

TESIS DOCTORAL

PREDICCIÓN DE CAUDALES EN TIEMPO REAL EN GRANDES CUENCAS
UTILIZANDO REDES NEURONALES ARTIFICIALES

Lucas Pujol Reig

Directores

Dr. Rafael García Bartual

Dr. Enrique Cifres Giménez

Departamento de Ingeniería Hidráulica y Medio Ambiente

Universidad Politécnica de Valencia

Valencia – España

18 de abril de 2009

Dedicatoria

A mi familia

Agradecimientos

Quisiera expresar en estas líneas mi más sincero agradecimiento a todas aquellas personas que de una u otra forma han contribuido a la realización de esta tesis. Sobre todo a mis padres que gracias a ellos he podido conocer a toda la gente que me ha ayudado durante estos tres años en España.

A Enrique Cifres por haberme dado la oportunidad de trabajar en España y facilitado las ideas y criterios iniciales para esta tesis.

A mi director de tesis, Rafael García Bartual, quisiera agradecerle la ayuda incondicional que siempre me ha prestado y el haber sabido guiar mi trabajo.

A todos mis amigos y compañeros de trabajo de Hidrogaia, quisiera agradecerles todo el apoyo y amistad que siempre me han brindado.

A Fernando Losano, quien me ayudo y facilitó los datos necesarios para realizar alguna de las aplicaciones de esta tesis.

A Alicia, quien supo aguantarme todos estos fines de semana que necesité para trabajar en la tesis y a mis amigos Marcela, Miguel, Poli, Lucía que me ayudaron a hacer las correcciones finales y estuvieron conmigo durante todo este largo proceso.

Resumen

La necesidad de conocer con suficiente tiempo de antelación los caudales futuros en ríos donde se asientan grandes ciudades e industrias es común en todas partes del mundo. Existen diversas metodologías que permiten resolver este problema, cada una con sus pros y sus contras. El acople y la comparación entre varios modelos de predicción de diferentes características es fundamental a la hora de analizar la situación futura en un caso de alerta, donde es necesario tomar decisiones trascendentales. En esta tesis se ha realizado una intensa revisión bibliográfica sobre los modelos de predicción con Redes Neuronales Artificiales (RNA) para conocer el estado del arte de esta metodología y, a partir de ese punto, proponer y estudiar mejoras que puedan contribuir a su avance.

Con la intención de darle significado físico a este tipo de modelos, se ha propuesto una metodología de modelo híbrido que permite identificar automáticamente el estado hidrológico de una cuenca determinada, para permitir modelar por separado cada estado mediante RNA simples. También se ha incorporado el concepto físico en la elección de las variables de entrada al modelo, proponiendo análisis geomorfológicos de la cuenca y de tiempos de respuesta que ayuden a identificar las variables más influyentes.

Por otro lado, dada la necesidad de conocer la función de distribución de las predicciones para casos reales, donde es necesario tomar decisiones a partir de estos resultados, se ha propuesto una metodología para el cálculo de la incertidumbre de las predicciones, pudiendo ser aplicado para cualquier tipo de modelo sin importar su complejidad.

Para conferir un uso práctico a estas ideas, se ha desarrollado una aplicación informática (ANN) capaz de realizar los cálculos necesarios para la construcción de un modelo de predicción con RNA. Se han incorporado módulos para el análisis de los datos, de los tiempos de respuesta de la cuenca y cauces, módulos de cálculos de parámetros, un módulo para el cálculo de la incertidumbre y otros de análisis de los resultados. Se ha creado un software enfocado a la utilización de este tipo de modelos en la hidrología, ya que actualmente no existe ningún programa que contenga todos los elementos necesarios y la flexibilidad que se necesita para construir modelos orientados a la predicción de caudales. Asimismo se ha desarrollado una guía de pasos a seguir para la obtención del modelo óptimo, teniendo en cuenta siempre la incorporación del significado físico del proceso a modelar.

Abstract

It is common everywhere in the world, the necessity to know with enough time of advance the future flows in rivers where big cities and industries are settled. There are many methodologies that allow solving this problem, each one with their advantages and disadvantages. The ensemble and the comparison among different models of prediction is fundamental when analyzing the future situation in case of alert where it is necessary to make important decisions. In this thesis it has been carried out an intense bibliographical revision on the use of Artificial Neural Networks (RNA) to make flows predictions. This is made to know the state of the art of this methodology and starting from that point, propose and study improvements that can contribute to the advance of this art.

With the intention of giving physical meaning to this type of models, it has been proposed a hybrid model's methodology that allows identifying, automatically, the hydrological state of a certain basin, allowing to model separately each state using simple RNA. It has also been incorporated the physical concept in the election of the input variables, proposing geomorphologic and time responses of the basin that help to identify the most influential variables.

On the other hand, given the necessity to know the distribution's function of the predictions in real cases, where it is necessary to make decisions from these results, it has been proposed a methodology to calculate the uncertainty of the predictions of any type of model without caring about their complexity.

To confer a practical use to these ideas, a computer application has been developed (ANN) which is able to carry out the necessary calculations for the construction of a forecasting RNA model. It incorporates modules for the analysis of the data, of the basins and river's respond times, modules of parameter's calculations, a module for the calculation of the uncertainty and others for the analysis of the results. This software has been created focused on the use in hydrology, since at the moment there are not programs that contain all the necessary elements and the flexibility oriented to the flows forecast. It has been also developed a guide of steps to follow for the obtaining of the optimal model, always keeping in mind the incorporation of the physical meaning of the process to model.

Resum

La necessitat de conèixer amb suficient temps d'antelació els futurs cabals als rius on s'assenten les grans ciutats i indústries es comú arreu del món. Existeixen distintes metodologies que permeten resoldre aquest problema, cadascuna d'elles amb els seus pros i contres. L'acoplament i la comparació de diversos models de predicció de diferents característiques és fonamental a l'hora d'analitzar la situació futura en un cas d'alerta, on és necessari prendre decisions transcendents. A aquesta tesi, s'ha realitzat una intensa revisió bibliogràfica sobre els models de predicció amb Xarxes Neuronals Artificials (XNA), per conèixer l'Estat de l'Art d'aquesta metodologia i, a partir d'aquest punt, proposar i estudiar millores que puguin contribuir al seu avanç.

Amb la intenció de dotar de significat físic a aquest tipus de models, s'ha proposat una metodologia d'un model híbrid que és capaç d'identificar automàticament l'estat hidrològic d'una conca determinada, per permetre modelar per separat cada estat mitjançant XNA simples. També s'ha incorporat el concepte físic en la tria de les variables d'entrada al model, proposant anàlisis geomorfològics de la conca i de temps de resposta que ajuden a identificar les variables que més influeixen.

Per altra banda, davant la necessitat de conèixer la funció de distribució de les prediccions per a casos reals, on és necessari prendre decisions a partir d'aquests resultats, s'ha proposat una metodologia per al càlcul de la incertesa de les prediccions, i que pot ser aplicat per a qualsevol tipus de model sense importar la seua complexitat.

Per conferir un ús pràctic a aquestes idees, s'ha desenvolupat una aplicació informàtica (ANN) capaç de realitzar els càlculs necessaris per a la construcció d'un model de predicció mitjançant XNA. S'han incorporat mòduls per l'anàlisi de les dades, dels temps de resposta de la conca i els caus, mòduls de càlculs de paràmetres, un mòdul per el càlcul de la incertesa i altres d'anàlisi de resultats. S'ha creat un software enfocat a la utilització d'aquest tipus de models a la hidrologia, donat que actualment no existeix cap programa que continga tots els elements necessaris i la flexibilitat que es necessita per construir models orientats a la predicció de cabals. Així mateix, s'ha desenvolupat una guia de passos a seguir per a la obtenció del model òptim, tenint sempre en compte la incorporació del significat físic del procés a modelar.

Índice General

Capítulo 1	1
1 Introducción.....	1
1.1 Motivo e Introducción	1
1.2 Objetivos.....	3
1.3 Contribuciones.....	3
1.4 Metodología.....	4
Capítulo 2	9
2 Conceptos básicos de hidrología e hidráulica.....	9
2.1 Introducción.....	9
2.2 Tipos de flujo.....	10
2.3 Mecanismos de generación de escorrentía	14
2.3.1 Mecanismo Hortoniano	14
2.3.2 Mecanismo de Dunne-Black o flujo superficial de saturación.....	16
2.3.3 Mecanismo de flujo sub-superficial	18
2.4 Tipos de hidrogramas	18
2.5 Propagación de una onda de crecida en un cauce.....	21
Capítulo 3	27
3 Introducción a las Redes Neuronales Artificiales	27
3.1 Introducción.....	27
3.2 Sus orígenes.....	27
3.3 Su historia.....	30
3.4 Sus ventajas	32
3.5 Diferentes estructuras	34
3.5.1 Perceptrón multicapa (MultiLayer Perceptron (MLP)).....	34
3.5.2 Mapas auto-organizativos de Kohonen (<i>Self Organizing Map (SOM)</i>)	37
Capítulo 4	43
4 Estado del arte sobre la predicción de caudales en tiempo real con Redes Neuronales Artificiales.....	43
4.1 Introducción.....	43
4.2 Descripción de las Redes Neuronales Artificiales.....	45
4.3 Comparación con otros modelos	54
4.4 Interpretación de las Redes Neuronales Artificiales	58

4.5 Elección de las variables de entrada	65
4.6 Modelos híbridos	68
4.7 Incertidumbre	72
4.8 Líneas de investigación.....	73
Capítulo 5.....	77
5 Modelo modular.....	77
5.1 Introducción	77
5.2 Modelo modular propuesto	79
5.3 Acerca de la clasificación de grupos.....	82
Capítulo 6.....	89
6 Incertidumbre.....	89
6.1 Introducción	89
6.2 Metodología para el cálculo de la incertidumbre de las predicciones.....	91
6.3 Incertidumbre en un modelo ARMAX	95
6.4 Consideraciones a tener en cuenta	99
6.5 Conclusiones.....	101
Capítulo 7.....	105
7 Aplicación informática desarrollada (ANN).....	105
7.1 Introducción	105
7.2 Módulo principal.....	107
7.2.1 Elementos de la red	107
7.2.2 Función de activación de la capa oculta.....	108
7.2.3 Algoritmos de entrenamiento de la red.....	108
7.2.4 Función objetivo	110
7.3 Preparación y análisis de los datos.....	110
7.3.1 Análisis de datos	110
7.3.2 Preparación de los datos.....	115
7.4 Entrenamiento	118
7.5 Parámetros.....	120
7.6 Validación.....	122
7.7 Predicción.....	124
7.8 Búsqueda de la red óptima	124
7.9 Modelo modular (SOM-MLP).....	126
7.9.1 Elementos de la red.....	128

7.9.2	Parámetros	132
7.9.3	Validación.....	133
7.10	Modelo ARMAX.....	135
7.11	Intervalos de confianza.....	137
Capítulo 8	143
8	Aplicaciones	143
8.1	Introducción.....	143
8.2	Predicción en tiempo real de caudales en el río Paraná: comparación entre los modelos MLP, SOM-MLP y ARMAX.....	146
8.2.1	Caso de estudio.....	147
8.2.2	Preparación y análisis de datos.....	150
8.2.3	Determinación de los modelos	157
8.2.4	Análisis de resultados	165
8.2.5	Conclusiones.....	176
8.3	Predicción de caudales en el río Neuquén.....	177
8.3.1	Caso de Estudio	178
8.3.2	Preparación y análisis de datos.....	192
8.3.3	Determinación de los modelos	203
8.3.4	Análisis de resultados	212
8.3.5	Conclusiones.....	227
Capítulo 9	231
9	Conclusiones y discusiones	231
Referencias	235
Apéndices	253
A	Tablas y parámetros de las aplicaciones.....	253
A.1	Aplicación sobre el río Paraná.....	253
A.1.1	Parámetros de los modelos	253
A.1.2	Resultados de calibración	258
A.2	Aplicación sobre el río Neuquén	264
A.2.1	Parámetros de los modelos	264
A.2.2	Resultados de calibración	268
B	Intervalos de confianza	273
B.1	Introducción	273
B.2	Resultados para la serie de calibración del modelo del Paraná	273

B.3 Resultados para la serie de validación del modelo del Paraná.....	275
B.4 Comparación con diferentes funciones marginales.....	276
C Medidas de evaluación de los modelos y test de normalidad.....	283
C.1 Medidas de evaluación de los modelos	283
C.2 Test de normalidad	285
D Distribución Meta-Gaussiana.....	287

Índice de Tablas

Tabla 4.1: Resumen de los artículos revisados.....	59
Tabla 6.1: Distribuciones de caudales observados y predichos para diferentes modelos	100
Tabla 7.1: Tabla ejemplo de preparación de datos de entrada.....	115
Tabla 7.2: Esquema de los pesos y umbrales de las redes neuronales	122
Tabla 8.1: Variables de predicción utilizadas en los modelos ARMAX, MLP y SOM-MLP	156
Tabla 8.2: Peak Flow Criteria. Índice de habilidad de predicción de picos	168
Tabla 8.3: Variables de predicción utilizadas en los modelos ARMAX, MLP y SOM-MLP	201
Tabla 8.4: Grupos de variables de entrada analizados.....	203
Tabla 8.5: Variación del coeficiente de Nash and Sutcliffe en función de los nodos en la capa oculta para la series de calibración. Eliminando los entrenamientos con sobreentrenamientos.....	205
Tabla 8.6: Análisis de cantidad de nodos en la capa oculta para el modelo MLP de cada grupo, para el entrenamiento, sin considerar los casos de sobreentrenamiento	212
Tabla 8.7: Coeficientes PFC de los resultados de validación.....	215
Tabla 8.8: Análisis de los coeficientes de Nash para cada uno de los grupos del modelo modular. Validación.....	215
Tabla 8.9: Análisis de los coeficientes de Nash para cada uno de los grupos del modelo modular. Calibración	216
Tabla A. 1: Parámetros funciones de distribución lognormal-lognormal para el cálculo de los intervalos de confianza.....	257
Tabla A. 2: Peak Flow Criteria. Índice de habilidad de predicción de picos para la serie de calibración.....	258
Tabla A. 3: Parámetros funciones de distribución lognormal-lognormal para el cálculo de los intervalos de confianza. Modelos del río Neuquén	267
Tabla A. 4: Peak Flow Criteria. Índice de habilidad de predicción de picos para la serie de calibración del río Neuquén	268
Tabla C. 1: Coeficientes de asimetría para series con menos de 150 datos (fuente: Salas et al., 1980, pag.93).....	286

Índice de Figuras

Figura 1.1: Inundaciones en Tabasco (México), Noviembre 2007 (fuente: BlogSonora.com).....	2
Figura 2.1: Componentes de un hidrograma	10
Figura 2.2: Componentes de escorrentía	11
Figura 2.3 Hidrograma típico	13
Figura 2.4: Dos métodos muy simples para la separación de las partes de un hidrograma	13
Figura 2.5: Esquema de la escorrentía hortoniana: a) generación y b) evolución de la tasa de infiltración.....	15
Figura 2.6: Generación de la escorrentía por exceso de saturación o mecanismo Dunne.....	16
Figura 2.7: Mecanismo Dunniano de generación de escorrentía.....	17
Figura 2.8: Hidrograma típico de climas húmedos. Flujo continuo (fuente: Chow et al., 1994).....	19
Figura 2.9: Hidrograma típico de climas áridos. Río efímero (fuente: Chow et al., 1994).....	19
Figura 2.10: Hidrograma típico de escorrentía alimentada por el derretimiento de la nieve (fuente: Chow et al., 1994).....	20
Figura 2.11: Ejemplo de diferentes respuestas hidrológicas en función de la forma de la cuenca (fuente: redibujo de Grepí, 2005)	20
Figura 2.12: Ejemplo de diferentes respuestas hidrológicas en función de la forma de la cuenca (fuente: redibujo de Grepí, 2005)	21
Figura 2.13: Celeridad de la onda c (fuente: Irving, 1995)	21
Figura 3.1: Estructura general de una red neuronal artificial (fuente: Muñoz, 1996).....	28
Figura 3.2: Estructura de una neurona (fuente: Muñoz, 1996).....	29
Figura 3.3: Estructura del perceptrón multicapa MLP (fuente: Muñoz, 1996).....	35
Figura 3.4: Estructura de un Mapa Auto-organizativo de Kohonen. Fuente: Muñoz, 1996.....	38
Figura 3.5: Red auto-organizativa (SOM).....	39
Figura 4.1: Cantidad de artículos de RNA revisados y distribuidos por año	44
Figura 4.2: Arquitectura de una red RTRL (fuente: Chiang et al., 2004)	47
Figura 4.3: Esquema de red neuronal artificial feedforward con una sola capa oculta.....	48
Figura 4.4: Esquema de un nodo general j	49
Figura 4.5: Valores observados y de predicción a 12 h. de caudales en el río Trent para el período de validación (fuente: Imrie et al., 2000).....	53
Figura 4.6: Niveles observados y predichos en el río Chao Phraya en Tailandia (fuente: Wangwongwiroj y Sukluan, 2004)	54
Figura 4.7: Esquema de red neuronal utilizada (fuente: Coulibaly et al., 2000).....	57
Figura 4.8: Comparación de los coeficientes de correlación para las predicciones de caudales a diferentes horizontes de predicción para el río Chutedu- Diable, Canadá (fuente: Coulibaly et al., 2000).....	57

Figura 4.9: Esquema de una red tipo GANN (Geomorphologic artificial Neural Network) con la precipitación en exceso y el caudal en tiempos anteriores como variables de entrada.....	65
Figura 4.10: Caudales observados y predichos usando una red neuronal tipo backpropagation con diferentes variables de entrada (fuente: Sahoo et al., 2006).....	67
Figura 4.11: Descomposición de un hidrograma (fuente: Jain y Srinivasulu, 2006).....	68
Figura 4.12: Arquitectura del modelo SOLO (fuente: Hsu et al., 2002).....	70
Figura 4.13: Características de clasificación de una red SOFM 15 x 15 utilizada para la clasificación previa de los datos (fuente: Hsu et al., 2002).....	71
Figura 4.14: Caudales predichos a 10 días para el río Amarillo, China (fuente: Wang et al., 2006).....	71
Figura 5.1: Concepto de redes modulares. Subdivisión de un problema en varios para que combinados realicen la predicción.....	77
Figura 5.2: Grados de pertenencia de los días del año para caudales diarios en Tangnaiha, río Amarillo, utilizando el método FCM “fuzzy C-means” (fuente Wang et al., 2006).....	78
Figura 5.3: Red SOM para la separación de un hidrograma.....	81
Figura 5.4: Separación de grupos tipo para un hidrograma. Aplicación en el río Paraná.....	82
Figura 5.5: Hidrograma de crecida del río Neuquén en “Paso de los Indios”	84
Figura 5.6: Hidrograma de crecida del río Neuquén en “Paso de los Indios” para época de derretimiento de nieve (primavera- verano).....	84
Figura 5.7: Hidrograma de crecida del río Neuquén en “Paso de los Indios” para un evento fuerte de precipitación en la época invernal	85
Figura 6.1 El problema de la incertidumbre de las predicciones para dar una alarma (fuente: Todini, 2004)	89
Figura 6.2: Muestra de la frecuencia conjunta de caudales observados y predichos, de la cual se estima la función de densidad de probabilidad bivariada	92
Figura 6.3: Esquema del cálculo de los intervalos de confianza para las predicciones de caudales a 10 días en el río Paraná.....	95
Figura 7.1: Módulo principal ANN	107
Figura 7.2: Funciones de activación	108
Figura 7.3: Algoritmos de entrenamiento	108
Figura 7.4: Funciones objetivo.....	110
Figura 7.5: Análisis de datos.....	111
Figura 7.6: Autocorrelación y correlaciones cruzadas.....	112
Figura 7.7: Autocorrelación parcial	112
Figura 7.8: Gráficos de probabilidad normal.....	113
Figura 7.9: Cálculos de tiempos de propagación de una onda de crecidas en un cauce con sección y pendiente constante	114

Figura 7.10: Sección utilizada para el cálculo de la velocidad del agua utilizando la ecuación de manning	114
Figura 7.11: Ejemplo de red neuronal artificial.....	115
Figura 7.12: Módulo de preparación de datos	116
Figura 7.13: Red neuronal artificial resultante de la preparación automática de datos.....	116
Figura 7.14: Funciones de transformación de las variables.....	117
Figura 7.15: Datos de verificación	118
Figura 7.16: Evolución de la función objetivo en para cada época. Línea roja para la evolución del error en los datos de verificación y azul para los datos de calibración.....	119
Figura 7.17: Gráfico de los valores observados y predichos en función del tiempo.....	119
Figura 7.18: Gráfico de los valores observados en función de los predichos	120
Figura 7.19: Parámetros calculados.....	120
Figura 7.20: Formato del archivo de parámetros.....	121
Figura 7.21: Ejemplo de los parámetros de un nodo de entrada con la red.....	121
Figura 7.22: Módulo de validación	123
Figura 7.23: Índices de fiabilidad.....	123
Figura 7.24: Módulo de predicción	124
Figura 7.25: Módulo para la búsqueda de la red óptima	125
Figura 7.26: Gráfico de cajas para seleccionar la cantidad de nodos en la capa oculta	125
Figura 7.27: Módulo del modelo SOM-MLP.....	126
Figura 7.28: Módulo de preparación de datos para la red SOM. Transforma cada variable entre a y b.....	127
Figura 7.29: Gráfico de la clasificación de grupos con la red SOM	128
Figura 7.30: Función topológica Hex.....	128
Figura 7.31: Función topológica Grid	129
Figura 7.32: Función topológica Rand	129
Figura 7.33: Evolución en tiempo real de la función objetivo para cada época de entrenamiento.....	132
Figura 7.34: Pesos de la red SOM y nombre de redes MLP	132
Figura 7.35: Archivo de texto que contiene las características de la red modular SOM-MLP ...	133
Figura 7.36: Módulo de validación de la red modular SOM-MLP	134
Figura 7.37: Gráfico de caudales observados en función de los simulados con la identificación de cada grupo	134
Figura 7.38: Menú principal del módulo ARMAX.....	135
Figura 7.39: Menú de preparación de datos para el modelo ARMAX.....	136
Figura 7.40: Parámetros ARMAX.....	137
Figura 7.41: Formato del fichero de texto para almacenar los parámetros ARMAX	137

Figura 7.42: Módulo para el cálculo de los intervalos de confianza.....	138
Figura 7.43: Gráfico de las caudales predichos en función de los observados.....	139
Figura 7.44: Gráfico de la función de densidad de probabilidad 3D.....	139
Figura 7.45: Gráfico de las series temporales de los caudales predichos con sus límites de confianza.....	139
Figura 8.1: Gráfico de cajas de los datos de calibración, utilizado para seleccionar la cantidad de nodos en la capa oculta.....	145
Figura 8.2: Mapa de ubicación de la zona de estudio.....	148
Figura 8.3: Caudales medios diarios mensuales para “Chapetón” (rojo) y “Corrientes” (azul).....	148
Figura 8.4: Sección transversal en “Chapetón” (fuente: Jaime et al., 1997).....	149
Figura 8.5: Cuenca en estudio. Tamaño 234,000 km ²	149
Figura 8.6: Interpolación para completar datos de caudales. En rojo datos completados, verde datos reales.....	150
Figura 8.7: Llenado de huecos en la serie de precipitación utilizando valores medidos el mismo mes del año anterior.....	151
Figura 8.8: Serie de datos completa e identificación de los grupos de calibración, validación y verificación.....	152
Figura 8.9: Análisis de correlación.....	153
Figura 8.10: Análisis de las series. “Chapetón” (Q), Media en “Corrientes” (MF) y Acumulado en “Batel Paso Cerrito” (SP).....	154
Figura 8.11: Auto-correlación parcial.....	155
Figura 8.12: Gráficas de distribución de probabilidades. De izquierda a derecha, de arriba abajo: caudales en la estación de “Chapetón” (sk = 0.66), caudales promediados de la estación de “Corrientes” (sk = 1.42), precipitación acumulada en la estación de “Batel Paso Cerrito” (sk = -0.19). Todos transformados con la función de García-Bartual, 2002.....	156
Figura 8.13: Modelo modular SOM-MLP.....	157
Figura 8.14: Modelo de red neuronal MLP.....	157
Figura 8.15: Modelo ARMAX.....	157
Figura 8.16: Red neuronal artificial tipo de 3 capas NN(11-3-1).....	158
Figura 8.17: Variables de entrada al modelo ARMAX.....	160
Figura 8.17: Descomposición de un hidrograma (fuente: Jain y Srinivasulu, 2006).....	161
Figura 8.18: Red auto-organizativa (SOM) utilizada para la clasificación de los datos de entrada.....	162
Figura 8.19: Gráfico de separación de grupos utilizando la red SOM para la serie de validación.....	162
Figura 8.20: Distribución de las variables por grupo.....	163
Figura 8.21: Caudales predichos en función de los observados con la identificación de los diferentes grupos.....	164
Figura 8.22: Gráfico de separación de grupos realizada manualmente.....	164

Figura 8.23: Función de autocorrelación de los errores y correlaciones cruzadas entre las variables y los errores del modelo ARMAX.....	165
Figura 8.24: Distribución de los errores para el modelo ARMAX	165
Figura 8.25: Índices estadísticos de los resultados de validación para los cuatro modelos analizados.....	166
Figura 8.26: Elección de los picos para el cálculo del PFC de los datos de validación	167
Figura 8.27: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza. Modelo SOM-MLP calibración	169
Figura 8.28: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza junto con las líneas de cuantiles del 5% y 95%. Datos de calibración del modelo SOM-MLP.....	169
Figura 8.29: Errores en función de los caudales predichos para los intervalos de confianza del 90% para los tres modelos	170
Figura 8.30: Errores en función de los caudales predichos para el cuantil del 50% de los tres modelos	171
Figura 8.31: Predicción a 10 días del modelo ARMAX para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	172
Figura 8.32: Predicción a 10 días del modelo MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior.....	173
Figura 8.33: Predicción a 10 días del modelo SOM-MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	174
Figura 8.34: Predicción a 10 días del modelo modular con separación de datos manual y redes MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	175
Figura 8.35: Esquema actual de las obras de control ubicadas sobre el río Neuquén (fuente: Valicenti, 2001).....	177
Figura 8.36: Foto de la sección de predicción en “Paso de los Indios”	178
Figura 8.37: Ubicación de la cuenca del Neuquén	178
Figura 8.38: Estimación de la distribución de la precipitación media anual en la cuenca	179
Figura 8.39: Distribución anual de la precipitación media mensual en la estación “Los Carrizos” y de los caudales medios mensuales en “Paso de los Indios”	180
Figura 8.40: Distribución anual de la precipitación media mensual en la estación “Los Carrizos” y de los caudales máximos mensuales en “Paso de los Indios”	180
Figura 8.41: Esquema de cálculo del gradiente para cada dirección de flujo	182
Figura 8.42: Códigos de direcciones de flujo	182
Figura 8.43: Direcciones de flujo en la cuenca del Neuquén hasta “Paso de los Indios”	183
Figura 8.44: Cálculo de las celdas drenantes acumuladas.....	183
Figura 8.45: Red de drenaje obtenida a partir del MDT 90 m x 90 m	184

Figura 8.46: Cuenca del río Neuquén hasta “Paso de los Indios”.....	186
Figura 8.47: Cuencas vertientes al río Neuquén	187
Figura 8.48: Cálculo del tiempo de concentración de la cuenca drenante a “Paso de los Indios”.....	188
Figura 8.49: Longitudes de drenaje a “Paso de los Indios”	188
Figura 8.50: Tiempos de concentración corregidos para cada punto de la cuenca.....	189
Figura 8.51: Sección del río en la estación de “Rahueco” obtenida del MDT 90 x 90 m	189
Figura 8.52: Sección del río en la estación de “Paso de los Indios” obtenida del MDT 90m x 90m	190
Figura 8.53: Sección tipo del río Neuquén entre “Paso de los Indios” y “Rahueco”	191
Figura 8.54: Cálculo del tiempo de respuesta para una sección media del cauce y un caudal dado.....	191
Figura 8.55: Tiempos de respuesta en función de los caudales	192
Figura 8.56: Estaciones de medición monitorizadas por la AIC.....	193
Figura 8.57: Series de datos de caudales en “Paso de los Indios” y precipitación en “Los Carrizos”.....	194
Figura 8.58: Ubicación de pluviómetros con datos en la cuenca de “Paso de los Indios”, en el entorno Fewes	195
Figura 8.59: Ejemplo de falta de datos (color magenta) en “Los Carrizos”, rellenado interpolando con la estación “Andacollo” y “Chos Malal”.....	195
Figura 8.60: Análisis de correlación cruzada. La escala de tiempo es de 6 horas. Caudal en “Paso de los Indios” (PasoQ) y caudal en “Rahueco” (RahuecoQ).....	196
Figura 8.61: Tiempos de desfase de los picos entre la estación de “Rahueco” y “Paso de los Indios”	197
Figura 8.62: Correlación cruzada a escala diaria entre la precipitación en “Los Carrizos” y los caudales medios diarios en “Paso de los Indios”.....	197
Figura 8.63: Análisis de las series. Caudal en “Paso de los Indios” (PasoQ), precipitación diaria en “Los Carrizos” (CarrizosP) y caudal en “Rahueco” (RahuecoQ)	198
Figura 8.64: Autocorrelación parcial. Escala de desfase seis horaria.....	199
Figura 8.65: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 00:00 h.....	200
Figura 8.66: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 06:00 h.....	200
Figura 8.67: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 12:00 h.....	200
Figura 8.68: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 18:00 h.....	200
Figura 8.69: Rango de tiempo (azul), donde los caudales en “Rahueco” aportan información sobre los caudales en “Paso de los Indios” en el tiempo t+4.....	201
Figura 8.70: Parámetros de la función de transformación elegida.....	202

Figura 8.71: Gráficas de distribución de probabilidades. De izquierda a derecha, de arriba abajo: caudales en la estación de “Paso de los Indios” ($sk = 1.45$), caudales en la estación de “Rahueco” ($sk = 1.67$) y precipitación acumulada en “Los Carrizos” ($sk = 2.10$).....	203
Figura 8.72: Red neuronal artificial MLP utilizada para predecir caudales en “Paso de los Indios” con una antelación de 24 horas. El intervalo de tiempo de los datos es de 6 horas	206
Figura 8.73: Paso 1. Predicción a $t+1$ de los caudales en “Paso de los Indios”	208
Figura 8.74: Paso 2. Predicción a $t+2$ de los caudales en “Paso de los Indios”, utilizando la predicción realizada en el paso 1 como variable de entrada.....	208
Figura 8.75: Paso 3. Predicción a $t+3$ de los caudales en “Paso de los Indios”, utilizando la predicción realizada en el paso 2 como variable de entrada.....	208
Figura 8.76: Paso 4 y último. Predicción a $t+4$ de los caudales en “Paso de los Indios”, utilizando la predicción realizada en el paso 3 como variable de entrada.....	208
Figura 8.77: Red auto-organizativa (SOM) utilizada para la clasificación de los datos de entrada.....	209
Figura 8.78: Distribución de las variables por grupo	210
Figura 8.79: Ejemplo de separación de grupos para el evento del 2006 en “Paso de los Indios”.....	210
Figura 8.80: Modelo modular SOM-MLP, para predicción de caudales a 1 día en “Paso de los Indios”	211
Figura 8.81: Índices estadísticos de los resultados de validación para los tres modelos analizados.....	213
Figura 8.82: Correlación cruzada entre los caudales predichos y los observados, para diferentes modelos	214
Figura 8.83: Elección de los picos, en la serie de validación, para el cálculo del coeficiente PFC.....	215
Figura 8.84: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza	216
Figura 8.85: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza junto con las líneas de cuantiles del 5% y 95%.....	217
Figura 8.86: Errores de predicción en función de los caudales predichos para los intervalos de confianza del 90% en los tres modelos.....	218
Figura 8.87: Errores de predicción en función de los caudales predichos para el cuantil del 50% en los tres modelos	218
Figura 8.88: Gráfica a escala normal para determinar la normalidad de la serie de los errores del modelo	219
Figura 8.89: Correlaciones cruzadas de la series de los errores del modelo con la de caudales en “Rahueco” (amarillo) y la de precipitación en “Los Carrizos” (morado)	220
Figura 8.90: Correlación cruzada entre la serie de los caudales en “Rahueco” y la de precipitación en “Los Carrizos” (morado). Con azul se muestra la auto-correlación de los caudales en “Rahueco”	220

Figura 8.91: Intervalos de confianza calculados con la metodología propuesta (rojo) y según metodología de los modelos estocásticos ARMAX (verde).....	222
Figura 8.92: Intervalos de confianza calculados con la metodología propuesta (rojo) y según metodología de los modelos estocásticos ARMAX (verde) en escala logarítmica.....	222
Figura 8.93: Errores de predicción en función de los caudales predichos, para los límites de confianza del 90%, calculados con la metodología propuesta, y en verde, según metodología de los modelos estocásticos ARMAX.....	223
Figura 8.94: Predicción a 1 día del modelo ARMAX para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	224
Figura 8.95: Predicción a 1 día del modelo MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	225
Figura 8.96: Predicción a 1 día del modelo SOM-MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior.....	226
Figura A. 1: Parámetros del modelo MLP del modelo del río Paraná.....	253
Figura A. 2: Parámetros del modelo ARMAX del modelo del río Paraná	253
Figura A. 3: Parámetros del modelo SOM del modelo del río Paraná.....	254
Figura A. 4: Parámetros del modelo MLP1 del modelo del río Paraná.....	254
Figura A. 5: Parámetros del modelo MLP2 del modelo del río Paraná.....	255
Figura A. 6: Parámetros del modelo MLP3 del modelo del río Paraná.....	255
Figura A. 7: Parámetros del modelo MLP4 del modelo del río Paraná.....	256
Figura A. 8: Parámetros del modelo MLP5 del modelo del río Paraná.....	256
Figura A. 9: Parámetros del modelo MLP6 del modelo del río Paraná.....	257
Figura A. 10: Discretización de picos para el cálculo del PFC en los datos de calibración ...	258
Figura A. 11: Índices de fiabilidad para los resultados de calibración del modelo ARMAX.....	258
Figura A. 12: Índices de fiabilidad para los resultados de calibración del modelo MLP	259
Figura A. 13: Índices de fiabilidad para los resultados de calibración del modelo SOM-MLP	259
Figura A. 14: Índices de fiabilidad para los resultados de calibración del modelo Manual-MLP	259
Figura A. 15: Predicción a 10 días del modelo ARMAX para el período de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior.....	260
Figura A. 16: Predicción a 10 días del modelo MLP para el período de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	261

Figura A. 17: Predicción a 10 días del modelo SOM-MLP para el período de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	262
Figura A. 18: Predicción a 10 días del modelo modular con separación manual y MLP para el período de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	263
Figura A. 19: Parámetros del modelo MLP para el río Neuquén	264
Figura A. 20: Parámetros del modelo ARMAX para el río Neuquén	264
Figura A. 21: Parámetros del modelo SOM para el río Neuquén.....	265
Figura A. 22: Parámetros del modelo MLP1 para modelo SOM del río Neuquén	265
Figura A. 23: Parámetros del modelo MLP2 para modelo SOM del río Neuquén	266
Figura A. 24: Parámetros del modelo MLP3 para modelo SOM del río Neuquén	266
Figura A. 25: Parámetros del modelo MLP4 para modelo SOM del río Neuquén	267
Figura A. 26: Discretización de picos para el cálculo del PFC en los datos de calibración del modelo del río Neuquén	268
Figura A. 27: Índices de fiabilidad para los resultados de calibración del modelo ARMAX del río Neuquén.....	268
Figura A. 28: Índices de fiabilidad para los resultados de calibración del modelo MLP del río Neuquén.....	269
Figura A. 29: Índices de fiabilidad para los resultados de calibración del modelo SOM-MLP del río Neuquén	269
Figura A. 30: Predicción a 1 día del modelo ARMAX para el período de calibración de la serie del río Neuquén. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	270
Figura A. 31: Predicción a 1 día del modelo MLP para el período de calibración de la serie del río Neuquén. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	271
Figura A. 32: Predicción a 1 día del modelo SOM-MLP para el período de calibración de la serie del río Neuquén. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior	272
Figura B. 1: Caudales observados en función de los caudales predichos de la serie de calibración. Intervalo de confianza del 90% entre las línea roja y magenta. La línea negra es la línea de predicción exacta y la línea azul, la de 50% de probabilidad. Las curvas circulares representan la función de densidad de probabilidad	273
Figura B. 2: Función de densidad bivariada entre caudales predichos y caudales observados (de calibración) con marginales lognormales	274

Figura B. 3: Azul caudal predicho, negro caudal observado (de datos de calibración), magenta y rojo intervalo de confianza del 90%	274
Figura B. 4: Caudales observados en función de los caudales predichos de la serie de validación. Intervalo de confianza del 90% entre las línea roja y magenta. La línea negra es la línea de predicción exacta y la línea azul, la de 50% de probabilidad. Las curvas circulares representan la función de densidad de probabilidad.....	275
Figura B. 5: Función de densidad bivariada entre caudales predichos y caudales observados (de validación) con marginales lognormales calculados con los datos de calibración.....	275
Figura B. 6: Caudal predicho (azul), caudal observado de datos de validación (negro), e intervalo de confianza del 90% (magenta y rojo)	276
Figura B. 7: Funciones de distribución de probabilidad para los caudales observados.....	277
Figura B. 8: Funciones de distribución de probabilidad para los caudales predichos	277
Figura B. 9: Gráficas de diferentes intervalos de confianza variando las funciones de densidad marginales de los caudales observados y predichos	282
Figura B. 10: Variación, a lo largo de los caudales predichos, de la diferencia entre el límite superior e inferior de los intervalos de confianza, calculados con diferentes funciones de distribución marginales	282

INTRODUCCIÓN

Capítulo 1

Capítulo 1

1 Introducción

1.1 Motivo e Introducción

La historia nos demuestra año tras año la importancia que tienen las predicciones de inundaciones en todo el mundo, ya que causan graves pérdidas económicas y personales. El desconocimiento de una posible inundación puede causar múltiples daños. Las inundaciones, en la mayoría de las catástrofes, no pueden ser evitadas pero, conociendo con suficiente tiempo de antelación la venida de fuertes inundaciones, se pueden minimizar las tragedias. Las siguientes citas de fuentes diversas nos demuestran que en la actualidad aún siguen ocurriendo catástrofes de enorme magnitud por todo el mundo.

“Al menos 22 personas, entre ellas seis niños, han muerto y miles han tenido que ser evacuadas en el oeste de Ucrania, donde lluvias torrenciales han ocasionado las peores inundaciones de los últimos 100 años...” [elperiódico.com]

“Al menos 11,500 personas han tenido que ser evacuadas de sus hogares a causa de las peores inundaciones registradas en Uruguay en 50 años...” [elpais.com]

“Las fuertes precipitaciones que se registran desde el sábado y las crecidas de los ríos del noreste de Estados Unidos ya dejaron por lo menos 12 muertos y obligaron a las autoridades a ordenar la evacuación de más de 200,000 personas en distintas zonas de la región...” [clarin.com]

“Santo Domingo.- Dos personas muertas y una desaparecida, así como 210 evacuadas y 42 viviendas inundadas fue el saldo dejado por los aguaceros que se registraron en el país, como consecuencia del paso de una activa onda tropical...” [Listindiario.com]

“Hanoi (Reuters) - Más de 80 personas murieron o están desaparecidas en tres provincias del norte de Vietnam, después de que la tormenta tropical Kammuri provocara intensas precipitaciones, deslaves e inundaciones...” [LaSemana.info]

“Un total de 280 personas podrían haber muerto en la pasada inundación en Tabasco, confirma el gobernador de la entidad...” [unafuente.com]

“Las lluvias que el fin de semana azotaron la isla de La Española, arrasando aldeas en la República Dominicana y Haití dejaron más de 1,000 muertos y millares de desaparecidos...” [telemundochicago.com]

Este tipo de problemas nos demuestran la importancia de los sistemas de alerta hidrológicos en tiempo real, que nos permiten conocer, con una cierta probabilidad, la venida de inundaciones. El tiempo necesario para que los organismos que se ocupan de la protección civil realicen sus tareas de prevención y evacuación, debe ser igual o menor que el horizonte de predicción de los caudales o calados.



Figura 1.1: Inundaciones en Tabasco (México), Noviembre 2007 (fuente: BlogSonora.com)

Existen muchos modelos para predecir caudales en tiempo real, cada uno con sus ventajas e inconvenientes. En esta tesis se proponen modelos que utilizan RNA por su fácil implementación en sistemas operativos que corren en tiempo real, y su comportamiento eficaz, rápido y flexible para todo tipo de cuencas. Estos modelos no sustituyen de ninguna forma a los conceptuales o físicamente basados, sino que son complementarios. No pueden representar las características distribuidas de la cuenca ni describir los procesos físicos generados en diferentes situaciones hidrológicas.

Por estos motivos se propone estudiar la utilización de un modelo modular que se encargue de resolver por separado cada proceso físico involucrado en el fenómeno de transformación de lluvia escurrentía. Para ello, se propone utilizar redes auto-organizativas de Kohonen (*SOM*) para la determinación de la situación hidrológica y redes neuronales artificiales del tipo perceptrón multicapa (*MLP*) para la modelación de cada proceso. Se obtiene, como resultado final, un valor puntual de caudal o calado para un determinado horizonte de tiempo junto con sus límites de confianza.

En los siguientes puntos se describen los objetivos de esta tesis, las aportaciones y la metodología utilizada para llevar a cabo dichos planteamientos.

1.2 Objetivos

El objetivo principal de esta tesis es desarrollar un modelo que permita predecir caudales en tiempo real, con la mayor precisión posible y con el conocimiento de su incertidumbre. Para ello se ha analizado el estado del arte de los modelos de predicción de caudales en tiempo real con RNA y, analizando las carencias existentes hasta la fecha, se han elegido unas metas que aporten mejoras al conocimiento de este arte. Los objetivos son:

- Desarrollar un modelo híbrido con un sistema automático de clasificación, que permita identificar, en tiempo real, la situación hidrológica de la cuenca y abordar cada situación con diferentes modelos expertos.
- Introducir una metodología para el cálculo de la incertidumbre de las predicciones obtenidas con cualquier tipo de modelo.
- Hacer una comparativa entre diferentes metodologías de predicción de caudales en tiempo real para dos casos de estudio.
- Proponer una guía metodológica para la obtención de un modelo óptimo de redes neuronales artificiales.
- Desarrollar un software innovador para la construcción de modelos de RNA, que resuelva las necesidades de un hidrólogo durante todo el proceso, desde el análisis de los datos y la cuenca, hasta el de los resultados. Ofreciendo al usuario la mayor flexibilidad posible y adaptación a cualquier sistema de ayuda a la decisión, permitiendo su ejecución en tiempo real y con el menor consumo de tiempo y recursos posible. También incorporar, junto a las predicciones, los límites de confianza con el nivel que el usuario desee.

