera definir la variable de salida. Para este caso el fenómeno es el tránsito de caudales a través de redes de drenaje; la variable de salida que se quiso obtener fueron los hidrogramas en la descarga de un punto específico de la red. Y pese a que el tránsito de caudales depende de un gran número de variables físicas sujetas a incertidumbre, las ANN's permiten definir todo el fenómeno en función de pocas variables conocidas, en este caso los hidrogramas de entrada en diversos puntos de la red.
- Conformación de parejas para entrenamiento y evaluación: Debido a que el proceso de entrenamiento es el paso más importante en la creación de arquitecturas inteligentes la conformación de parejas de entrenamiento debe ser un proceso riguroso en el que se incluyan series de tiempo diversas que, de ser posible, representen todos los posibles estados del fenómeno. Sin embargo la inclusión de estas series no debe limitarse a un solo evento pues la red requiere en el proceso de aprendizaje de varios ejemplos para su óptimo funcionamiento.
- El análisis de correlación entre las variables de entrada y las de salida es otro paso importante en la metodología porque permite definir los valores a lo largo de la serie de tiempo más adecuados para determinar un valor de salida. En este caso se determinó qué caudales de entrada, desfasados un valor $t - d$ en el tiempo, guardaban mayor correlación con un caudal de salida en el tiempo t .
- La selección de arquitectura hace referencia a la escogencia de número de neuronas y capas ocultas que conformarán la red neuronal. En cada capa se decidirá a su vez una función de transformación de datos (sigmoidea, tangencial o lineal). Los porcentajes de entrenamiento corresponden a la selección y agrupación de parejas de entradas vs salidas que definirán de todo el conjunto de parejas, que porcentaje se utilizará para el entrenamiento/validación y qué porcentaje se destinará para la evaluación inicial de desempeños. Con respecto a este último punto es recomendable asegurar que en el porcentaje de entrenamiento se encuentre un grupo diverso de datos, sin caer en la repetición accidental de demasiados eventos con características específicas. Para el porcentaje de evaluación

resulta recomendable incluir una pareja por cada estado posible; de esta manera será posible obtener en la evaluación inicial una mayor aproximación a los resultados que se esperan obtener en la predicción en tiempo real.

- Entrenamiento de la red: Comprende el proceso de entrenamiento para el cual se definirán parámetros que en cada iteración evaluarán el estado de aprendizaje de la red neuronal. Para este caso se utilizó la medición del error cuadrático medio.
- Predicción: Una vez que la evaluación inicial de la red neuronal cumpla con los criterios del diseñador será posible utilizar la red en la práctica, con datos que no hayan formado parte del espacio de entrenamiento.
- Cuando por causas exógenas o endógenas las condiciones del fenómeno se vean alteradas, así como la relación entradas vs salidas, se deberá registrar las nuevas parejas que describan el cambio con el fin de actualizar la red neuronal artificial. Para este caso el cambio de las condiciones del fenómeno se resume en cambios graduales o totales de la hidrología y la hidráulica del sistema.
- Actualización de parejas entradas vs salidas: En el evento que los cambios en las condiciones del fenómeno induzcan un mal desempeño en la ANN, y en la medida en la que estos cambios sean registrados, el conjunto de entradas y salidas deberá ser actualizado. Dependiendo de la influencia del cambio en el sistema este nuevo grupo de parejas será complementado al existente o conformará un nuevo grupo de entrenamiento.
- Adaptación o reentrenamiento: La adaptación y el reentrenamiento son herramientas que permiten actualizar la red neuronal existente frente a cambios en el fenómeno. El reentrenamiento es recomendable cuando las variaciones en el fenómeno son súbitos y generan una caída drástica en el desempeño. Por otro lado, la adaptación es recomendable cuando el cambio es gradual y monitoreado.

7 CONCLUSIONES Y RECOMENDACIONES

- Pese a que se evaluaron múltiples arquitecturas con diferentes algoritmos de entrenamiento, los resultados obtenidos no permitieron determinar con certeza una configuración en particular que garantizase una predicción confiable de los hidrogramas de salida, frente a diversos escenarios de operación, de las redes de drenaje objeto de estudio.
- Una revisión de los resultados obtenidos por las 8 mejores redes neuronales artificiales, frente a los diferentes cambios de hidrología, muestran que cuanto más complejos se hicieron los caudales el desempeño se vio disminuido.
- Durante el desarrollo de la investigación se hizo evidente que para obtener un buen desempeño con las ANN's es necesaria una cantidad considerable de datos disponibles para el entrenamiento. Sin embargo, debido a las condiciones propias del fenómeno estudiado, la consecución de tal cantidad de datos exigiría una gran inversión de tiempo y recursos, hecho que desvirtúa la utilización práctica de las redes neuronales para este caso en específico.
- Pese a la poca aplicabilidad de las redes en este caso de estudio, no se deben desconocer los buenos resultados que se obtuvieron para algunas arquitecturas como las redes entrenadas con el algoritmo de Levenberg – Marquardt. Los avances y resultados obtenidos en esta investigación abren la puerta a un estudio más riguroso sobre las redes neuronales y su aplicación en la ingeniería hidráulica.
- Con base en las últimas predicciones realizadas en el modelo Nicolás de Federmán se puede establecer que para obtener unos resultados de evaluación altamente confiables, es necesario que el porcentaje de valores destinados para la evaluación contemplen múltiples eventos que comprendan etapas diversas del fenómeno estudiado. Un espacio de evaluación que no sea diverso genera incertidumbre frente a los verdaderos resultados que generaría la ANN ante eventos fuera del espacio de entrenamiento.
- Se comprobó cualitativa y cuantitativamente el efecto positivo de procesos como la adaptación y el reentrenamiento en el desempeño de las ANN. Los escenarios predichos comprobaron que estos son capaces de mantener actualizada a la red frente a cambios en el fenómeno.