1.3 Contribuciones

Como se ha mencionado en el apartado anterior, el objetivo de esta tesis es contribuir, en la medida de lo posible, a mejorar y aportar nuevas ideas a este arte que son los modelos de predicción de caudales en tiempo real utilizando RNA.

Esta metodología ha sido utilizada en aplicaciones hidrológicas desde principios de los 90 y desde entonces ha aumentado su uso y estudio por expertos e investigadores de todo el mundo.

Dadas las grandes posibilidades de esta metodología, sin quitar nunca importancia a los modelos conceptuales o físicamente basados, se pretende darle significado físico para que deje de considerarse un modelo de caja negra. La elección correcta de las variables de entrada a las RNA es crucial para la obtención de resultados óptimos. Por tanto, se utilizan conceptos hidrológicos para determinar cuáles son las variables predictoras más influyentes, reduciendo así la incertidumbre sobre los elementos de entrada.

Siguiendo con la intención de conferir un significado físico a este tipo de modelos, se plantea un nuevo modelo híbrido o modular. Éste identifica automáticamente el estado hidrológico de la cuenca al inicio de cada predicción y utiliza modelos expertos basados en RNA para resolver individualmente cada proceso físico generado durante la transformación de lluvia-escorrentía o la propagación de una onda de crecida.

Un valor único como resultado absoluto de un modelo no es útil en sistemas operativos donde hay que tomar decisiones relevantes sobre el futuro, ya que ningún modelo genera predicciones exactas. Presentan inevitablemente una incertidumbre que debe tenerse en cuenta en cualquier procedimiento de actuación. Por tanto es fundamental la incorporación de la incertidumbre en los resultados de los modelos, un hecho muy importante que en general no ha sido tenido en cuenta en las aplicaciones de redes neuronales artificiales. Esta tesis introduce una metodología universal capaz de calcular la incertidumbre en cualquier tipo de modelo, detectando posibles mejoras e invitando a futuros investigadores a profundizar sobre este tema tan importante y extenso.

Para facilitar la aplicación de las ideas planteadas en esta tesis se ha creado un novedoso software (ANN) capaz de unificarlas y emplearlas en situaciones reales. Este programa resuelve todos los problemas y casos planteados en esta tesis y, junto con una guía simple, ayudar al usuario a obtener el modelo óptimo. Se incluyen también consejos básicos a tener en cuenta en la elección del modelo y de las variables de entrada, que ayudarán al hidrólogo o modelador a darle significado físico al modelo.

1.4 Metodología

Las pautas metodológicas seguidas en la preparación y ejecución de esta tesis se iniciaron, una vez elegido el tema, con una amplia investigación bibliográfica y consulta de todo tipo de fuentes para determinar el estado del arte del tema a tratar. Esta etapa fue imprescindible para adquirir una visión global de la evolución de la metodología tratada e identificar cuáles son los principales problemas que existen en la actualidad.

Ya que, para que cualquier aportación a la ciencia sea novedosa, es necesario conocer en detalle todo lo investigado hasta el momento, pudiendo así tomar ideas de soluciones planteadas anteriormente, incorporar nuevas ideas no tenidas en cuenta o proponer soluciones no planteadas en ningún caso.

Analizando toda la información recopilada, se detectaron varias posibles líneas de investigación y, tomando en cuenta las más relevantes, se determinaron los objetivos a alcanzar en la tesis para contribuir a la evolución y mejora de la modelación con RNA aplicada a la predicción de caudales. Se distribuyó el trabajo por etapas, según las metas individuales y se comenzaron a estructurar los contenidos.

En este punto, se vio la necesidad de revisar de forma exhaustiva las fuentes especializadas y obtener datos que en un primer acercamiento pudieran haber pasado desapercibidos. A su vez se analizaron fuentes con métodos similares aplicados a otros temas como economía, biología, medicina, etc.

Una vez realizadas las consultas necesarias y ampliadas en varias direcciones la investigación, se desarrolló una propuesta de aplicación completa y detallada. Se probaron las hipótesis establecidas con dos casos de estudio diferentes para demostrar su viabilidad y, a partir de los resultados, se escribieron las conclusiones de la tesis. Por último, se abrió la posibilidad a nuevas líneas de investigación, con varias sugerencias extraídas de las conclusiones del proyecto.

La tesis está dividida en nueve capítulos con sus referencias y apéndices. En el Capítulo 1, además de la metodología, se incluyen una introducción general, los objetivos a desarrollar y las contribuciones aportadas.

En el Capítulo 2 se introducen los conceptos básicos de hidrología e hidráulica necesarios para el desarrollo de un modelo de predicción. Se mencionan y explican los procesos de generación de escorrentía, algunos conceptos de propagación de ondas en cauces, tipos de hidrogramas que nos ayudarán a identificar el tipo de cuenca a modelar, etc.

En el Capítulo 3 se describen las Redes Neuronales Artificiales (RNA), realizando una breve presentación, un resumen de su historia y una explicación más detallada de las RNA que se utilizan en esta tesis.

El Capítulo 4 trata acerca del estado del arte de la predicción de caudales o niveles con RNA. Se identifican diferentes líneas de investigación y se destacan varios puntos que fueron importantes durante el período del desarrollo e investigación de esta metodología.

El Capítulo 5 describe el modelo modular propuesto en la tesis con ideas para el desarrollo y la mejora del mismo.

En el Capítulo 6 se hace una revisión sobre diferentes metodologías utilizadas para el cálculo de la incertidumbre, describiendo más en detalle la metodología propuesta y extrayendo conclusiones para futuras investigaciones y mejoras.

El Capítulo 7 contiene una descripción del programa informático creado para realizar las aplicaciones de esta tesis, sirviendo dicha descripción como manual de uso.

El Capítulo 8 contiene el estudio de dos casos reales empleando la metodología propuesta, donde se comparan los resultados con los modelos ARMAX (modelo autorregresivo de media móvil con variable exógena) y se obtienen conclusiones que ayudarán a identificar los problemas de las metodologías propuestas al inicio de la tesis. Se desarrollan dos modelos de predicción, uno predice caudales a 10 días en una estación ubicada sobre el río Paraná (Argentina), y el otro predice caudales a 1 día en una estación sobre el río Neuquén (Argentina). En ambos casos se trata de grandes cuencas de 3,005,000 km² y 32,500 km², respectivamente.

Por último, en el Capítulo 9 se incluye un resumen de todas las conclusiones obtenidas en esta tesis y se introducen nuevas líneas de investigación.

CONCEPTOS BÁSICOS DE HIDROLOGÍA E HIDRÁULICA

Capítulo 2

Capítulo 2

2 Conceptos básicos de hidrología e hidráulica

2.1 Introducción

Las precipitaciones producen en las cuencas hidrográficas una respuesta que se caracteriza, tanto por la cantidad de agua que se infiltra en el subsuelo como por la que escurre por los cauces de su red de drenaje superficial.

La componente de infiltración varía en función de la permeabilidad de los suelos y de la permanencia del agua en el sitio. El tipo y uso del suelo y la cobertura vegetal son trascendentes en este aspecto. Los suelos compactos y desnudos contribuyen a generar una componente de escorrentía importante, mientras que los suelos sueltos y vegetados producen el efecto contrario.

La escorrentía esperable en un determinado punto de la cuenca no sólo es consecuencia del de la infiltración, sino que involucra varios elementos adicionales. La cobertura areal de la tormenta, el tipo de precipitación (lluvia y/o nieve), su intensidad y duración, conjuntamente con las variables físicas de la cuenca (geometría, relieve, etc.), la presencia de embalses naturales y las características del cauce, representan el conjunto de variables principales que rigen el fenómeno.

En la modelación de procesos hidrológicos e hidráulicos como los que se tratan en esta tesis es importante poseer algunos conceptos básicos de hidrología, a pesar de que no todos los modelos utilizados requieren una componente conceptual. Esta componente es introducida por el modelador, al elegir el tipo de modelo y las variables a utilizar. Para ello, es necesario conocer una serie de conceptos que se presentan en este capítulo.

En el primer apartado de este capítulo se describen los tipos de flujo que se generan en un proceso de transformación de lluvia escorrentía, lo cual es importante, ya que cada uno involucra un proceso físico diferente. Esto nos ayudará a entender los procesos físicos y las variables que intervienen en cada una de las etapas de transformación, las cuales no son fácilmente separables. Luego se explican diferentes mecanismos de generación de escorrentía junto con los tipos de hidrogramas que se pueden encontrar, según el tipo de cuenca y clima. Finalmente se comenta brevemente el mecanismo de propagación de una onda cinemática de crecida en un cauce natural.

2.2 Tipos de flujo

El camino seguido por una gota de agua, desde el momento en el cual alcanza la tierra hasta que llega al cauce de una corriente, es incierto. El fenómeno físico que produce la escorrentía en una cuenca es muy complejo. El conocimiento de estos fenómenos físicos principales es limitado, por lo tanto conviene imaginar tres caminos principales: escorrentía superficial, escorrentía sub superficial o interflujo y flujo base o escorrentía subterránea (ver Figura 2.2).

Un hidrograma típico resultante de un período aislado de lluvia consta de una rama ascendente, un segmento de cresta y una rama descendente o recesión como el que se muestra en la Figura 2.1.

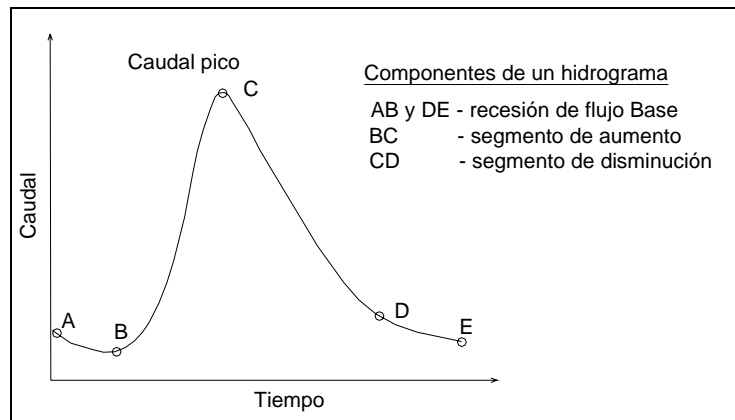


Figura 2.1: Componentes de un hidrograma

La forma de la rama ascendente está influenciada principalmente por las características de la lluvia que causa el ascenso. Se supone generalmente que el punto de inflexión en el lado descendente del hidrograma coincide con el tiempo a partir del cual cesa la escorrentía superficial hacia el sistema de canales. De ahí en adelante, la curva de recesión representa el aporte de agua almacenada dentro de la cuenca. La forma de la recesión es bastante independiente de las características de la lluvia que causa el ascenso. En cuencas grandes, en las cuales la escorrentía que produce una lluvia se genera únicamente sobre una parte del área, la recesión puede variar de una tormenta a otra, dependiendo del área particular que genera escorrentía. Si la lluvia ocurre durante la recesión de una tormenta anterior, puede esperarse que la recesión se distorsione [Linsley et al., 1988].

La *escorrentía superficial* viaja sobre la superficie del terreno a través de los canales al punto de salida de la cuenca. La palabra canal, tal como se utiliza aquí, hace referencia a cualquier depresión que pueda transportar una pequeña corriente de agua en flujo turbulento durante una lluvia y durante un período corto después de su terminación.

La descripción de los tipos de flujo se puede apreciar en la Figura 2.2. El flujo va del punto (1) al (2) y puede estar compuesto por: flujo sobre ladera y flujo en canal. La parte de escorrentía superficial que escurre sobre el terreno hacia los canales se denomina escorrentía sobre ladera. La escorrentía superficial ocurre cuando la intensidad de precipitación supera las demandas iniciales de interceptación, infiltración y capacidad de almacenaje de la superficie. Ésta varía durante la tormenta y puede disminuir a lo largo de la misma o en su etapa final. Como la escorrentía superficial fluye hacia la salida de la cuenca, una parte de ella es infiltrada al suelo o en el lecho del canal. La infiltración que se produce en el canal se denomina pérdidas por transmisión. Esta situación es muy común en zonas áridas, semiáridas y zonas de clima sub-húmedo. De hecho, estas pérdidas pueden ser tan grandes como para eliminar totalmente la escorrentía superficial. La distancia de viaje entre (3) y (4) depende de la cantidad de escorrentía superficial, de las condiciones de humedad del suelo y de la fisiografía de la cuenca [Vijay, 1988].




Figura 2.2: Componentes de escorrentía

La *escorrentía sub-superficial* representa la porción de precipitación infiltrada que se mueve lateralmente a través de las capas de suelo superiores hasta alcanzar el cauce. Como se observa en la Figura 2.2(c) el agua infiltrada en (5) vuelve a la superficie en el punto (6) continuando como escorrentía superficial hasta (7). Dicha agua se mueve más lentamente que en la escorrentía superficial y puede unirse a esta durante o después de la tormenta. La proporción de escorrentía sub-superficial en el flujo del canal depende de las características geológicas de la cuenca y de las propiedades de espacio-tiempo de la precipitación. Ésta se encuentra generalmente en climas húmedos y en cuencas con altas capacidades de infiltración y pendientes moderadas y altas [Vijay, 1988].

El *flujo base o escorrentía subterránea* es la parte de agua infiltrada que llega al nivel freático y luego descarga al cauce. Como se ve en la Figura 2.2(d), el agua que entra en el punto (8) va directamente al nivel freático y luego entra al río en el punto (9). Este tipo de flujo se mueve mucho más lento y tiene poco efecto en el caudal pico en cuencas pequeñas, depende de la permeabilidad del suelo. La respuesta del flujo base varía mucho de un tipo de aguas subterráneas a otro [Vijay, 1988].

Estas componentes de escorrentía pueden no aparecer siempre en una cuenca. Por ejemplo, en cuencas pequeñas de zonas áridas se produce casi siempre escorrentía superficial. En áreas húmedas, la escorrentía sub-superficial es la que predomina. Por otro lado, una sucesión larga de tormentas puede producir escorrentía sub-superficial y hasta flujo base en zonas áridas. Por lo tanto, el tipo de escorrentía que ocurre en una cuenca se determina a partir de una combinación de factores climáticos y fisiográficos junto con las características de espacio y tiempo de la precipitación.

A pesar de que estas componentes de escorrentía se originan debido a fuentes diversas o tienen diferentes caminos de viaje, la distinción entre ellas permanece arbitraria. En el curso del recorrido del agua, los componentes de escorrentía pueden tener caminos cruzados y cambiar de forma. Por ejemplo, el interflujo puede subir a la superficie durante parte de su recorrido y aparecer como escorrentía superficial. De igual forma, dependiendo de las formaciones geológicas, el flujo base y el interflujo pueden compartir parte de sus características. Por lo tanto, en la práctica puede ser muy difícil separar estos componentes con precisión. Esto puede explicar en parte la división arbitraria que se hace entre flujo directo y flujo base. Se considera que el flujo directo consiste en escorrentía superficial, y el flujo base consiste en interflujo retrasado y escorrentía subterránea.

En un hidrograma típico como el mostrado en la Figura 2.3 se distinguen dos partes: la escorrentía directa y el flujo base. La parte más baja del hidrograma, que ocurre muy pocas veces, está sujeta a un cambio gradual a lo largo del año; se refiere al flujo base. La parte de rápida fluctuación, que representa la respuesta inmediata a la precipitación, se refiere al flujo directo.

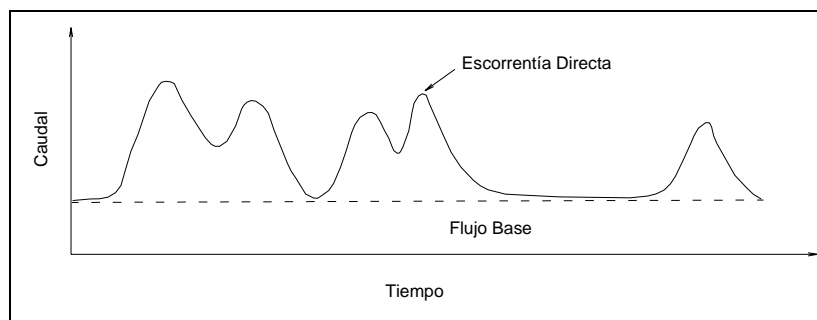


Figura 2.3 Hidrograma típico

Como se ha dicho anteriormente, la separación del flujo directo y el flujo base se hace de una manera totalmente arbitraria. Hay varios métodos en la literatura hidrológica para la separación de las partes de un hidrograma. Dos ejemplos muy simples se muestran en la Figura 2.4. En uno, el flujo base se representa por ABC , donde AB y BC se dibujan tangentes al comienzo del ascenso del hidrograma y del fin de la recesión, respectivamente. En el otro método, el flujo base representado por ADE se asume simplemente constante. De este modo se comprueba que el flujo base puede ser separado de maneras totalmente arbitrarias.




Figura 2.4: Dos métodos muy simples para la separación de las partes de un hidrograma

El flujo directo está influenciado directamente por la precipitación efectiva. La diferencia entre precipitación efectiva y precipitación en exceso es que la primera incluye la última más las abstracciones o pérdidas. Se considera que las tormentas están compuestas por dos partes: una que contribuye a la escorrentía y la otra a las abstracciones, incluyendo intercepción, evaporación, transpiración e infiltración. Como la precipitación efectiva se transforma totalmente en escorrentía directa, su volumen debe igualarse al volumen de escorrentía superficial.

Para un hidrograma dado, el volumen de escorrentía directa se determina separando el flujo base. Así se obtiene el volumen de precipitación efectiva, que se calcula sustrayendo el volumen de escorrentía distribuido en el tiempo (determinación de la función de pérdidas) y la intensidad de precipitación. Debido a la alta heterogeneidad en las condiciones antecedentes, la extrapolación de esta función de pérdidas a otros eventos de precipitación es extremadamente difícil. La función de pérdidas se puede determinar de diferentes formas. La precisión de la determinación de esta función es fundamental para la modelación hidrológica de una cuenca [Chow et al., 1994].

2.3 Mecanismos de generación de escorrentía

Los factores que controlan la generación de escorrentía son: el clima, la geología, la topografía, las características del suelo, la vegetación y los usos del suelo. La importancia relativa de cada factor varía en el tiempo y el espacio. Según las características físicas de los suelos y la cobertura de vegetación (el denominado complejo suelo-vegetación), así como las características climáticas de una cuenca, las diversas variables que intervienen en la infiltración tendrán una importancia u otra, dando lugar a distintos mecanismos de formación de escorrentía superficial. Los más conocidos son el denominado mecanismo de Horton, el de exceso de saturación o Dunne y el del de flujo sub-superficial.

2.3.1 Mecanismo Hortoniano

Para la elaboración de su teoría, Horton (1933) parte de tres premisas [Ward y Robinson, 1990]:

- La superficie del suelo actúa como un plano completamente separado de la atmósfera (no existe ninguna zona de transición).
- El suelo es homogéneo.
- La capacidad de infiltración de los suelos es una variable fácilmente medible (aunque no tiene en cuenta de las dificultades que existen al pasar de una medición puntual a una areal). Una vez conocida, junto con la intensidad de precipitación se puede calcular fácilmente la escorrentía superficial.

En una cuenca de estas características, al inicio de un evento de precipitación, toda el agua que precipita penetra en el suelo, se infiltra. La velocidad a la que se infiltra (f) en esos momentos es relativamente elevada y se conoce como la tasa de infiltración inicial (f_0). Esta tasa, poco a poco, va disminuyendo hasta llegar a una tasa mínima constante (f_c) que se mantiene durante todo el evento. La escorrentía se produce cuando la intensidad de la precipitación es mayor que la tasa de infiltración.




Figura 2.5: Esquema de la escorrentía hortoniana: a) generación y b) evolución de la tasa de infiltración

Para Colosimo y Mendicino (1996), el mecanismo de escorrentía hortoniana es básicamente función de la variación espacial de la precipitación, de las características de los suelos y del contenido inicial de humedad del suelo. Su formación conlleva un rápido aumento y descenso de los caudales en el hidrograma, aunque no siempre es así, en algunas zonas boscosas carecen de escorrentía superficial pero presentan picos en los hidrogramas debido al flujo sub-superficial.

Este mecanismo otorga más importancia al flujo en superficie desde áreas parciales, donde el suelo se satura en la superficie desde arriba, debido a intensidades de precipitación que superan la capacidad de infiltración. Estas áreas se controlan con la distribución de los tipos de suelo. En este mecanismo se pueden ver las interacciones dinámicas entre el flujo en superficie y el flujo subsuperficial.

Despreciando la interceptación por vegetación, la escorrentía superficial es aquella parte de lluvia no absorbida por el suelo mediante la infiltración. Si el suelo tiene una capacidad de infiltración f , entonces, cuando la intensidad de lluvia i es menor que f , la lluvia se absorbe completamente y no existe escorrentía superficial. Se puede decir en una primera aproximación que si i es mayor que f , la escorrentía superficial ocurrirá a una tasa de $(i - f)$, a esta diferencia se le llama “exceso de lluvia”. Horton consideró que la escorrentía superficial tomaba la forma de un flujo en láminas y, a medida que el flujo se acumulaba moviéndose a lo largo de la pendiente, su profundidad aumentaba hasta que la descargaba al canal. En el flujo superficial existe un almacenamiento en las depresiones de la superficie y otro por detención superficial proporcional a la profundidad del mismo flujo superficial. El suelo almacena el agua infiltrada y luego la libera lentamente como flujo sub-superficial para entrar en la corriente como flujo base durante los períodos secos.

El flujo hortoniano es aplicable a superficies impermeables en áreas urbanas y en superficies naturales con capas delgadas de suelo y baja capacidad de infiltración, como ocurre en tierras semiáridas. Este mecanismo ocurre rara vez en zonas con superficies húmedas y abundante vegetación [Chow et al., 1994].

2.3.2 Mecanismo de Dunne-Black o flujo superficial de saturación

El mecanismo de formación de escorrentía por exceso de saturación se produce cuando el suelo presenta un nivel muy elevado de saturación de agua, bien debido a la existencia de flujos de agua sub-superficial (lo que se conoce como el mecanismo de Dunne, 1978), bien porque el nivel freático está muy elevado [Hewlett, 1961]. En ambos casos, cuando existe precipitación, el suelo apenas puede absorber más agua de la que ya contiene, por lo que inicia la escorrentía sin darse apenas infiltración. Las variables que principalmente condicionan este tipo de escorrentía son la topografía de la superficie y la posición del nivel freático [Colosimo y Mendicino, 1996].




Figura 2.6: Generación de la escorrentía por exceso de saturación o mecanismo Dunne

Durante los últimos años, varios autores [Todini, 1996 y Liu y Todini, 2002] han señalado la importancia que tiene el hecho de que la formación de escorrentía por este mecanismo no se produce de una manera general por toda la cuenca, sino únicamente en algunas áreas (es lo que algunos autores denominan las áreas contribuyentes variables). Las más propensas a formar parte de dichas áreas contribuyentes variables son las siguientes [Beven y Kirby, 1979]:

- Áreas próximas a los cauces de los ríos, donde el nivel freático está más próximo a la superficie. Estas áreas se incrementan poco a poco a medida que la precipitación continúa.
- Áreas de las laderas en forma cóncava, donde se acumula más rápidamente agua y aumentan de prisa los niveles freáticos.
- Áreas con suelos poco profundos, donde la capacidad de almacenamiento de agua y de transmisividad es baja y rápidamente se llega al estado de saturación del suelo.

Al igual que estas áreas de aportación de escorrentía van aumentando a medida que transcurre la precipitación, una vez ésta acaba, la extensión de dichas zonas disminuye. La importancia de esta diversificación de áreas contribuyentes de escorrentía es reflejada en Nachabe et al., 1997, donde se analiza cómo la diferente distribución de dichas áreas da origen a distintos hidrogramas de crecida.

El flujo superficial se genera por precipitación en áreas contribuyentes variables adyacentes a los canales. Ocurre cuando el suelo se satura en la superficie desde abajo, aumentando el nivel freático. La topografía y las configuraciones hidrogeológicas de las pendientes de las colinas controlan estas áreas de fuentes variables.




Figura 2.7: Mecanismo Dunni de generación de escorrentía

La expresión áreas contribuyentes variables, es utilizada por los hidrólogos para denominar el área en la cuenca que realmente contribuye con el flujo a una corriente en cualquier momento. Éste área se expande durante una tormenta y disminuye después de finalizada. En la Figura 2.7 se representa un ejemplo de cómo se producen estas áreas contribuyentes variables según un mecanismo basado en el flujo superficial de saturación. Las pequeñas flechas en los hidrogramas muestran como se incrementa el caudal a medida que las áreas de fuente variable se extienden a pantanos, suelos pocos profundos y canales efímeros. El proceso se invierte a medida que el caudal declina.

El flujo superficial de saturación se produce cuando el flujo sub-superficial satura el suelo cerca de la parte inferior de la pendiente, entonces se presenta el flujo superficial, a medida que la lluvia cae en el suelo saturado. El flujo superficial difiere del hortoniano en que, en este último, el suelo se satura desde arriba mediante infiltración,

mientras que en el flujo superficial de saturación o dunniano el suelo se satura desde abajo por un flujo sub superficial. El flujo superficial de saturación ocurre con más frecuencia en la parte inferior de las colinas cerca del cauce. La velocidad del flujo sub-superficial es tan baja que no todo él o el flujo superficial de saturación contribuyen a incrementar la corriente durante una tormenta [Chow et al., 1994].

2.3.3 Mecanismo de flujo sub-superficial

El flujo sub-superficial (interflujo y flujo subterráneo) lleva el agua directamente al cauce de flujo permanente o a una red de canales intermitentes de áreas de fuentes variables. La hidrogeología controla el sistema de flujo sub-superficial. La recarga a las aguas subterráneas se controla por las zonas no saturadas sobre ellas.

Bajo condiciones húmedas en zonas con vegetación, la capacidad de infiltración del suelo excede las intensidades de lluvia observadas para todos los casos, con excepción de las lluvias extremas. En esta situación, el flujo sub-superficial se convierte en el mecanismo primordial de transporte de agua hacia los cauces. Las velocidades de flujo sub-superficial son normalmente tan bajas, que por si solo no puede contribuir en forma significativa a transmitir la precipitación directamente al flujo de la corriente, excepto bajo circunstancias especiales en que la conductividad hidráulica del suelo sea muy alta. Sin embargo, el flujo a través de las raíces en un terreno boscoso puede ser más rápido que el flujo a través de la masa de suelo adyacente [Chow et al., 1994].

2.4 Tipos de hidrogramas

Hay diferentes tipos de hidrogramas anuales dependiendo de las zonas, climas y mecanismos de generación de la escorrentía. Éstos pueden variar mucho entre zonas húmedas y áridas y también entre hidrogramas de cuencas alimentadas principalmente por el derretimiento de la nieve. A continuación se muestran tres claros ejemplos donde pueden apreciarse estas diferencias.

El hidrograma de la Figura 2.8 presenta régimen perenne o de flujo continuo, característico de climas húmedos. Los picos que se originan por las tormentas se conocen como escorrentía directa o flujo rápido, mientras que el flujo con pocas variaciones en los períodos sin lluvia se llama flujo base. El volumen total de flujo bajo el hidrograma anual es la capacidad de la cuenca. La mayor parte de la capacidad de la cuenca proviene del flujo base para un río con flujo perenne, lo cual indica que una gran proporción de la lluvia se infiltra en la cuenca y alcanza al río como flujo sub-superficial.




Figura 2.8: Hidrograma típico de climas húmedos. Flujo continuo (fuente: Chow et al., 1994)

La Figura 2.9 es un ejemplo de un río efímero en un clima árido. Existen largos períodos durante los cuales el río está seco. La mayor parte de la lluvia se convierte en escorrentía directa y presenta muy poca infiltración. En este caso, la capacidad de la cuenca es el resultado de la escorrentía directa de grandes tormentas.




Figura 2.9: Hidrograma típico de climas áridos. Río efímero (fuente: Chow et al., 1994)

La Figura 2.10 muestra un hidrograma típico de un río que se alimenta por el derretimiento de la nieve. La mayor parte del flujo ocurre en la primavera y a comienzos del verano, debido al derretimiento. El gran volumen de agua que se almacena en forma de nieve, junto con su permanente salida, configuran un hidrograma anual que varía de forma más suave, a lo largo del año, que los otros hidrogramas indicados anteriormente [Chow et al., 1994].




Figura 2.10: Hidrograma típico de escorrentía alimentada por el derretimiento de la nieve (fuente: Chow et al., 1994)

El aspecto de los hidrogramas depende también de la forma de la cuenca. Por ejemplo, en la

Figura 2.11 y en la Figura 2.12 se esquematizan los hidrogramas de cuatro cuencas hidrológicas con la misma superficie y elevación, pero con diferente forma y red hidrográfica. En las figuras se observa que también el tiempo al pico de hidrograma está condicionado por la forma de la cuenca. Con una misma área de cuenca, cuanto menor sea la dimensión transversal, mayor será la longitud del cauce principal de la cuenca, menor el caudal pico y mayor el tiempo para alcanzarlo (ver

Figura 2.11), cuanto mayor sea la dimensión transversal en la proximidad del desagüe de la cuenca, menor será el tiempo al pico y mayor el caudal máximo(Figura 2.12).

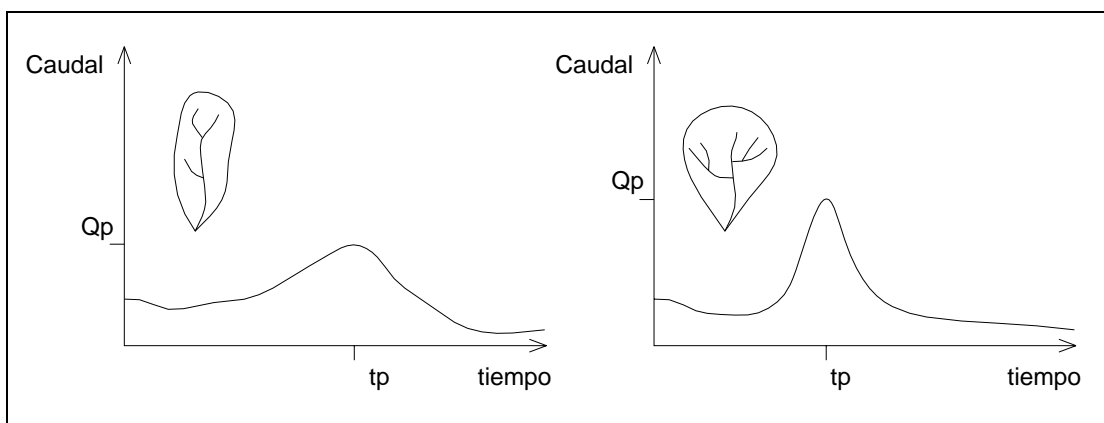


Figura 2.11: Ejemplo de diferentes respuestas hidrológicas en función de la forma de la cuenca (fuente: redibujo de Grepí, 2005)




Figura 2.12: Ejemplo de diferentes respuestas hidrológicas en función de la forma de la cuenca (fuente: redibujo de Grepí, 2005)

2.5 Propagación de una onda de crecida en un cauce

Los ingenieros hidráulicos y los matemáticos han estudiado durante más de 100 años la celeridad (c) y la forma de las ondas gravitacionales. Debido a la gran complejidad del fenómeno, los estudios se han restringido en general a ondas de aguas llanas, es decir, ondas con una longitud (l) bastante mayor que la profundidad (y), lo que produce resultados que pueden ser válidos para canales y ríos [Irving, 1995].




Figura 2.13: Celeridad de la onda c (fuente: Irving, 1995)

Se reconocen dos aproximaciones para la propagación de una onda en un cauce, el método hidrológico y el hidráulico. El hidrológico está basado en el concepto de almacenamiento y el hidráulico, en los principios de conservación de la masa y el momento. Para este último existen tres tipos de técnicas: onda cinemática, onda de difusión y onda dinámica. El de onda dinámica es el modelo más completo de flujo no permanente en canales abiertos. Los métodos de onda cinemática y de difusión son aproximaciones prácticas y convenientes a la onda dinámica. Otro método alternativo al hidrológico e hidráulico es el método híbrido Muskingum Cunge, 1930, basado en la ecuación diferencial de almacenamiento [Ponce, 1989].

En este capítulo se emplea únicamente el método de onda cinemática para el cálculo del tiempo de viaje de una onda de crecida entre dos secciones de un cauce.

Este método es el más simplificado y plantea como hipótesis tomar solamente en cuenta la fricción y la gravedad, excluyendo de la ecuación de conservación de momento, términos de inercia convectiva, gradiente de presión y los términos de fuentes de momentum [Ponce, 1989].

En flujo uniforme en canales abiertos, la fórmula de Manning describe al caudal como:

$$Q = A \frac{1}{n} R^{2/3} \sqrt{S_f} \quad [2.1]$$

donde Q es el caudal, A el área mojada de la sección, R (A/P) el radio hidráulico, P el perímetro mojado de la sección, n el coeficiente de rugosidad de manning y S_f la pendiente del fondo [Ponce, 1989].

Reemplazando la ecuación de radio hidráulico en [2.1] se obtiene:

$$Q = A^{5/3} \frac{1}{n} \frac{1}{P^{2/3}} \sqrt{S_f} \quad [2.2]$$

suponiendo que la pendiente (S_f) es constante y el perímetro (P) también (con la hipótesis de canales suficientemente anchos se asume que P es independiente de A).

$$Q = \alpha A^\beta \quad [2.3]$$

Diferenciando Q con respecto a A se obtiene:

$$c = \frac{dQ}{dA} = \beta \frac{Q}{A} = \beta V = \frac{5}{3} V \quad [2.4]$$

donde V es la velocidad media del agua y c la celeridad de la onda cinemática.

Partiendo de la ecuación de la conservación de la masa:

$$\frac{dA}{dt} + \frac{dQ}{dx} = 0 \quad [2.5]$$

y multiplicando por la ec. [2.4], la ecuación de la onda cinemática se expresa como:

$$\frac{dQ}{dt} + (\beta V) \frac{dQ}{dx} = 0 \quad [2.6]$$

Esta ecuación describe el movimiento de las ondas cinemáticas donde se desprecia la inercia y el gradiente de presión (profundidad del flujo). La onda cinemática viaja con una velocidad βV y no se atenúa [Ponce, 1989].

Los valores teóricos de β a demás de $5/3$ se pueden obtener para otro tipo de secciones. Para flujo turbulento gobernado por la ecuación de Manning, presenta un límite superior a $5/3$ y, generalmente, no es menor a 1. Para flujo laminar en canales anchos es igual a 3, para flujos mixtos entre laminar y turbulento está entre $5/3$ y 3 [Ponce, 1989].

Para la aplicabilidad de este método se debe cumplir la siguiente expresión:

$$\frac{tSV}{h} > 85$$

[2.7]

donde t es el tiempo que tarda el hidrograma de entrada en subir, S la pendiente media del cauce, V la velocidad media, y h el calado medio.

El tiempo de viaje que tarda una onda de crecida, para un determinado caudal, en recorrer una cierta distancia teniendo en cuenta la onda cinemática, es:

$$t = \frac{L}{c}$$

[2.8]

donde L es la longitud entre dos secciones y c la celeridad de la onda cinemática.

INTRODUCCIÓN A LAS REDES NEURONALES ARTIFICIALES

Capítulo 3

Capítulo 3

3 Introducción a las Redes Neuronales Artificiales

3.1 Introducción

Antes de empezar a hablar de redes neuronales es necesario conocer un poco más acerca de sus orígenes y su historia. Por esta causa se hace en este capítulo una breve descripción de las mismas, junto con un resumen de su historia y sus orígenes. Se mencionan también sus ventajas y se describen en los últimos apartados las redes neuronales artificiales que se utilizarán en esta tesis.

3.2 Sus orígenes

Las Redes Neuronales Artificiales (RNA) surgieron de la observación del funcionamiento del cerebro y de su comparación con la forma de trabajar de los ordenadores digitales. Los elementos estructurales del cerebro, las neuronas biológicas [Ramón y Cajal, 1911], son unos seis órdenes de magnitud más lentas que las puertas lógicas de silicio, ofreciendo tiempos de respuesta del orden del milisegundo, frente a los vertiginosos tiempos de respuesta del orden del nanosegundo que alcanzan ciertos dispositivos digitales actuales.

Esta relativa lentitud no impide al cerebro realizar ciertas funciones habituales, como son las tareas de reconocimiento, percepción y control motriz, con una eficacia y rapidez fuera del alcance del mejor ordenador digital. Esta supremacía le viene dada por la alta complejidad de su estructura, formada por un elevado número de células nerviosas (neuronas) masivamente interconectadas y funcionando en paralelo. Se estima que el número de neuronas en el córtex humano es del orden de diez millares de millones (10^{10}), y que el número de sinapsis o conexiones es del orden de 60 billones (60×10^{12}). La alta complejidad de esta estructura biológica no sería operativa si no fuese además eficiente. La eficiencia energética del cerebro es aproximadamente de 10^{-16} julios por operación por segundo, mientras que los mejores ordenadores no superan los 10^{-6} julios por operación por segundo [Faggin, 1991].

Al nacer, el cerebro ya tiene gran parte de su estructura formada y lo que es más importante, está dotado de los mecanismos necesarios para construir sus propias reglas a través de lo que conocemos como “experiencia”. Este proceso de aprendizaje se extiende a lo largo de los años, aunque el desarrollo más espectacular tiene lugar durante los dos primeros años de vida,

cuando se forman alrededor de un millón de sinapsis por segundo. La adaptación del sistema nervioso a su entorno sigue dos mecanismos distintos en un cerebro adulto: la creación de nuevas conexiones sinápticas y la modificación de las conexiones existentes.

Podemos pues, concluir que el cerebro humano es una estructura compleja, no lineal y paralela de tratamiento de información que almacena su conocimiento en las conexiones que ligan a sus elementos de proceso (neuronas) y que es capaz de adaptarse a su entorno. Las RNA están inspiradas de la estructura del cerebro y fueron concebidas para resolver cierto tipo de problemas especialmente mal resueltos por las técnicas de programación tradicionales. Formalmente, Computación Neuronal es la disciplina tecnológica que trata sistemas paralelos y adaptativos de procesamiento de información distribuida, que desarrollan sus capacidades bajo la exposición a un entorno de información.

Esta definición muestra claramente el paralelismo entre la estructura cerebral biológica y las RNA. Esta similitud ha motivado a muchos investigadores de diversos campos de la ciencia a profundizar en la interpretación biológica de las RNA, proponiendo nuevas estructuras conexionistas y estrategias de aprendizaje directamente inspiradas de la modelización del cerebro. Dichos estudios han dado resultados sumamente interesantes en el campo de las RNA, pero desde un punto de vista subjetivo, lo más importante de ellos es el conocimiento que directa o indirectamente están aportando para esclarecer los complejos procesos de aprendizaje, percepción y gestión del conocimiento que tienen lugar en el cerebro humano.

Robert Hecht Nielsen [Hecht-Nielsen, 1990] realiza una definición más concreta de las redes neuronales artificiales:




Figura 3.1: Estructura general de una red neuronal artificial (fuente: Muñoz, 1996)

“Una red neuronal artificial es una estructura de procesamiento paralelo de información distribuida, bajo forma de grafo orientado (en matemáticas se denomina grafo a un conjunto de objetos unidos por enlaces que permiten representar relaciones binarias entre elementos del mismo) con las siguientes definiciones y restricciones (ver Figura 3.1):

- Los nodos del grafo son llamados nodos o neuronas.
- Las uniones del grafo son llamadas conexiones (unidireccionales e instantáneas).
- Se admite cualquier número de conexiones de entrada.
- Cada neurona sólo puede tener una señal de salida, que puede ramificarse en cualquier número de conexiones de salida.
- Las neuronas pueden tener memoria local.
- Cada neurona tiene una función de transferencia con la capacidad de utilizar y alterar la memoria local, puede usar las señales de entrada, y produce la señal de salida. La función de transferencia puede actuar de forma continua o discreta en el tiempo. Si actúa de forma discreta, existirá una entrada de estímulo que active la aplicación de la función de transferencia proveniente de la unidad de control de la red neuronal artificial”.

La Figura 3.2 muestra el esquema general de una neurona.

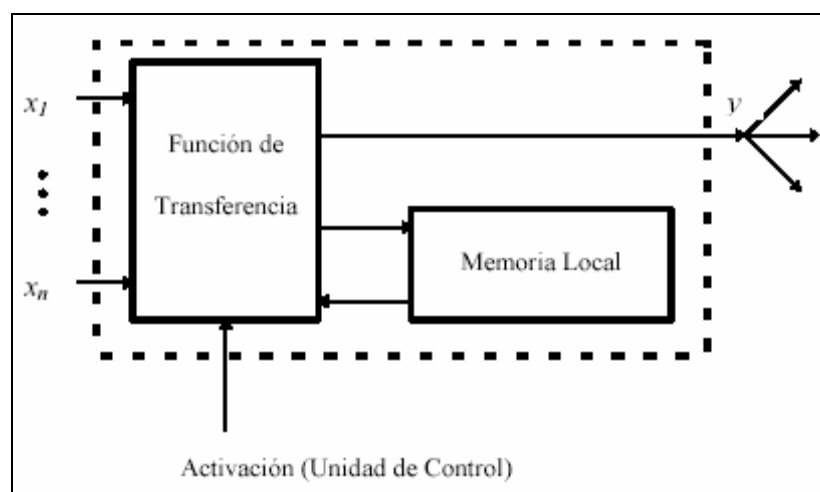


Figura 3.2: Estructura de una neurona (fuente: Muñoz, 1996)

Podemos pues, concluir que las RNA son estructuras adaptativas de procesamiento de información inspiradas en la estructura cerebral, donde el procesamiento se lleva a cabo mediante

la interconexión de neuronas. Esta arquitectura da lugar a estructuras altamente paralelizables, donde el flujo de información no sigue un camino secuencial, sino que se distribuye a través de las conexiones de las neuronas donde es tratada la información.

Durante la fase de aprendizaje, la red neuronal artificial se expone a un entorno de información para que pueda adaptar sus pesos (parámetros libres que dan forma a las funciones de transferencia de sus neuronas o nodos) y posiblemente también su estructura. Durante la fase de evaluación, los pesos de la red se mantienen fijos y la RNA se limita a tratar la información de entrada que se le suministra.

3.3 Su historia

Los comienzos

- **S. XIX** Se plantea a nivel teórico la posibilidad de modelar la fisiología del cerebro, teniendo como objetivo la creación de un modelo capaz de reproducir procesos del razonamiento humano.

- **1943** Warren Mc Culloch y Walter Pitts publican la formalización de la descripción de una neurona artificial que sigue siendo hoy en día elemento constitutivo de las redes neuronales artificiales más complejas. No contemplan, sin embargo aplicaciones prácticas.

- **1949** Donald Hebb publica "La organización del comportamiento", donde afirma que el condicionamiento psicológico es una propiedad de las neuronas a nivel individual. Propone una ley de aprendizaje que le permite explicar cualitativamente algunos ejemplos experimentales de carácter psicológico.

- **1951** Marvin Minsky construye el primer neurocomputador (*Snark*). Resulta un éxito desde el punto de vista técnico, pues ajusta automáticamente sus pesos, pero no se llega a darle ninguna aplicación práctica.

Primeros éxitos

- **1957-1958** Frank Rosenblatt, Charles Whightman y otros, construyen el primer neurocomputador (*Mark I Perceptron*) con aplicación práctica al reconocimiento de patrones. Rosenblatt publica "Principios de Neurodinámica".

- **1960** Bernard Widrow y Marcian E. Hoff desarrollan la ADALINE y la dotan de una potente ley de aprendizaje con una aplicación muy extensa a lo largo del tiempo. Widrow funda también la "*Memistor Corporation*".

Etapa de crisis

La falta de rigor analítico que se produjo al basar todos los trabajos en la mera experimentación, unida a un entusiasmo descontrolado, constituyen el origen de esta etapa.

- **1969** Minsky y Papert publican "*Perceptrons*", donde se prueba que un perceptrón no puede resolver problemas linealmente no separables, como es el caso de la función XOR. Llevan a cabo una verdadera campaña anti redes neuronales artificiales.

Momentos de silencio

- **1967-1982** La investigación en este campo en los EEUU se ve acallada por el libro "*Perceptrons*". Sin embargo se consolidan importantes pilares de las redes neuronales artificiales, bajo los nombres de proceso adaptativo de señales, reconocimiento de patrones y modelado biológico. Pertenecen a esta época Shun-ichi Amari, James Anderson, Kunihiro Fukushima, Stephen Grossberg, Harry Klopf, Teuvo Kohonen y David Willshaw.

El despegue

- **Principios de los 80** Se produce el resurgimiento de la computación neuronal en EEUU, en parte financiado por la *Defense Advanced Research Projects Agency* (DARPA).

Por otro lado Hopfield, físico de gran reputación, se dedica entre 1983 y 1986 a relanzar la computación neuronal mediante publicaciones y conferencias.

- **1986** Publicación de "*PDP Books*" (*Parallel Distributed Processing, Vol. I y II*), editados por David Rumelhart y James Mc Clelland, hecho que supone un verdadero acontecimiento por la presentación del método de retropropagación (*backpropagation*) [Rumelhart et al., 1986b].

- **1987** *IEEE International Conference on Neural Networks*, con 1700 participantes (San Diego). Se crea la *International Neural Networks Society* (INNS).

- **1988** Publicación de la revista "*Neural Networks*" por el INNS.

- **1989** Publicación de la revista "*Neural Computation*".

- **1990** Publicación de la revista "*Transactions on Neural Networks*" por el IEEE.

- **Década de los 90** Primeras aplicaciones en la hidrología, como predicción de lluvia [Chang et al., 1991; French et al., 1992; Hall y Minns, 1993; Flood y Kartam, 1994a y b], consumo de agua y estimación de caudales [Daniell, 1991] y predicción de caudales [Karunanithi et al., 1994].

3.4 Sus ventajas

Las redes neuronales artificiales deben su capacidad de procesamiento de información a su estructura distribuida y paralela (la información queda almacenada en los nodos de la red de forma no centralizada) y a su capacidad de aprendizaje y, por tanto, de generalización (en contraposición con la memorización). A pesar de que un nodo aislado implementa su función de forma lenta y algo imperfecta, colectivamente, una red puede efectuar una sorprendente cantidad de tareas muy con gran eficiencia [Reilly y Cooper, 1990]. Esta característica de procesamiento de la información hace que las RNA sean un dispositivo computacional muy potente y capaz de aprender de ejemplos y para luego generalizar en situaciones no vistas anteriormente.

Estas capacidades de procesamiento hacen que las redes neuronales artificiales sean capaces de resolver cierto tipo de problemas muy complejos (tanto por su tamaño como por su estructura) que hasta el momento no habían quedado resueltos de forma satisfactoria.

Hay que dejar claro que las RNA no son una nueva metodología de ingeniería para la resolución global de problemas. Son herramientas de tratamiento de información que pueden integrarse fácilmente en arquitecturas modulares, para resolver de forma muy eficaz aquellas sub-tareas precisas del problema global que mejor se adapten a sus capacidades. Entre estas sub-tareas cabe citar procedimientos de reconocimiento de patrones, de aproximación funcional y de memorias asociativas.

Las propiedades o características más útiles de las RNA son:

- **No linealidad:** las neuronas son elementos de proceso generalmente no lineales. La interconexión de estos elementos genera estructuras de transformación de datos donde este carácter no lineal queda distribuido a lo largo y ancho de la red. Esa característica permite modelar procesos intrínsecamente no lineales (como por ejemplo, el proceso de transformación de lluvia-escorrentía), pero complica también los métodos de análisis de las estructuras resultantes, impidiendo la aplicación de técnicas de análisis bien establecidas, como son las de los sistemas lineales.

- **Modelado de relaciones de entrada/salida:** un paradigma de aprendizaje especialmente extendido y útil es el llamado aprendizaje supervisado. En este tipo de aprendizaje se dispone de un conjunto de muestras de la relación entrada/salida a modelar, formado por pares (entradas, salidas deseadas) que permite optimizar los pesos de la red de tal forma, que se espera que la relación de entrada/salida generada sea capaz de reproducir casos no representados en el conjunto de datos original. Esta capacidad de generalización se obtiene utilizando estructuras de aproximación funcional con capacidad de representación universal y estrategias de aprendizaje que cuidan de que no se sobrepase el límite del sobre-entrenamiento.

- **Adaptabilidad:** las RNA son, por definición, estructuras adaptativas capaces de ajustar sus pesos, y por tanto su función de transferencia, a cambios en el entorno. Esta característica las hace particularmente útiles en el tratamiento de procesos no estacionarios, donde pueden diseñarse estrategias de aprendizaje en tiempo real, para que el modelo conexionista se vaya adaptando de forma continua a los cambios del proceso en cuestión.

- **Flexibilidad:** Las redes neuronales artificiales son una herramienta muy flexible a la hora de modelar procesos verdaderamente complejos. Permiten resolver problemas de diferentes dimensiones sin tener que cambiar su estructura. Una misma estructura de red puede ser utilizada para resolver problemas totalmente diversos y los datos utilizados como entradas no tienen que cumplir ningún requisito de normalidad o independencia, como sí pasa con los modelos estadísticos.

- **Rápida construcción:** El proceso de construcción de un modelo de RNA es rápido, ya que no se necesita hacer pruebas subjetivas de las variables de entrada. Por otro lado, la ausencia de una secuencia de pasos para su construcción y la falta de procedimientos para la determinación de una red óptima, hace que sea complicada la elección de cada uno de sus elementos. No existen reglas ni procedimientos universales que ayuden a la determinación de los diferentes elementos de una red. Se suelen utilizar métodos de prueba y error o de poda “*prunning*”, que ayudan a la elección de las diferentes componentes de la red, pero no solucionan el problema de la búsqueda de la red óptima.

- **Insensibilidad a datos con ruido:** Las redes neuronales artificiales presentan una buena adaptabilidad para resolver problemas donde los datos de entrada contienen ruido [Karunanithi et al., 1994; Thirumalaiah y Deo, 1998a Zealand et al., 1999; *ASCE Task Committee on Application of Artificial Neural Networks in Hydrology*, 2000a]. El gran problema es que, para poder disponer de una RNA tan eficaz que resuelva el problema de los ruidos, es necesario tener una gran cantidad de datos para poder entrenarla y justamente éstos, son los que generalmente faltan. Por lo tanto, es importante destacar que este tipo de modelos es siempre complementario a los modelos físicamente basados o conceptuales. Es importante contar con varios modelos para resolver el mismo problema y así poder compararlos y obtener mejores resultados. Un modelo no invalida al otro, sino que lo complementa.

- **Computacionalmente eficaces:** Este tipo de modelos resulta muy eficaz computacionalmente. La programación del algoritmo de las redes neuronales artificiales es muy simple y no cambia para diferentes problemas. Por lo tanto, la resolución de problemas muy complejos cuesta lo mismo, computacionalmente, que la de otros más sencillos.

3.5 Diferentes estructuras

Una gran cantidad de modelos de redes neuronales artificiales se han propuesto desde 1980. Tal vez los más influyentes son los del tipo perceptrón multicapa (*Multilayer Perceptron MLP*), las redes de Hopfield y las redes de Kohonen auto-organizativas. Hopfield (1982) propone una red neuronal recurrente que trabaja como una memoria asociativa. Una memoria de este tipo puede obtener un ejemplo de una versión distorsionada. Estas redes no tienen capas ni una conectividad completa entre los nodos. Las salidas de los modelos no tienen que ser necesariamente función de las entradas. Son estados estables de procesos iterativos. Los mapas de Kohonen (1982) están motivados por el comportamiento auto-organizativo del cerebro humano [Zhang et al., 1998].

Dado el enorme abanico de estructuras conexionistas existentes, nos limitamos, en este apartado, a describir las dos estructuras utilizadas en esta tesis. Para cada una de ellas se especifican sus creadores o desarrolladores más decisivos, su fecha de aparición o desarrollo, las referencias bibliográficas más relevantes, una descripción de su estructura y una pequeña reseña de sus algoritmos de entrenamiento, aplicaciones y ventajas e inconvenientes.

Para obtener una visión general de las RNA se recomienda la consulta de los artículos de introducción Lippmann, 1987 y Hush y Horn, 1992. El primero de ellos es una referencia clásica pero un poco anticuada, mientras que el segundo presenta una visión más actualizada.

Como libros de consulta de carácter general se recomiendan Hecht-Nielsen, 1989 y Haykin, 1994. Este último es, sin lugar a dudas, uno de los mejores tratados que se han escrito sobre redes neuronales artificiales, no sólo por sus aportaciones originales, sino también por la riqueza de su índice de materias y la claridad y seriedad de su exposición [Muñoz, 1996].

A continuación se describen la red del tipo perceptrón multicapa y la red auto-organizativa.

3.5.1 Perceptrón multicapa (MultiLayer Perceptron (MLP))

Este tipo de red fue creada por P.J. Werbos, D. Parker y D. Rumelhart entre 1974 y 1986 [Werbos, 1974; Parker, 1985; Parker, 1987; Rumelhart et al., 1986a; Rumelhart et al., 1986b; Werbos, 1988; Werbos, 1989]. Es una de las estructuras más utilizadas en el campo de la hidrología, como se puede ver en el Capítulo 4. Este tipo de red se compone, generalmente, de varias capas de nodos. La primera capa es la de entrada, donde se recibe la información externa. Es transparente y sirve sólo para proveer de información a la red. La última, es la capa de salida, donde se obtiene el resultado del problema. Los nodos entre capas adyacentes, en general, se conectan totalmente de una capa inferior a una superior. La Figura 3.3 es un ejemplo de una *MLP* totalmente conectada con tres capas ocultas.




Figura 3.3: Estructura del perceptrón multicapa MLP (fuente: Muñoz, 1996)

El número de capas ocultas y la cantidad de nodos en cada capa se determinan usualmente por el método de prueba y error. Los nodos entre las capas adyacentes están totalmente conectados y se le asigna a cada conexión un peso sináptico que representa la fuerza relativa del nexo entre dos nodos o neuronas.

Antes de que una red desarrolle una determinada tarea, debe ser entrenada para hacerla. Básicamente, el entrenamiento es el proceso en el cual se determinan los pesos de las conexiones que son el elemento clave de una red. El conocimiento almacenado en una red está en las conexiones y nodos en forma de pesos y umbrales. Es precisamente a través de las conexiones, como una red puede realizar mapeos no lineales y muy complejos de los nodos de entrada a los nodos de salida. En este tipo de redes el entrenamiento es supervisado, es decir que la respuesta deseada de la red (los valores objetivos) para cada conjunto de entradas siempre está disponible.

Los datos de entrada utilizados para el entrenamiento se presentan en forma de vectores, donde cada elemento del vector de entrada corresponde a un nodo de entrada a la red. Por lo tanto, la cantidad de nodos de entrada a la red es igual a la dimensión del vector de entrada. Para un problema de predicción, el número de nodos de entrada está bien definido y corresponde a la cantidad de variables independientes asociadas al problema. En cambio, para un problema de predicción de series temporales, la cantidad apropiada de nodos de entrada no es de fácil determinación. Generalmente, los vectores de entrada para un problema de este tipo siempre están compuestos de una ventana de longitud fija que se mueve a lo largo de la serie. El total de datos disponibles se divide generalmente en dos o tres partes:

Serie de calibración. Para determinar los pesos de las conexiones y los umbrales de los nodos.

Serie de validación. Mide la habilidad de generalización de la red.

Serie de verificación. Es opcional y se utiliza para verificar que la red no se sobreentrene.

El proceso de entrenamiento es el siguiente: Primero, se introducen en los nodos de entrada de la red, los ejemplos de la serie de entrenamiento. Los valores de activación de los nodos de entrada se ponderan y acumulan en cada nodo de la primera capa oculta. El total se transforma con la función de activación de la capa. Estos valores de activación, se convierten luego en las entradas a los nodos de la segunda capa oculta, y se repite este proceso hasta obtener los valores de activación de los nodos de salida.

El algoritmo de entrenamiento se utiliza para encontrar los pesos que minimicen una función objetivo, como puede ser la suma de los errores al cuadrado, entre otras. De ahí que el entrenamiento de una red es un problema de optimización no lineal sin restricciones.

Este tipo de arquitectura es estática, es decir que la red no tiene memoria para almacenar la información contextual del pasado. Por lo tanto, las entradas a la red deben contener toda la información contextual necesaria para representar las salidas [Koskela, 2003].

La complejidad de este tipo de redes puede variar desde un modelo lineal hasta un modelo no lineal muy complejo, sólo variando la cantidad de capas y nodos y los valores de sus pesos. Una red de una sola capa oculta y K salidas tiene la siguiente forma funcional:

$$f_k(x, w) = w_{ko} + \sum_{j=1}^q w_{kj} g \left(w_{jo} + \sum_{i=1}^p w_{ji} x_i \right) \quad [3.1]$$

donde p es el número de entradas, q el número de nodos en la capa oculta, g la función de activación de los nodos de la capa oculta, x son las entradas y w los pesos. Los índices i y j corresponden al nodo de salida y a los nodos de la capa oculta, respectivamente.

Los algoritmos de entrenamiento suelen sobre-entrenar las redes. El modelo con menor error en la etapa de entrenamiento, no siempre generaliza bien para datos nuevos. Por lo tanto, se deben utilizar métodos como el de parada temprana (*early stop*) para poder identificar estos problemas de entrenamiento.

A pesar de las buenas características de las RNA, construir una no es una tarea trivial. Una cuestión muy importante es determinar la arquitectura de la red, es decir, la cantidad de capas a considerar y sus respectivos nodos, así como la cantidad de conexiones entre ellos. Otras decisiones de diseño son: la elección de las funciones de activación de las capas ocultas y de salida, el algoritmo de entrenamiento, los métodos de transformación o normalización de los datos, la separación de los datos entre validación y calibración y las medidas de comportamiento. La elección de todos estos parámetros depende del problema.

Aunque existen varios métodos para la selección de la red óptima, son muy complejos y de difícil implementación y además ninguno de ellos puede garantizar que la red sea la óptima. Todo esto lleva a pensar que el diseño de una RNA sea más un arte que una ciencia [Zhang et al., 1998].

Este tipo de red neuronal artificial puede ser utilizado para resolver una amplia variedad de problemas, como almacenamiento y búsqueda de información, aproximaciones funcionales, reconocimiento de patrones, filtrado de señales, segmentación de imágenes y señales, eliminación de ruido, control adaptativo, desarrollo de mapeos generales de patrones de entrada a patrones de salida o resolución de problemas de optimización.

Sus principales ventajas son:

- Capacidad de representación funcional universal
- Gran rapidez de procesamiento
- Genera buenas representaciones internas de las características de los datos de entrada.
- Ampliamente estudiada
- Es la estructura conexionista que más se ha aplicado en la práctica

Y sus desventajas:

- Tiempo de aprendizaje elevado para estructuras complejas
- Necesidad de gran cantidad de datos de entrenamiento, para que pueda generalizar
- Difícil determinación de la red óptima

3.5.2 Mapas auto-organizativos de Kohonen (*Self Organizing Map (SOM)*)

Su creador fue T. Kohonen en 1981 [Kohonen, 1990]. Este tipo de red se utiliza generalmente para la determinación de densidades o para proyectar patrones de espacios de alta a baja dimensión (generalmente 2D). Es un método de clasificación no supervisado, utilizado para agrupar datos basándose solamente en la estadística, sin la definición previa de las clases. Se emplea para aproximar la distribución de patrones objetivos con una pequeña cantidad de pesos. Tiene la capacidad de ajustar los pesos de las unidades adyacentes de la capa de competencia a un vector similar, utilizando técnicas de aprendizaje de competencia y de aproximar la distribución de los patrones objetivos, usando los vectores totales de pesos adquiridos como resultado. La capa de neuronas competitivas, ubicadas en forma de malla, se conecta a todas las entradas por pesos ajustables. La capa de entrada identifica patrones similares y los agrupa en conjuntos.

La Figura 3.4 muestra una estructura típica de este tipo de redes. La mayor diferencia entre este tipo de red y las técnicas clásicas de reconocimiento de patrones es que las redes auto-organizativas permiten una organización grafica de las relaciones de los patrones y una estimación cercana de la función de densidad de probabilidad.

Los pesos de las conexiones entre los nodos representan puntos en el espacio de entrada o, mejor dicho, centros de las funciones Gaussianas [Moradkhani et al., 2004].

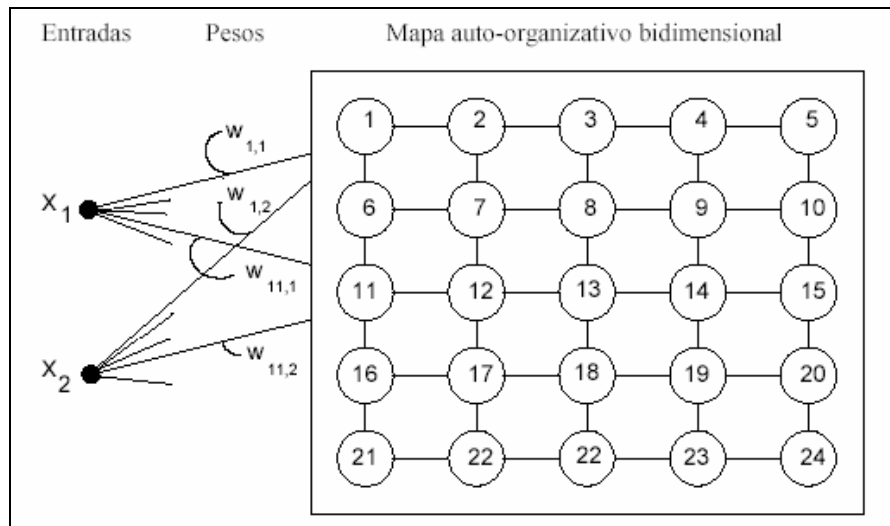


Figura 3.4: Estructura de un Mapa Auto-organizativo de Kohonen. Fuente: Muñoz, 1996

En los mapas auto-organizativos de Kohonen las neuronas están ordenadas topológicamente. Frente a la presentación de un patrón n -dimensional de entrada, compiten lateralmente hasta que sólo una de ellas queda activada. Esta relación no lineal (vector de entrada/unidad vencedora) se fragua mediante aprendizaje no supervisado en la etapa de entrenamiento. El objetivo de este aprendizaje es que, patrones de entrada con características parecidas, queden asociados a neuronas topológicamente cercanas o, dicho de otra forma, se trata de sintonizar de una manera topológicamente ordenada, las neuronas de la red con las características de los patrones de entrada.

El algoritmo de entrenamiento selecciona de forma aleatoria el vector de entradas x , lo compara al vector de los pesos w y elige la unidad b que mejor coincide con el vector de entradas, usando un criterio métrico como, por ejemplo, la distancia euclídea entre los dos vectores x y w .

El procedimiento utilizado para determinar el nodo ganador dentro de la capa de competencia es el siguiente: primero se determina la extensión en la cual cada nodo de dicha capa se ajusta al patrón de entradas y se calcula la distancia entre los pesos de cada nodo con el vector de entrada. El nodo con menor distancia es el ganador. Luego, todos los nodos cercanos al nodo ganador actualizan sus pesos y, a continuación, se presenta el siguiente conjunto de datos de entrada. Se continúa así hasta que se llegue a la convergencia [Bowden et al., 2005].

Las SOM se utilizan generalmente como métodos de agrupación y representación de datos. También se emplean para la compresión y optimización de datos, así como para formar hipótesis de la estructura topológica presente en determinados conjuntos de datos, etc.

Una de sus ventajas respecto a otros métodos de agrupamiento es que crea una representación vectorial, ordenada topológicamente, de los datos de entrada. Y como desventaja, se puede destacar que no hay una metodología clara para la selección del número de representantes y de los parámetros de aprendizaje.

Las redes SOM están compuestas por dos capas, la de entrada y la de salida, que es un mapa de nodos, como se puede ver en la Figura 3.5. Cada conexión tiene su peso (w_{ij}) pero no su umbral (b_i) como las redes MLP.




Figura 3.5: Red auto-organizativa (SOM)

La función PSP es del tipo radial (RBF):

$$y_j = \sum_{i=1}^n (x_i - w_{i,j})^2$$

[3.2]

La función de activación es la raíz cuadrada ($g(y) = \sqrt{y}$), de modo que la activación de los nodos representa exactamente la distancia euclídea entre un patrón de entrenamiento dado y el centro de clase representado por esa unidad radial. Como *output* final, se le asigna al nodo con menor distancia el valor 1 y a los demás 0, identificando de ese modo a qué grupo (nodo) corresponde el conjunto de datos de entrada a la red.

El entrenamiento de la red SOM, a diferencia de la MLP es no supervisado. Se lleva a cabo en dos etapas. En una primera fase, el algoritmo (con valores elevados de la tasa de aprendizaje y del radio de vecindad) establece un mapa topológico de centros aproximado. En una segunda fase, estas definiciones se afinan más, ya con valores reducidos de los parámetros de aprendizaje y vecindad.

ESTADO DEL ARTE

Capítulo 4

Capítulo 4

4 Estado del arte sobre la predicción de caudales en tiempo real con Redes Neuronales Artificiales

4.1 Introducción

El gran interés por los modelos de redes neuronales artificiales en hidrología para la predicción de caudales o calados de ríos ha adquirido mucha importancia en la última década. Estos modelos son capaces de reproducir cualquier relación no lineal entre diferentes variables que describen un cierto proceso, por lo tanto tienen una buena adaptabilidad para describir el proceso de lluvia escorrentía o el de propagación de una onda de crecida en un río. El objetivo de este capítulo es realizar una síntesis de los estudios de este tipo realizados hasta la fecha, identificar las líneas de investigación y desarrollar algunas aplicaciones de predicción de caudales, a diferentes escalas espaciales, para la comparación de los modelos de redes neuronales artificiales y ARMAX.

Se revisan más de noventa artículos, en los cuales, las RNA son utilizadas para la predicción o simulación de caudales o niveles a diferentes escalas de tiempo y espacio. En la mayoría de ellos se comparan con los modelos tradicionales, tanto físicamente basados como conceptuales y estadísticos. La adaptabilidad de las RNA a cualquier tipo de problema y los buenos resultados obtenidos en diferentes estudios, hacen que esta herramienta sea una buena elección entre las diversas metodologías para predicción en tiempo real.

La utilización de modelos híbridos donde los datos de entrada se separan en grupos según diferentes criterios, ha adquirido gran interés en los últimos años, ya que incorporan, mediante varios modelos, conceptos físicos importantes para la modelación del proceso hidrológico.

Se destacan varios puntos importantes para la mejora y el buen entendimiento de estos modelos, haciéndolos más adecuados para el uso operacional. Entre ellos están la interpretación física de la estructura de las redes y la incorporación de la incertidumbre de las predicciones del modelo. Éstos son dos de los puntos fundamentales para la total aceptación de este tipo de modelos.

El concepto de RNA surge en 1943 por Walter Pitts y Warren McCulloch, que proponen una conceptualización del funcionamiento del cerebro humano basada en una red de células interconectadas. Tras una evolución de las RNA en el año 1951, Minsky y Edmonds construyen la primera máquina de redes neuronales y en 1959, Bernard Widrow y Marcial Hoff son los primeros en utilizar una RNA en la aplicación en un caso real.

En el año 1969 se produce un bloqueo en la utilización de las redes neuronales hasta 1982, cuando aparece la técnica de aprendizaje denominada retropropagación del error [Rumelhart et al., 1986b] y a partir de entonces ha continuado con grandes evoluciones.

La utilización de las redes neuronales en ingeniería civil viene de los años 80, pero sólo a partir de 1991, aparecen las primeras aplicaciones en hidrología, como predicción de lluvia [Chang et al., 1991; French et al., 1992; Hall y Minns, 1993; Flood y Kartam, 1994a y b], consumo de agua y estimación de caudales [Daniell, 1991] y predicción de caudales [Karunanithi et al., 1994]. Para los hidrólogos es una técnica joven, pero ha tenido una rápida aceptación y un expansión positivo en publicaciones y conferencias [Govindaraju y Rao, 2000].




Figura 4.1: Cantidad de artículos de RNA revisados y distribuidos por año

Se han revisado una gran cantidad de artículos, donde sólo los que se aplican para predecir caudales y calados, se muestran en la Figura 4.1 y Tabla 4.1. Se observa como, a partir de los años 90, empiezan a aparecer bastantes artículos que utilizan las redes neuronales para la predicción de caudales o calados a diferentes escalas de tiempo. Hay un gran aumento en estos últimos años, dado que el avance en el conocimiento de las RNA es cada vez mayor.

A continuación se hace una descripción general de las redes neuronales artificiales, nombrando los diferentes tipos utilizados en hidrología, junto con sus características generales. Luego, se comparan las RNA con algunos modelos tradicionales utilizados para la predicción de caudales o niveles. También se hace un resumen de los diferentes artículos donde se trata de interpretar físicamente la estructura interna de las redes neuronales. Y seguidamente, se nombran las diferentes variables de entrada de los modelos y los distintos métodos empleados para la elección de dichas variables.

Se introduce el concepto de modelos híbridos y se enumeran algunos utilizados por distintos autores. Asimismo se plantea el problema de incluir la incertidumbre de las predicciones y, por último, se resumen las diferentes líneas de investigación para poder mejorar esta técnica.

4.2 Descripción de las Redes Neuronales Artificiales

No hay una definición universal, pero se podría decir que una RNA es una red de muchos procesadores simples (nodos), cada uno con una pequeña memoria local. Los nodos están conectados por canales de comunicación (conexiones) que generalmente contienen datos numéricos codificados de varias maneras. Los nodos operan sobre sus propios datos y entradas que reciben de las conexiones [Warren, 2005].

A continuación se presentan varias de las definiciones encontradas en la literatura:

- Son sistemas adaptables que aprenden relaciones de un grupo de entradas y salidas y luego son capaces de predecir un conjunto de datos que no hayan sido vistos previamente, con características similares a los datos de entrada [*ASCE Task Committee on Application of Artificial Neural Networks in Hydrology*, 2000a].
- Según Haykin, 1994 p.2, una red neuronal artificial es un procesador distribuido en paralelo que almacena conocimiento experiencial y lo hace accesible al uso. Se asimila al cerebro en dos maneras:
 - El conocimiento de la red se logra por un proceso de aprendizaje.
 - Los pesos de las conexiones interneuronales, conocidas como pesos sinápticos, se usan para almacenar el conocimiento.
- Es un circuito compuesto por una gran cantidad de elementos simples de procesamiento basados en el funcionamiento de las neuronas. Cada elemento opera asincrónicamente, sólo con información local [Nigrin, 1993, p.11].
- Son sistemas celulares físicos que pueden adquirir, almacenar y utilizar conocimiento experiencial [Zurada, 1992, p.xv].
- Son estructuras que predicen a través de ajustes de patrones y procedimientos de comparación. [Abrahart et al., 2004].
- Son técnicas alternativas y complementarias de los modelos tradicionales. Para los hidrólogos, han tenido más y más interés en los últimos 10 años.

Las redes neuronales artificiales tienen una gran capacidad de reconocimiento y clasificación de patrones inspirados en el funcionamiento del cerebro humano, donde las neuronas son capaces de aprender a partir de la experiencia. Son modelos tipo *data-driven* auto-adaptativos, aprenden de ejemplos y pueden reconocer relaciones funcionales entre variables no conocidas o difíciles de describir. Por esta razón son especialmente apropiadas para describir procesos difíciles de reproducir, como la transformación de lluvia-escorrentía.

Son capaces de generalizar, después del aprendizaje, y de reproducir resultados fuera de los rangos de los datos utilizados para el entrenamiento [Zhang et al., 1998; Imrie et al., 2000; Abrahart, 2001; Cigizoglu, 2003; Moradkhani et al., 2004; Wangwongwiroj y Sukluan, 2004; Dawson et al., 2006], aunque varios autores a principios de los años 90 no opinaban lo mismo [Minns y Hall, 1996].

Son aproximadores universales. Como se ha demostrado, pueden aproximar funciones no lineales con cualquier precisión deseada [Irie y Miyake, 1988; Hornik et al., 1989]. En contraste con los modelos estadísticos tradicionales de predicción, las RNA pueden estimar la función en cuestión entre las variables de entrada (como caudales o niveles en tiempos anteriores u otras variables relacionadas) y las variables de salida (como caudales o calados en tiempos futuros) sin limitación alguna.

Las redes neuronales artificiales pueden ser aproximadores lineales o no lineales dependiendo del tipo de red a utilizar, en comparación con los modelos más utilizados para la predicción, como *Box-Jenkins* o ARIMA, que asumen que las series de tiempos se generan por procesos lineales. También se utilizan otros tipos de modelos no lineales, como entre otros, el modelo bilineal [Granger y Anderson, 1978]. La mayoría de ellos hipotetizan inicialmente la relación no lineal entre las variables. Las RNA son modelos más generales y flexibles.

También son utilizadas como conversores de señales de *remote-sensing*, transformando las lluvias distribuidas espacialmente en escorrentía [Smith y Eli, 1995].

Se han utilizado para diferentes tamaños de cuenca, obteniendo resultados satisfactorios en todos los casos (ver Tabla 4.1). No requieren una descripción matemática explícita que describa la naturaleza compleja del proceso en estudio [Fernando y Jayawardena, 1998]. Es una herramienta muy poderosa para resolver problemas de recursos del agua altamente no lineales [Hsu et al., 1995, 2002].

Las redes neuronales son más adecuadas para la predicción dinámica de caudales porque los pesos asociados con los parámetros de las entradas al modelo pueden ser actualizados cuando se dispone de nuevas observaciones. [Thirumalaiah y Deo, 1998a; ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000b; Chiang et al., 2004; Pan y Wang, 2004; Chau et al., 2005]. Chiang et al., 2004 comparan las redes estáticas *feedforward* (con algoritmos de *backpropagation* y *conjugate gradient (CG)*) con las redes dinámicas *feedback* (con algoritmo de *real-time recurrent learning*), ver Figura 4.2. Entre las dos redes estáticas, se obtienen mejores resultados con el algoritmo de entrenamiento CG. En general una red dinámica es más eficaz si no se cuenta con datos suficientes para entrenar una red estática.

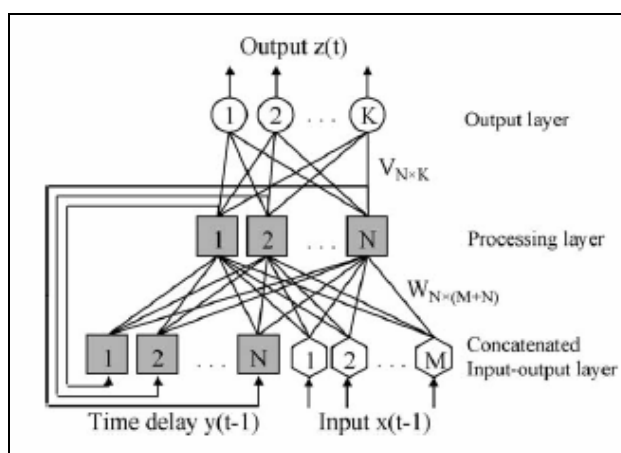


Figura 4.2: Arquitectura de una red RTRL (fuente: Chiang et al., 2004)

No requieren de ninguna entrada exógena, mas que de un conjunto de vectores de entrada-salida para el entrenamiento [Thirumalaiah y Deo, 1998a]. Debido a esto, como el cerebro humano, pueden reconocer relaciones entre variables sin ninguna consideración explícita [ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a].

Funcionan bien aunque los datos de entrenamiento contengan errores de medición o ruidos. [Karunanithi et al., 1994; Thirumalaiah y Deo, 1998a Zealand et al., 1999; ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a] y/o cuando la cantidad de variables de entrada es limitada [Sajikumar y Thandaveswara, 1999; Dolling y Varas, 2002].

Contienen características de procesamiento de información innatas y una vez entrenadas, son fáciles de usar [ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a].

El desarrollo de las RNA se basa en las siguientes reglas:

- El proceso de la información ocurre en muchos elementos llamados nodos o neuronas.
- La información pasa entre los nodos a través de conexiones.
- Cada conexión tiene un peso asociado que representa la fuerza de la conexión.
- Cada nodo, generalmente, aplica una transformación no lineal, llamada función de activación, a sus señales de entrada para determinar la señal de salida.

Cada red se caracteriza por su arquitectura, la cual es representada por la forma de las conexiones con los nodos y el método de determinar los pesos de las conexiones.

Una forma de clasificar las redes es por su número de capas y la dirección del flujo de la información y procesos.

En una red *feedforward*, los nodos se agrupan en capas, empezando por la primera capa de entradas y terminando por una capa final de salidas. Puede haber varias capas (*multilayer*) ocultas, cada una con uno o más nodos. La información pasa de los nodos de entrada a los de salida. Todos los nodos de una capa se conectan totalmente con los de las capas adyacentes, pero no con los de la misma.

A cada conexión se le asigna un peso sináptico para representar la fuerza de las conexiones entre los nodos y predecir la relación entre las entradas y las salidas (*inputs - outputs*).

En la Figura 4.3 se puede ver un esquema de una red neuronal *feedforward* (5-4-1) de una sola capa oculta con 5 nodos en la capa de entrada, 4 en la capa oculta y 1 en la capa de salida.

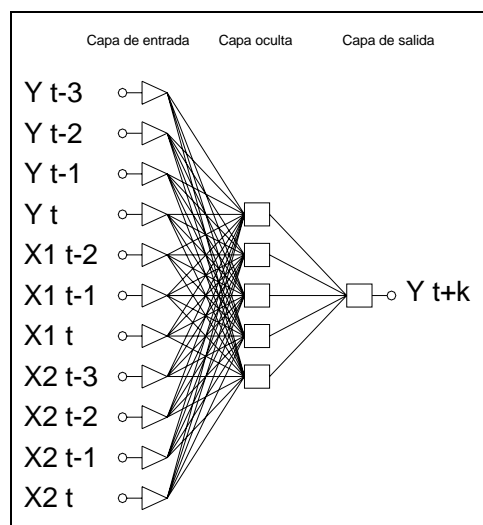


Figura 4.3: Esquema de red neuronal artificial feedforward con una sola capa oculta

En la Figura 4.4 se muestra un diagrama esquemático del nodo j . Los W_{ij} representan los pesos de las conexiones entre el nodo i de la capa anterior y el nodo j . La salida del nodo Y_j se obtiene de la función de activación $g(X, W, b_j)$, donde b_j es el valor del umbral (*bias*) del nodo en cuestión (j). La función de activación se aplica a la combinación de todas las conexiones de la capa anterior con el nodo j . Este tipo de combinación se llama función *PSP* (*Post-Synaptic-Potential*).

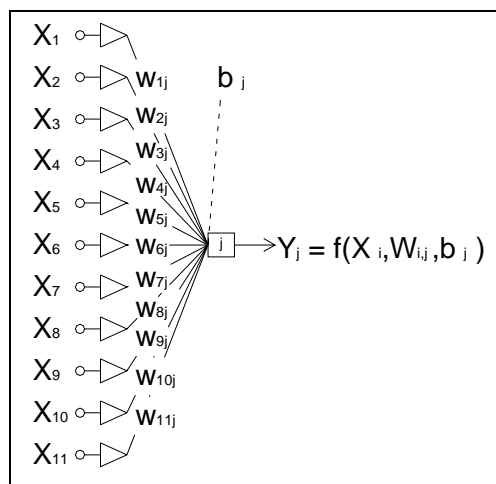


Figura 4.4: Esquema de un nodo general j

La función f se denomina función de activación. Su forma funcional determina la respuesta del nodo a las entradas totales que recibe.

El proceso de entrenamiento o de aprendizaje se utiliza para encontrar los valores de los pesos W y umbrales b que minimicen una función de error predeterminada.

El entrenamiento es un proceso por el cual los pesos de las conexiones de una red son adaptados a través de un proceso continuo de simulación. Hay dos tipos de entrenamiento, supervisado (*data-driven*) y no supervisado. El procedimiento de entrenamiento ajusta de forma iterativa los umbrales y pesos de cada nodo para llegar al objetivo final, que es minimizar la función del error.

Para el entrenamiento de una red se inician los pesos y umbrales de forma aleatoria o mediante otros métodos, por lo tanto es aconsejable entrenarla varias veces, ya que en cada entrenamiento el algoritmo puede caer en mínimos locales de la función del error y no en un mínimo global.

Minimizar el error cuadrático medio (MSE) para el entrenamiento de una red asume que los errores del modelo tienen una distribución normal de media cero y varianza desconocida [Velásquez et al., 2006].

Según lo visto anteriormente, las redes neuronales artificiales pueden ser de varios tipos, ya que cada componente de la misma puede variar de diferentes formas.

Resumiendo, los componentes o características de las RNA son los siguientes:

1. Dirección de flujo de la información
2. Cantidad de nodos
3. Cantidad de capas
4. Entrenamiento supervisado o no (*data driven* o *no data driven*)
5. Algoritmos de entrenamiento
6. Función de activación
7. Función *PSP* (*Post-Synaptic-Potential*)
8. Función objetivo
9. Criterios de finalización de entrenamiento
10. Pre-procesamiento de los datos de entrada [Shi, 2000]

De la variación de estas características surgen diferentes tipos de redes neuronales artificiales utilizadas para aplicaciones en la hidrología (ver Tabla 4.1):

- *Multilayer Perceptron* (MLP) [ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a]
- *Multilayer Perceptron* (MLP) con algoritmo de entrenamiento tipo *backpropagation* [Werbos, 1990]
- *Multilayer Perceptron* (MLP) con algoritmo de entrenamiento tipo *Levenberg–Marquardt backpropagation* (LM) [Coulibaly et al., 2000]
- *Conjugate Gradient* (CG) [ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a]
- *Cascade Correlation* (CC) [Fahlman y Lebiere, 1991; ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a.]
- *Radial Basis Function* (RBF) [Jayawardena y Fernando, 1998; ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a]
- *Radial Basis Function* (RBF) con algoritmo de entrenamiento tipo *Ortogonal Least Squares* (OLS)

- *Generalized Regression Network* (GR) [Cigizoglu, 2005]
- *Temporal BackPropagation Network* (TBP) [Sajikumar y Thandaveswara, 1999]
- *Dynamic Recurrent Network* (DRN) [Pan y Wand, 2004]
- *Threshold Network* (TN) [Wang et al., 2006]
- *Recurrent Network* (RNN) [ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a]
- *Cluster Network* (CN) [Wang, et al., 2006]
- *Periodic Network* (PN) [Wang, et al., 2006]
- *Time Delay Neural Network* (TDNN) [Wan, 1990; Diamantopoulou et al., 2006]
- *Self Organizing Feature Map* (SOFM) [ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a]
- *Recurrent Self Organizing Feature Map* (RSOFM) [Koskela, 2003]
- *Finite Impulse Neural Network* (FIRNN) [Koskela, 2003]
- *Real Time Recurrent Learning* (RTRL) [Chiang et al., 2004]

Es importante tomar varias decisiones en el momento de desarrollar un modelo con una red neuronal. Para ello es necesario estudiar cada componente de dicha RNA y elegir bien el tipo, desde la elección y pre-procesamiento de los datos de entrada hasta la elección de la cantidad de nodos y funciones de activación de la misma.

Para una buena descripción de las redes neuronales, consultar el artículo de Flood y Kartam, 1994a y b. En él se describe cómo se utilizan las RNA, sus aplicaciones en la ingeniería civil y cómo enfrentar diferentes problemas, los factores que afectan a la habilidad de aprendizaje y generalización, validación de las redes, limitaciones de diferentes configuraciones de RNA, la elección adecuada del conjunto de datos para el entrenamiento, etc. En la mayoría de los artículos se utilizan las redes de tipo *Multilayer Perceptron* con algoritmo de entrenamiento *BackPropagation* (MLP/BP) [Werbos, 1990] (ver Tabla 4.1). Y también se empiezan a utilizar cada vez más redes neuronales Modulares [Ronco y Gawthrop, 1995] que son redes utilizadas en conjunto, donde cada una describe una parte del proceso a modelar.

El comité del ASCE [*ASCE Task Committee on Application of Artificial Neural Networks in Hydrology*, 2000b] hace una revisión de aplicaciones de las RNA en hidrología hasta el año 2000 donde surgen varias cuestiones a resolver:

En el caso de no tener suficientes datos que cubran todo el rango del proceso físico a modelar no podemos anticipar el rango donde la red va a fallar al predecir los datos. Ésta es una de las causas por las que no se confía en las capacidades de una red neuronal, ya que se las suele describir como modelos “*data-driven*”, donde las salidas tienen gran dependencia de los datos de entrenamiento. Por lo tanto es muy importante reconciliar los modelos físicamente basados con éstos, utilizando una combinación de las dos aproximaciones [Toth y Brath, 2002] o diseñando una cama de pruebas para determinar el rol de cada tipo de modelo, los campos de validez y aplicación de los diferentes modelos [Todini, 2007]. También es importante incorporar conceptos físicos en la construcción de las RNA [Sudheer y Jain, 2004].

Es difícil considerar, en una red, la heterogeneidad de la cuenca en el tiempo, como por ejemplo cambios del tipo del suelo, rotaciones de cultivos, etc. Como las redes son de parámetros fijos, no se puede tener en cuenta este tipo de cambios. Por ello, el entrenamiento debería ser adaptativo o asignarle a los pesos y umbrales, valores con significado físico y estadístico [Thirumalaiah y Deo, 1998a; *ASCE Task Committee on Application of Artificial Neural Networks in Hydrology*, 2000b; Chiang et al., 2004; Pan y Wang, 2004; Chau et al., 2005].