-
- Con base en los resultados y en las limitaciones de las ANN's se concluye que su uso para la modelación y diagnóstico de complejos sistemas de drenaje no es práctico; sin embargo su uso para el monitoreo y el control de puntos específicos en una red es factible.
 - Aunque la metodología planteada en esta tesis se enfoca a la construcción, entrenamiento y puesta en marcha de arquitecturas inteligentes para el tránsito de caudales, es igualmente aplicable y válida para cualquier otro tipo de fenómeno de interés en la ingeniería hidráulica.

8 TRABAJOS FUTUROS

Gracias a la gran aplicabilidad de las ANN (Véase Numeral 3.2) los trabajos futuros que pueden emprenderse basados en este trabajo son múltiples.

- Pese a que la aproximación al problema del tránsito de caudales a través de una red de drenaje se realizó desde el ingreso a la red nudo a nudo hasta un punto de descarga, una aproximación más práctica es ampliar el rango de estudio y predecir el tránsito desde el registro de los eventos de lluvia en pluviogramas próximos a la zona de interés hasta nudos dentro de la red; de esta manera la cantidad de datos de entrada así como su consecución se hacen más prácticos. Dicho estudio simplificaría el tránsito de caudales además del proceso lluvia-escorrentía y marcaría la pauta para el control en tiempo real aprovechando el tiempo de tránsito hasta los puntos de interés en la red.
- Convencionalmente el estudio y modelación de diversas estructuras del drenaje urbano (alivios, tanques de amortiguación, desarenadores, sifones, etc.) implican un conocimiento riguroso de las condiciones físicas e hidráulicas que influyen en su operación, con mediciones controladas las ANN's ofrecen una alternativa de predicción rápida y confiable con capacidad de representar exactamente la operación de dichas estructuras.
- El uso de ANN's puede enfocarse más allá de la generación de hidrogramas, y enfocarse en la predicción de múltiples variables de interés como polutogramas o limnigramas entre otros.
- Finalmente, la metodología planteada en el Numeral 6, abre las puertas a la selección rápida y efectiva de una arquitectura adecuada para cualquier problema expresable en términos de series dinámicas de tiempo. Pensado como un algoritmo programable la metodología deberá permitir la exploración de múltiples redes, estructuras y algoritmos de entrenamiento evaluando siempre los mismos datos de interés respecto a los criterios de validación que el diseñador requiera. Para esto MatLab y su lenguaje de programación propio ofrecen una herramienta útil para el desarrollo de un software que explore de manera optimizada múltiples combinaciones de arquitecturas inteligentes.

9 REFERENCIAS BIBLIOGRÁFICAS

- Andreas Kurth, P. A. (2008). Application of artificial neural networks (ANNs) for the prediction of CSO discharges. *11th International Conference on Urban Drainage*, (págs. 1-10). Edinburgh, Scotland, UK.
- Basoqain Olabe, J. (2005). *Redes Neuronales artificiales y sus aplicaciones*. Bilbao: Publicaciones de la Escuela de Ingenieros.
- Bentley®. (2014). Recuperado el 22 de Noviembre de 2014, de Bentley Web Site: <http://www.bentley.com/en-US/Products/SewerGEMS/>
- Dawson, C. (2006). Flood estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*, 391-409.
- Delgado, A. (1999). Aplicacion de las Redes Neuronales en Medicina. *Revista de la facultad de medicina Universidad Nacional de Colombia*, 221-223.
- Ebtehaj, I., & Bonakdari, H. (2013). Evaluation of sediment transport in sewer using artificial neural network. *Engineering Applications of Computational Fluid Mechanics*, 382-392.
- Elizabeth L. Cavanaugh, E. D. (2007). Using Artificial Neural Networks to Forecast Wet Weather Flow in a Sanitary Sewer System. *ASCE*.
- Erik R. Kandel, J. H. (2001). *Principios de neurociencia*. USA: McGraw Hill-Interamericana.
- J Dolz, G. M. (1994). Problemática del drenaje de aguas pluviales en zonas urbanas y del estudio hidráulico de las redes de colectores. Barcelona, España.
- José R. Hilera, V. J. (2000). *Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones*. Madrid, España : RA-MA Editorial.
- MathWorks Inc. (2013). Centro de documentacion de MatLab.
- Michael Bruen, J. Y. (2006). Combined Hydraulic and Black-Box Models for Flood Forecasting in Urban Drainage Systems. *Journal of hydrologic engineering ASCE*, 589-596.

-
- Morales, J. F. (2004). *Tránsito de crecientes en sistemas de alcantarillado utilizando redes neuronales artificiales*. Bogotá, Colombia.
- Páez, D. A. (2010). *Sensibilidad de la respuesta hidráulica en redes de alcantarillado, a cambios en la rugosidad y el diámetro*. Bogotá, Colombia.
- Solomatine, D. (2002). Data-driven modelling: machine learning and data mining in water related problems. *V International Conference on Hydroinformatics*. Cardiff, UK.
- Universidad Konrad Lorenz. (Enero de 2009). *Fundación Universitaria Konrad Lorenz*. Recuperado el 10 de Septiembre de 2014, de <http://www.konradlorenz.edu.co>
- Xiangfei Li, F. Z. (2011). Applications of artificial Neural Networks in Urban Water System. *ASCE*, 508-519.