Minns y Hall en 1996 encuentran que sus modelos de redes neuronales no pueden estimar picos generados sintéticamente que excedan los datos utilizados para la calibración. La selección de los datos de entrenamiento tiene gran impacto sobre la precisión de las predicciones del modelo. Si los datos no representan las características de la cuenca y el clima, luego el modelo no dará resultados fiables en sus predicciones [Tokar y Jonson, 1999]. Imrie et al. en el año 2000, dan la respuesta al problema de las redes para extrapolar valores de predicción superiores a los datos históricos utilizados para la calibración. Utilizan un método que modifica el algoritmo de entrenamiento *Cascade Correlation* incluyendo una validación cruzada. En sus casos de estudio todas las redes pueden extrapolar fuera del rango de datos de calibración y sólo ser sobrepasados cuando se utiliza una función polinomial cúbica en la capa de salida. La Figura 4.5 muestra la comparación entre una red entrenada con el algoritmo CC (*Cascade Correlation*) modificado con función de activación polinómica y otra entrenada con el *BackPropagation* (BP).

Abrahart utiliza en 2001 un *Single Model Bootstrap* para obtener mejores generalizaciones globales. La maniobra del *Bootstrap* es un procedimiento que usa resamplado intensivo, que lo que hace es copiar la componente aleatoria de un proceso y reducir la varianza promediando sobre una cantidad numerosa de diferentes particiones de los datos. Con dichas particiones se entrena la red, reduciendo el error debido a la división de los datos para entrenar, validar y verificar la red. Para mejorar la generalización, Moradkhani et al., 2004, utilizan el método de *S-fold*, validación cruzada que divide a la serie en diferentes conjuntos y entrena a la red con todos ellos. En lugar de utilizar un *early stop*, emplea un criterio que busca el mínimo de una función objetivo, que vincula el RMSE de entrenamiento con el de verificación. Dawson et al., 2006 también utilizan el *cross sampling* para entrenar la red y de esta forma no tener problemas al dividir los datos.

Cigizoglu, 2003, emplea un modelo autorregresivo para generar series sintéticas y utilizarlas como *inputs* en una red neuronal, mejorando así su capacidad de reproducir caudales extremos con mayor eficacia que al entrenarlo con los datos observados.




Figura 4.5: Valores observados y de predicción a 12 h. de caudales en el río Trent para el período de validación (fuente: Imrie et al., 2000)

Wangwongwiroj y Sukluan, 2004, prueban la capacidad de una red MLP a extrapolar o generalizar para valores que son superiores a los datos utilizados para el entrenamiento, llegando a resultados satisfactorios, como se muestra en la Figura 4.6.

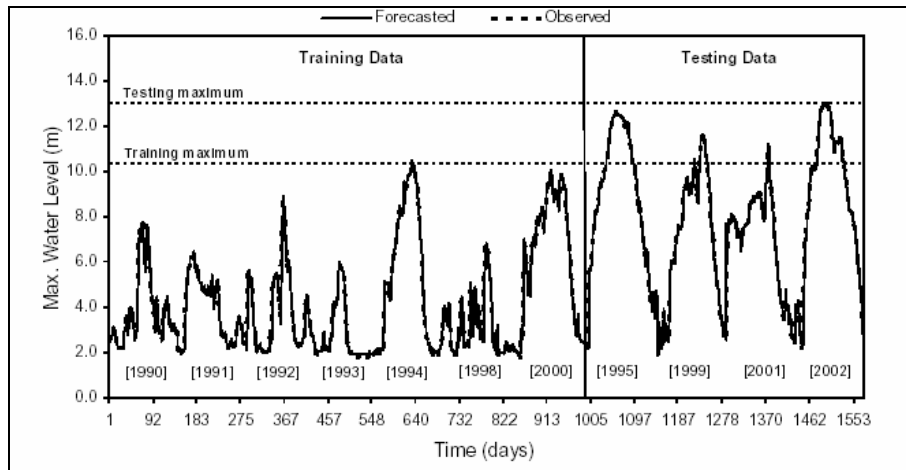


Figura 4.6: Niveles observados y predichos en el río Chao Phraya en Tailandia (fuente: Wangwongwiroj y Sukluan, 2004)

En la Tabla 4.1 se hace referencia a ejemplos de aplicaciones satisfactorias de redes neuronales para la predicción o simulación de caudales o calados en diferentes cuencas del mundo, desde 150,000 km² hasta 1 km² o cuencas de laboratorio. Casi todas ellas utilizadas para predicción a corto plazo y algunas a largo plazo, como anuales o estacionales. Se puede observar una amplia gama de técnicas de modelación con redes neuronales de las cuales la MLP (*MultiLayer Perceptron* con algoritmo de entrenamiento *backpropagation*) es la más utilizada. Esta tabla da una idea de la buena adaptabilidad de la técnica de RNA para todo tipo de cuencas y escalas de tiempo.

4.3 Comparación con otros modelos

Muchas de las técnicas usadas hoy en día para modelar series de tiempo hidrológicas y para generar series sintéticas asumen relaciones lineales entre las variables. Los dos grandes grupos de técnicas incluyen a los modelos conceptuales y físicamente basados y a los modelos de series de tiempo [Zealand et al., 1999].

Los modelos conceptuales y físicamente basados están diseñados para simular matemáticamente los sub-procesos y mecanismos físicos que gobiernan el ciclo hidrológico. Generalmente incorporan formas simplificadas de las leyes físicas y son no lineales, invariables en el tiempo y determinísticos. Usan parámetros representativos de las características de la cuenca pero ignoran la variación en el tiempo y las propiedades estocásticas del proceso de lluvia escurrentía. El problema con los modelos conceptuales es que las regularidades o periodicidades empíricas no son siempre evidentes y pueden ser cubiertas por ruidos (SAC-SMA, SIRT, SCRR, Watbal, PREVIS, ADM, Hidrograma unitario, etc.).

Los modelos de series de tiempo están representados mayoritariamente por los autorregresivos de media móvil (ARMA). El punto de partida de los modelos *data-driven* empieza por Box y Jenkins (1970), quienes mostraron el vínculo entre los modelos de función de transferencia y los autorregresivos con variables exógenas (ARX). Tradicionalmente, los modelos ARMA son los modelos estadísticos más utilizados para modelar series de tiempo hidrológicas. Son más prácticos que los conceptuales porque no es necesario entender la estructura interna del proceso físico a modelar. Para aplicar un modelo ARMA óptimo, la serie debe ser estacionaria y seguir una distribución normal. Como tienen la capacidad de determinar la relación interna entre las entradas y salidas del modelo, permiten una buena generalización.

Las redes neuronales artificiales no son muy diferentes a los modelos estadísticos típicos, pero sí muy valiosas por su manera flexible de implementación. La complejidad del modelo puede ser variada con sólo cambiar la función de transferencia o de activación o la arquitectura de la red. Son más rápidas de construir y necesitan menos pruebas subjetivas de los datos de entrada [Abrahart y See, 2000]. No es necesario conocer la distribución estadística de dichos datos y la no estacionariedad de éstos se tiene en cuenta implícitamente dentro de la estructura no lineal de la red. Las RNA tienen la habilidad de determinar qué entradas del modelo son críticas. Por lo tanto no es necesario el conocimiento previo de la relación entre las variables a modelar. Estas redes son relativamente insensibles a los datos con ruido. Maier y Dandy desarrollan, en el año 2000, una buena comparación entre las redes neuronales y los métodos estadísticos, mostrando la equivalencia de distintos modelos estadísticos con las redes, variando solamente su función de transferencia. Las mayores diferencias surgen del hecho de que los objetivos principales de los modelos estadísticos son desarrollar una metodología universal y lograr un óptimo estadístico de los resultados. En cambio, los usuarios de las redes neuronales se interesan por la precisión de las predicciones y por encontrar métodos que funcionen. Como resultado, los usuarios de las redes neuronales generalmente enfocan problemas más complejos, la dimensión de los modelos tiende a ser mayor, y las metodologías cambian para cada aplicación en particular [Maier y Dandy, 2000].

Las RNA tienen la ventaja, en comparación a modelos ARMA y regresivos, de que captan la no linealidad en las relaciones entre las variables [Hsu et al., 1995] y la caja negra puede verse, si se desea, en detalle para poder entender la naturaleza de la solución.

En contraste con modelos de predicción estadísticos tradicionales, las RNA pueden estimar la función en cuestión entre las variables de entrada y las de salida sin limitación alguna. Teniendo el problema, sin embargo de la difícil determinación de los límites de confianza de las predicciones, algo que por otro lado, los modelos estadísticos tienen muy bien definido analíticamente.

En la revisión bibliográfica se han encontrado muchos artículos donde se comparan los modelos de las redes neuronales con modelos tradicionales estadísticos y/o conceptuales [Hsu et al., 1995; Shamseldin, 1997; Fernando y Jayawardena, 1998; Valença y Ludermir, 1998; Zealand et al., 1999; Dibike y Solomatine, 1999; Tokar y Markus, 2000; Toth et al., 2000; Coulibaly et al., 2000; Abrahart y See, 2000; Birikundavyi et al., 2002; Jain y Indurthy, 2003; Kisi, 2004].

Zhang et al., 1998, hacen un estado del arte de la utilización de las RNA para la predicción y encuentran que en general, hasta esa época, no se sabía cuándo las redes eran mejores o peores que los métodos estadísticos clásicos. El problema de prueba y error para encontrar la red óptima hace que afecte al rendimiento de las redes.

Existen métodos de poda (*prunning*) que permiten reducir el tamaño de una red teniendo en cuenta la importancia relativa de los nodos de entrada u ocultos y de las conexiones, pudiendo eliminar las que menos influyen y obtener redes de menor dimensión, mejorando la capacidad de generalización y evitando el sobre-entrenamiento. Existen dos tipos de podas, los basados en criterios de sensibilidad y los basados en penalizaciones. El artículo de T.R. Neelakantan [Lingireddy S. y Brion, 2005] detalla de forma clara y sintética los aspectos prácticos más destacables de la aplicación de los métodos de poda.

Luego se demuestra que las redes neuronales, al ser utilizadas como modelos de predicción de caudales o calados de agua a diferentes escalas de tiempo y espacio y con diferentes variables de entrada o como modelos de transformación de lluvia escurrentía (ver Tabla 4.1), tienen un mejor comportamiento frente a los modelos ARMAX [Hsu et al., 1995; Coulibaly et al., 2000], SAC-SMA [Hsu et al., 1995; Tokar y Markus, 2000], ARMAX con filtro de Kalman [Fernando y Jayawardena, 1998; Birikundavyi et al., 2002], ARIMA [Valença y Ludermir, 1998], ARMA [Zealand et al., 1999; Toth et al., 2000 (predicción de precipitación); Abrahart y See, 2000; Kisi, 2004], SIRT [Dibike y Solomatine, 1999], Watbal, SMA [Tokar y Markus, 2000], *Nearest Neighbour* [Yakowitz y Karlsson, 1987; Shamseldin, 1997; Bordignon y Lisi, 2000; Sivakumar et al., 2001; Toth et al., 2000 (predicción de precipitación); Coulibaly et al., 2005], LPM (modelo lineal de perturbación), SLM (modelo lineal simple) [Shamseldin, 1997], PREVIS [Coulibaly et al., 2000; Birikundavyi et al., 2002], Hidrograma unitario [Jain y Indurthy, 2003], regresión múltiple lineales y no lineales [Jain y Indurthy, 2003].

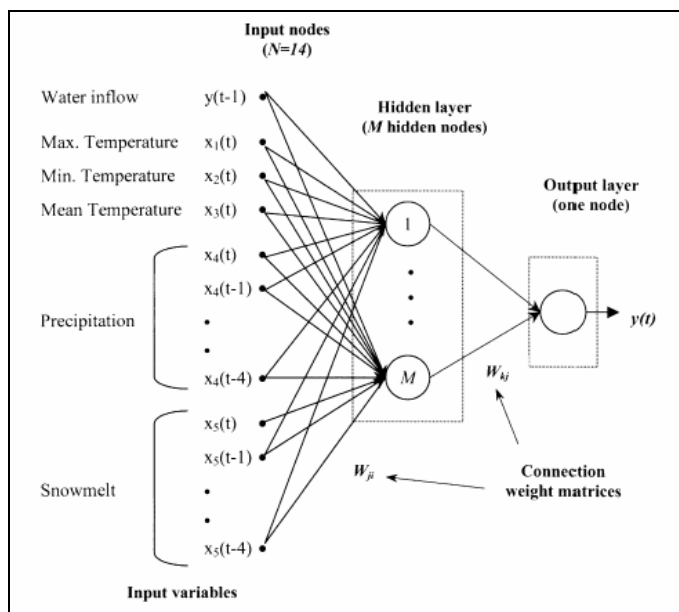


Figura 4.7: Esquema de red neuronal utilizada (fuente: Coulibaly et al., 2000)

Coulibaly et al., 2000, hacen una comparación entre los modelos de redes neuronales con algoritmo de entrenamiento LMBP (*Levenberg–Marquardt BackPropagation training*) y también utilizando la técnica de parada temprana (*early stopped training approach STA*), el modelo ARMAX y el modelo conceptual PREVIS. Las variables de entrada son caudales, temperatura, precipitación y nieve (ver Figura 4.7).

Se obtienen muy buenos resultados con los modelos de redes neuronales para todos los horizontes de predicción, no así con el modelo estocástico tipo ARMAX, como se puede observar en la Figura 4.8.

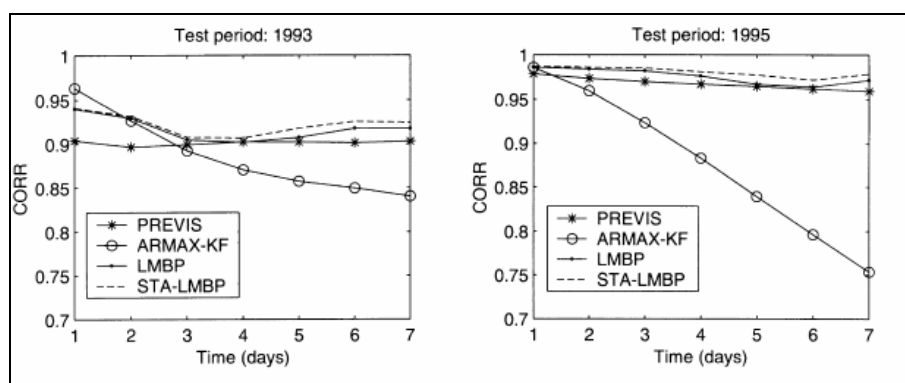


Figura 4.8: Comparación de los coeficientes de correlación para las predicciones de caudales a diferentes horizontes de predicción para el río Chutedu-Diable, Canadá (fuente: Coulibaly et al., 2000)

Las redes son más precisas que los modelos conceptuales, lo cual las convierte en una mejor alternativa para modelos de predicción o simulación entre entradas y salidas, en situaciones que no requieran la modelación de la estructura interna de la cuenca [Kisi, 2004].

La calidad de una red depende generalmente de la calidad y cantidad de datos y, aunque se tengan muchos datos históricos, no se estará seguro de que las condiciones se mantengan constantes en el tiempo. Otra limitación mayor de las RNA es la ausencia de conceptos y relaciones físicas, lo cual fue la principal causa de la actitud escéptica hacia este método. También el hecho de no existir una forma estandarizada para la selección de la arquitectura, algoritmos de entrenamiento y definición, que generalmente se eligen según la experiencia del usuario y no por un aspecto físico del problema [ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a].

4.4 Interpretación de las Redes Neuronales Artificiales

Muchos autores describen a las RNA como modelos de caja negra [Karunanithi et al., 1994; Zhang et al., 1998; Dibike y Solomatine, 1999; Kumar y Minocha, 2001; Toth y Brath, 2002; Chau et al., 2005], lo cual las hace menos preferibles que otros modelos. Claramente las relaciones entre las variables se producen por el ordenador, por lo tanto son vulnerables a los problemas de datos inadecuados y así no tan aceptados como modelos de predicción. Puede haber muy diferentes resultados utilizando la misma arquitectura de red con los mismos datos de entrenamiento [Witten y Frank, 2000]. En los años 70 se observa una tendencia de vinculación y reconciliación de las aproximaciones estocásticas y determinísticas [Quimpo, 1971; Klemes, 1973; Moss y Bryson, 1974; O'Connor, 1976; Pegram, 1977; Dawdy et al., 1978], dándole una justificación física a los modelos estocásticos de aportaciones. Por esta misma etapa están pasando las RNA a partir los inicios del 2000. Se le está dando gran importancia a la interpretación física de la estructura interna de una red para que ésta no sea simplemente un modelo tipo caja negra, sino que tenga también una componente conceptual que le confiera un mayor grado de importancia a este nuevo paradigma [Abrahart et al., 2001; Setonio et al., 2002; Wilby et al., 2003; Jain y Indurthy, 2003; Zhang y Govindaraju, 2003; Jain y Srinivasulu, 2004; Sudheer y Jain, 2004; Jain et al., 2004a; Sudheer, 2005; Pan y Wang, 2005].

Existen varias técnicas para el estudio y análisis de los efectos de cada componente de una red, como por ejemplo el análisis de “*saliency*” o técnica de desagregación, que trabaja con los datos de entrada y salida [Abrahart et al., 2001]; el análisis de perturbación, para estudiar como cada variable afecta a la modelación de las diferentes partes del hidrograma [Sudheer, 2005]; la comparación de las funciones de activación con la curva de caudal-duración, para describir qué parte del hidrograma es interpretado

por cada nodo de la capa oculta [Sudheer y Jain, 2004]; la búsqueda de relaciones con las regresiones lineales que son más fáciles de entender para el usuario [Setonio et al., 2002].

De los intentos conferirle un significado físico a las redes surge el concepto de modelo de “caja-gris” donde, para la elección de las variables o dentro de la búsqueda o elección de la cantidad de nodos o pesos, se tienen en cuenta conceptos importantes sobre el proceso de transformación de lluvia-escorrentía o de propagación de la onda. Zhang y Govindaraju, 2003, utilizan una red neuronal que tiene en cuenta, explícitamente, en su arquitectura la geomorfología de la cuenca. Crean una red donde los pesos de las conexiones con la capa oculta son iguales a los coeficientes (ps) utilizados en la teoría del hidrograma unitario (ver Figura 4.9) y relacionan las conexiones entre los nodos de entrada y los ocultos con la cantidad de ríos que se conectan al cauce principal. La representación de la influencia de los tiempos de viajes de las crecidas se hace a través de los nodos de la RNA. Como entradas al modelo se utilizan la precipitación en exceso, calculada restando la infiltración acumulada (calculada con la ecuación de infiltración *Green-Amt*) y la precipitación acumulada.

Pan y Wang, 2005, de manera similar asocian a los pesos de la red con los parámetros de Harkov del hidrograma unitario. Jain y Indurthy, 2003, consideran el tiempo de concentración para determinar el número de variables de lluvia antecedente como variable de entrada. Jain y Srinivasulu, 2004, combinan técnicas conceptuales y de redes neuronales para desarrollar un modelo de lluvia-escorrentía integrado. Proponen un modelo capaz de incorporar elementos conceptuales dentro de una red neuronal. Lo logran modelando el proceso de infiltración por medio de las ecuaciones de *Green-Ampt*, modelando el contenido de humedad del suelo, la evaporación y el flujo base con técnicas conceptuales. También calculan la precipitación efectiva en cada intervalo de tiempo para utilizarla como entrada del modelo de la RNA. La incorporación de la precipitación efectiva [Sajikumar y Thandaveswara, 1999; Jain y Srinivasulu, 2006] como entrada de los modelos es muy importante ya que es ella la que produce realmente la escorrentía. Puede haber diferentes caudales para una misma tormenta con igual volumen y duración, ya que el caudal a predecir depende mucho de la humedad antecedente del suelo, la evapotranspiración, etc.

Tabla 4.1: Resumen de los artículos revisados

Referencia	VARIABLES DE ENTRADA	VARIABLES DE SALIDA	Cuenca	Área (km ²)	Técnica
Abrahart y See, 2000	Caudales, Caudales diferenciados y Factores de estación	Caudales	Upper River Wye y the River Ouse, UK	S/D	SOM/MLP
Abrahart, 2001	Caudales, Precipitación, Factor de periodicidad	Caudales	River Wye, Gales	10,55	MLP/BPNN
Anctil et al., 2005	Caudales y Precipitación	Caudales	Francia y USA	500<A<8,000	MLP/BPNN
Anctil et al., 2006	Caudales y Precipitación	Caudales	Bas-en-Basset, Francia	3,234	MLP/BPNN
Anmala et al., 2000	Precipitación y Temperatura	Caudales	Council Grove, El Dorado Marion, USA	600	MLP/BPNN
Birikundavyi et al., 2002	Caudales, Precipitación, Temperatura y Nieve	Caudales	Mistassibi, Canadá	9,320	MLP/BPNN
Chau et al., 2005	Calados	Calados	Yangtze, China	S/D	ANN-GA y ANFIS
Chiang et al., 2004	Caudales y Precipitación	Caudales	Lan-Yang, Taiwán	978	MLP/BPNN-CC/RTRL
Cigizoglu, 2003	Caudales y Factor de periodicidad	Caudales	Göksu, Turquía	S/D	S/D
Cigizoglu, 2005	Caudales	Caudales	Ergene, Turquía	S/D	GRNN
Clair y Ehrman, 1996	S/D	Caudales	Canadá	S/D	S/D
Coulibaly et al., 2000	Caudales, Precipitación, Temperatura y Nieve	Caudales	Chute-du-Diable, Canadá	9700	MLP/BPNN-LM
Coulibaly et al., 2005	Caudales y Precipitación	Caudales	Kipawa y Matawin, Canadá	5,960 y 4,118	MLP/LM
Crespo y Mora, 1993	S/D	Caudales	Pisuena, España	S/D	S/D
Dawson y Wilby, 1998	S/D	Caudales	Mole, UK	S/D	S/D
Dawson y Wilby, 1998	S/D	Caudales	Amber, UK	S/D	S/D
Dawson et al., 2006	Descriptores de la cuenca	Caudales	850 de UK	1 a 9,951	MLP/BPNN
Deka et al., 2005	Caudales	Caudales	Brahmaputra, India		FL-MNN-MLP/BPNN
Diamantopoulou et al., 2006	Caudales en la estación y en otras diferentes aguas arriba	Caudales	Aliakmon, Grecia	5,005	TDNN/CC
Dibike y Solomatine, 1999	Caudales, Precipitación, Evapotranspiración	Caudales	Apure, Venezuela	40,000	MPL-RBF
Dolling y Varas, 2002	Caudales, Precipitación, Temperatura, Humedad, Horas de sol, Número del mes, Viento, Nieve, Número de días nublados y índice ENSO (T del Pacífico)	Caudales	San Juan, Argentina	20,000	MIMO/CC/BPNN

Referencia	VARIABLES DE ENTRADA	VARIABLES DE SALIDA	Cuenca	Área (km ²)	Técnica
Elshorbagy et al., 2000	Caudales, Precipitación total, Índice de precipitación antecedente, Índice de derretimiento de nieve, Índice de temperatura del invierno	Caudales	Red, Canadá	61,000	MLP/BPNN
Fernando y Jayawardena, 1998	Caudales y Precipitación	Caudales	Experimental, Japón	3.12	RBF/OLS
Furundzic, 1998	Caudales, Precipitación y Temperatura	Caudales	Lim, República Checa	3,160	SOM/MLP
Garbrecht, 2006	Caudales, Precipitación, Identificador del cada mes, Precipitación en excedencia	Caudales	Fort Cobb, USA	815	MLP/BPNN
García-Bartual, 2002	Caudales y Precipitación	Caudales	Serpis, España	460	MLP/BPNN
Golob et al., 1998	S/D	Caudales	Soca, Eslovenia	S/D	S/D
Hsu et al., 1995	S/D	Caudales	Leaf, USA	S/D	S/D
Hsu et al., 2002	Caudales y Precipitación	Caudales	Leaf River, USA	1,949	SOLO
Imrie et al., 2000	Caudales	Caudales	Trent, UK	7,486	CC
Imrie et al., 2000	Caudales	Caudales	Dove, UK	883	CC
Jain y Indurthy, 2003	Caudales y Precipitación	Caudales	Salado Creek, San Antonio	63,232	MLP/BPNN
Jain y Srinivasulu, 2006	Caudales y Precipitación efectiva	Caudales	Kentucky	17,820	SOM
Jayawardena y Fernando, 1998	Caudales y Precipitación	Caudales	Kamihonsha, Japón	3.12	RBF
Karunanithi et al., 1994	Caudales	Caudales	Hurton, USA	S/D	MLP/CC
Kerh y Lee, 2006	Caudales y Factores físicos de las estaciones aguas arriba	Caudales	Kaoping, Taiwán	3,075.5	MLP/BPNN-LM
Kisi, 2004	Caudales	Caudales	Göksudere, Turquía	S/D	MLP/BPNN
Kneale et al., 2001	Calados	Calados	Tyne, UK	2,920	BPNN-TDNN
Koskela, 2003	Caudales, Precipitación y Temperatura	Caudales	Jökulsa Eystrí, Islandia	S/D	RSOM
Lauzon et al., 2006	Caudales y Precipitación	Caudales	Bas-en-Basset, Francia	3,234	MLP
Liong et al., 2000	Calados	Calados	Ganges, Brahmaputra y Meghna, Bangladesh	1,500,000	MLP/BPNN
Lorrai y Sechi, 1995	S/D	Caudales	Araxisi, Italia	S/D	S/D
Minns y Hall, 1996	S/D	Caudales	S/D	S/D	S/D
Moradkhani et al., 2004	Caudales, Precipitación y Temperatura	Caudales	Salt, USA	10,000	SORB
Muttiah et al., 1997	S/D	Caudales	USA	S/D	S/D
Pan y Wang, 2004	Caudales y Precipitación	Caudales	Wu-Tu, Taiwán	204	SSNN-DRNN
Poff et al., 1996	S/D	Caudales	Little Patuxent, USA	S/D	S/D

Referencia	VARIABLES DE ENTRADA	VARIABLES DE SALIDA	Cuenca	Área (km ²)	Técnica
Pulido-Calvo y Portela, 2006	Caudales, Caudales diferenciados y suavizado con una función de convolución	Caudales	Tua, Portugal	3,718	ARIMA-MLP/BPNN
Pulido-Calvo y Portela, 2006	Caudales, Caudales diferenciados y suavizado con una función de convolución	Caudales	Coa, Portugal	1,685	MLP/BPNN
Rajurka et al., 2004	Caudales y Precipitación	Caudales	Krishna, India	26,200	MLP/BPNN
Rajurka et al., 2004	Caudales y Precipitación	Caudales	Narmada, India	17,157	MLP/BPNN
Rajurka et al., 2004	Caudales y Precipitación	Caudales	Bird Creek, USA	2,344	MLP/BPNN
Rajurka et al., 2004	Caudales y Precipitación	Caudales	Brosna, Irlanda	1,207	MLP/BPNN
Rajurka et al., 2004	Caudales y Precipitación	Caudales	Garrapatos, Colombia	1,490	MLP/BPNN
Rajurka et al., 2004	Caudales y Precipitación	Caudales	Kizu, Japón	1,445	MLP/BPNN
Rajurka et al., 2004	Caudales y Precipitación	Caudales	Pampanga, Filipinas	5,273	MLP/BPNN
Raman y Sunilkumar, 1995	S/D	Caudales	India	S/D	S/D
Sahoo y Ray, 2006	Calados, Velocidades, Ancho y Área de la sección	Caudales	Manoa, Hawaii	15.5	MLP y RBF/BPNN
Sahoo y Ray, 2006	Calados, Velocidades, Ancho y Área de la sección	Caudales	Waiakeakua, Hawaii	2.75	MLP y RBF/BPNN
Sahoo et al., 2006	Calados, Precipitación y Evapotranspiración	Caudales	Manoa-Palolo, Hawaii	24.6	MLP/BPNN
Sahoo et al., 2006	Calados, Precipitación y Evapotranspiración	Caudales	Manoa, Hawaii	2,675	MLP/BPNN
Sajikumar y Thandaveswara, 1999	Caudales y Precipitación efectiva	Caudales	Lee, UK	1,419	TBPNN
Sajikumar y Thandaveswara, 1999	Caudales y Precipitación efectiva	Caudales	Thuthapuzha, India	1,030	TBPNN
Shamseldin, 1997	Caudales, Precipitación, Valores estacionales	Caudales	Sunkosi-1, Nepal	18,000	MLP/BPNN
Shamseldin, 1997	Caudales, Precipitación, Valores estacionales	Caudales	Yanbian, China	2,350	MLP/BPNN
Shamseldin, 1997	Caudales, Precipitación, Valores estacionales	Caudales	Brosna, Irlanda	1,207	MLP/BPNN
Shamseldin, 1997	Caudales, Precipitación, Valores estacionales	Caudales	Bird Creek, USA	2,344	MLP/BPNN

Referencia	VARIABLES DE ENTRADA	VARIABLES DE SALIDA	Cuenca	Área (km ²)	Técnica
Shamseldin, 1997	Caudales, Precipitación, Valores estacionales	Caudales	Wolombi Brook, Australia	1,580	MLP/BPNN
Shamseldin, 1997	Caudales, Precipitación, Valores estacionales	Caudales	Sunkosi-3, China	3,092	MLP/BPNN
Shukula et al., 1996	S/D	Calados	S/D	S/D	S/D
Smith y Eli, 1995	Precipitación	Pico y tiempo al pico	Grid 5x5 cells	S/D	MLP/BPNN
Solomatine et al., 2004	Caudales y Precipitación	Caudales	Xixian, China	10,190	TM5-MLP/BPNN
Sureerattanana y Phien, 1997	S/D	Caudales	Mae Klong, Tailandia	S/D	S/D
Tawfic et al., 1997	S/D	Caudales	Nilo	S/D	S/D
Thirumalaiah y Deo, 1998a	Calados	Calados	Indravathi, India	S/D	MLP/CC,CG,BPNN
Thirumalaiah y Deo, 1998b	S/D	Caudales	Bhasta, India	S/D	S/D
Thirumalaiah et al., 2000	Calados	Calados	Godavari, India	313,000	MLP/CC,CG,BPNN
Thirumalaiah et al., 2000	Caudales y Precipitación	Caudales	Bhatsa, India	399	MLP/CC,CG,BPNN
Tokar y Jonson, 1999	Precipitación, Temperatura y Nieve	Caudales	Little Patuxent, USA	98.4	MLP/BPNN
Tokar et al., 2000	Precipitación y Temperatura	Caudales	Little Patuxent, USA	98.4	MLP/BPNN
Tokar et al., 2000	Caudales, Precipitación, Temperatura y Nieve	Caudales	Fraser, USA	458.2	MLP/BPNN
Tokar et al., 2000	Caudales, Precipitación y Temperatura	Caudales	Raccoon, USA	960	MLP/BPNN
Toth y Brath, 2002	Caudales y Precipitación	Caudales	Sieve, Italia	830	MLP/BPNN
Wang et al., 2006	Caudales	Caudales	Amarillo, China	133,650	TNN/CNN/PNN
Wangwongwiroj y Sukluan, 2004	Calados	Calados	Chao Phraya, Tailandia	S/D	MLP/BPNN
Wu et al., 2005	Caudales y Precipitación	Caudales	Cape Fear, USA	96.2	MLP/BPNN
Yang et al., 1996	S/D	Calados	S/D	S/D	S/D
Zealand et al., 1999	Caudales, Precipitación, Temperatura y Nieve	Caudales	Winnipeg, Canadá	20,000	MLP/BPNN
Zhang y Govindaraju, 2003	Caudales y Precipitación	Caudales	Back Creek, India	62.4	MLP/BPNN
Zhang y Govindaraju, 2003	Caudales y Precipitación	Caudales	Kentuck Creek, India	71.2	MLP/BPNN

Leyenda

ANFIS	<i>Adaptive Network based Fuzzy Inference System</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
BPNN	<i>BackPropagation Neural Network</i>
CC	<i>Cascade Correlation</i>
CG	<i>Conjugate Gradient</i>
CNN	<i>Cluster Neural Network</i>
FL	<i>Fuzzy Logic</i>
GA y ANFIS	<i>Genetic Algorithm</i>
GRNN	<i>Generalized Regression Neural Networks</i>
LM	<i>Levenberg Marquardt</i>
MIMO	<i>Multi Input Multi Output</i>
MLP	<i>Multi Layer Perceptron</i>
OLS	<i>Orthogonal Least Squares</i>
PNN	<i>Periodic Neural Network</i>
RBF	<i>Radial Basis Function</i>
RSOM	<i>Recurrent Self-Organizing Map</i>
RTRL	<i>Real Time Recurrent Learning</i>
S/D	<i>Sin Datos</i>
SOLO	<i>Self-Organizing Lineal Output</i>
SOM	<i>Self-Organizing Map</i>
SORB	<i>Self-Organizing Radial Basis</i>
SSNN-DRNN	<i>State Space Neural Network - Dynamic Recurrent Neural Network</i>
TBPNN	<i>Temporal BackPropagation Neural Network</i>
TDNN	<i>Time Delay Neural Network</i>
TM5	<i>Tree M5</i>
TNN	<i>Threshold Neural Network</i>

Diferentes partes del hidrograma son dominadas por diferentes procesos. En las ramas descendientes de los hidrogramas, estos procesos incluyen, por ejemplo, flujo interno, flujo superficial retardado y flujo base. En contraste, la rama ascendente es dominada por características de la tormenta como la intensidad y la duración de la lluvia, altas capacidades de infiltración, baja humedad del suelo y capacidad de la cuenca. Por otro lado, las partes de las ramas ascendentes cerca de los picos son influenciadas por bajas capacidades de infiltración, saturación del suelo y capacidad de almacenaje de la cuenca cercana a la saturación. Se puede decir que diferentes nodos ocultos pueden estar imitando diferentes procesos de la cuenca [Wilby et al., 2003; Sudheer y Jain, 2004; Jain et al., 2004a]. El número de nodos ocultos debe ser suficiente como para describir completamente el total de la función de activación. De esta forma se puede determinar, al validar una red, si ésta será capaz de predecir flujos mayores o fuera del rango de los datos de entrenamiento [Sudheer y Jain, 2004].




Figura 4.9: Esquema de una red tipo GANN (Geomorphologic artificial Neural Network) con la precipitación en exceso y el caudal en tiempos anteriores como variables de entrada

4.5 Elección de las variables de entrada

Como se puede ver en la Tabla 4.1, se suelen utilizar diferentes variables de entrada para un mismo objetivo, que es el de predecir caudales. Pero dependiendo del lugar, la disponibilidad de datos y las características físicas de la cuenca, unas variables son más adecuadas que otras.

Una variable muy utilizada es la precipitación total, una de las más comunes e importantes en las entradas de los modelos de transformación de lluvia escorrentía. Es sabido que ésta no es la que produce la escorrentía sino la precipitación efectiva (P_{eff}), precipitación total (P_{tot}) menos las pérdidas. El problema es que resulta difícil de estimar porque depende de las condiciones de humedad antecedentes de la cuenca, las cuales cambian con el tiempo. Por lo tanto el cálculo de la precipitación está sujeto a grandes errores. Según este razonamiento, la variable de entrada debería ser la P_{eff} , pero por otro lado, si se usa P_{tot} , los parámetros relacionados con ese nodo deberían ser variables en el tiempo. Esto es muy difícil para las redes neuronales, así que según Kumar y Minocha, 2001, no son adecuadas para analizar este tipo de fenómeno. Una forma de realizar una red que adapte sus pesos en el tiempo es utilizando algoritmos de Kalman que adapten los pesos de las conexiones cada vez que se realice una predicción. Esta metodología constituye un tema muy importante que podría ser abordado en futuras investigaciones. Algunos artículos que utilizan la precipitación efectiva como entrada en las redes neuronales son: Sajikumar y Thandaveswara, 1999 y Jain y Srinivasulu, 2006.

Otras de las variables utilizadas como entradas a los modelos son (ver Tabla 4.1):

- Temperatura
- Evapotranspiración [Anctil y Rat, 2005]
- Caudales en tiempos anteriores
- Caudales en estaciones aguas arriba del punto a predecir
- Media móvil de la precipitación antecedente [Abrahart, 2001]
- Elementos de periodicidad [Cigizoglu, 2003]
- Diferenciación de caudales, como los modelos ARIMA [Anctil y Rat, 2005]
- Temperatura de los mares que afectan para las predicciones anuales [Dolling y Varas, 2002]
- Precipitación distribuida [García-Bartual, 2002] o agregada
- Precipitación efectiva [Sajikumar y Thandaveswara, 1999]
- Humedad del suelo [Karunanithi et al., 1994]
- Índice de precipitación antecedente
- Índice de derretimiento de la nieve
- Calados
- Velocidades
- Características físicas de la sección
- Viento [Dolling y Varas, 2002]

La adecuada elección de las variables de entrada tiene gran importancia en la eficiencia de las predicciones de los modelos. Para ello se pueden hacer análisis de correlación de las variables [Kumar y Minocha, 2001; Olsson et al., 2004; Sudheer y Jain, 2004], análisis de sensibilidad [Liong et al., 2000] y utilizar distintos métodos como: los conceptuales, que emplean del tiempo de concentración para determinar qué cantidad de precipitación antecedente utilizar [Jain, 2005], el método del F-Estadístico [Furundzic, 1998], los algoritmos de *prunning* [Furundzic, 1998], AMI (*Average Mutual Information*) [Abebe y Price, 2004], los algoritmos genéticos [Bowden et al., 2005; Anctil et al., 2006], PMI (*Partial Mutual Information algorithm*) [Bowden et al., 2005].

Una alternativa para la elección de las variables es utilizar una SOM para reducir la dimensionalidad del espacio de los elementos de entrada y obtener variables independientes [Bowden et al., 2005] o utilizar metodologías estadísticas como *Akaike criterion* que se suelen usar para la determinación del orden de un modelo ARMA [Cigizoglu, 2005].

Un ejemplo de las diferentes variables de entrada en un modelo de predicción puede ser el artículo de Sahoo et al., 2006. En este artículo se utilizan las RNA para predecir caudales de avenidas de respuesta rápida y los parámetros de calidad de agua, como oxígeno disuelto, PH, temperatura del agua, turbidez y conductancia específica. Se utilizan dos estaciones (Waaloa Road (WK) 2,675 km² y Kaimuki High School (KHS) 24.6 km²) ubicadas en la cuenca de Manoa-Palolo, Hawai. Las variables utilizadas a escala quinceminutal son: la precipitación en una estación adoptada como la media de la cuenca (R_t), los calados (H_t y H_{t-1}) y la evapotranspiración (ET_t). Esta última se calcula en función de la evapotranspiración de referencia (calculada con el software REF-ET) y el factor de cultivo (*crop-factor*), que se considera igual a 1 ya que es un modelo agregado. De un análisis de sensibilidad se destaca que el rendimiento de las predicciones de caudales se mejora con la incorporación de variables meteorológicas como la lluvia y la evapotranspiración.

En la Figura 4.10 se muestra una comparación entre una RNA con diferentes variables de entrada con: (a) con todos los inputs, (b) todos los inputs y sin ET, (c) solo calados como inputs, (d) todos los inputs y sin calados para la estación WK, y para la estación KHS: (e) todos los inputs, (f) todos los inputs sin ET, (g) solo calados como inputs, y (h) relación entre los calados medidos y los caudales en la estación.

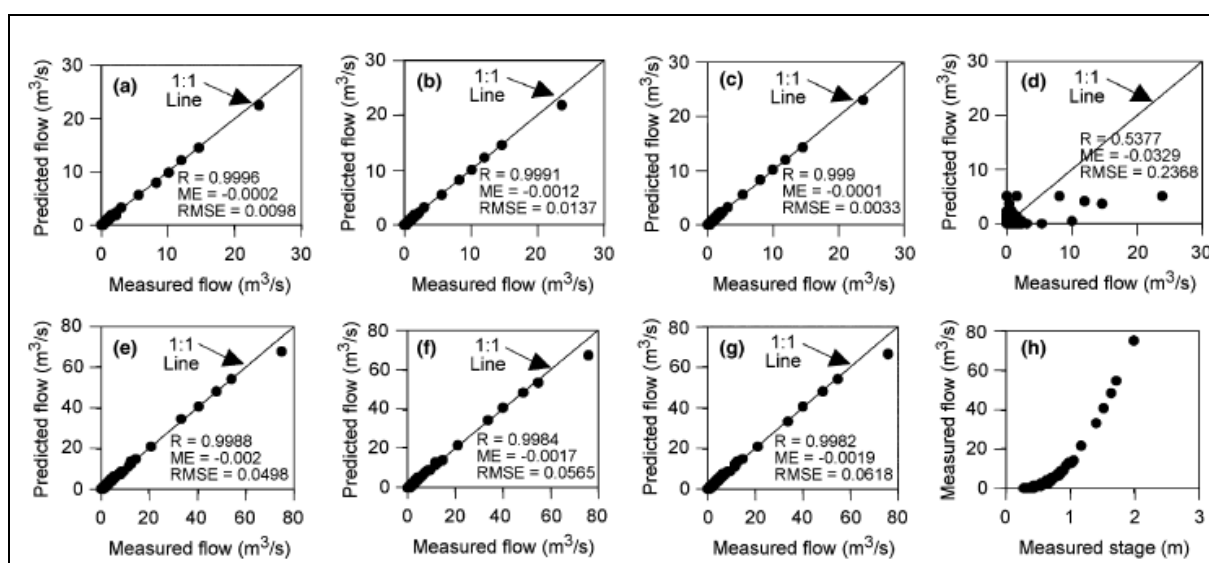


Figura 4.10: Caudales observados y predichos usando una red neuronal tipo backpropagation con diferentes variables de entrada (fuente: Sahoo et al., 2006)

4.6 Modelos híbridos

La esorrentía de una cuenca, representada por varios segmentos de un hidrograma, se produce por diferentes procesos físicos. Por ejemplo, la rama ascendente del hidrograma es el resultado de una suelta gradual de agua de varios elementos de almacenaje de las cuencas generados por el llenado gradual de los almacenajes o capacidades cuando la cuenca es sujeta a entradas de lluvias. Las características de la rama ascendente del hidrograma (forma, pendiente, tamaño, etc.) son influenciadas por la variación de la capacidad de infiltración, las características de almacenaje de la cuenca y la naturaleza de la lluvia (duración e intensidad) y en menor medida por los factores climáticos, como la temperatura y la evapotranspiración. Por ejemplo, una rama ascendente con pendiente pronunciada indica una cuenca pequeña con grandes pendientes y lluvia intensa y de corta duración. Por otro lado, una menos pronunciada indica grandes cuencas con baja pendiente y lluvia menos intensa y de mayor duración.

La rama descendente del hidrograma es el resultado de la suelta gradual de agua de la cuenca cuando la lluvia ha finalizado y está más influenciada por las capacidades de almacenaje de la cuenca y las características climatológicas. Si presenta una gran pendiente indica menor capacidad de la cuenca para la retención de agua y por otro lado, menor pendiente indica mayor capacidad de la cuenca para la retención del agua. Además, el proceso físico responsable del segmento inicial de la rama ascendente (R1 en Figura 4.11) es diferente del último segmento cercano a los caudales pico (R2). Y en la rama descendente, el primer tramo (F1) está más influenciado por el flujo superficial, el intermedio (F2) por el flujo interno y el último (F3) por el flujo base [Jain y Srinivasulu, 2006].




Figura 4.11: Descomposición de un hidrograma (fuente: Jain y Srinivasulu, 2006)

Algunos estudios sugieren que las RNA no pueden predecir los eventos de caudales altos y bajos de forma satisfactoria [Minns y Hall, 1996], ya que el mecanismo interno de generación de escorrentía puede ser muy diferente durante periodos de caudales bajos, medios y altos. Para resolver tal problema se pueden emplear redes neuronales híbridas, combinadas para modelar los sistemas no lineales, dividiendo los datos de entrada en grupos o regiones. Este tipo de modelo ha tenido gran interés en los últimos años, ya que permiten otorgar un mayor valor conceptual a las redes neuronales artificiales.

Los modelos híbridos de RNA pueden ser definidos como la integración de una cantidad diferente de modelos donde siempre uno de los modelos constituyentes es una RNA. Los modelos de redes neuronales híbridos pueden ser clasificados en modulares o no modulares, según la manera de modelar la subdivisión [Abrahart et al., 2004]. Los modelos híbridos modulares resuelven los problemas complejos de predicción dividiéndolo en una cantidad de modelos más simples; un modelo apropiado o experto es usado para resolver cada uno de los sub-problemas y sus resultados se integran para producir la predicción híbrida. Se los denomina no modulares cuando varios modelos son utilizados para generar la misma solución y luego se integran para producir la solución final o se combinan diferentes modelos en serie.

Existen muchos modelos no lineales similares a las Redes Neuronales Modulares (MNN) pero con diferentes denominaciones: integradas, de umbral, etc [Wang, et al., 2006]. Algunas de ellas pueden ser consideradas como casos especiales de redes neuronales modulares y otras tienen diferentes formas de combinar las redes. Por ejemplo, en lugar de utilizar una red de entrada para mediar la competición de redes expertas (redes especiales que modelan cada conjunto dividido por la red de entrada, como ocurre en el caso del SOFM o RSOFM (*Recurrent Self Organizing Feature Map*) [Furundzic, 1998; Abrahart y See, 2000; Hsu et al., 2002; Koskela, 2003; Moradkhani et al., 2004; Jain y Srinivasulu, 2006], algunas redes híbridas usan modelos *Fuzzy logic* [Bezdek, 1981; See y Openshaw, 1999; Deka y Chandramouli, 2005; Chau et al., 2005; Corani y Guariso, 2005, Wang et al., 2006] para vincular redes expertas individuales al sistema de modelos integrados o utilizan técnicas de análisis de grupos (*cluster*), modelos de “vecino más próximo” (*nearest neighbour*) [Hu et al., 2001], modelos de árbol (*Tree*) M5 [Solomatine y Xue, 2004] o modelos de descomposición conceptual [Jain y Srinivasulu, 2006].

En los últimos años ha surgido un gran interés por la aplicación de este tipo de modelos. Como demuestra una extensa proliferación de artículos al respecto: Jacobs et al., 1991; Jacobs y Jordan, 1993; Jordan y Jacobs, 1994; Furundzic, 1998; See y Openshaw, 1999; Zhang y Govindaraju, 2000a y b; Abrahart y See, 2000; Zhang y Govindaraju, 2000b; Hu et al., 2001; Hsu et al., 2002; Koskela, 2003; Moradkhani et al., 2004; Solomatine y Xue, 2004; Deka y Chandramouli, 2005; Chau et al., 2005; Jain y Srinivasulu, 2006; Wang et al., 2006. Todos estos artículos de modelos se basan en el mismo concepto de subdivisión de los datos de entrada en subgrupos según conceptos físicos. Las diferencias radican en la elección de los grupos a dividir, de qué forma hacerlo y de cómo modelar cada proceso. Para la modelación de cada subgrupo algunos utilizan redes neuronales del tipo MLP [Furundzic, 1998, Solomatine y Xue, 2004] y otros RBF [Moradkhani et al., 2004; Jain y Srinivasulu, 2006], también modelos simples lineales [Hsu et al., 2002] o modelos de recesión para modelar el flujo de la rama descendente del hidrograma [Jain y Srinivasulu, 2006].

Hsu et al., 2002, utilizan un procedimiento de redes neuronales multivariado llamado SOLO (*Self-Organizing Linear Output mapping network*). Emplea esta metodología para la predicción de caudales diarios para el río Leaf, USA. La red SOLO consiste en 3 capas, la capa de entrada, la capa de clasificación de los datos, y la capa de salida, como se muestra en la Figura 4.12.

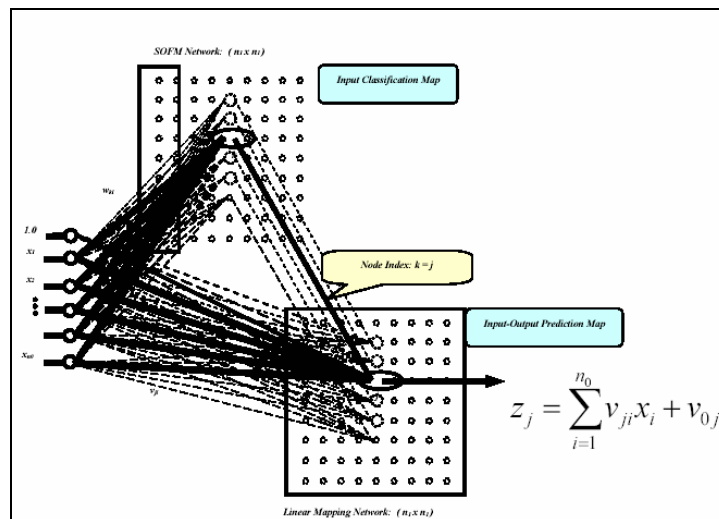


Figura 4.12: Arquitectura del modelo SOLO (fuente: Hsu et al., 2002)

La red SOFM clasifica los datos en 5 regiones diferentes (ver Figura 4.13) y según la región a la que pertenezca, se utiliza un modelo lineal diferente para reproducir el resultado final. La región 1 caracteriza el flujo base, la 2 es la región del aumento de precipitación, la 3 representa los picos del hidrograma, la 4 recesiones rápidas y la 5 recesiones lentas.

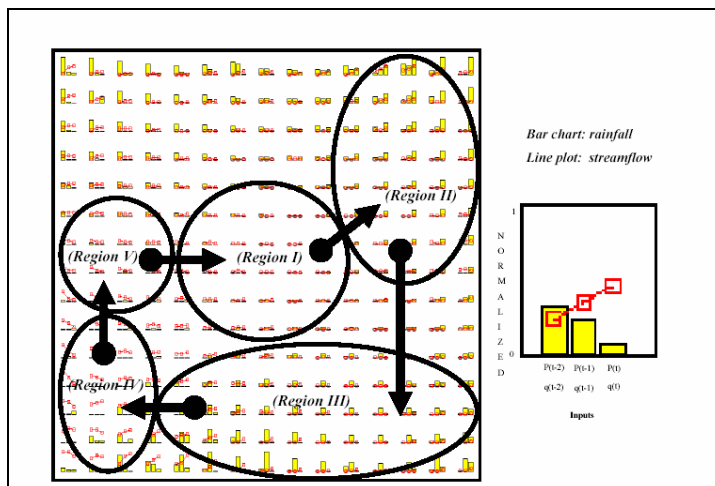


Figura 4.13: Características de clasificación de una red SOFM 15 x 15 utilizada para la clasificación previa de los datos (fuente: Hsu et al., 2002)

Wang et al., 2006, comparan tres modelos de redes neuronales modulares (*Threshold-based ANN* (TANN), *Cluster-based ANN* (CANN) y *Periodic ANN* (PANN)) para predicciones de caudales en el río Amarillo, China. Los contrastan a su vez con el clásico *multilayer perceptron* (MLP). El TANN divide los datos de caudales según dos umbrales y construye una red MLP para cada régimen. El CANN divide los datos en grupos basándose en las técnicas de análisis de grupos (*Fuzzy C-Means*). El PANN básicamente separa los datos por períodos del año. De todos los modelos el que mejor se comporta es el PANN (Ver Figura 4.14).

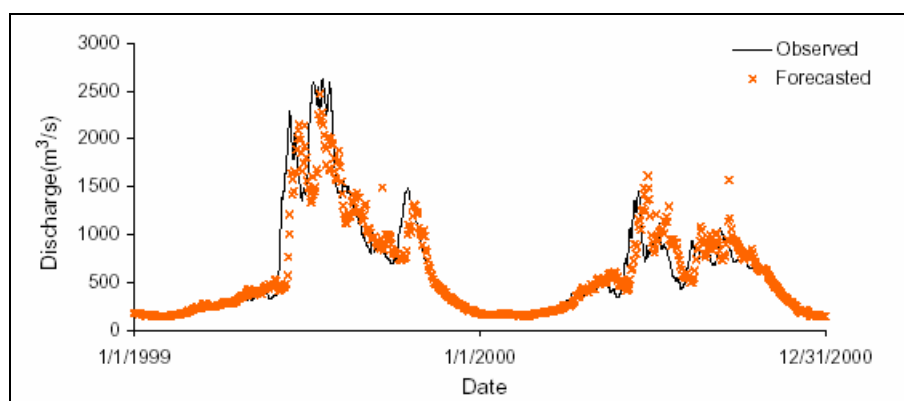


Figura 4.14: Caudales predichos a 10 días para el río Amarillo, China (fuente: Wang et al., 2006)

En todos los casos se demuestra la gran ventaja de utilizar redes modulares por su mayor precisión frente a modelos únicos para la descripción de todo el proceso de lluvia escorrentía.

El otro grupo de redes híbridas, los modelos no modulares, pueden ser como el siguiente ejemplo: la utilización de redes neuronales artificiales para la predicción de errores de un modelo conceptual físicamente basado [Toth y Brath, 2002; Abebe y Price, 2004].

Toth y Brath, 2002, utilizan las RNA para actualizar las predicciones de un modelo conceptual y también las emplean para predecir la precipitación y luego introducirla al modelo conceptual.

Un modelo no modular puede ser también la combinación de modelos diferentes, como por ejemplo un modelo conceptual, una red neuronal y un modelo de vecino más próximo, utilizados para resolver el mismo problema. Luego se ponderan los resultados de los tres para obtener un único resultado más fiable [Coulibaly et al., 2005].

Otro ejemplo puede ser la combinación de modelos estadísticos con redes neuronales, donde se utiliza un modelo autorregresivo para predecir caudales y una RNA para predecir el error del modelo AR y viceversa. También pueden ser utilizadas las predicciones de uno de ellos como entradas al otro, mejorando la eficacia de la predicción [Rajurkar et al., 2004; Pulido-Calvo y Portela, 2006].

Por último cabría destacar la utilización de redes periódicas que modelan con diferentes RNA cada época del año [Garbrecht, 2006].

El resultado de las redes híbridas muestra que siempre la combinación de varios modelos es un método más eficiente y preciso que la utilización de un modelo aislado.

4.7 Incertidumbre

Muchas de las aplicaciones de RNA revisadas no incluyen la medida de la incertidumbre de las predicciones. La incertidumbre o su análisis es crucial dado el grado de complejidad interno involucrado en este tipo de modelo. La incertidumbre puede ser causada por varios factores como la estructura del modelo, los parámetros, elección de la división de los datos para entrenar la red y el error de los datos de entrada. La comparación de las redes con los métodos tradicionales debería hacerse sobre la incertidumbre de cada modelo y así poder elegir si usar o no tal modelo. El análisis de la incertidumbre puede mejorar la utilidad del sistema de predicción, ya que habilita la posibilidad de conocer la probabilidad de las inundaciones. Esto conlleva varios beneficios, como la posibilidad de crear un criterio basado en el riesgo para códigos de alerta de crecidas y planes de emergencia [Abrahart et al., 2004]. Hay varios métodos complejos para el análisis de la incertidumbre, como el *Mean Value First Order Method* (MVFOM), el método de modelación de Monte Carlo [Melching, 1992; Yu et al., 2001], el método de la búsqueda *tree-structured* [Spear et al., 1994] y el método GLUE (*Generalized Likelihood Uncertainty Estimation*) [Beven y Binley, 1992; Hossain y Anagnostou, 2005]. Aunque Mantovan y Todini (2006) encuentran al método GLUE incoherente respecto a las inferencias Bayesianas.

La toma de decisiones racional (para sistemas de alerta, navegación y embalses) requiere cuantificar, en forma de distribución de probabilidad, la incertidumbre total acerca del predictor hidrológico (como niveles del agua, caudales, o volumen) condicionada a toda la información y conocimiento disponible [Krzysztofowicz, 1999]. El objetivo de las predicciones es describir la incertidumbre de valores futuros calculados en tiempo real (calados, caudales, volúmenes de escorrentía, etc.), antes que la incertidumbre de las predicciones generadas por los modelos de predicción hidrológica. La incertidumbre, generalmente expresada en términos de función de densidad de probabilidades (*pdf*) o distribución de probabilidades (*PDF*), es condicionada a las predicciones del modelo, que supondría el conocimiento del futuro, aunque incierto [Todini, 2007].

4.8 Líneas de investigación

El uso de las redes neuronales en hidrología ha aumentando en los últimos años. Se utilizan para desarrollar modelos capaces de obtener predicciones más precisas que las de los modelos tradicionales. Es importante continuar mejorando los modelos existentes de RNA, comparando estos modelos con soluciones operacionales basadas en procesos, fijando y probando criterios de evaluación con significado y mejorando el entendimiento del modelo [Abrahart et al., 2004]. Hasta la fecha ha ido incrementándose rápidamente la utilización de las RNA como modelos de transformación de lluvia-escorrentía y predicción, dado que muestran un rendimiento superior a los modelos tradicionales. Aún así hay poca evidencia de que esta tecnología se esté transfiriendo a entornos operacionales, que sería el paso siguiente a tomar. Los puntos más importantes de la mejora de este método son:

- Mayor énfasis en la comparación con modelos operacionales
- Desarrollo y construcción de criterios de evaluación más eficaces
- Incremento de la investigación para la comprensión de su comportamiento interno y los significados de cada componente de una red
- Desarrollo de redes neuronales adaptativas en el tiempo o dinámicas
- Desarrollo de modelos para la predicción de caudales en secciones sin medidas, donde los datos de entrada son las características de las cuencas [Dawson et al., 2006], pudiendo utilizar el mismo modelo para diferentes cuencas
- Incorporación de la incertidumbre de las predicciones [Valverde Ramírez et al., 2005]
- Desarrollo de redes neuronales híbridas. Comparación con los diferentes métodos de clasificación y modelación de cada subgrupo

MODELO MODULAR

Capítulo 5

Capítulo 5

5 Modelo modular

5.1 Introducción

Como se ha mencionado en el Capítulo 2, el fenómeno físico de transformación de lluvia a escorrentía es muy complejo, por lo tanto muy difícil de modelar con metodologías simples. Es diferente intentar simular una cuenca cuyos mecanismos de generación de escorrentía sean Dunniano u Hortoniano (ver 2.3. Mecanismos de generación de escorrentía) o modelar hidrogramas de cuencas con climas húmedos o áridos. Además en una misma cuenca las características de los hidrogramas de salida son muy diferentes dependiendo de las características espacio-temporales de la tormenta, la situación inicial en la que se encuentra la cuenca, el grado de humedad, etc.

Ya a mediados de los 90 algunos estudios habían sugerido que las RNA no pueden predecir los eventos de caudales altos y bajos de forma satisfactoria [Minns y Hall, 1996], ya que el mecanismo interno de generación de escorrentía varía mucho durante períodos de caudales bajos, medios y altos.

El proceso de generación de escorrentía, es no lineal y estacional, ya que los procesos tienen medias, varianzas y estructuras de dependencia estacionales y los mecanismos de generación de escorrentía son diferentes para caudales bajos, medios y altos, especialmente cuando ocurren eventos extremos. Por ejemplo, los caudales bajos se mantienen por el flujo base y los caudales altos se generan por eventos de fuerte precipitación [Wang et al., 2006].

Dadas estas dificultades, se hace necesario utilizar diferentes modelos para simular los diversos fenómenos físicos que producen la transformación de lluvia a escorrentía. A esta combinación de modelos para reproducir un fenómeno tan complejo, la llamamos *modelo modular*.




Figura 5.1: Concepto de redes modulares. Subdivisión de un problema en varios para que combinados realicen la predicción

El modelo modular, como se ve en la Figura 5.1, resuelve un problema dividiéndolo en diferentes sub-problemas y luego combina sus resultados para obtener la predicción final.

En general los modelos modulares se construyen con dos tipos de redes llamadas redes expertas y redes de entrada. Las expertas pueden ser de cualquier tipo de RNA. Cada red se diseña para un problema en particular. La red de entrada recibe las variables de entrada y devuelve tantas salidas como redes expertas existan. Estas salidas son no negativas y suman a la unidad, representando los pesos de las salidas de cada una de las redes expertas. La suma ponderada de las salidas de las redes expertas genera la salida final del modelo modular [Wang et al., 2006]. En la Figura 5.2 se muestra un tipo de modelo de entrada que utiliza el método FCM (*Fuzzy C-means*) para la separación de 5 grupos estacionales donde, según el día del año, los 5 modelos expertos se ponderan según los grados de pertenencia indicados en el eje vertical del gráfico.




Figura 5.2: Grados de pertenencia de los días del año para caudales diarios en Tangnaiha, río Amarillo, utilizando el método FCM "fuzzy C-means" (fuente Wang et al., 2006)

Cada módulo debe cumplir una función interpretable y relevante en concordancia con las propiedades físicas y mecánicas del sistema. Esto quiere decir que, según el sistema a modelar, la descomposición entre sub-problemas debe tener un significado [Ronco y Gawthrop, 1995].

En la literatura se encuentran muchos artículos sobre la implementación del concepto de modelos modulares. La principal diferencia entre ellos es el tipo de división que se realiza y la forma de hacerlo. Además de utilizar redes neuronales artificiales, se han empleado otros modelos, como por ejemplo de lógica difusa (*Fuzzy Logic*), de análisis de grupos (*cluster*), modelos de árbol (*tree*), de vecino más próximo (*nearest neighbour*), métodos conceptuales, etc. [Bezdek, 1981; Jacobs et al., 1991; Jacobs y Jordan, 1993; Jordan y Jacobs, 1994;

Furundzic, 1998; See y Openshaw, 1999; Abrahart y See, 2000; Zhang y Govindaraju, 2000a; Zhang y Govindaraju, 2000b; Hu et al., 2001; Hsu et al., 2002; Koskela, 2003; Moradkhani et al., 2004; Solomatine y Xue, 2004; Chau et al., 2005; Corani y Guariso, 2005; Deka y Chandramouli, 2005; Jain y Srinivasulu, 2006; Wang et al., 2006].

La gran importancia y buen comportamiento de estos modelos los convierten en uno de los temas principales de las líneas de investigación en predicción de caudales en tiempo real.

En este capítulo se expone un procedimiento automático de selección y clasificación de datos utilizando redes auto-organizativas de Kohonen [Hsu et al., 2002].

5.2 Modelo modular propuesto

La representación del estado hidrológico inicial de una cuenca (ej. la cantidad y distribución de almacenamiento de agua en la misma) determina enormemente la respuesta de la cuenca para un evento de precipitación. Para poder determinarlo se utilizan caudales en pasos de tiempo anteriores como entradas a las RNA, ya que éstos son indicadores indirectos de las condiciones hidrológicas [De Vos y Rientjes, 2005].

La elevada autocorrelación de las series de tiempo de caudales hace que la componente autorregresiva del modelo, que está implícitamente dentro de los modelos de redes neuronales artificiales que utilizan caudales en tiempos anteriores como entradas, sea predominante. Las redes conceden mayor peso a los últimos caudales observados (Q en el tiempo t) para calcular la predicción (Q_{t+k}). En otras palabras, las redes consideran que la mejor predicción de caudales a un cierto horizonte es cercana al valor actual de caudales. El efecto de desfase en las predicciones es especialmente significativo en las predicciones con horizontes pequeños. Pero por otro lado, a mayor horizonte de predicción menor correlación entre Q_t y Q_{t+k} . Como resultado, la red otorgará más peso a la información de precipitación, disminuyendo así los desfases de predicción [De Vos y Rientjes, 2005].

El estado hidrológico de una cuenca anterior a un evento de precipitación es importante, ya que éste gobierna los procesos de respuesta de la cuenca a dicha precipitación y la proporción del volumen de entrada que aparece en el cauce como parte del hidrograma. Los indicadores más directos del estado hidrológico son variables relacionadas con la humedad del suelo y los niveles de agua subterránea.

Además de estas consideraciones, como se ha explicado anteriormente, hay que tener en cuenta que los fenómenos de generación de escorrentía son muy diferentes según la época del año, los niveles de caudales actuales, la intensidad de precipitación, etc.

Dadas estas características de los procesos de generación de escorrentía, la utilización de modelos modulares puede ser de gran utilidad para la determinación de los diferentes estados de la cuenca, pudiendo emplear un modelo experto diferente para cada uno de los procesos.

Lo importante en este tipo de metodologías, no son las técnicas utilizadas como modelos expertos o de entrada, sino la elección de los grupos y las variables de entrada a utilizar como predictoras. La subdivisión es siempre diferente según el tipo de cuenca y datos de que se disponga.

En esta tesis se propone utilizar una red auto-organizativa (ver 3.5.2 Mapas auto-organizativos de Kohonen (*Self Organizing Map (SOM)*) pag. 37) para la clasificación automática de grupos. Éste es un método de clasificación no supervisado, utilizado para agrupar datos basándose solamente en la estadística, sin la definición previa de las clases. El objetivo del aprendizaje de este tipo de redes es que, patrones de entrada con características similares, queden asociados a neuronas topológicamente cercanas. Por lo tanto, es un método que se puede utilizar para clasificar cualquier tipo de datos, dependiendo de las variables de entrada elegidas. A diferencia del ejemplo mostrado en la Figura 5.2, éste método otorga un peso igual a la unidad para el grupo elegido, e igual a cero para cada uno de los demás grupos, utilizando un solo modelo experto para simular el conjunto de datos pertenecientes a ese grupo.

Una vez clasificados los datos, es necesario elegir un modelo que simule de mejor forma cada uno de los grupos. Se propone utilizar redes neuronales artificiales del tipo MLP, aunque se deja abierta la posibilidad de probar con otros tipos de redes. Cada una de estas redes expertas pueden tener topologías diferentes que se adapten mejor a cada problema.

Para construir un modelo de este tipo, primero se debe decidir la cantidad de grupos en los que se desea dividir el problema principal, que en este caso es la predicción de caudales, y qué tipo de clasificación se va a realizar. Hay que tener en cuenta que la clasificación da una idea del estado actual de la cuenca a partir del cual se hace la predicción (como por ejemplo las condiciones de humedad iniciales), por lo tanto hay que asegurarse de que ese estado actual sea lo más influyente sobre los resultados en el horizonte de predicción. Si este horizonte está muy alejado, puede ocurrir que su resultado no dependa del estado actual de la cuenca. Esta aclaración es importante para decidir el horizonte de predicción. El tipo de clasificación que se quiera realizar determina la cantidad de grupos a separar. Depende mucho del tipo de cuenca, por lo tanto es necesario conocer muy bien el proceso de transformación de lluvia escorrentía de la cuenca y las características geomorfológicas de la misma.

En la literatura existen diversos ejemplos con separaciones diferentes, como discretización de grupos en bajos, muy bajos, medios, altos y muy altos [Deka y Chandramouli, 2005], estacionales [Wang et al., 2006], estados de humedad teniendo en cuenta la precipitación [Corani y Guariso, 2005], diferentes tipos de flujos [Hsu et al., 2002, Jain y Srinivasulu, 2006], etc.

En la Figura 5.3 se muestra un ejemplo de la red auto-organizativa (SOM) utilizada para clasificar un hidrograma en 6 grupos, dividiendo en dos grupos principales que describen si el grupo pertenece a la rama ascendente o descendente del hidrograma. Cada una de las ramas se divide a su vez en tres según los caudales. Eligiendo diferentes variables de entrada se pueden obtener las separaciones que se deseen. Luego se asocia un modelo MLP para cada grupo.




Figura 5.3: Red SOM para la separación de un hidrograma

En este caso, con las variables de dQ se determina si el hidrograma está en fase ascendente o descendente y con la variable Q se determina el nivel de caudales en que se encuentra el hidrograma.

Para cada uno de los grupos se utiliza una red del tipo MLP (*MultiLayer Perceptron*) con diferentes topologías. Se analiza cada uno de los modelos por separado, pudiendo determinar el grupo con mayor dificultad para predecir caudales y centrarse en resolver el problema específico, para mejorar así el resultado global del modelo modular.

En el transcurso de esta investigación se ha desarrollado un programa informático que permite combinar estos dos tipos de redes, de tal forma que facilite y agilice el entrenamiento y la preparación de los datos. Esta herramienta permite, de forma sencilla, hacer pruebas con diferentes métodos de separación de los grupos y analizar mediante la validación el comportamiento de diferentes modelos modulares.




Figura 5.4: Separación de grupos tipo para un hidrograma. Aplicación en el río Paraná

5.3 Acerca de la clasificación de grupos

Este punto es el más importante a la hora de utilizar modelos modulares. Permite incorporar al modelo conceptos físicos para mejorar notablemente sus resultados finales. Ayuda a identificar el problema principal de predicción, pudiendo centrarse así en mejorar los resultados del grupo que peor se comporta para aumentar el rendimiento final del modelo.

En episodios de grandes precipitaciones, su distribución espacio-temporal gobierna la formación de la onda de crecida en un río, mientras que otros procesos hidrológicos (como evapotranspiración y evaporación de los cuerpos de agua o contribuciones de acuíferos al flujo) tienen menos relevancia. Por lo tanto, la precisión de las predicciones hidrológicas depende en gran parte de la exactitud de las mediciones de los campos de precipitación y su representación. Es importante tener en cuenta que sólo parte de la precipitación (precipitación efectiva) se vincula directamente con el río, mientras que la remanente se infiltra y almacena en el suelo, para llegar posteriormente al río aumentando la duración de la crecida. Durante eventos fuertes de precipitación, la cuenca se satura progresivamente, y esto causa que el proceso de infiltración se vuelva menos efectivo, llevando mayor parte de la precipitación efectiva hacia el río. Es bien conocido que la respuesta de una cuenca a impulsos de precipitación puede cambiar mucho dependiendo del grado de saturación de la cuenca, lo cual constituye un punto crítico en la modelación. De hecho, la estimación de los parámetros de infiltración es una de las fuentes de incertidumbre más importantes en los modelos físicamente basados [Corani y Guardiso, 2005].

Como se ha mencionado anteriormente, las consideraciones a tener en cuenta en la elección de los grupos son: el tipo de cuenca, su geomorfología, la respuesta de la misma, la disposición y cantidad de datos, su discretización temporal, etc.

El disponer de suficientes datos a una escala temporal acorde con la respuesta de la cuenca es muy importante. Si se poseen pocos datos no es aconsejable realizar separaciones en muchos grupos, ya que cada uno de ellos dispondrá de muy pocos datos para poder generalizar y no sobre-entrenarse.

En cuencas grandes de respuesta lenta, donde se diferencian claramente los diferentes tipos de flujo, superficial, interflujo y base, es importante realizar la separación de los grupos tratando de identificar cuándo nos encontramos en cada uno de ellos. Un ejemplo de este tipo, es la cuenca del Paraná (ver aplicación del Capítulo 8), donde un hidrograma de crecida tarda aproximadamente 2.5 meses en llegar a su pico máximo (ver Figura 5.4) y con datos discretizados diariamente se disponen de suficientes mediciones (75 mediciones de caudal) como para realizar tres separaciones de grupos en cada rama.

En el caso de cuencas de respuesta más rápida, como en el río Neuquén (ver aplicación del Capítulo 8), un hidrograma de crecidas (ver Figura 5.5) tarda 36 horas en llegar a su pico máximo, generándose en este tipo de cuencas y para este tipo de eventos sólo flujo directo y el resto del año, flujo base alimentado por los deshielos en la parte alta de la cuenca. En este caso, es condicionante la discretización temporal de los datos ya que, para poder describir de mejor manera las ramas de estos hidrogramas, será necesaria una mayor cantidad de mediciones de caudales. En este caso real los datos se registran cada 6 horas, disponiendo sólo de 6 valores de caudal en la rama ascendente. Una mejor discretización sería tomar datos horarios, aumentando de esta forma la cantidad de mediciones de caudal en la rama.

En este tipo de cuencas torrentosas de respuesta rápida es necesario realizar una separación para poder modelar individualmente las situaciones de eventos fuertes, medianos y bajos o sin eventos por derretimiento de nieve. Para ello se recomienda utilizar las variables de precipitación, ya que sus características indican la existencia o no de un evento y la magnitud del mismo.




Figura 5.5: Hidrograma de crecida del río Neuquén en “Paso de los Indios”

En la Figura 5.6 y Figura 5.7 se puede ver un ejemplo de separación de grupos utilizando la precipitación como variable de entrada al modelo SOM. En la Figura 5.6 se puede observar un evento en la época de primavera-verano producido por el derretimiento de la nieve. Casi todo el evento pertenece al grupo número 4 (rojo), salvo los picos producidos por la precipitación que pertenecen al grupo 1 (azul).




Figura 5.6: Hidrograma de crecida del río Neuquén en “Paso de los Indios” para época de derretimiento de nieve (primavera- verano)

La Figura 5.7 muestra un evento torrencial producido en la época invernal con grandes precipitaciones, en él se observan los diferentes grupos producidos por fuertes (azul) y medianas (verde) precipitaciones.

El proceso de generación de escorrentía en los dos casos descritos en las figuras anteriores es totalmente diferente, por lo tanto los modelos empleados también lo serán.

En cuencas duneanas (ver Capítulo 2) donde el porcentaje de humedad del suelo influye mucho en el proceso de generación de escorrentía, es importante realizar separaciones que tengan en cuenta esta característica. Por ejemplo, la utilización de la precipitación acumulada en períodos anteriores puede dar una idea del estado de humedad de la cuenca. Por lo tanto, se podrían utilizar diferentes modelos para simular la cuenca en sus posibles situaciones de humedad (húmeda, medio o seca).




Figura 5.7: Hidrograma de crecida del río Neuquén en “Paso de los Indios” para un evento fuerte de precipitación en la época invernal

Otro punto a tener en cuenta a la hora de la elección de los grupos es la cantidad de datos disponibles, ya que si son pocos, al separarlos, cada grupo dispondrá de muy pocos datos, impidiendo el buen entrenamiento de las redes expertas.

INCERTIDUMBRE

Capítulo 6

Capítulo 6

6 Incertidumbre

6.1 Introducción

La incorporación de la incertidumbre en un modelo de predicción es fundamental para darle una buena utilidad en un sistema operativo, ya que posibilita conocer la probabilidad de las inundaciones generando varios beneficios como poder crear un criterio basado en el riesgo para códigos de alerta de crecidas y planes de emergencia [Abrahart et al., 2004]. La toma racional de decisiones (para sistemas de alerta, navegación y embalses) requiere cuantificar, en forma de distribución de probabilidad, la incertidumbre total acerca del predictor hidrológico (como niveles de un río, caudales, o volumen) condicionada a toda la información y conocimiento disponible [Krzysztofowicz, 1999]. El objetivo de las predicciones es describir la incertidumbre de valores futuros calculados en tiempo real de los calados, caudales, volúmenes de escorrentía, etc. antes que la incertidumbre de las predicciones generadas por los modelos de predicción hidrológica.

Los sistemas de predicción de crecidas en tiempo real son herramientas con el objetivo de reducir la incertidumbre en eventos futuros y así permitir a los responsables pertinentes tomar decisiones más efectivas [Todini, 2004]. Esto significa que, para ser operativos, los sistemas de predicción no sólo deben ser precisos en un cierto horizonte de predicción, sino también proveer una cuantificación útil de la incertidumbre de la predicción. La Figura 6.1 muestra un ejemplo de una toma de decisión para dar una alarma. Este caso demuestra por qué una predicción de una crecida, sin la medida de su incertidumbre, puede no tener ningún valor y ser a veces peligrosa.

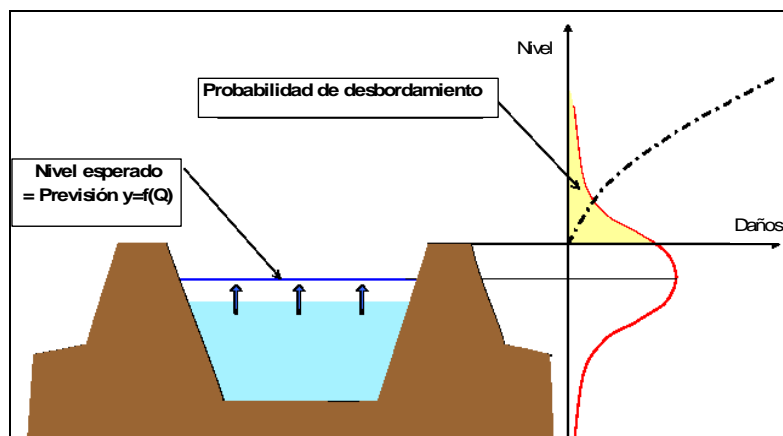


Figura 6.1 El problema de la incertidumbre de las predicciones para dar una alarma (fuente: Todini, 2004)

En este ejemplo, si el nivel del agua supera las motas o diques laterales, aparecerán daños con un costo que aumenta siguiendo la línea punteada. La predicción estima que el valor esperado del nivel del agua será inferior al umbral de desbordamiento, lo que supone un costo de daños igual a cero, no requiriendo acciones preventivas. Desafortunadamente, debido a la incertidumbre de las predicciones, que están siempre presentes (esquemáticas en la Figura 6.1, como la función de densidad de probabilidad con media igual al valor predicho), se puede comprobar que el daño esperado (la integral del producto de la densidad por el costo) es distinto de cero. Por lo tanto, la decisión más apropiada puede resultar ser algo totalmente diferente [Todini, 2004].

Es muy importante el análisis de la incertidumbre, dado el grado de complejidad interna involucrada en los modelos. Dicha incertidumbre puede ser causada por varios factores, como la estructura del modelo, los parámetros, la elección de la división de los datos al entrenar la red, el error de los datos de entrada, la función de transformación elegida, etc. La comparación de las redes con los métodos tradicionales debería hacerse respecto a la incertidumbre de cada modelo, para así poder elegir el modelo que mejor se comporte. Muchas de las aplicaciones de redes neuronales artificiales revisadas no incluyen la medida de la incertidumbre de las predicciones.

Existen gran cantidad de métodos para el cálculo de la incertidumbre de los modelos. Seguidamente se exponen algunos de ellos.

Mean Value First Order Method (MVFOM) y el método de modelación de Monte Carlo. [Melching, 1992; Yu et al., 2001], método de la búsqueda *tree-structured* [Spear et al., 1994], *Bootstrapping* [Efron y Tibshirani, 1993], el método GLUE (*Generalized Likelihood Uncertainty Estimation*) [Beven y Binley, 1992; Hossain y Anagnostou, 2005], la descripción de la incertidumbre a partir de la función de densidad de probabilidades (*pdf*) condicionada a las predicciones del modelo [Todini, 2007].

Una de las aproximaciones más extendidas es el método GLUE [Beven y Binley, 1992]. Consiste en una estimación bayesiana muy flexible que se basa en la afirmación de que diferentes parametrizaciones, al igual que diferentes estructuras de modelos, pueden simular por igual el sistema de observaciones. En este método, las relaciones dentro del modelo se ponderan y clasifican en una escala de verosimilitud, y los pesos se utilizan para formular una distribución acumulada de las predicciones [Ratto et al., 2006]. La metodología GLUE puede ser considerada como un procedimiento bayesiano deductivo (*inferencial*) que utiliza funciones de probabilidad calculadas de una manera no probabilística.

Esta metodología resulta atractiva porque no es necesario conocer los detalles de las funciones de distribución de las variables observadas ni de los errores, incluso en situaciones complejas, como en el caso de que exista más de una fuente de error. Tampoco cuando el modelo es complejo o cuando el número de parámetros es elevado [Mantovan y Todini, 2006].

Mantovan y Todini (2006) encuentran al método GLUE incoherente respecto al proceso deductivo bayesiano, que inevitablemente lleva a la sobre estimación de la incertidumbre de los parámetros y de los resultados de las predicciones del modelo.

En este capítulo se describe la metodología utilizada en la tesis para el cálculo de la incertidumbre de las predicciones. Esta metodología es la propuesta por Todini (2007) empleada en Liu et al., 2005.

6.2 Metodología para el cálculo de la incertidumbre de las predicciones

La estimación de la incertidumbre es un aspecto fundamental en la modelación hidrológica e hidráulica. Los modelos matemáticos son siempre aproximaciones de la realidad y la evaluación de la incertidumbre es una de las claves en todos los procesos de modelación [Ratto et al., 2006].

A la hora de calibrar un modelo es importante entender, más que sólo evaluar, la influencia de sus diferentes incertidumbres. El análisis de sensibilidad puede jugar un rol importante en este marco de trabajo, ayudando a mejorar el entendimiento de la estructura y a descubrir las principales fuentes de incertidumbre de las salidas del modelo [Ratto et al., 2006].

A pesar de la innegable importancia de la incertidumbre en la modelación y predicción, todavía no se ha llegado a un consenso entre los hidrólogos, por su complejidad estadística y también debido a que los usuarios finales no tienen el criterio suficiente sobre el uso de la información relevante [Todini, 2007].

Si una cantidad es conocida con exactitud, no es necesario utilizar conceptos probabilísticos, pero si no es conocida perfectamente, es necesario emplear la función de densidad de probabilidad o su integral para describirla [Todini, 2007].

Si el objetivo es la estimación de los parámetros, debemos asumir implícitamente que éstos tienen un valor verdadero aunque desconocido y que pueden ser estimados, una vez que la densidad de probabilidad futura haya sido determinada tanto en términos de máxima verosimilitud como de valores esperados [Mantovan y Todini, 2006].

Cuando el objetivo es la predicción, la aproximación bayesiana no requiere de la estimación de valores de parámetros específicos, sino de la estimación de la densidad de probabilidad futura que expresa la incertidumbre después de comparar con las observaciones. Tal vez convenga tener en cuenta que una variable determinística puede ser representada por su valor puntual, mientras que una variable no conocida o incierta requiere ser descrita por su distribución de probabilidad [Mantovan y Todini, 2006].

El objetivo de predecir es describir la incertidumbre de los valores calculados para el futuro, en lugar de realizar una descripción de la incertidumbre de las predicciones generadas por el modelo. La incertidumbre se expresa en términos de densidad de probabilidad y es condicional a la predicción del modelo, que es el conocimiento disponible, aunque no conocido, del futuro [Todini, 2007].

Para aclarar este aspecto, se define la función de densidad de probabilidad de la variable observada a predecir y (en este caso, los caudales) y la predicción del modelo \hat{y} . La gráfica de los valores observados en función de los predichos generalmente es como la Figura 6.2, salvo que las predicciones sean exactas. Esta gráfica representa una muestra de la frecuencia conjunta de las dos variables y puede ser utilizada para estimar la función de densidad de probabilidades conjunta [Todini, 2007].




Figura 6.2: Muestra de la frecuencia conjunta de caudales observados y predichos, de la cual se estima la función de densidad de probabilidad bivariada

Para un modelo dado, la variable predicha \hat{y}_t en un tiempo determinado, depende de los parámetros de los modelos φ y de las variables de entrada x_t (precipitación, caudales, etc).

Por lo tanto, la función de distribución de probabilidad conjunta puede ser expresada de la siguiente manera:

$$f(y_t, (\hat{y}_t | (x_t, \varphi))) \quad [6.1]$$

Salvo que las predicciones sean exactas, se debe obtener la probabilidad condicional de y_t dada una predicción \hat{y}_t , de tal forma que se pueda predecir y_t . La función de densidad de probabilidad condicional de los caudales observados para una determinada predicción, se obtiene cortando la densidad conjunta para un determinado valor de predicción (línea roja de la Figura 6.2) y renormalizándola de la siguiente manera:

$$f(y_t | (\hat{y}_t | (x_t, \varphi))) = \frac{f(y_t, (\hat{y}_t | (x_t, \varphi)))}{\int_0^{\infty} f(y_t, (\hat{y}_t | (x_t, \varphi))) dy} \quad [6.2]$$

Esta ecuación representa la incertidumbre de una predicción para un determinado modelo, dadas unas variables de entrada y un conjunto de parámetros. Esto no guarda relación con la incertidumbre inducida por la elección del modelo, por la elección de los parámetros o por los errores de medición de las variables de entrada y salida. Siguiendo una aproximación bayesiana, las incertidumbres descritas previamente pueden ser marginalizadas más tarde determinando su densidad de probabilidad. Los parámetros calculados están condicionados a las variables históricas utilizadas para el entrenamiento del modelo, por lo que la incertidumbre de la predicción puede estar descrita según:

$$f(y_t | (\hat{y}_t | (x_t, x_h, y_h))) = \int_{\Theta} f(y_t | (\hat{y}_t | (x_t, \varphi))) g(\varphi | (x_h, y_h)) d\varphi \quad [6.3]$$

donde,

$f(y_t | (\hat{y}_t | (x_t, x_h, y_h)))$ es la densidad de probabilidad de la variable a predecir, condicionada a los valores históricos y a las variables de entrada, después de marginalizar la incertidumbre debido a los parámetros

x_t son las variables de entrada al modelo

y_t es la variable observada a predecir

\hat{y}_t es la variable predicha

x_h, y_h son las variables históricas utilizadas para entrenar al modelo

φ son los parámetros del modelo

Θ es el espacio que contiene todos los posibles valores de parámetros

$f(y_t | (\hat{y}_t | (x_t, \varphi)))$ es la densidad de probabilidad de la variable observada condicionada a los valores predichos, la cual también está condicionada a los parámetros del modelo y a las variables de entrada

$g(\varphi | (x_h, y_h))$ es la densidad de probabilidad de los parámetros condicionados a las variables históricas utilizadas para calcular los mismos

$f(y_t, (\hat{y}_t | (x_t, \varphi)))$ es la función de densidad de probabilidad bivariada de $y - \hat{y}$

La ecuación [6.3] es la ecuación más completa de la incertidumbre de las predicciones, teniendo en cuenta la marginalización de la incertidumbre de los parámetros. La función de densidad de probabilidad de los parámetros puede ser estimada por el proceso de inferencias bayesianas [Montavan y Todini, 2006]. Para poder hacer una predicción y determinar su incertidumbre con la ecuación [6.3] se deben hacer tantas predicciones como parámetros posibles y luego, con la función $g(\varphi | (x_h, y_h))$, marginalizar las incertidumbres debidas a los parámetros [Todini, 2007].

En general se suelen estimar con un conjunto de parámetros, que se consideran los más apropiados en este caso. La incertidumbre de las predicciones puede ser expresada condicionada a los parámetros de la siguiente forma:

$$f(y_t | (\hat{y}_t | (x_t, x_h, y_h))) = f(y_t | (\hat{y}_t | (x_t, \varphi(x_h, y_h))))$$

[6.4]

Esta aproximación puede llevar a estimaciones de las predicciones e incertidumbres menos robustas y su uso debe ser justificado por la necesidad de reducir el tiempo computacional del modelo, como en el caso de sistemas en tiempo real, o demostrando que la variación de los parámetros no afecta considerablemente a los resultados del modelo [Todini, 2007].

En esta tesis se utiliza la ecuación [6.4] para la descripción de la incertidumbre de los modelos de redes neuronales artificiales.

Para el cálculo de los intervalos de confianza de un modelo de predicción, se calcula la función de distribución de los caudales observados condicionados a los predichos. Como muestra el esquema de la Figura 6.3, la función calculada se obtiene cortando la función de densidad de probabilidad bivariada por un plano igual al caudal predicho y renormalizándola, generando la gráfica derecha de la Figura 6.3. Por lo tanto, si se quiere calcular los intervalos de confianza del 90% para un caudal de 20,000 m³/s, es necesario obtener la función de distribución correspondiente a ese caudal y calcular los caudales observados para el cuantil 0.95 y 0.05 correspondientes al límite superior e inferior, respectivamente.

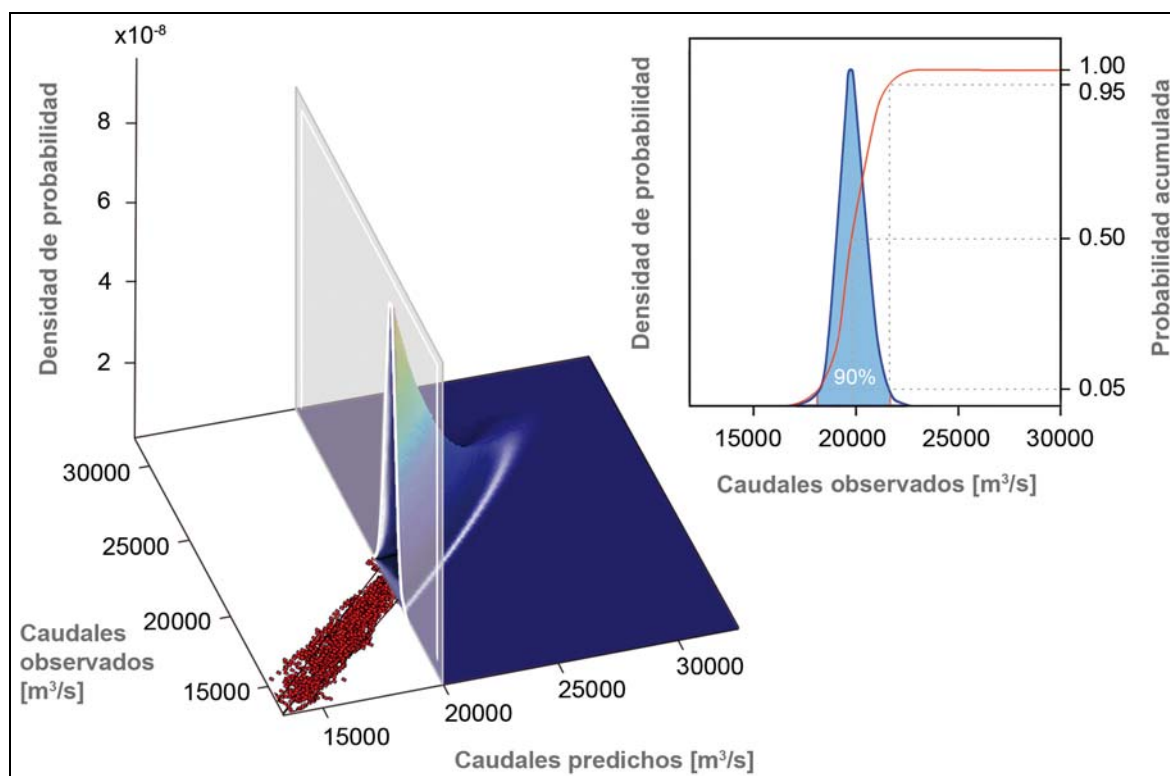


Figura 6.3: Esquema del cálculo de los intervalos de confianza para las predicciones de caudales a 10 días en el río Paraná

6.3 Incertidumbre en un modelo ARMAX

Para poder calcular los intervalos de confianza de un modelo ARMAX es necesario que las series temporales de las variables exógenas y los residuos del modelo cumplan con una serie de hipótesis, como la normalidad y la independencia entre ellas.

Para estudiar la normalidad de los residuos estandarizados se pueden utilizar las técnicas que se enumeran a continuación:

- Gráficos: el gráfico de cajas, el histograma, la estimación no paramétrica de la función de densidad, el gráfico de simetría y los gráficos $p - p$ y $q - q$.
- Contrastes de normalidad: contraste de asimetría (ver Apéndice C.2) y curtosis, contraste chi-cuadrado, contraste de Kolmogoroff-Smirnoff-Lilliefors.

Si la hipótesis de normalidad no se verifica, esto afecta al modelo en que:

- Los estimadores por mínimos-cuadrados de los parámetros del modelo no coinciden con los máximos-verosímiles. Los estimadores obtenidos son centrados, pero no eficientes.
- Los contrastes de significación (de la F y de la t) dejan de ser válidos y los intervalos de confianza obtenidos para los parámetros del modelo no son correctos. A pesar de ello, si el tamaño muestral es razonablemente grande por el teorema central del límite, los contrastes e intervalos de confianza obtenidos serán una buena aproximación de los reales.

Es muy importante conocer la causa por la que no se cumple la hipótesis de normalidad, ya que esta información puede ayudar a corregir el modelo ajustado. Entre otros motivos, la falta de normalidad puede ser debida a un conjunto pequeño de observaciones atípicas que originan apuntamiento o a la existencia de una variable cualitativa oculta que hace que la distribución sea multimodal. En estos casos se puede mejorar el modelo corrigiendo dichos problemas. En otras ocasiones, la falta de normalidad es debida a una fuerte asimetría de la distribución que, generalmente, va acompañada de otros problemas como falta de linealidad o heterocedasticidad. Entonces lo recomendable es transformar la variable respuesta, que normalmente soluciona ambos problemas. La familia de transformaciones de Box-Cox es la más utilizada.

$$y_i^{(\lambda)} = \begin{cases} \frac{y_i^\lambda - 1}{\lambda} & \text{si } \lambda \neq 0 \\ \ln(y_i) & \text{si } \lambda = 0 \end{cases} \quad i = 1, 2, \dots, n.$$

[6.5]

La falta de independencia se produce fundamentalmente cuando se trabaja con variables aleatorias que se observan a lo largo del tiempo, esto es, cuando se trabaja con series temporales. Por ello, una primera medida para evitar la dependencia de las observaciones consiste en aleatorizar la recogida muestral.

El incumplimiento de la hipótesis de independencia afecta gravemente a los resultados del modelo, se obtienen estimadores de los parámetros y predicciones ineficientes y los intervalos de confianza no son válidos. Esto es debido a que se asume que la varianza de la suma de variables independientes es igual a la suma de las varianzas de cada variable, propiedad que no se cumple para variables dependientes.

Si no se cumple la hipótesis de independencia, existen dos alternativas. La primera se basa en transformar los datos para obtener observaciones incorreladas (independientes, bajo hipótesis de normalidad) y luego aplicar las técnicas de mínimos cuadrados. Este método es un caso particular de la denominada técnica de mínimos cuadrados generalizados, que se puede aplicar en situaciones muy precisas y, por tanto, su utilización es un tanto restringida. La segunda opción se basa en aplicar métodos estadísticos diseñados para el estudio con observaciones dependientes, como son los métodos de series de tiempo y los modelos de regresión dinámica.

La dependencia entre las observaciones surge, la mayoría de las veces, porque los datos son recogidos a lo largo del tiempo y los gráficos son válidos para detectarla. Algunos gráficos para detectar dependencia son: el gráfico de los residuos frente al índice tiempo (t, e_t), el gráfico de los residuos e_{t+1} frente a e_t y el correlograma.

En el caso de que se cumplan las hipótesis fundamentales, los intervalos se calculan mediante la ecuación [6.12].

Utilizando la notación de *Box-Jenkins*, el modelo ARMAX con dos variables exógenas (*SP* y *MF*) se expresa de la siguiente forma:

$$\phi(B)Q_{t+k} = \gamma(B)SP_{t+k} + \lambda(B)MF_{t+k} + \theta(B)\varepsilon_{t+k} \quad [6.6]$$

Despejando Q_{t+k} ,

$$Q_{t+k} = \frac{\gamma(B)SP_{t+k}}{\phi(B)} + \frac{\lambda(B)MF_{t+k}}{\phi(B)} + \frac{\theta(B)\varepsilon_{t+k}}{\phi(B)} \quad [6.7]$$

donde, B es el operador de desfase. $B^k Y_t = Y_{t-k}$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\gamma(B) = 0 + 0B + 0B^2 + \dots + \gamma_L B^L + \gamma_{L+1} B^{L+1} + \gamma_{L+2} B^{L+2} + \dots + \gamma_{L+r_1} B^{L+r_1}$$

$$\lambda(B) = 0 + 0B + 0B^2 + \dots + \lambda_J B^J + \lambda_{J+1} B^{J+1} + \lambda_{J+2} B^{J+2} + \dots + \lambda_{J+r_2} B^{J+r_2}$$

$$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$$

Utilizando la propiedad de variables normales e independientes, donde si $y = a \pm bx \pm cz$ entonces $Var(y) = b^2 Var(x) + c^2 Var(z)$. Para toda variable aleatoria y , x y z normales e independientes y a , b y c constantes. Aplicando a [6.7] el operador de varianza y utilizando la propiedad mencionada anteriormente, queda que la varianza de la predicción es:

$$\sigma_{Q_{t+k}}^2 = \left(\frac{\gamma(B)}{\phi(B)} \right)^2 \sigma_{SP_{t+k}}^2 + \left(\frac{\lambda(B)}{\phi(B)} \right)^2 \sigma_{MF_{t+k}}^2 + \left(\frac{\theta(B)}{\phi(B)} \right)^2 \sigma_{\varepsilon}^2 \quad [6.8]$$

Transformando la división de los operadores de desfase por una función polinómica [Söderström, 2002] se obtiene:

$$\frac{C(B)}{A(B)} = h_0 + h_1 z + h_2 z^2 + h_3 z^3 + \dots = \sum_{j=0}^{\infty} h_j z^j \quad [6.9]$$

Aplicando la transformación [6.9] en [6.8] queda:

$$\sigma_{Q_{t+k}}^2 = \left(\sum_{j=0}^{k-1} v_j^2 \right) \sigma_{SP_{t+k}}^2 + \left(\sum_{j=0}^{k-1} \eta_j^2 \right) \sigma_{MF_{t+k}}^2 + \left(\sum_{j=1}^k \psi_j^2 \right) \sigma_{\varepsilon}^2 \quad [6.10]$$

Los intervalos de confianza se calculan de la siguiente manera:

$$Q_{t+k} = Q_{t+k}^{pred} \pm \mu_{\alpha/2} \sigma_{Q_{t+k}} \quad [6.11]$$

Por lo tanto, reemplazando [6.8] en [6.11], la forma explícita de los intervalos de confianza es:

$$Q_{t+k} = Q_{t+k}^{pred} \pm \mu_{\alpha/2} \left[\left(\sum_{j=0}^{k-1} v_j^2 \right) \sigma_{SP_{t+k}}^2 + \left(\sum_{j=0}^{k-1} \eta_j^2 \right) \sigma_{MF_{t+k}}^2 + \left(\sum_{j=1}^k \psi_j^2 \right) \sigma_{\varepsilon}^2 \right]^{1/2} \quad [6.12]$$

donde,

$\mu_{\alpha/2}$ es el valor de la normal estandarizada superado por un $\alpha/2$ x100 %.

Los coeficientes de $\nu(B)$, $\eta(B)$ y $\psi(B)$ se calculan igualando los coeficientes del mismo término del polinomio en B .

$$\frac{\gamma(B)}{\phi(B)} = \nu(B) \Rightarrow \gamma(B) = \nu(B)\phi(B)$$

$$\frac{\lambda(B)}{\phi(B)} = \eta(B) \Rightarrow \lambda(B) = \eta(B)\phi(B)$$

$$\frac{\theta(B)}{\phi(B)} = \psi(B) \Rightarrow \theta(B) = \psi(B)\phi(B)$$

[6.13]

En la aplicación del apartado 8.3, donde se construye un modelo ARMAX para predecir caudales a 1 día, se puede ver un ejemplo de esta metodología comparándola con la propuesta.

6.4 Consideraciones a tener en cuenta

Un aspecto muy relevante de la metodología descrita anteriormente es el cálculo de la función de distribución bivariada.

Para que los intervalos de confianza describan de la mejor forma posible la distribución de probabilidad del conjunto de datos, es necesario encontrar una metodología lo suficientemente flexible para ajustarse a dichos datos. La elección definirá la precisión de los intervalos de confianza calculados para cada caudal predicho.

En la bibliografía existen muchas metodologías para el cálculo de funciones de distribución bivariadas [Cuadras, 1992; Genz, 1992; Kelly y Krzysztofowicz, 1997; Molenberghs y Lesaffre, 1997; Venter, 2002; Romano, 2002; Obereder et al., 2007]. Lo importante a la hora de la elección de una de ellas es asegurarse de que capte la variabilidad de la distribución para diferentes caudales predichos, ya que para diferentes modelos, la correlación entre los caudales predichos y observados no es la misma a lo largo de todos los caudales predichos y la variación no es siempre lineal.

Por ejemplo en las figuras de la Tabla 6.1 se muestran algunos ejemplos de estas variaciones, donde se puede ver que en la mayoría de ellas la dispersión de las predicciones aumenta al aumentar los caudales.

En esta tesis se utiliza la distribución meta-gaussiana (ver Apéndice D) para el cálculo de las distribuciones de probabilidad conjuntas.


$$H(x, y) = P(X \leq x, Y \leq y) = B(Q^{-1}(F(x)), Q^{-1}(G(y)); \gamma),$$

[6.14]


Esta función permite utilizar una distribución marginal para cada conjunto de datos (en este caso, para los caudales predichos $F(x)$ y para los observados $G(x)$) y un coeficiente de correlación (γ) que correlaciona las dos series de datos. Este coeficiente es único y caracteriza la correlación entre los caudales observados y predichos para todos los niveles.

También se ha utilizado la ecuación [6.4] para el calculo de incertidumbre de las predicciones, las cuales están condicionadas a los parámetros, considerando que la elección de los mismos es la correcta y no presentan ninguna incertidumbre.


Tabla 6.1: Distribuciones de caudales observados y predichos para diferentes modelos




Fuente: [Pan y Wan, 2004]




Fuente: [Zealand, 1999]




Fuente: [Rajurkar et al., 2004]




Fuente: [Wang et al., 2006]




Fuente: [Chiang et al., 2004]



Fuente: [Thirumalaiah y Deo, 2000]



Fuente: [Thirumalaiah y Deo, 1998]



Fuente: [Pujol et al., 2007]

6.5 Conclusiones

En ninguno de los artículos analizados en la revisión bibliográfica donde se utilizan redes neuronales artificiales se calcula la incertidumbre de las predicciones. En general, el resultado del modelo es un valor único sin ninguna función de densidad de probabilidad asociada a la misma. Esto hace que el modelo no tenga utilidad en sistemas operativos de alerta, donde es necesario tomar decisiones cruzando la función de densidad de probabilidad de las predicciones con la función de riesgos o costos, conociendo las consecuencias de la decisión tomada y su probabilidad.

La metodología adoptada para el cálculo de los intervalos de confianza permite introducir de manera sencilla esta información tan necesaria en los sistemas de alerta, obteniendo, como resultado final del modelo, un rango de caudales con una probabilidad asociada.

Esta metodología puede ser mejorada utilizando diferentes aproximaciones de la función de densidad de probabilidad bivariada, que permitan tener en cuenta una variación del coeficiente de correlación para diferentes caudales predichos simulados. Esto permitirá adaptarse a las diferentes distribuciones de frecuencia encontradas en modelos de predicción como los de la Tabla 6.1.

También se podría analizar la posibilidad de marginalizar la incertidumbre de los parámetros. Una tarea complicada dada la alta cantidad de variables que intervienen en el proceso de cálculo, como por ejemplo, la serie histórica utilizada, las funciones de transformación utilizadas, el número de nodos ocultos, la función de activación, etc.

APLICACIÓN INFORMÁTICA DESARROLLADA (ANN)

Capítulo 7

Capítulo 7

7 Aplicación informática desarrollada (ANN)

7.1 Introducción

Se ha creado un programa informático para la realización de los modelos de redes neuronales artificiales y ARMAX. Es un programa muy completo programado en Visual Basic 6.0 que utiliza componentes de MatlabTM 7.0. Está enfocado principalmente a modelos hidrológicos, aunque puede ser utilizado para resolver cualquier tipo de problema.

A pesar de que existen ya programas que permiten el entrenamiento de RNA y la calibración de modelos estocásticos del tipo ARMAX, se ha optado por desarrollar uno propio que unifique todas las operaciones necesarias para la realización de modelos de predicción de caudales y tener el control completo del proceso. En la aplicación se incluye los siguientes módulos:

- *Análisis de series temporales*: Permite calcular diversos estadísticos (media, desvío estándar, máximos, mínimos, coeficiente de asimetría) de cada serie, graficar la función de distribución sobre papel a escala normal, para poder determinar su normalidad y graficar los correlogramas. También permite calcular el tiempo de concentración de la cuenca, para poder tener una idea de los tiempos de respuesta de la misma y ayudar a elegir la amplitud de la ventana de tiempo a utilizar en algunas variables de entrada. Como información adicional, se incorpora un módulo para el cálculo del tiempo de propagación de una onda de crecida en un cauce, utilizando la ecuación de manning.
- *Preparación de datos*: Permite transformar las series de entrada, utilizando cinco funciones diferentes de transformación, y ubicar los datos de entrada a la red según la ventana de tiempo elegida para cada serie.
- *Entrenamiento de la red neuronal*: Módulo para entrenar una RNA perceptrón multicapa (*MLP*) con un nodo en la capa de salida, una capa oculta y la cantidad deseada de nodos en la capa de entrada. Se puede elegir entre tres funciones de activación para la capa oculta, cuatro algoritmos de entrenamiento y dos funciones objetivo. También permite entrenar la red con datos de verificación para poder comparar la evolución de la función objetivo de la serie de verificación con la de entrenamiento y detenerlo si se detecta un sobre-entrenamiento.

- *Validación de la red neuronal*: Permite validar la red y graficar las series observadas y simuladas para poder compararlas gráficamente, tanto en función del tiempo, como las observadas en función de las simuladas.
- *Búsqueda de red óptima*: Permite entrenar una cierta topología de red variando la cantidad de nodos en la capa oculta y eligiendo el número de entrenamientos a realizar por topología, de tal manera que, para cada una de las topologías entrenadas se validan y se calculan los estadísticos que ayudan, tras un análisis, a elegir la mejor topología de red.
- *Análisis de resultados*: Calcula diferentes índices estadísticos para el análisis de los resultados. Los índices que calcula son: índice de Akaike (*AIC*), coeficiente de Nash y Sutcliffe (*Nash*), error cuadrático medio, error relativo absoluto medio, error medio, coeficiente de persistencia y coeficientes de umbral (*Ts*).
- *Modelo modular de redes neuronales artificiales*: Permite desarrollar un modelo modular con una red auto-organizativa de Kohonen (*SOM*) (*Self-Organizing Maps*) que clasifique los datos y redes perceptrón multicapa (*MLP*) para modelar cada grupo clasificado con la red *SOM*. Es posible graficar la serie clasificada para poder visualizar la separación de los grupos y elegir la red *SOM* que mejor se adapte al problema. El entrenamiento de los grupos se puede realizar conjuntamente o eligiendo cada grupo por separado.
- *Modelo ARMAX*: Permite calibrar un modelo autorregresivo con variables exógenas con la posibilidad de utilizar tantas variables como se desee. Para el cálculo de los parámetros del modelo se utilizan los algoritmos de Matlab™ 7.0. También es posible validar el modelo y analizar los resultados.
- *Intervalos de confianza*: Se ha incluido un módulo para calcular los intervalos de confianza de cualquier modelo. Éstos se basan en la obtención de funciones de distribución de los caudales observados condicionados a los predichos. Permite elegir entre siete funciones de distribución para cada serie para decidir, mediante diferentes gráficas, cuál es el par de distribuciones que mejor se adapta al problema.

Para el cálculo de los parámetros es necesario tener instalado MATLAB™ 7.0.0.19920 (R14) o versión superior. Además de:

- Paquete de simulación de redes neuronales de Matlab™ (versión 4.0.3 ó superior) desarrollado por la compañía *Math Works Inc* [Demuth y Beale, 1992]

- Establecer la configuración regional de Windows como:
 - Símbolo decimal: . (punto)
 - Símbolo de separación de miles: , (coma)
- Tener Windows actualizado

7.2 Módulo principal

En el módulo principal (ver Figura 7.1) se eligen los elementos de la RNA, se preparan los datos y se calibra la red elegida. Luego, desde este módulo, se puede acceder a los módulos de validación, SOM-MLP y ARMAX.

El programa permite guardar en un archivo (*.ann) todos los datos introducidos, para poder recuperarlos nuevamente cuando sea necesario.

7.2.1 Elementos de la red

En este cuadro se eligen los elementos principales de una red (ver Figura 7.1)

- Número de nodos en la capa de entrada
- Número de nodos en la capa oculta
- Función de activación
- Algoritmo de entrenamiento
- Función objetivo

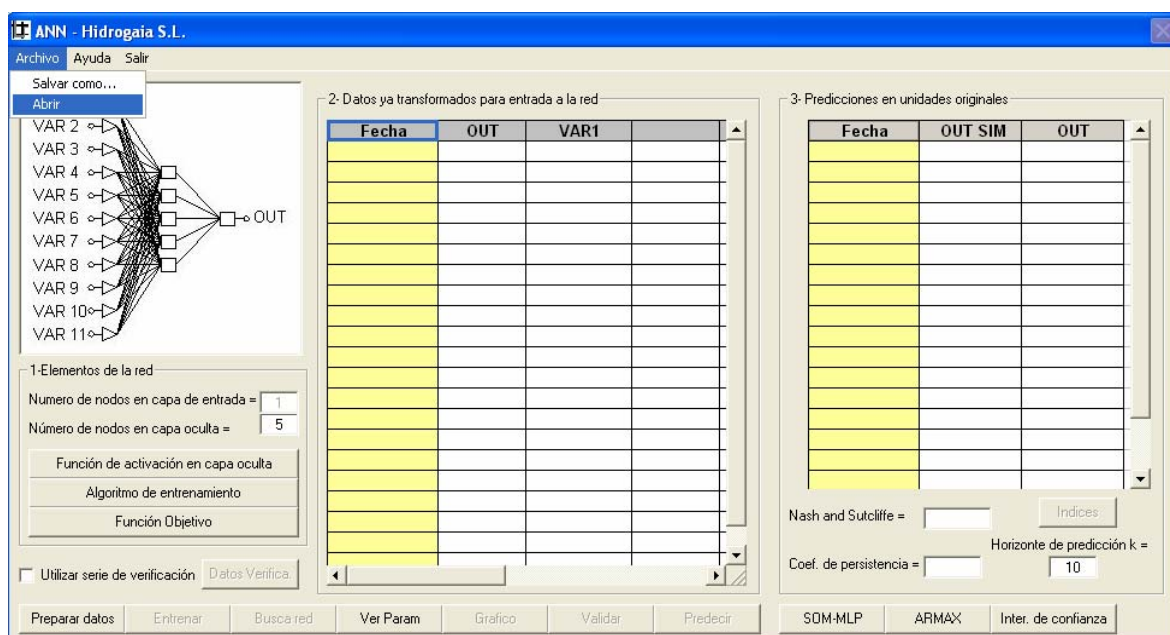


Figura 7.1: Módulo principal ANN

7.2.2 Función de activación de la capa oculta

Existe la opción de elegir entre tres funciones de activación diferentes como, se observa en la Figura 7.2 siguiente figura. En la capa oculta se utiliza por defecto la función de activación lineal.




Figura 7.2: Funciones de activación

7.2.3 Algoritmos de entrenamiento de la red

Los algoritmos de entrenamiento a elegir son los que figuran en la Figura 7.3. Para la resolución de los algoritmos se utiliza el programa Matlab™, por lo que es necesario tenerlo instalado en el momento de la calibración de la red (para una mejor descripción de los algoritmos consultar el apartado de ayuda de Matlab7.0™).




Figura 7.3: Algoritmos de entrenamiento

- I. *Trainbfg - BFGS quasi-Newton backpropagation*. Los umbrales y pesos son actualizados utilizando el siguiente algoritmo:

$$X = X + a dX$$

[7.1]

donde,

X representa los valores de los parámetros calculados

$$dX = -H/gx$$

gx es el gradiente

H es la matriz del hessiano.

II. *Trainlm - Levenberg-Marquardt backpropagation*. El algoritmo de entrenamiento es el siguiente:

$$jj = jX.JX$$

$$je = jX.E$$

$$dX = \frac{-(jj + I.mu)}{je}$$

[7.2]

donde,

X representa los valores de los parámetros calculados

jX es el Jacobiano de la función objetivo con respecto a los parámetros a calcular (X)

I es la matriz identidad

E son los errores

mu es un valor que se adapta con el entrenamiento

III. *Trainrp - Resilient backpropagation*. El algoritmo de cálculo de los parámetros es el siguiente:

$$dX = \text{delta}X.\text{sign}(gx)$$

[7.3]

donde,

X representa los valores de los parámetros calculados

gx es el gradiente

IV. *Trainngdm - Gradient descent with momentum backpropagation*. El algoritmo de cálculo es el siguiente:

$$dX = mc.dX_{prev} + lr(1 - mc).\frac{dperf}{dX}$$

[7.4]

donde,

X representa los valores de los parámetros calculados

mc es el *momentum factor*

lr es el *learning rate*

Para este algoritmo de entrenamiento es necesario especificar el *momentum factor* (mc) y el *learning rate* (lr) (Figura 7.3), dos parámetros utilizados para el entrenamiento de la red.

7.2.4 Función objetivo

Se eligen como funciones objetivo para los algoritmos de entrenamiento el error cuadrático medio y la suma de los errores al cuadrado (ver Figura 7.4).




Figura 7.4: Funciones objetivo

7.3 Preparación y análisis de los datos

7.3.1 Análisis de datos

Antes de preparar los datos de entrada a la red es necesario analizarlos para poder determinar qué variables y de qué manera utilizar. Para ello está el módulo de análisis de las series, al que se accede desde el módulo principal de preparación de datos (Figura 7.12).

Este módulo calcula los estadísticos y correlogramas de las series de datos ubicadas en el módulo de preparación de datos. Los estadísticos calculados para cada variable son los siguientes:

Media

$$\mu = \frac{1}{N} \sum_{i=1}^N y_i \quad [7.5]$$

Desvío estándar

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \mu)^2} \quad [7.6]$$

Coefficiente de asimetría

$$sk = \frac{1}{N} \frac{\sum_{i=1}^N (y_i - \mu)^3}{\sigma^3} \quad [7.7]$$

Valor Máximo y valor Mínimo

$$Max(y_i) \ ; \ Min(y_i) \quad [7.8]$$

También calcula las correlaciones cruzadas entre todas las variables y la variable objetivo y la autocorrelación (ver Figura 7.6) y autocorrelación parcial (Figura 7.7). Junto con cada figura se grafican los límites de Anderson (95%), calculados de la siguiente forma:

$$\pm rk(95\%) = \frac{-1 \pm 1.96\sqrt{N - k - 1}}{N - k}$$

[7.9]

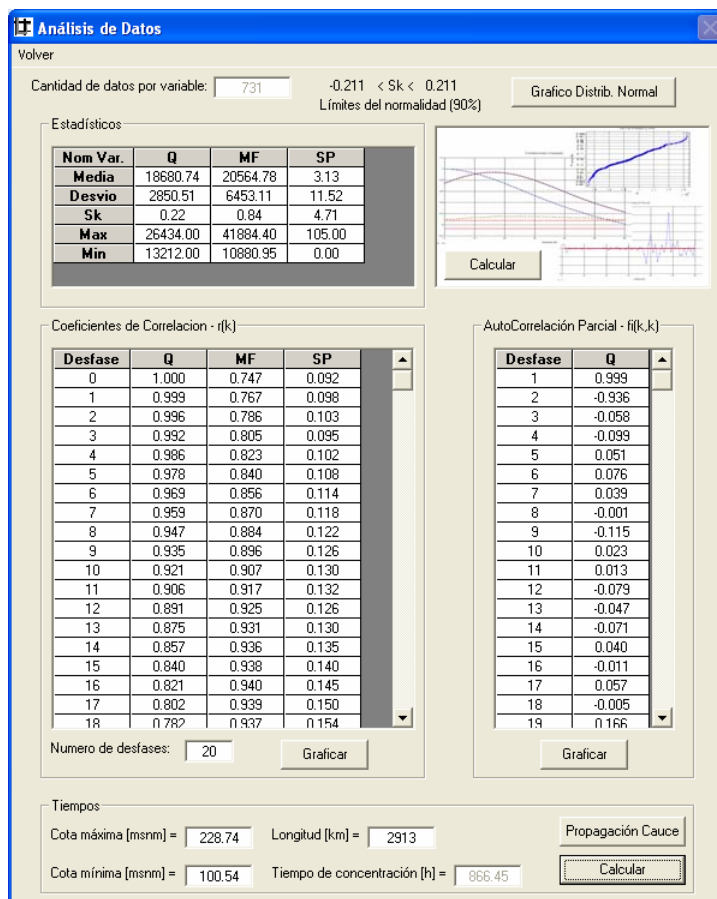


Figura 7.5: Análisis de datos

Además de los estadísticos, también calcula el tiempo de concentración de la cuenca según Témez (1987).

$$tc = 0.3(L/\sqrt[4]{S})^{0.76}$$

[7.10]

donde,

S es la pendiente media de la cuenca [m/m]

L es la longitud edel cauce entre el punto más alto y el más bajo de la cuenca [Km]

El tiempo de concentración puede servir para decidir qué variables de entrada a la red utilizar y conocer los tiempos de respuesta de la cuenca.




Figura 7.6: Autocorrelación y correlaciones cruzadas




Figura 7.7: Autocorrelación parcial

Como se muestra en la Figura 7.8, también se grafican las funciones de densidad de todas las variables en gráficos escalados según la distribución de probabilidad normal; de tal manera que se puede determinar la normalidad de las series a partir de su comparación con las líneas rectas rojas, siendo las series normales si se aproximan a éstas. Ver Apéndice C.2 para el test de normalidad utilizando el índice de asimetría. En la parte superior de la Figura 7.5 se muestran los límites de normalidad con una probabilidad del 90%.

Se ha incorporado al módulo de análisis la posibilidad de obtener los tiempos de respuesta de un cauce, calculando la celeridad de la onda cinemática de crecida (ver Figura 7.9).

Una onda se define como una variación en el flujo, que se caracteriza por una velocidad de propagación que corresponde a la velocidad con que ésta viaja a lo largo del cauce. Dicha velocidad de propagación depende del tipo de onda que se considere y puede ser sustancialmente diferente de la velocidad de escurrimiento. Por lo tanto,

se considera que la onda cinemática (ver 2.5 Propagación de una onda de crecida en un cauce, pag. 21) de crecida se transporta con una celeridad igual a 5/3 veces la velocidad media del agua en la sección tipo. Esta simplificación propuesta y comprobada en el año 1900, calcula la velocidad de tránsito de una avenida, que no se lamina. En cauces prismáticos o en cauces muy anchos, de pendiente mayor a 0.2 %, el tránsito de avenidas cumple estas propiedades [Vide, 2002].




Figura 7.8: Gráficos de probabilidad normal

Para el cálculo de la velocidad media del agua se utiliza la ecuación de manning, asumiendo la simplificación de régimen uniforme (ecu. [7.11]).

$$V = \frac{1}{n} R^{2/3} \sqrt{J}$$

[7.11]

donde,

n es el coeficiente de rugosidad de manning del cauce [s/m^{1/3}]

J es la pendiente media del cauce (Cota máxima-Cota mínima)/Longitud total [m/m]

R es el radio Hidráulico = A/P (Área mojada de la sección/Perímetro mojado) [m]

Se calcula la celeridad de dos formas diferentes. Una, considerando la hipótesis de cauces anchos donde $c = 5/3 V$ y otra, según la teoría de la onda cinemática donde la celeridad se calcula de la siguiente forma:

$$c = \frac{dQ}{dh}$$

[7.12]

La variación del caudal con respecto al calado se calcula para una variación de calado entre un $\pm 10\%$ del calado calculado con la ecuación de manning para un determinado caudal.

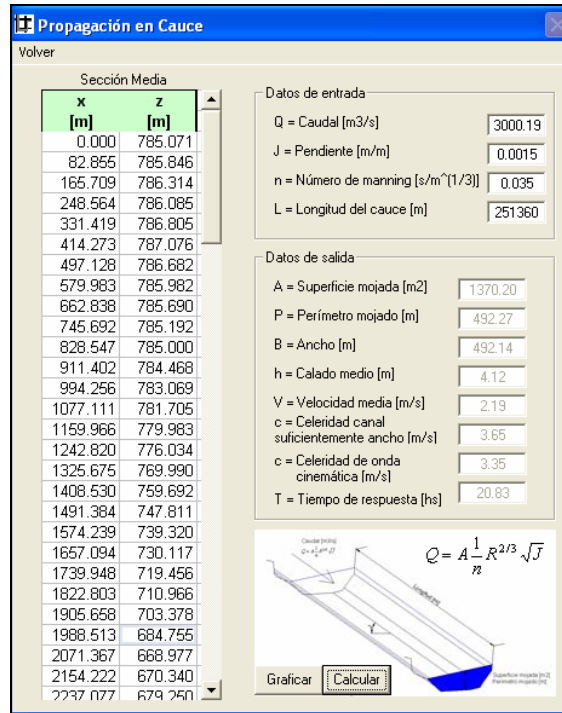


Figura 7.9: Cálculos de tiempos de propagación de una onda de crecidas en un cauce con sección y pendiente constante

Con esta celeridad c y la longitud del cauce L se calcula el tiempo de respuesta

$$t = \frac{L}{c}$$

[7.13]

Como se puede ver en la Figura 7.10, este módulo permite realizar los cálculos para cualquier tipo de sección, determinada por las coordenadas de cada punto, y también gráfica la variación del caudal con respecto al calado.




Figura 7.10: Sección utilizada para el cálculo de la velocidad del agua utilizando la ecuación de manning

7.3.2 Preparación de los datos

Una vez determinadas las variables a utilizar se procede a preparar los datos para poder entrenar la red.

Los datos se pueden preparar manualmente directamente del módulo principal (Figura 7.1) o automáticamente utilizando la función **Preparar datos**.

El formato de entrada de los datos es el siguiente:

Los datos tienen que estar ya transformados (si corresponde) tal cual entran a la red. Si esto se hace manualmente los valores de salida de la red no son los datos reales, sino que hay que aplicarle la transformación inversa. En el caso de ingresar los datos desde la **Preparar datos**, el programa transforma automáticamente los datos de salida, según la función de transformación elegida.

En el caso de una red del tipo de la Figura 7.11 donde las variables pueden ser cualquiera ($VAR1, VAR2, \dots, VAR11$) y la variable de salida OUT , se deben ingresar los datos manualmente y la entrada de datos se hace como sigue:

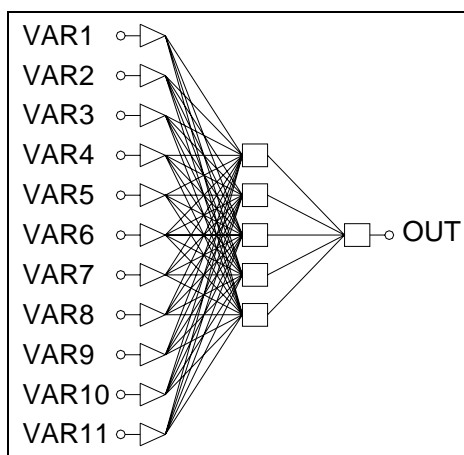


Figura 7.11: Ejemplo de red neuronal artificial

Tabla 7.1: Tabla ejemplo de preparación de datos de entrada

Nº de entrada	OUT	Var 1	Var 2	Var 3	Var 4	Var 5	Var 6	Var 7	Var 8	Var 9	Va10	Va11
1	0.980	0.240	0.323	0.393	0.464	0.624	0.802	0.877	0.961	0.989	0.933	0.840
...
n	1.098	0.393	0.464	0.546	0.593	0.877	0.961	0.989	0.933	0.840	0.793	0.793

Cada fila representa una relación entre las variables VAR y la variable OUT , ubicada como muestra la tabla. Se coloca tanta cantidad de filas como relaciones entre las variables se tengan, siendo el primer nodo de entrada la $VAR 1$ y el último la $VAR11$, tal como se muestra en la Tabla 7.1.

En el caso de que las variables sean series temporales, donde cada nodo es la misma variable pero desplazada en el tiempo, y la variable *OUT* sea la predicción en un tiempo *k* de la **primer variable** (en este caso *Q*), se puede utilizar el módulo de **Preparar datos** (ver Figura 7.12) para prepararlos y transformarlos de forma más rápida.

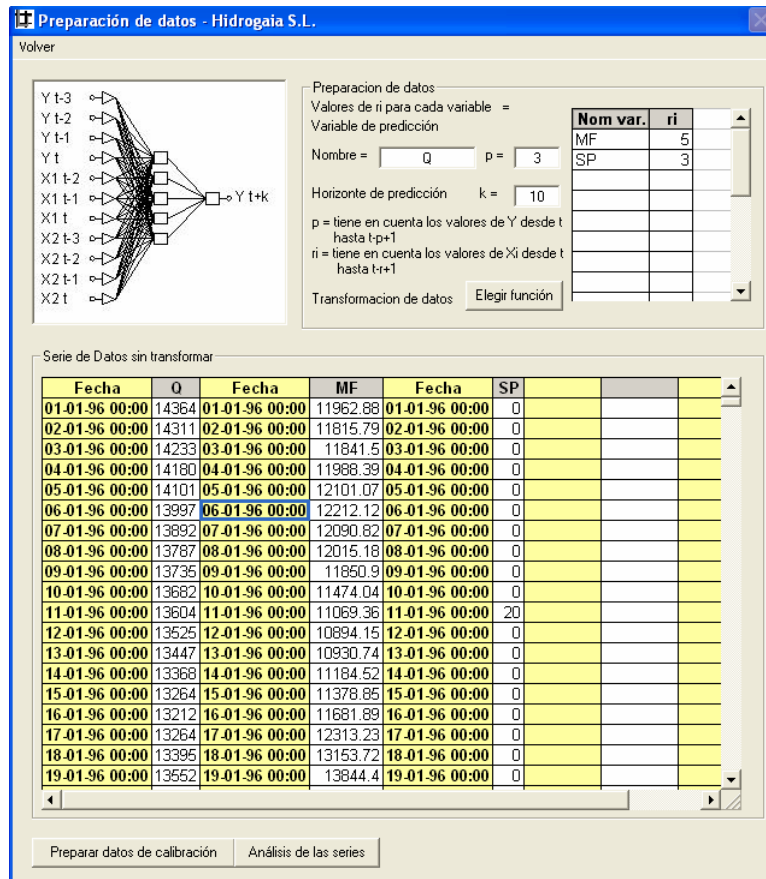


Figura 7.12: Módulo de preparación de datos

En la preparación automática de datos se pueden utilizar todas las variables que se deseen, siendo *Y* la variable de predicción y *X(i)* $i = 1, 2, \dots, n$, otras variables de entrada.




Figura 7.13: Red neuronal artificial resultante de la preparación automática de datos

Para la preparación de los datos se debe indicar:

$k = 10$ significa que la variable de salida es Y_{t+10} . Se predice a k intervalos de tiempo.

$p = 4$ significa que se utilizan en la entrada del modelo 4 valores de Y , que son:

$$Y_t, Y_{t-1}, Y_{t-2} \text{ y } Y_{t-3}.$$

En la tabla de arriba se indican los r_i para cada una de las variables $X(i)$:

$r_1 = 3$ significa que se utilizan en la entrada del modelo 3 valores de $X(1)$ (con nombre MF), que son: $X1_t, X1_{t-1}$ y $X1_{t-2}$.

$r_2 = 4$ significa que se utilizan en la entrada del modelo 4 valores de $X(2)$ (con nombre SP), que son: $X2_t, X2_{t-1}, X2_{t-2}$ y $X2_{t-3}$.

Las variables se ordenan en la red tal como se indica en la Figura 7.13.

La función de transformación a elegir es la misma para cada variable. Puede consistir en una de las que se muestran en la Figura 7.14.

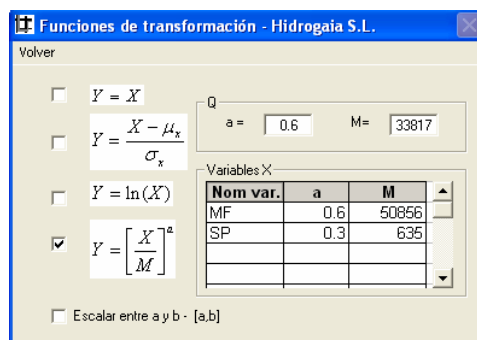


Figura 7.14: Funciones de transformación de las variables

La segunda transformación calcula la media y el desvío estándar de cada variable, al igual que la cuarta transformación, donde los parámetros pueden ser diferentes para cada variable (M es un valor cercano al máximo de la serie de cada variable). En los cuadros de texto de la Figura 7.14 se indican los parámetros a y M de la variable principal (Q) y en la tabla inferior los de las otras variables (X).

La ecuación para transformar entre a y b es:

$$y_i = \frac{b - a}{x_{Max} - x_{Min}} x_i + \frac{ax_{Max} - bx_{Min}}{x_{Max} - x_{Min}}$$

[7.14]

Una vez elegida la función de transformación y la serie de datos a utilizar, se transforman los valores automáticamente y se colocan en la pantalla principal para poder entrenar la red.

7.4 Entrenamiento

La cantidad de veces que pasan los datos de entrenamiento por la red para ser entrenada son las “épocas”. Estas se fijan estas en 100,000 ya que se puede parar el entrenamiento cuando se desee. Se grafica en tiempo real la evolución de la *función objetivo* en función de las épocas (ver Figura 7.16) o se detiene automáticamente cuando la función objetivo alcanza un gradiente menor a 10^{-10} .

El entrenamiento puede llevarse a cabo con datos de verificación para poder realizar una parada temprana cuando se entrena la red, como en la Figura 7.16, donde la línea roja indica la evolución del error de los datos de verificación y con la azul representa los datos de calibración. Se puede seleccionar esta opción desde el menú principal activando (ver Figura 7.1) **Utilizar serie de verificación**, e introducir los datos de verificación de la misma manera que los de calibración (ver Figura 7.15).

Fecha	Qt + 10	Qt - 2	Qt - 1	Qt - 0
15/01/1998	23713	23373	23373	23474
16/01/1998	23610	23373	23474	23576
17/01/1998	23508	23474	23576	23713
18/01/1998	23407	23576	23713	23782
19/01/1998	23306	23713	23782	23817
20/01/1998	23173	23782	23817	23887
21/01/1998	23040	23817	23887	23956
22/01/1998	22909	23887	23956	23921
23/01/1998	22812	23956	23921	23887
24/01/1998	22747	23921	23887	23782
25/01/1998	22715	23887	23782	23713
26/01/1998	22683	23782	23713	23610
27/01/1998	22677	23713	23610	23508
28/01/1998	23239	23610	23508	23407
29/01/1998	23206	23508	23407	23306
30/01/1998	23206	23407	23306	23173
31/01/1998	23173	23306	23173	23040
01/02/1998	23139	23173	23040	22909

Figura 7.15: Datos de verificación

Una vez entrenada la red, se muestran en el cuadro **3- Predicciones en unidades originales** de la Figura 7.1, los valores de salida de la red *OUT SIM* y los valores conocidos *OUT*. También se calcula el coeficiente de *Nash and Sutcliffe* (E_{mod}) y el coeficiente de persistencia (C_p), para el cual es necesario indicar el horizonte de predicción (k).

Un modelo de persistencia consiste básicamente en suponer que el valor predicho en el tiempo k es igual al actual:

$$Y_t = Y_{t+k}$$

[7.15]

Por lo tanto, para calcular el C_p se calcula el coeficiente de Nash and Sutcliffe (E_{pers}) de este modelo y se divide por el del modelo de redes neuronales, para poder comparar y ver si el modelo calculado es efectivamente mejor al de persistencia.

$$C_p = 1 - E_{per}/E_{mod} \tag{7.16}$$

Valores de C_p menores a 0 indican que el modelo calculado es peor que el de persistencia, por lo tanto no es aceptable. Valores mayores a 0 indican que el modelo calculado es mejor que el de persistencia.




Figura 7.16: Evolución de la función objetivo en para cada época. Línea roja para la evolución del error en los datos de verificación y azul para los datos de calibración

Además de obtener los valores numéricamente en el módulo principal (Figura 7.1), se pueden graficar los resultados, tanto en función del tiempo (Figura 7.17), como los valores observados en función de los simulados (Figura 7.18). Estos gráficos pueden ser exportados como imágenes.




Figura 7.17: Gráfico de los valores observados y predichos en función del tiempo




Figura 7.18: Gráfico de los valores observados en función de los predichos

7.5 Parámetros

Los parámetros calculados pueden ser vistos y ser importados o exportados de un archivo de texto (ver Figura 7.19).

Parámetros entre capa oculta y capa de salida:						
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	umbral
Q t + 10	11.06	0.22	2.49	0.43	-9.21	7.32
Parámetros entre capa de entrada y c.:						
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	
umbral	-13.85	3.50	1.06	-5.45	8.63	
Q t - 0	8.22	-3.76	4.87	-6.03	13.27	
Q t - 1	4.05	0.72	-13.45	4.08	3.17	
Q t - 2	0.81	8.34	9.33	4.24	-3.16	
MF t - 0	-2.38	-8.92	-2.65	11.27	4.65	
MF t - 1	-4.81	-8.40	-1.23	2.55	-0.41	
MF t - 2	-3.68	-4.91	4.85	0.71	0.45	
MF t - 3	-4.94	1.41	-6.25	0.31	2.64	
MF t - 4	-1.95	9.31	6.76	-9.13	3.66	
SP t - 0	2.78	-0.03	0.11	-0.10	4.14	
SP t - 1	0.02	0.78	0.12	-0.64	-1.72	
SP t - 2	-3.39	-0.51	0.14	0.04	-1.73	

Figura 7.19: Parámetros calculados

En el archivo exportado de los parámetros se guardan, junto con ellos, todas las características de la red.

El formato del archivo exportado es como el de la Figura 7.20 donde se muestran:

Línea 1: nombre de la variable de predicción, p, cantidad de variables x (*cantr*), k, nodos en la capa de entrada, nodos en la capa oculta, función de activación (tres valores seguidos), función de transformación (5 valores últimos)

Línea 2: $r_1, r_2, r_3, \dots, r_i$

Línea 3: nombre de variable₁, a_1 (parámetro de Bartual), M_1 (parámetro de Bartual), nombre de variable₂, a_2 (parámetro de Bartual), M_2 (parámetro de Bartual), ... nombre de variable_{cantr}, a_{cantr} (parámetro de Bartual), M_{cantr} (parámetro de Bartual)

Línea 4: media variable₁, desvío variable₁, máximo variable₁, mínimo variable₁, media variable₂, desvío variable₂, máximo variable₂, mínimo variable₂, ..., media variable_{cantr}, desvío variable_{cantr}, máximo variable_{cantr}, mínimo variable_{cantr}

Línea 5: variable principal (Parámetro de Bartual), M variable principal, media, desvío, mínimo, máximo (todos de la variable principal)

Línea 6: parámetros de la capa de salida

Línea 7 a última: parámetros de la capa de entrada

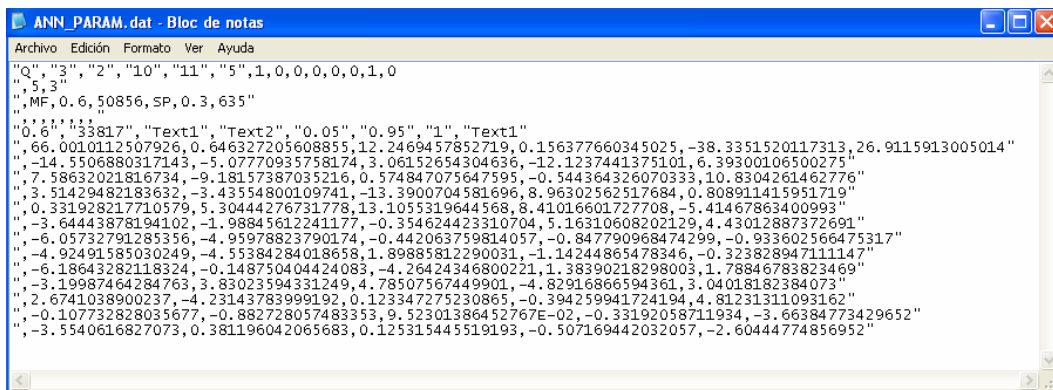


Figura 7.20: Formato del archivo de parámetros

En la Figura 7.21 se presenta un ejemplo de las conexiones de un nodo de la capa de entrada con la red, para poder entender el significado de cada uno de los parámetros de la Tabla 7.2.

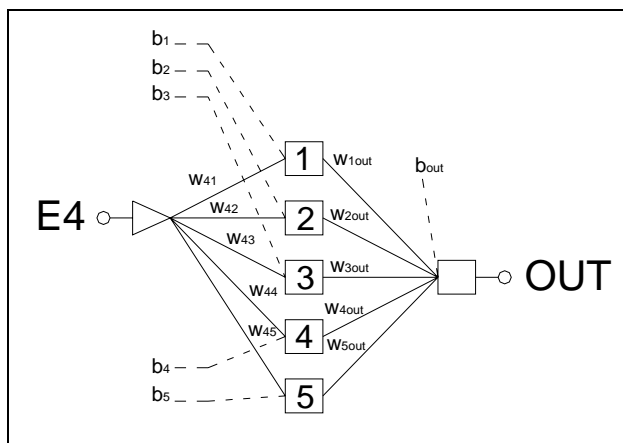


Figura 7.21: Ejemplo de los parámetros de un nodo de entrada con la red

Tabla 7.2: Esquema de los pesos y umbrales de las redes neuronales

Parámetros entre capa oculta y capa de salida						
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	umbral
OUT	W_{1out}	W_{2out}	W_{3out}	W_{4out}	W_{5out}	b_{out}

Parámetros entre capa de entrada y capa oculta						
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	
umbral	b_1	b_2	b_3	b_4	b_5	
E4	W_{41}	W_{42}	W_{43}	W_{44}	W_{45}	

7.6 Validación

Para validar la red, la preparación de los datos es semejante a la de los datos de calibración, al igual que los resultados de la validación, tanto en términos numéricos como gráficos.

En la Figura 7.22 se muestra la pantalla principal del módulo de validación, la cual tiene las mismas funciones que la de calibración. Se puede obtener un resumen (*analisi.txt*) de todas las validaciones que se han realizado, para poder analizar todas las redes y poder elegir la óptima. El resumen contiene los siguientes campos

Id: número de validación

Función de activación: *logsig*, *tansig* o *purelin*

Algoritmo de entrenamiento: *trainbfg*, *trainlm*, *trainrp* o *traingdm*

Función objetivo: *mse* o *sse*

Función de transformación: *lineal*, *media_y_desvío*, *logarítmica*, *bartual* o *escalada*

Nodos en la capa de entrada

Nodos en la capa oculta

Horizonte de predicción

Persis validación: coeficiente de persistencia para la validación

Nash validación: coeficiente de *Nash and Sutcliffe* para la validación

Persis calibración: coeficiente de persistencia para la calibración

Nash calibración: coeficiente de *Nash and Sutcliffe* para la calibración

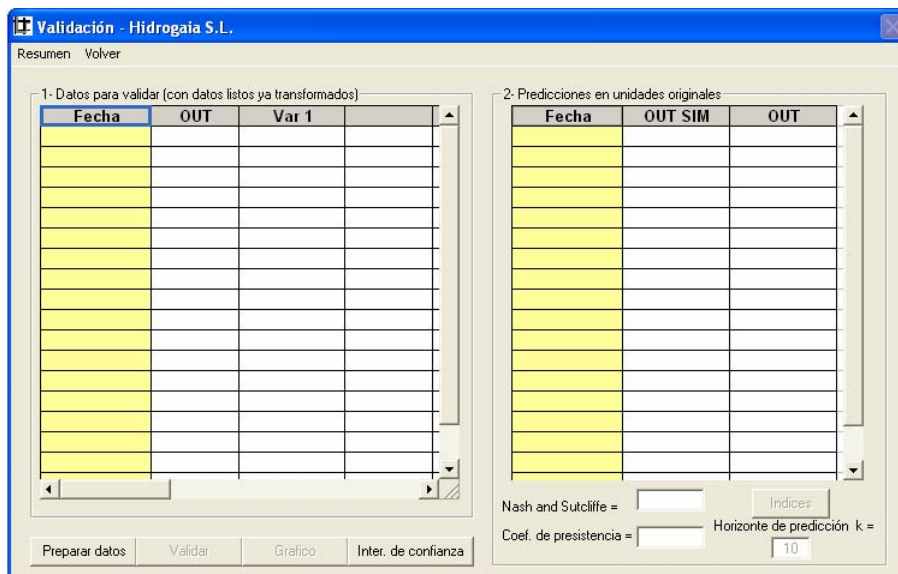


Figura 7.22: Módulo de validación

Tanto para la validación como para la calibración, se pueden calcular diferentes índices de fiabilidad:

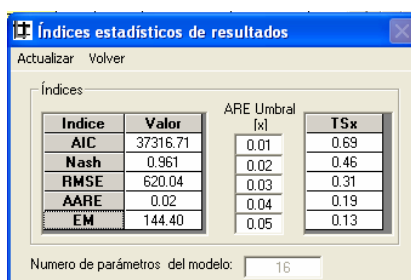


Figura 7.23: Índices de fiabilidad

AIC (Akaike Information Criterion):

$$AIC = N \ln(\sigma_{\epsilon}^2) + 2(Nparametros) \tag{7.17}$$

Coeficiente de *Nash and Sutcliffe* (1970) (Nash)

$$E = 1 - \frac{\sum_{i=1}^n (Q_i^{pre} - Q_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \tag{7.18}$$

Raíz de los errores cuadráticos medios (*RMSE*)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_i - Q_i^{pre})^2}{n}} \tag{7.19}$$

Error relativo absoluto promedio (*AARE*)

$$AARE = \frac{\sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right|}{n} \quad [7.20]$$

Error medio

$$EM = \frac{\sum_{i=1}^n (\hat{y}_i - y_i)}{n} \quad [7.21]$$

Estadístico de umbral (*TS*)

$$TS_x = \frac{N_x}{N} \quad [7.22]$$

donde, N_x es el número de predicciones para los cuales el error absoluto relativo (ARE) es menor que un cierto umbral x , determinado a partir de los resultados. N es el número total de puntos predichos.

7.7 Predicción

El módulo de predicción está enfocado para la utilización de la red en tiempo real, donde se introducen los datos de las variables de entrada conocidos en el presente y se calcula la predicción.

Los valores de las variables de entrada ya tienen que estar transformados, y el resultado de la predicción ya es transformado en las unidades originales según la función de transformación elegida en la calibración de la red.




Figura 7.24: Módulo de predicción

7.8 Búsqueda de la red óptima

Este módulo esta pensado para la búsqueda de la red óptima. Ejecutando el botón **Buscar Red**. Como se aprecia en la Figura 7.25, el módulo pregunta entre qué cantidad de nodos en la capa oculta iterar, cuántos entrenamientos por topología y qué cantidad de épocas en cada entrenamiento.

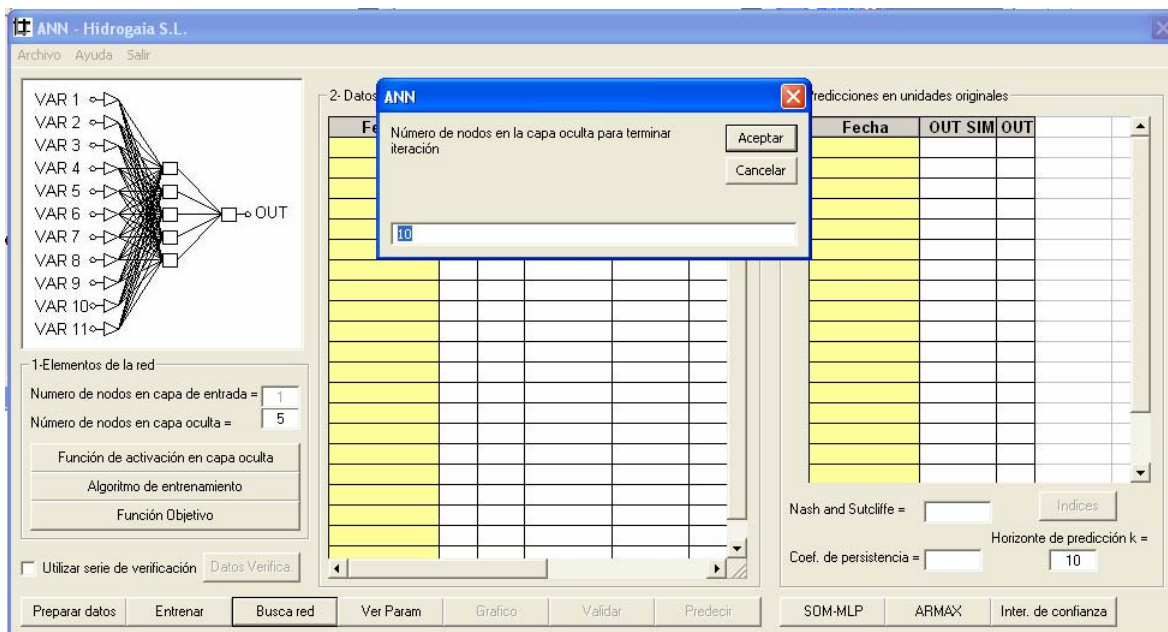


Figura 7.25: Módulo para la búsqueda de la red óptima

Para cada entrenamiento se guarda la red con el siguiente nombre “MLP_nh_iter”, donde *nh* es la cantidad de nodos en la capa oculta e *iter* el número de iteración correspondiente al entrenamiento de esa red.

Cada una de las redes se verifica (ubicando los datos de verificación en la tabla de validación) y se crea el fichero de resumen (*analisi.txt*) explicado en el apartado 7.6 Validación. Luego, este fichero servirá para analizar todas las redes entrenadas y verificadas, para poder elegir la que mejor se comporte y eliminar las redes con sobre entrenamientos.

Un ejemplo de un posible análisis es el mostrado en la Figura 7.26. Donde se puede ver que la mejor red es la red con 6 nodos en la capa oculta.




Figura 7.26: Gráfico de cajas para seleccionar la cantidad de nodos en la capa oculta

7.9 Modelo modular (SOM-MLP)

Para construir un modelo modular, primero hay que entrenar la red auto-organizativa (SOM) con una serie de variables de entrada previamente elegidas. Luego, entrenar cada uno de los modelos MLP con los datos de los grupos identificados con la red SOM.

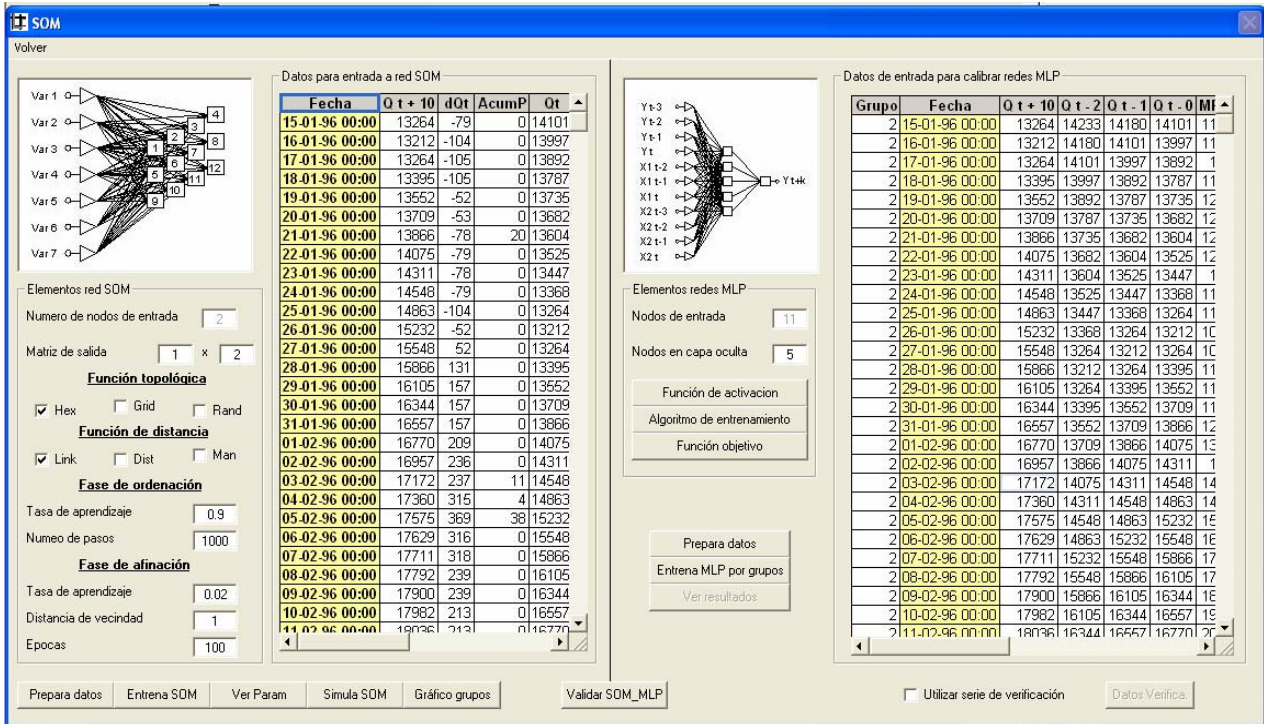


Figura 7.27: Módulo del modelo SOM-MLP

Como se ve en la Figura 7.27, en la tabla izquierda se colocan los datos de entrada a la red SOM. En las primeras dos columnas se coloca la fecha y la variable objetivo a clasificar y en las siguientes columnas, las variables de entrada a la red SOM (en este caso se ven sólo tres variables de entrada: dQt , $AcumP$ y Qt). Cada fila de la tabla izquierda debe corresponderse con las filas de la tabla derecha. Por ejemplo, la primera fila utiliza ciertas variables para determinar el grupo correspondiente a la primera fila de la tabla derecha. Por lo tanto, la variable Qt de la tabla derecha en la primera fila, debe corresponder a la variable Qt de la tabla derecha. Como se muestra en la Figura 7.27, en los dos casos es igual a 14,101 m³/s.

Las variables de entrada a la red SOM pueden ser transformadas entre a y b con el módulo de preparación de datos (ver Figura 7.28). Este pre-procesamiento de los datos es importante para concederles el mismo peso a todas las variables o la importancia que se desee. En la primera columna se ubica la variable a clasificar, la cual sólo es utilizada para ser graficada. En las siguientes columnas se colocan las variables utilizadas como entradas de la red,

las cuales se escalan entre a y b según lo que se indique en la tabla superior derecha (ver Figura 7.28).

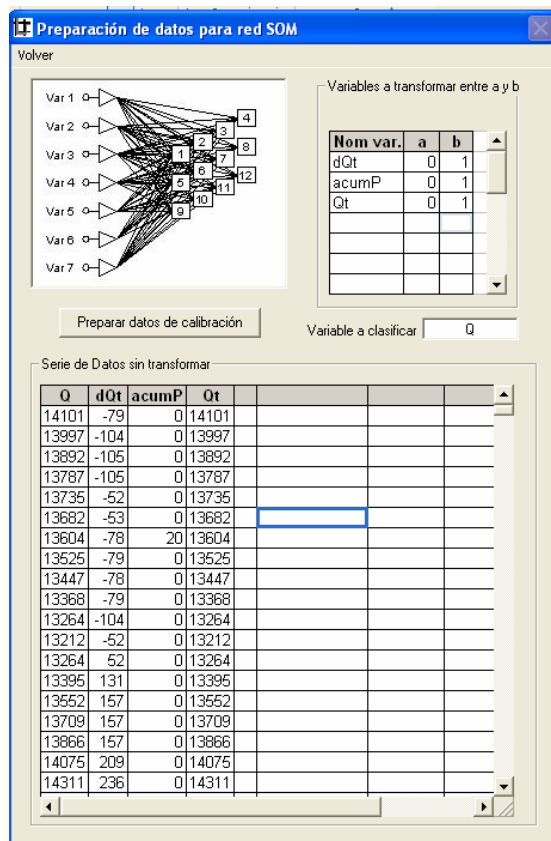


Figura 7.28: Módulo de preparación de datos para la red SOM. Transforma cada variable entre a y b

El objetivo es clasificar con la red SOM los diferentes estados al inicio de la predicción. Una vez entrenada, se colocan los identificadores de los grupos en la primera columna de la tabla derecha, junto con las variables de entrada de las redes MLP. Luego se entrenan tantas redes MLP como grupos se tengan. Todas las MLP tienen la misma estructura, donde se debe determinar la cantidad de nodos en la capa de entrada y oculta, la función de activación, el algoritmo de entrenamiento, la función objetivo y la función de transformación.

Finalmente se tiene una red MLP para cada grupo. Para predecir, por ejemplo, caudales que pertenecen al grupo 1, se utiliza la red MLP1, si el caudal a predecir pertenece al grupo 2, se utiliza la red MLP2 y así sucesivamente.

Se pueden graficar los grupos para verificar la forma en la que está clasificando la red SOM (ver Figura 7.29).

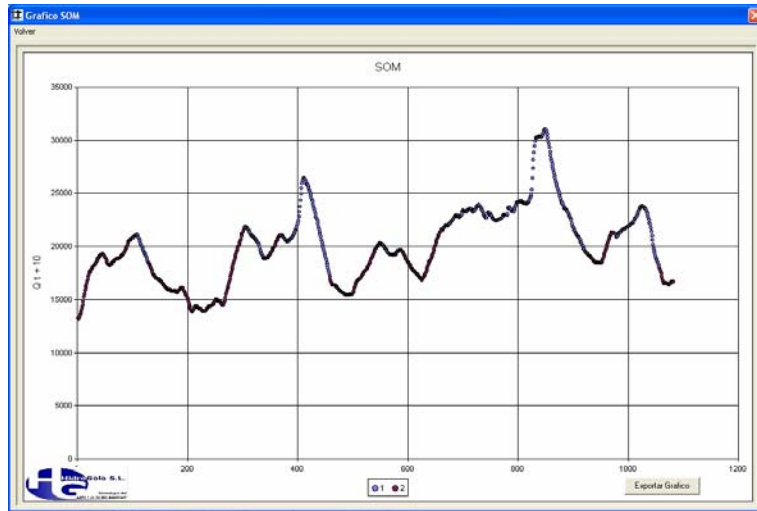


Figura 7.29: Gráfico de la clasificación de grupos con la red SOM

7.9.1 Elementos de la red

Se deben determinar los siguientes parámetros:

- Cantidad de nodos en la capa de entrada
- Dimensiones de la matriz de salida
- Función topológica
- Función de distancia
- Parámetros de entrenamiento

Función Topológica

La función topológica es la función que se encarga de seleccionar la ubicación inicial de los centros (inicializar los pesos).

Hex: Ubica los centros con una distribución hexagonal, como se puede ver en la Figura 7.30




Figura 7.30: Función topológica Hex

Grid: Ubica los centros con una distribución regular, como se muestra en la Figura 7.31




Figura 7.31: Función topológica Grid

Rand: Ubica los centros de forma aleatoria, como se observa en la Figura 7.32




Figura 7.32: Función topológica Rand

Función de distancia

Se pueden elegir diferentes funciones para medir la distancia entre las neuronas de salida y el vector de entradas. Se utilizan sólo en el entrenamiento, en la validación se emplea siempre la función *Dist*.

Link: La distancia *link* de una neurona u otra es la cantidad de enlaces o pasos que se deben seguir para llegar a la neurona en cuestión. La distancia *link* (D_{ij}) entre dos vectores P_i y P_j y una serie de vectores S se corresponde con:

$$0, \text{ si } i = j$$

$$1, \text{ si } \sqrt{\sum (P_i - P_j)^2} \leq 1$$

$$2, \text{ si existe un } k \text{ para el cual } D_{ik} = D_{kj} = 1$$

$$3, \text{ si existe } k_1 \text{ y } k_2 \text{ y } D_{ik_1} = D_{k_1 k_2} = D_{k_2 j} = 1$$

N, si existe k_1, k_2, \dots, k_N y $D_{ik_1} = D_{k_1k_2} = \dots = D_{k_Nj} = 1$

S, si no se cumple ninguna de las condiciones anteriores

Dist: es la distancia euclídea

$$D = \sqrt{\sum (P_i - P_j)^2}$$

Man: Es la distancia Manhattan

$$D = \sum |P_i - P_j|$$

Parámetros de entrenamiento

El algoritmo de entrenamiento funciona de la siguiente manera:

En primer lugar, la red identifica la neurona ganadora. Después, los pesos de ésta y de las neuronas en su vecindad se desplazan hacia el vector de entradas según el algoritmo de aprendizaje.

Los pesos de la neurona ganadora se alteran proporcionalmente a la tasa de aprendizaje y los de las neuronas vecinas, proporcionalmente a la mitad de la tasa de aprendizaje. Los parámetros (tasa de aprendizaje y distancias vecinas) utilizados para determinar cuáles son las neuronas dentro de la vecindad de la ganadora, se alteran durante el aprendizaje a través de dos fases: fase de ordenación y fase de afinación.

Fase 1: Fase de ordenación

Ésta dura la cantidad de pasos indicados. La distancia de vecindad empieza como la máxima distancia entre dos neuronas y disminuye hasta la distancia de vecindad de la fase de afinación. La tasa de aprendizaje empieza con la indicada para esta fase y disminuye hasta llegar a la de la fase de afinación. A medida que dichos parámetros disminuyen a lo largo de esta fase, las neuronas de la red se ordenan en el espacio de las entradas según la topología indicada.

Fase 2: Fase de Afinación

Ésta fase continúa el resto del entrenamiento. La distancia de vecindad se mantiene en la indicada en esta fase. La tasa de aprendizaje continúa decreciendo, muy lentamente, desde la tasa de afinación. El número de épocas para esta fase debería ser mayor que la cantidad de pasos de la fase de ordenación.

La red identifica la neurona ganadora i^* según las reglas de Kohonen.

Se ajustan todas las neuronas dentro de un radio de vecindad $i \in N_{i^*}(d)$

$$w_i(q) = w_i(q-1) + \alpha(p(q) - w_i(q-1)) \text{ ó } w_i(q) = (1 - \alpha)w_i(q-1) + \alpha p(q)$$

donde,

$$\alpha = lr \cdot A2$$

lr es la tasa de aprendizaje

P es el vector de entradas

la activación $A2$ se obtiene de la capa de salida A y distancias entre neuronas D y la distancia de vecindad actual ND :

$$A2(i, q) = 1, \quad \text{si } A(i, q) = 1$$

$$A2(i, q) = 0.5, \quad \text{si } A(i, q) = 1 \text{ y } D(i, j) \leq ND$$

$$A2(i, q) = 0, \quad \text{si no se cumple ninguna condición anterior}$$

la vecindad $N_{i^*}(D)$ contiene todos los índices de las neuronas que entran dentro de un radio de vecindad D de la neurona ganadora i^*

$$N_i(D) = \{j, D_{i,j} \leq D\}$$

Si los vectores de entrada a la red se distribuyen probabilísticamente de forma uniforme en el espacio de entradas, las neuronas se ordenarán con distancias semejantes entre sí. Si estos vectores ocurren con frecuencias diferentes en el espacio de entradas, la capa de salida tiende a ubicar las neuronas en áreas proporcionales a la frecuencia de aparición de los vectores de entradas. De esta forma, cuando se entrena la red para categorizar las entradas, también aprende la topología y distribución de las entradas.

Al entrenar la red existe la posibilidad de utilizar datos de verificación (ver cuadro de activación en la esquina inferior derecha de la Figura 7.33) para comprobar que no se produzca sobre entrenamiento cada vez que se entrena una MLP.




Figura 7.33: Evolución en tiempo real de la función objetivo para cada época de entrenamiento

7.9.2 Parámetros

Una vez entrenada la red SOM se preparan los datos para poder entrenar cada una de las redes MLP, guardándose en un archivo diferente cada una de las redes entrenadas. En la Figura 7.34 se pueden ver los pesos calculados para la red SOM y los nombres de los archivos donde se guardan los parámetros de las diferentes redes MLP.

	Nodo 1	Nodo 2					
dQt	20978.9761	19116.6172					
AcumP	20980.67393	19119.13754					
Arch MLP	MLP1.txt	MLP2.txt					

Figura 7.34: Pesos de la red SOM y nombre de redes MLP

Estos datos se pueden exportar en un fichero de texto (ver Figura 7.35) con las siguientes características:

Primera línea: número de nodos en la capa de entrada, dimensión 1 (D_1) del mapa de salida y dimensión 2 (D_2).

Segunda línea: nombres de las variables de entrada.

Siguientes líneas: los pesos de las conexiones ubicados según se muestra en la Figura 7.34.

Cuarta línea: los nombres de los archivos donde se guardan las características de las redes MLP de cada nodo de salida de la red SOM.

Quinta a última línea: parámetros de transformación de las series (a, b), máximos y mínimos, topologías, función de distancia y parámetros de las fases de ordenación y afinación.

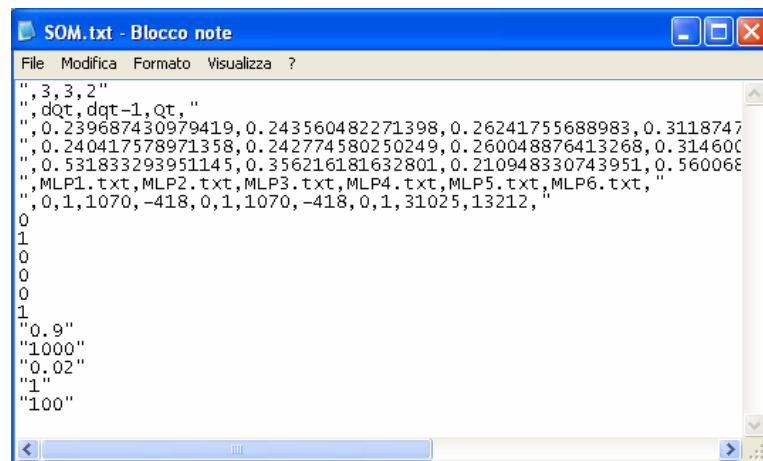


Figura 7.35: Archivo de texto que contiene las características de la red modular SOM-MLP

7.9.3 Validación

Una vez guardados los ficheros de cada una de las redes MLP, se puede validar el modelo modular SOM-MLP. Hay que tener en cuenta que cada fila de la tabla de la izquierda (Figura 7.36) debe corresponder con las de la tabla derecha. Esto quiere decir que las variables utilizadas para determinar el grupo de la primera fila de la tabla derecha equivalen a las variables de la primera fila de la tabla izquierda, y así sucesivamente.

Para visualizar el comportamiento de cada grupo, se pueden graficar los caudales predichos en función de los observados con un color diferente para cada grupo (ver Figura 7.37). De esta manera se pueden elegir los grupos que peor funcionan y mejorar sus modelos.

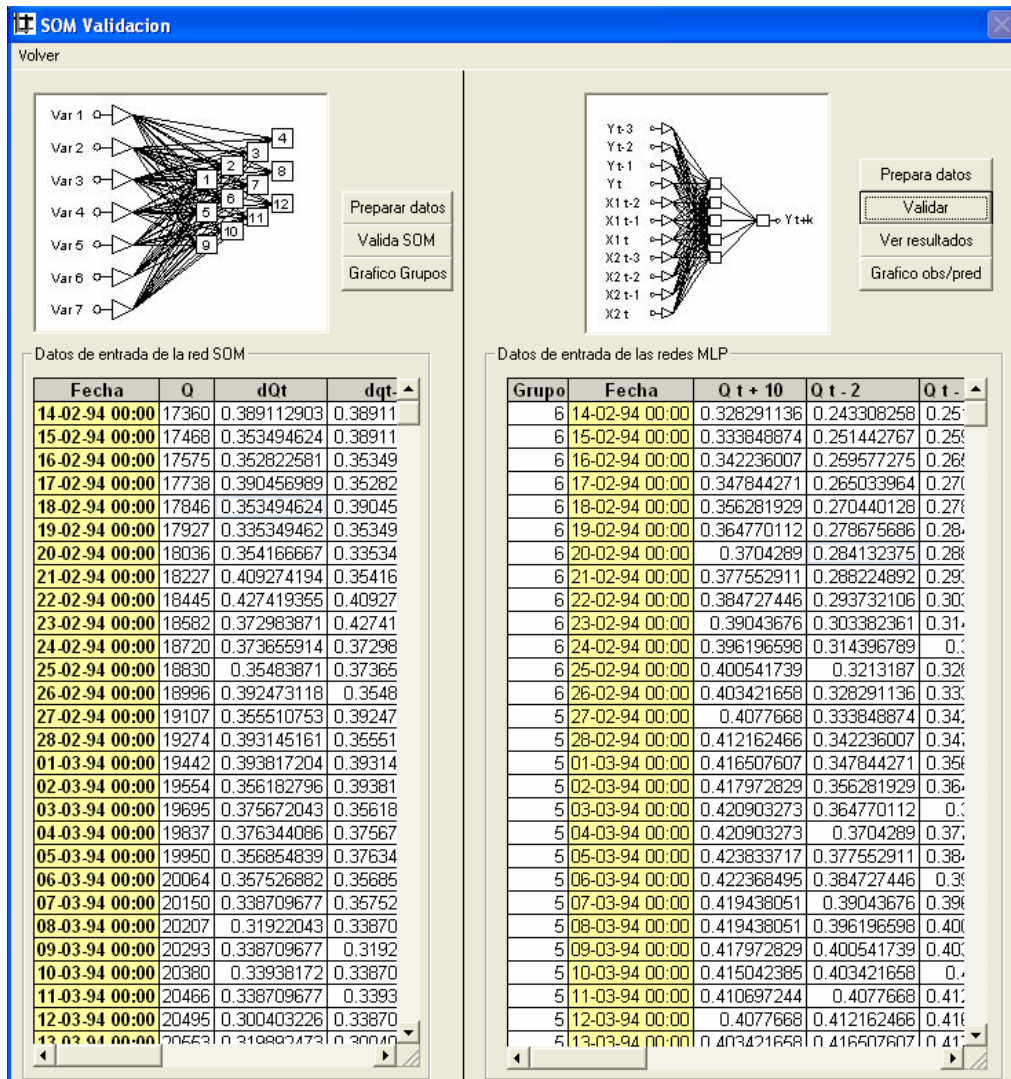


Figura 7.36: Módulo de validación de la red modular SOM-MLP




Figura 7.37: Gráfico de caudales observados en función de los simulados con la identificación de cada grupo

7.10 Modelo ARMAX

Este módulo permite calibrar y validar diferentes modelos estocásticos, desde un simple autorregresivo hasta uno autorregresivo con media móvil y variables exógenas. En la Figura 7.38 se puede observar el menú principal.

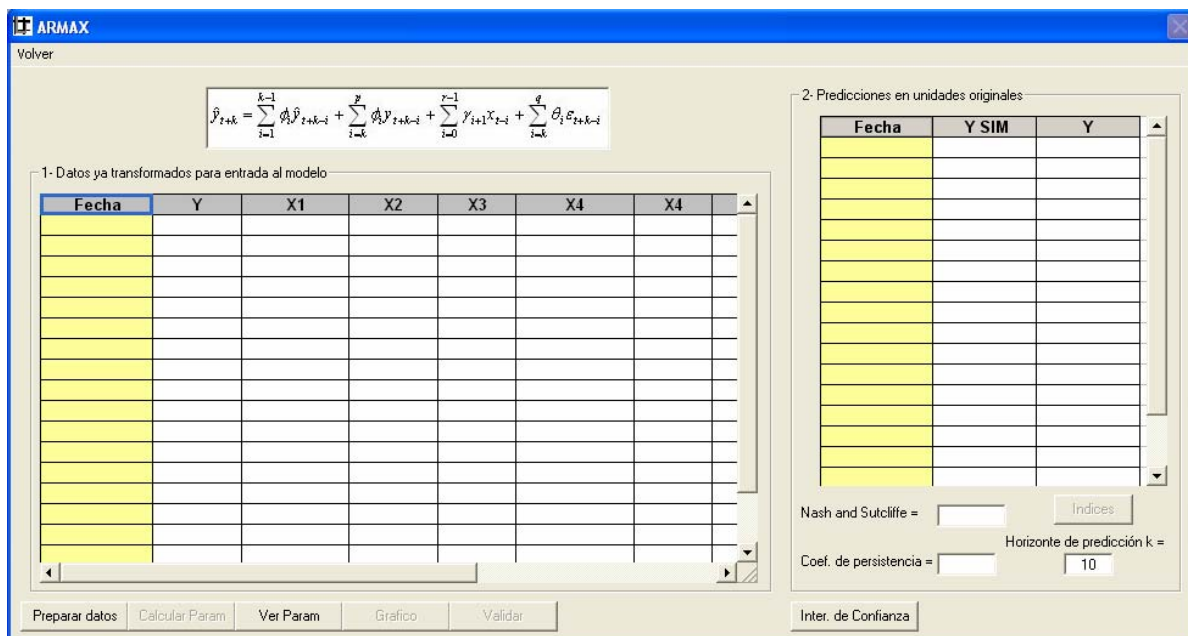


Figura 7.38: Menú principal del módulo ARMAX

El modelo calcula los parámetros para la predicción a un paso de tiempo (ecu. [7.23]) y luego se utiliza el mismo modelo recursivamente, para obtener predicciones mas alejadas.

$$\hat{y}_{t+1} = \sum_{i=1}^p \phi_i y_{t+1-i} + \sum_{i=0}^{r-1} \gamma_{i+1} x_{t+1-nk-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+1-i} \tag{7.23}$$

Por lo tanto, para realizar predicciones a $t+k$ se emplea el mismo modelo, pero de la siguiente forma:

$$\begin{aligned} \hat{y}_{t+1} &= \sum_{i=1}^p \phi_i y_{t+1-i} + \sum_{i=0}^{r-1} \gamma_{i+1} x_{t+1-nk-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+1-i} \\ \hat{y}_{t+2} &= \phi_1 \hat{y}_{t+1} + \sum_{i=2}^p \phi_i y_{t+2-i} + \sum_{i=0}^{r-1} \gamma_{i+1} x_{t+2-nk-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+2-i} \\ \hat{y}_{t+3} &= \phi_1 \hat{y}_{t+2} + \phi_2 \hat{y}_{t+1} + \sum_{i=3}^p \phi_i y_{t+3-i} + \sum_{i=0}^{r-1} \gamma_{i+1} x_{t+3-nk-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+3-i} \\ &\dots \\ \hat{y}_{t+k} &= \sum_{i=1}^{k-1} \phi_i \hat{y}_{t+k-i} + \sum_{i=k}^p \phi_i y_{t+k-i} + \sum_{i=0}^{r-1} \gamma_{i+1} x_{t+k-nk-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+k-i} \end{aligned}$$

El modelo se ejecuta recursivamente utilizando los resultados de predicciones anteriores y las variables exógenas (x) se desplazan con un valor $nk=k$, de tal manera que siempre se utilicen valores observados de las mismas. Esto se realiza suponiendo que no existen predicciones de la variable exógena.

Como se observa en la Figura 7.38, los datos de entrada al modelo se colocan en la tabla ubicando la variable a predecir en la primera columnar y en las siguientes, las variables exógenas. En esta tabla es necesario colocar los datos ya transformados. Por lo tanto, se crea un módulo de preparación de datos (Figura 7.39) donde se eligen las variables, la función de transformación y los valores de p , q y r_i .

En la Figura 7.41 se muestran los parámetros calculados por el modelo ARMAX. En la primera columna se muestran tantos parámetros como el valor de p elegido. Luego, en las siguientes, se muestran los parámetros para cada variable exógena según el r_i elegido en el menú de preparación de datos.

Estos parámetros pueden ser exportados en un fichero de texto con el formato indicado en la Figura 7.41, donde las primeras 5 filas son iguales a las del modelo MLP y luego, en las últimas filas se guardan los parámetros en el mismo orden en que se visualizan en la Figura 7.40.

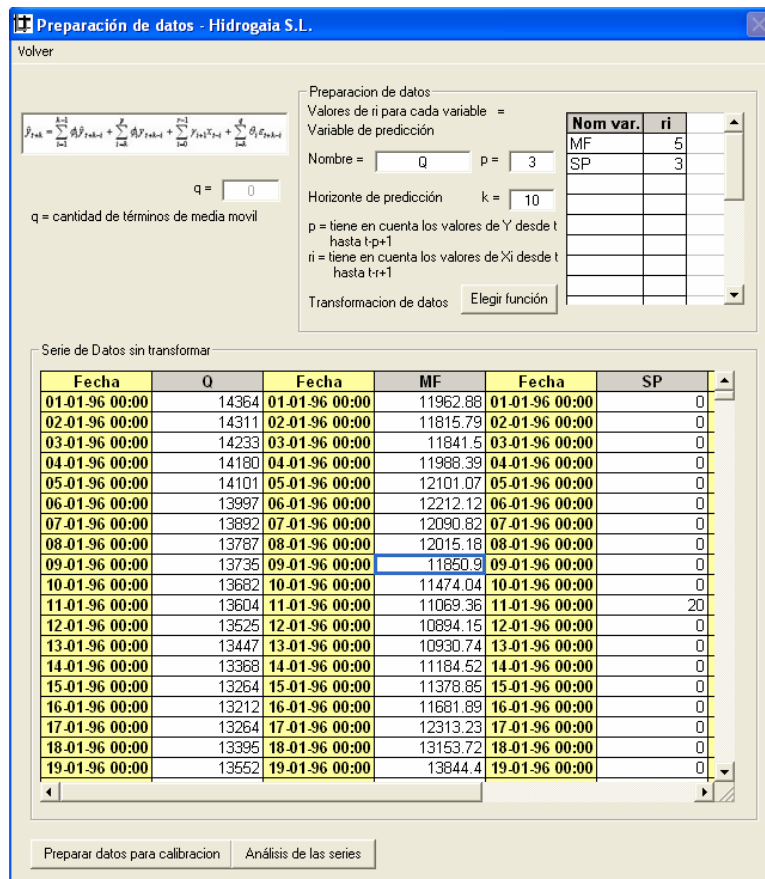


Figura 7.39: Menú de preparación de datos para el modelo ARMAX

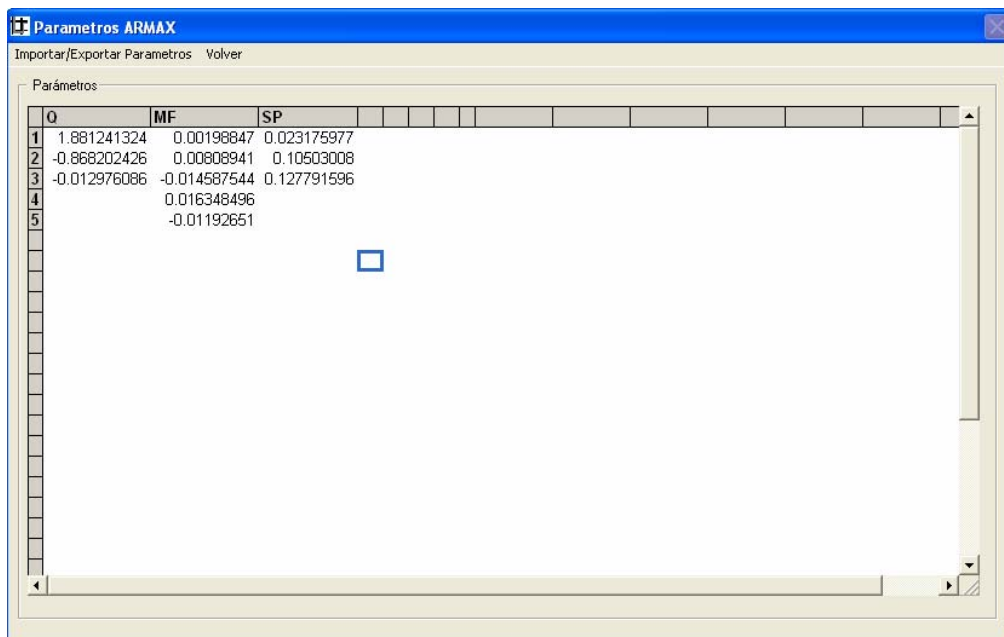


Figura 7.40: Parámetros ARMAX

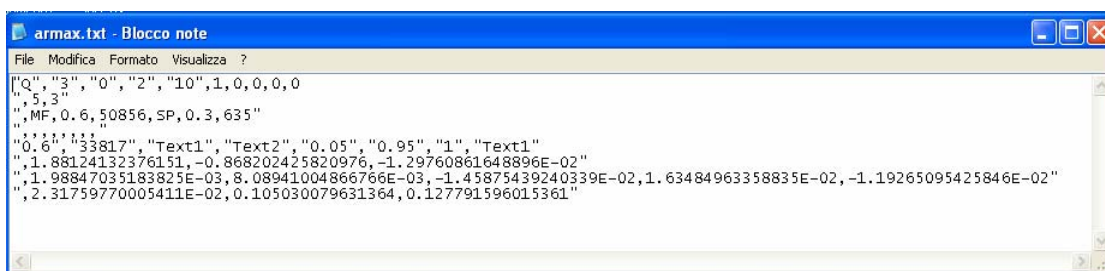


Figura 7.41: Formato del fichero de texto para almacenar los parámetros ARMAX

7.11 Intervalos de confianza

Se ha desarrollado un módulo para el cálculo de los intervalos de confianza en cualquiera de los modelos. Se calculan los parámetros con los resultados de la calibración y luego se utilizan para los resultados de validación.

Los intervalos de confianza se obtienen a partir de la función de distribución bivariada meta-gaussiana [Kelly y Krzysztofowicz, 1997] entre los caudales observados y predichos. Se obtiene la función de distribución de los caudales observados condicionados a los predichos (ecu. [7.24]) y con ésta, se calculan los límites de confianza para cada valor predicho en el futuro.

$$K(y|x) = Q \left(\frac{Q^{-1}(G(y)) - \gamma Q^{-1}(F(x))}{\sqrt{1 - \gamma^2}} \right)$$

[7.24]

donde, $K(y|x)$ es la función de densidad de y condicionada a x

F y G son las funciones marginales de x e y

Q^{-1} es la inversa de la distribución normal estándar Q

γ es el coeficiente de correlación de *Pearson* entre las variables W y Z , que se relacionan con las variables originales a través de la transformación normal (*Normal Quantile Transform* NQT)

$$Z = Q^{-1}(F(X))$$

$$W = Q^{-1}(G(Y))$$

De la ecuación anterior se obtiene el cuantil condicional ($y_{p|x}$) (ecu. [7.25]) donde, dado un cierto valor de x (predicción) y un valor de p (el cuantil que se desee conocer), se obtiene el valor de y (observado):

$$y_{p|x} = G^{-1}\left(Q\left(\gamma Q^{-1}(F(x)) + \sqrt{1-\gamma^2} Q^{-1}(p)\right)\right) \quad [7.25]$$

Los intervalos de confianza se calculan con la ecuación [7.25] para los cuantiles p según se desee. Por ejemplo, si se quiere un intervalo de confianza del 90%, los cuantiles serán 0.05 y 0.95.

En la Figura 7.42 se muestran las 7 diferentes funciones de distribución que se pueden seleccionar para cada serie de datos. También se puede elegir el intervalo de confianza que se quiere calcular. Para analizar los resultados se pueden visualizar 3 gráficas como las que se muestran en la Figura 7.43, Figura 7.44 y Figura 7.45.

Para las series de validación se utilizan los coeficientes calculados por este módulo.

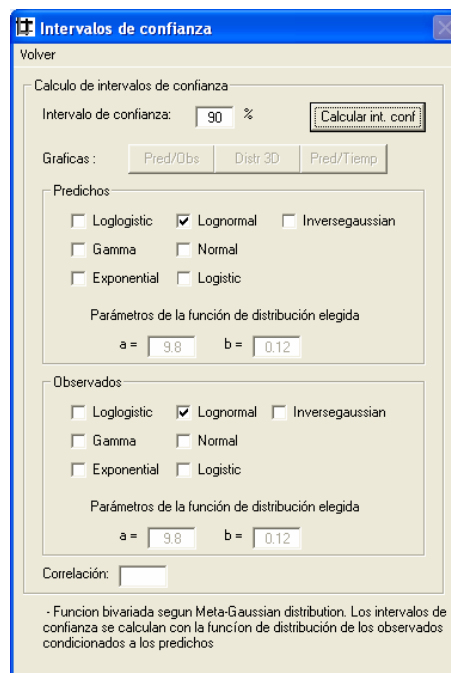


Figura 7.42: Módulo para el cálculo de los intervalos de confianza




Figura 7.43: Gráfico de las caudales predichos en función de los observados




Figura 7.44: Gráfico de la función de densidad de probabilidad 3D




Figura 7.45: Gráfico de las series temporales de los caudales predichos con sus límites de confianza

APLICACIONES

Capítulo 8

Capítulo 8

8 Aplicaciones

8.1 Introducción

En este capítulo se proponen una serie de pasos a seguir para construir un modelo de redes neuronales artificiales. No existe una metodología que garantice el modelo óptimo, pero sí es posible acercarse lo máximo posible al mismo.

Se propone una metodología simple con un análisis conceptual previo, dada la alta cantidad de variables que influyen en la construcción de un modelo como:

- selección de datos para calibrar
- funciones de transformación
- función de activación
- cantidad de capas
- elección de las variables de entrada
- algoritmos de entrenamiento
- función objetivo
- parámetros al inicio de calibración, etc

Seguidamente se enumeran los pasos a seguir en la metodología propuesta.

A. Caso de estudio

Estudio de la cuenca. En primer lugar es necesario el estudio de la cuenca drenante al punto de predicción. Hay que determinar el tipo de cuenca, su geomorfología, la hidrología, los fenómenos involucrados en la transformación de lluvia escorrentía, qué información hay disponible y la calidad de la misma. Para facilitar esta labor son muy útiles las herramientas GIS que permiten, a partir de un modelo digital del terreno (MDT) calcular la red de drenaje, la cuenca drenante al punto de predicción, superficies y longitudes que interesan para analizar la geomorfología de la zona de estudio.

B. Preparación y Análisis de datos

Completar datos. Es necesario, antes de la utilización de los datos, realizar una validación de los mismos, eliminando los datos de mala calidad y rellenando huecos de la serie.

Análisis de datos. También hay que llevar a cabo un análisis de los datos disponibles, como por ejemplo la correlación de las variables, para elegir los posibles conjuntos de datos a utilizar como entradas al modelo (2 o 3 opciones).

Separación de los datos. Es muy importante que la elección de los grupos de datos a utilizar para la calibración sea adecuada, dejando la suficiente cantidad de datos para validar posteriormente. Si se dispone de suficientes datos, es recomendable separarlos en tres grupos: calibración, verificación y validación.

C. Determinación del modelo

Búsqueda del modelo óptimo. La búsqueda del modelo óptimo no es sencilla por la gran cantidad de variables del modelo. Se propone dividir el proceso en dos pasos:

I. Búsqueda del número de nodos en la capa oculta. Para esta búsqueda fijamos las siguientes variables:

- función de activación
- número de capas
- función de transformación de datos
- algoritmo de entrenamiento
- función objetivo

Se modifican las siguientes variables:

- Nodos en la capa oculta (entre 1 y 10)
- Variables de entrada (elegidas en el punto 3)

Cada topología de red se calibra 20 veces [Iyer y Rhinehart, 1999] para probar diferentes valores iniciales de los pesos. Por lo tanto cada topología tendrá una media del coeficiente *Nash and Sutcliffe* (Nash) (línea gruesa horizontal, Figura 8.1), un percentil del 75% y uno del 25% (límite superior e inferior de las cajas de la Figura 8.1) y un máximo y mínimo (extremo inferior y superior de las líneas verticales de la Figura 8.1). Se elige la topología de red con mayor índice de fiabilidad (Nash) tras analizar la gráfica de cajas, como en la Figura 8.1. Comprobando siempre con la serie de verificación que no se hayan producido sobre-entrenamientos.




Figura 8.1: Gráfico de cajas de los datos de calibración, utilizado para seleccionar la cantidad de nodos en la capa oculta

II. *Refinamiento de la red.* Una vez determinada la cantidad de nodos de la red, se comparan diferentes funciones de transformación de los datos de entrada (1 o 2) y algoritmos de entrenamiento (1 o 2). Al igual que en el punto anterior, cada prueba de topología se entrena y verifica 20 veces, comprobando que no se produzcan sobre-entrenamientos. De esta forma se elige finalmente la topología de la red a utilizar, permitiendo al modelador probar con diferentes funciones de activación y funciones objetivo. Es posible también la utilización de la metodología de *prunning* para la definición final de las variables de entrada.

Se propone utilizar una sola capa oculta, ya que una cantidad superior no mejorará sustancialmente el comportamiento de la red [Chiang et al., 2004]. Aumentar la cantidad de nodos en la capa oculta debería ser suficiente para la mayoría de las aplicaciones.

Esta metodología de prueba y error puede ser realizada con el programa desarrollado para esta tesis.

Utilizando los coeficientes de fiabilidad descritos en el Apéndice C junto con la observación de diferentes gráficos, como la superposición de las series predichas con las observadas y los caudales observados en función de los predichos, se determina tras una serie de pruebas y errores el modelo más adecuado.

En los siguientes apartados se exponen diversos ejemplos de aplicación de modelos de redes neuronales. Se comparan los modelos estocásticos con el modelo MLP y el modelo modular propuesto.

8.2 Predicción en tiempo real de caudales en el río Paraná: comparación entre los modelos MLP, SOM-MLP y ARMAX

En esta aplicación se comparan los resultados de las predicciones de caudales a 10 días para una sección de río Paraná, ubicada a 34 km. aguas arriba de la ciudad de Santa Fé (Argentina). Los modelos utilizados son: un modelo autorregresivo de media móvil con variable exógena (ARMAX), una red neuronal artificial tipo perceptrón multicapa (*MLP*) y un modelo modular con una red neuronal auto-organizativa (*SOM*) para la clasificación de los datos y varias redes perceptron multicapa para la modelación de cada grupo. Se utilizan como entradas a los modelos los caudales medios diarios en la sección mencionada anteriormente y de otra ubicada a 571 km. aguas arriba, junto con la precipitación medida en una estación intermedia. La serie temporal utilizada para los modelos pertenece al período 1978-2006.

Se comparan y analizan diferentes configuraciones de los modelos, variando el número de entradas y parámetros. En general la calidad de los resultados con cualquier método es similar y satisfactoria.

La predicción de los caudales y de niveles del agua en diferentes secciones de río Paraná (con un caudal medio aproximado de 18,000 m³/s) es crucial para minimizar los efectos de las crecidas que perjudican a las actividades humanas. Por otro lado, los caudales bajos pueden afectar a las condiciones de navegabilidad a lo largo de río. El Instituto Nacional del Agua y del Ambiente y el Sistema de Alerta Hidrológico de la cuenca del Plata Argentina (INA SiyAH) realiza predicciones a 5 y 10 días, para varios puertos ubicados en el Paraná medio y bajo. Esta anticipación es suficiente para alertar a la población en diferentes zonas agrícolas y urbanas y tomar las acciones necesarias para reducir daños y pérdidas económicas. Las predicciones se obtienen a partir del modelo hidráulico Ezeiza-V [Jaime y Menéndez, 1997].

Esta investigación fue desarrollada bajo el mismo esquema de trabajo, aplicando métodos de modelación alternativos para mejorar las predicciones de los caudales en el río Paraná, usando como horizonte de predicción los 10 días.

La aplicación de las RNA en varios aspectos de la modelación hidrológica ha llevado a resultados interesantes y prometedores en los últimos años [Kang et al., 1993; Karunanithi et al., 1994; Smith y Eli, 1995; Minns y Hall, 1996; Shamseldin, 1997; Fernando y Jayawardena, 1998; Sajikumar y Thandaveswara, 1999; Tokar y Markus, 2000; Kumar y Minocha, 2001; García-Bartual, 2002; Jain y Prasad, 2003; Abrahart et al., 2004; Cigizoglu, 2005; Sahoo et al., 2006]. Un aspecto atractivo de las redes neuronales es la habilidad y facilidad de incorporar sistemáticamente relaciones no lineales entre las variables.

Por otro lado, el modelo estocástico clásico ARMAX (*AutoRegressive Moving Average with exogenous inputs*) ha demostrado ser una herramienta eficiente para la predicción cuando se poseen datos de precipitación y caudales en diferentes puntos o secciones del río y no se dispone de información respecto a la cuenca, estrictamente necesaria para modelos más complejos como los físicamente basados. [Burn y McBean, 1985; Awwad y Valdés, 1992; Hipel y McLeod, 1994; Papamichail y Georgiou, 2001].

En los últimos años ha surgido un gran interés por la aplicación de modelos modulares basados en la subdivisión de los datos de entrada según conceptos físicos [Jacobs et al., 1991; Jacobs y Jordan, 1993; Jordan y Jacobs, 1994; Furundzic, 1998; See y Openshaw, 1999; Zhang y Govindaraju, 2000a y b; Abrahart y See, 2000; Zhang y Govindaraju, 2000b; Hu et al., 2001; Hsu et al., 2002; Koskela, 2003; Moradkhani et al., 2004; Solomatine y Xue, 2004; Deka y Chandramouli, 2005; Chau et al., 2005; Jain y Srinivasulu, 2006; Wang et al., 2006]. Las diferencias entre las diferentes aplicaciones nacen en la elección de los grupos a dividir, de qué forma hacerlo y cómo modelar cada proceso.

Los tipos de modelos elegidos presentan la clara ventaja de poder modelar en tiempo real, ya que una vez calibrados e implementados son computacionalmente rápidos y se adaptan perfectamente bien a las limitaciones y restricciones impuestas por los sistemas de predicción en tiempo real bajo operación.

8.2.1 Caso de estudio

La cuenca del Plata tiene una área drenante de 3,005,000 km², siendo la quinta cuenca más grande del mundo. Pertenece a cinco países de Sudamérica: Argentina, Bolivia, Brasil, Paraguay y Uruguay. El área de estudio es en el bajo Paraná, como se observa en la Figura 8.2. La cuenca entre la sección de predicción “Chapetón” y “Corrientes” es de aproximadamente 234,000 km² (ver Figura 8.5) y la longitud del cauce principal entre ellas es de 571 km. Este tramo se caracteriza por su baja pendiente (5.7 cm/km) y una gran diversidad en la forma de las secciones, dependiendo del nivel del agua (ver Figura 8.4). En esta zona, el río tiende a identificarse completamente por un curso de agua típico, denominado “río de llanura con lecho de fondo móvil”, lo que implica un cauce menor con grandes caudales y bajas pendientes. El caudal máximo histórico registrado en la estación de “Chapetón” es de 31,930 m³/s (1982) y el caudal medio anual es de 18,248 m³/s.

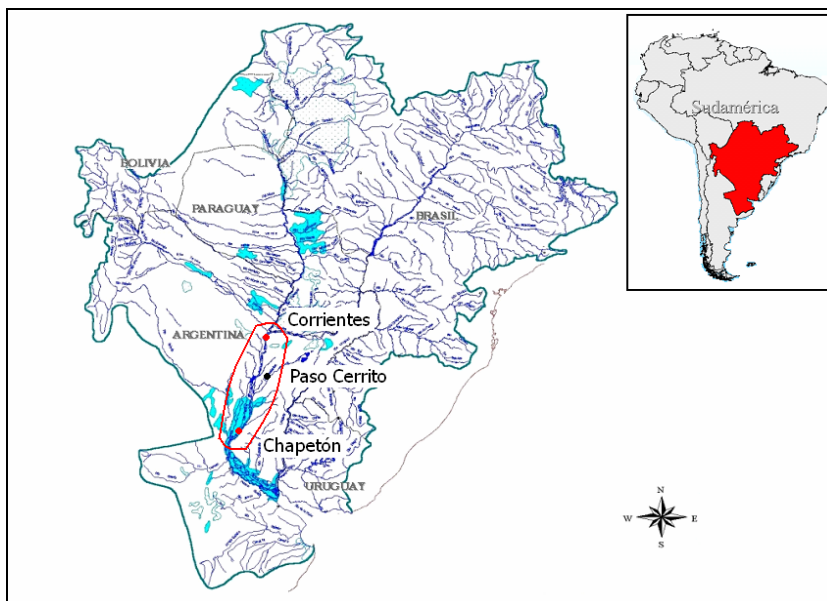


Figura 8.2: Mapa de ubicación de la zona de estudio

La información disponible para esta investigación fue obtenida del Ministerio de Planificación Federal; Inversión Pública y Servicios; Secretaría de Obras Públicas; Subsecretaría de Recursos Hídricos Argentina, 2004 (ver referencias), e incluye los caudales medios diarios en la estación de “Chapetón” y “Corrientes” y también la serie de precipitaciones en “Batel-Paso Cerrito”, ubicada entre las dos estaciones de aforo (ver Figura 8.2). Se disponen de datos en continuo desde el 30/06/1978 al 31/08/2006.

La Figura 8.3 muestra los caudales medios diarios mensuales en “Chapetón” y “Corrientes”. Se puede comprobar que los caudales en la estación de aguas arriba (“Corrientes”) son significativamente menores durante la primera parte del año hidrológico, mientras que de enero a abril ocurre lo contrario.




Figura 8.3: Caudales medios diarios mensuales para “Chapetón” (rojo) y “Corrientes” (azul)

El tiempo medio de viaje de un pico de caudal de “Corrientes” a “Chapetón” se estima en 15 días. Esto se puede ver en la Figura 8.9, donde la máxima correlación entre los caudales en “Chapetón” y en “Corrientes” (línea azul) se da a los 15 días.

El tiempo de concentración de la cuenca en estudio, con una cota máxima de 60 msnm y mínima de 12 msnm y una longitud de 571 km, es de aproximadamente 9 días (ver Figura 8.10).




Figura 8.4: Sección transversal en “Chapetón” (fuente: Jaime et al., 1997)

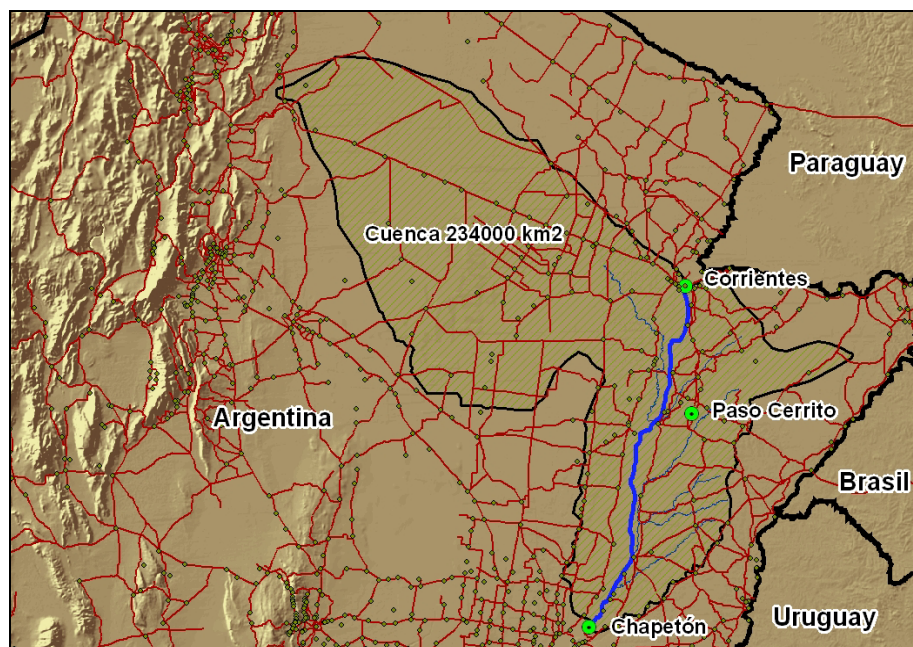


Figura 8.5: Cuenca en estudio. Tamaño 234,000 km²

8.2.2 Preparación y análisis de datos

Preparación de datos

En un principio, para la calibración de los modelos ARMAX y MLP se utilizaron sólo los datos del período 1994-1998, ya que dicha cantidad era suficiente para obtener buenos resultados. Sin embargo no fueron datos suficientes para entrenar el modelo modular elegido, por lo que fue necesario emplear todo el período de datos comprendido entre 1978 y 2006.

Este largo período de datos de aproximadamente 28 años no estaba totalmente completo. Se tuvieron que completar todas las series para poder luego trabajar con ellas.

Los datos se completaron en base a los siguientes criterios:

- Para caudales:
 1. Tanto para períodos largos como cortos se realiza una interpolación entre los datos existentes antes y después del período faltante. En la Figura 8.6 se muestra un ejemplo de una interpolación realizada para completar los datos faltantes. Primero se calcula una curva con los datos reales (puntos verdes) y luego, con esa curva se calculan los datos faltantes (puntos rojos). La interpolación puede ser tanto lineal como no lineal, según se crea conveniente en cada caso.




Figura 8.6: Interpolación para completar datos de caudales. En rojo datos completados, verde datos reales

- Para precipitación:
 1. Si el período faltante es corto, se completa manualmente con valores acordes a los anteriores y posteriores. Por ejemplo, si faltan datos en un período sin lluvia se completan con valores nulos, y si faltan valores en el medio de una tormenta se completan con valores del orden a los más próximos.
 2. Si el período faltante es largo, se utiliza la precipitación del mismo mes pero del año anterior, como se puede ver en la Figura 8.7.




Figura 8.7: Llenado de huecos en la serie de precipitación utilizando valores medidos el mismo mes del año anterior

En Figura 8.8 se representan las series de datos completas, indicando la elección de los grupos utilizados para la calibración (30/06/1978 - 30/09/1991), validación (01/10/1991 - 30/09/1999) y verificación (01/10/1999 - 31/08/2006).

Para la elección de la separación de los grupos se debe tener en cuenta que en las series de entrenamiento o calibración existan situaciones extremas, como caudales picos muy altos y períodos de caudales bajos, que puedan describir de manera general todo el rango de comportamiento del río a modelar. También se necesita suficiente cantidad de datos para evitar el sobre-entrenamiento. Este se comprueba mediante la serie de verificación.




Figura 8.8: Serie de datos completa e identificación de los grupos de calibración, validación y verificación

Análisis de datos

Una vez completadas las series de datos es necesario un riguroso análisis de las mismas para poder entender la relación entre cada una y su distribución estadística y así tener una ayuda para la elección de las variables de entrada a los modelos.

Se realiza un análisis de correlación cruzada entre los caudales en la estación “Chapetón” y la precipitación acumulada en la estación de “Batel Paso Cerrito”, probando con diferentes días de acumulación hasta determinar el período con mayor correlación. De igual forma se procede con la media móvil de los caudales en la estación de “Corrientes”, demostrando que los caudales suavizados en “Corrientes” presentan mayores correlaciones con los de “Chapetón”. Por lo tanto, se adoptan como entradas las siguientes variables:

SP = Precipitación acumulada de 10 días en la estación pluviométrica “Batel Paso Cerrito” $[\text{Sum}P_{(t,t-9)}]$

MF = Media de 11 días de los caudales en la estación de “Corrientes” $[\text{Prom}F_{(t,t-10)}]$

Q = Caudales en la estación de “Chapetón” (caudales objetivos)

En la Figura 8.9 se puede comprobar la diferencia de correlación considerando la precipitación diaria (amarillo) y la precipitación acumulada a 10 días (violeta). De la misma forma se puede ver cómo la gráfica de correlación cruzada de los caudales de “Corrientes” (verde) se desplaza hacia la izquierda, al considerar la media móvil de 10 días, obteniendo correlaciones mayores en tiempos de desfase (k) menores.




Figura 8.9: Análisis de correlación

En la Figura 8.10 se observan los estadísticos principales de las tres series analizadas y el tiempo de concentración de la cuenca en estudio (9.25 días), lo cual nos transmite una idea del tiempo de respuesta de la cuenca.

Para poder identificar el orden de los posibles modelos estocásticos y obtener una idea de cuáles podrían ser las variables de entrada en la RNA, se grafican los correlogramas (Figura 8.9) y la función de autocorrelación parcial (Figura 8.11) con sus límites de Anderson.

Los límites de probabilidad de 95% para un correlograma de series independientes se calculan, según Anderson (1941), de la siguiente manera:

$$r_k(95\%) = \frac{-1 \pm 1.96\sqrt{N-k-1}}{N-k}$$

[8.1]

donde N es la cantidad total de datos de la serie y k es el tiempo de desfase.

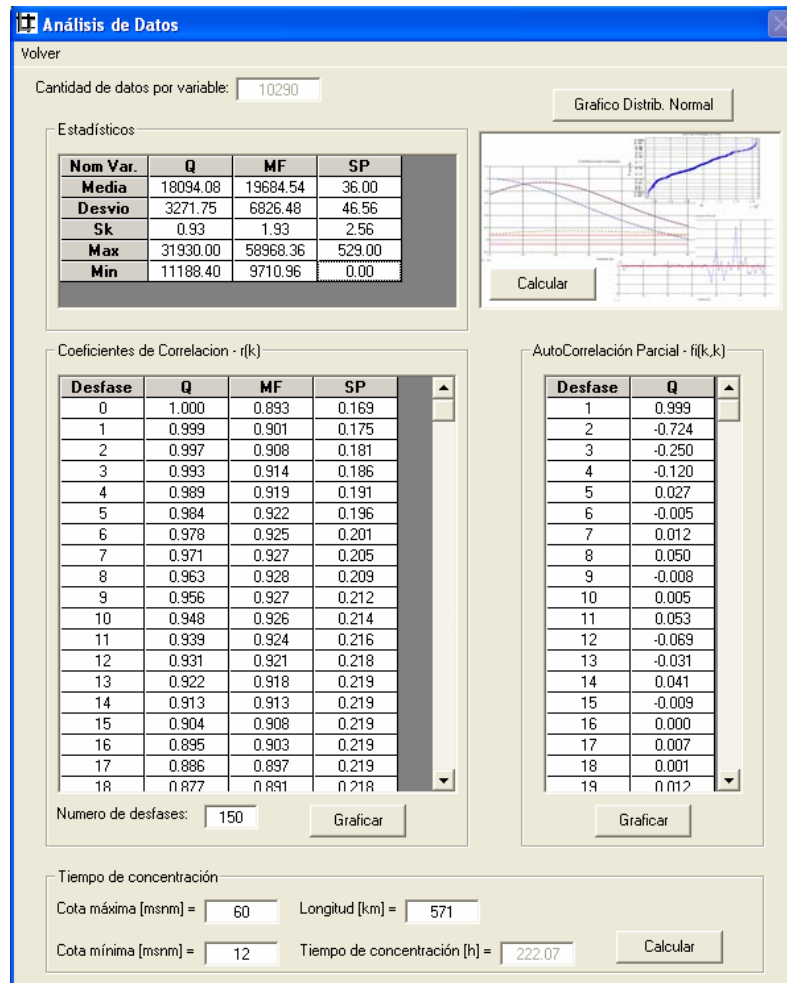


Figura 8.10: Análisis de las series. “Chapetón” (Q), Media en “Corrientes” (MF) y Acumulado en “Batel Paso Cerrito” (SP)

Que una serie sea independiente significa que, por ejemplo, si se toma un punto de la serie al azar y se observa el próximo punto, éste tendrá la misma probabilidad de estar situado sobre o por debajo de la media sin tener en cuenta la referencia del punto anterior.

Otra forma de representar la estructura de dependencia con el tiempo de la serie del modelo es analizando la función de autocorrelación parcial. Para que un proceso sea de orden p , los $\Phi_{k,k}$, para $k > p$, deben tener una distribución normal con media cero y varianza $1/N$ (N : número total de datos).

El sistema muestra una larga memoria con coeficientes de autocorrelación (línea celeste en Figura 8.9) significantes (mayores a 0.8) para 26 días de desfase. El análisis de autocorrelación parcial (Figura 8.11) muestra que un posible modelo estocástico a utilizar es un autorregresivo de orden 3. Se observa también que las variables de precipitación y caudales en “Corrientes” presentan sus máximas correlaciones entre desfases de 10 a 20 días.

Con este análisis y numerosas pruebas con diferentes variables de entrada, se decide utilizar las variables indicadas en la Tabla 8.1 para todos los modelos.




Figura 8.11: Auto-correlación parcial

Para mejorar la eficiencia de los tres modelos se aplica una transformación que permite la reducción del sesgo y la homogenización de los rangos de variación para las diferentes variables. Varios criterios diferentes se pueden aplicar con este mismo propósito. Para el modelo ARMAX y MLP se utiliza una función también empleada en García-Bartual, 2002, definida por dos parámetros:

$$x'_i = \left[\frac{x_i}{M_x} \right]^\alpha \tag{8.2}$$

donde x es la variable y M es un valor de referencia cercano al máximo de la serie. Los parámetros usados son:

Precipitación en “Batel-Paso Cerrito” [$\alpha = 0.3$; $M = 635$ mm], caudales en “Corrientes” [$\alpha = 0.6$; $M = 50,856$ m³/s] y caudales en “Chapetón” [$\alpha = 0.6$; $M = 33,817$ m³/s].

Para la utilización de los datos en un modelo estocástico es necesario comprobar previamente que la serie esté distribuida según una distribución normal (*Gaussiana*). Para ello se realizan diferentes análisis: se grafican los datos en un papel de probabilidad normal y se comprueba que los puntos graficados sigan aproximadamente una línea recta (Figura 8.12). También se comprueba que el coeficiente de asimetría o *skewness* (s_k) esté dentro de un rango específico (ver Apéndice C).

Para $N = 11,400$ datos, se considera que una serie es 90% simétrica si el coeficiente de asimetría (sk) está entre -0.065 y 0.065 .

Tabla 8.1: Variables de predicción utilizadas en los modelos ARMAX, MLP y SOM-MLP

Precipitación en la estación pluviométrica de “Batel-Paso Cerrito” [mm]	Caudales en la estación de “Corrientes” [m ³ /s]	Caudales en la estación de “Chapetón” [m ³ /s]
$SP_t = \text{SumP}_{(t; t-9)}$	$MF_{t-5} = \text{PromF}_{(t; t-10)}$	Q_t
$SP_{t-10} = \text{SumP}_{(t-10; t-19)}$	$MF_{t-10} = \text{PromF}_{(t-5; t-15)}$	Q_{t-1}
$SP_{t-20} = \text{SumP}_{(t-20; t-29)}$	$MF_{t-15} = \text{PromF}_{(t-10; t-20)}$	Q_{t-2}
	$MF_{t-20} = \text{PromF}_{(t-15; t-25)}$	
	$MF_{t-25} = \text{PromF}_{(t-20; t-30)}$	

La Figura 8.12 muestra que las series de caudales en “Chapetón” y de precipitación en “Batel Paso Cerrito” presentan una distribución probabilística aproximadamente normal. Por otro lado, los caudales promediados en “Corrientes” se alejan un poco de esa distribución. Estos resultados son determinantes para el modelo estadístico ARMAX, ya que una de sus hipótesis es suponer que las series utilizadas se distribuyen de forma normal. Por el contrario, este hecho no influye para los modelos RNA.

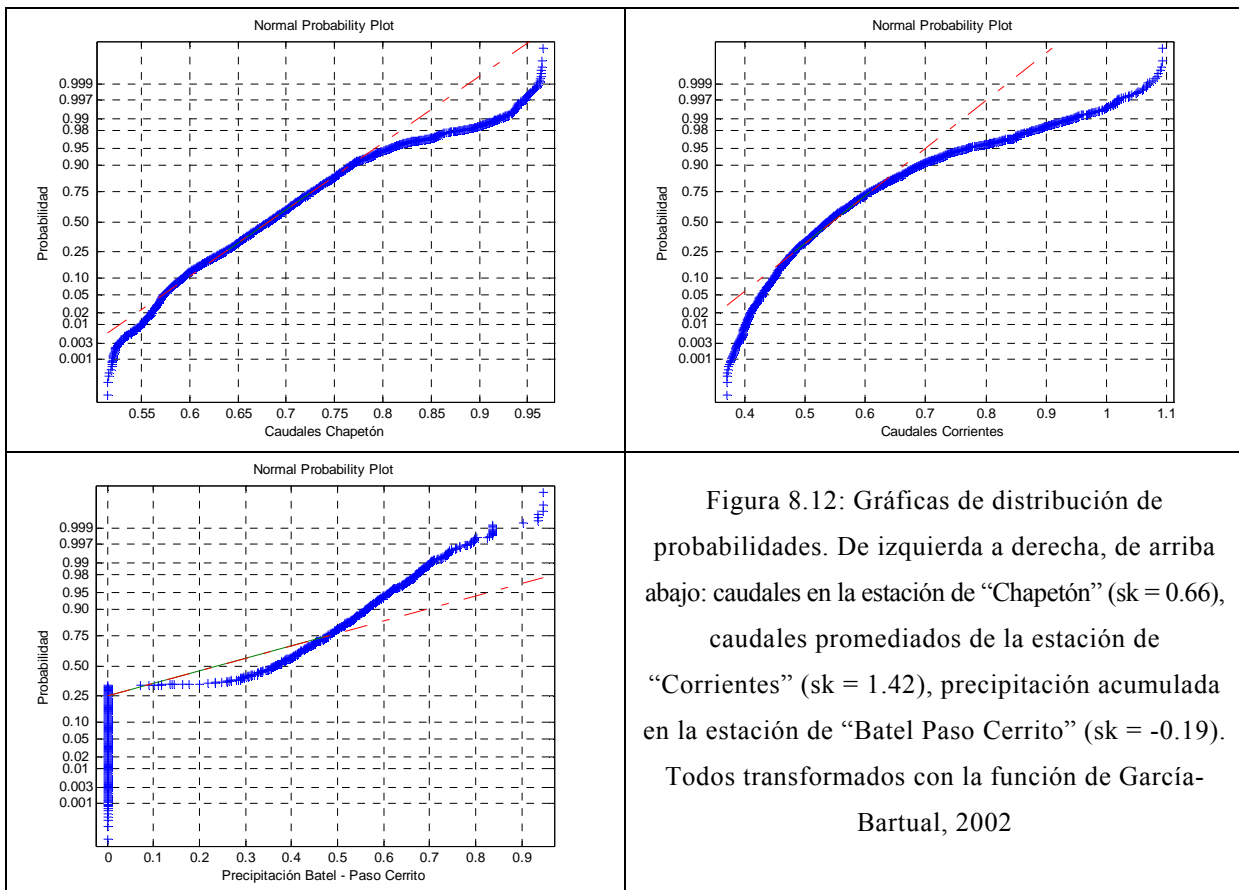


Figura 8.12: Gráficas de distribución de probabilidades. De izquierda a derecha, de arriba abajo: caudales en la estación de “Chapetón” ($sk = 0.66$), caudales promediados de la estación de “Corrientes” ($sk = 1.42$), precipitación acumulada en la estación de “Batel Paso Cerrito” ($sk = -0.19$). Todos transformados con la función de García-Bartual, 2002

8.2.3 Determinación de los modelos

Los modelos utilizados en este estudio son: una red neuronal artificial MLP, un modelo estocástico autorregresivo con variables exógenas (ARMAX) y un modelo modular donde se combina una red neuronal auto-organizativa con seis MLP.

La obtención de los modelos se hizo siguiendo los pasos descritos en la introducción de este capítulo llegando, tras una extensa tarea de prueba y error a los siguientes modelos:

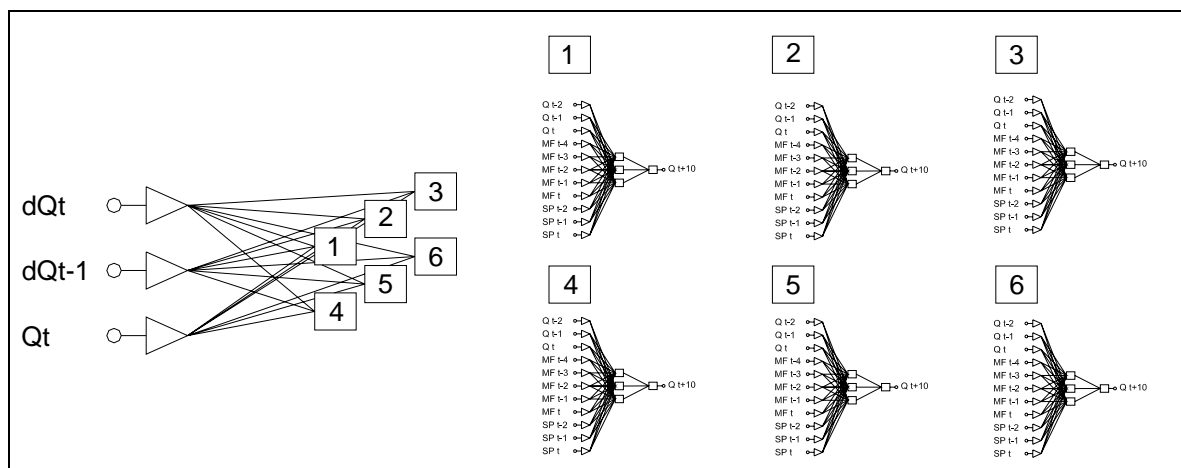


Figura 8.13: Modelo modular SOM-MLP




Figura 8.14: Modelo de red neuronal MLP

$$Q_{t+1}^{pred} = \sum_{i=1}^p \phi_i Q_{t-k-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} SP_{t+1-L-i} + \sum_{i=0}^{r_2-1} \lambda_{i+1} MF_{t+1-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+1-i}$$

Figura 8.15: Modelo ARMAX

En el Apéndice A se muestran los parámetros calculados para cada uno de los modelos que se describen más detalladamente a continuación.

Red Neuronal Artificial MLP

La gran mayoría de las redes neuronales se entrenan con el algoritmo BPNN (*BackPropagation learning algorithm*) [Sahoo et al., 2006], el cual es utilizado en esta investigación junto con la función objetivo MSE (*Mean Squared Error function*). El número de capas ocultas se fija en uno, cantidad suficiente para aproximar cualquier función compleja no lineal con la precisión deseada [Cybenko, 1989; Hornik et al., 1989].




Figura 8.16: Red neuronal artificial tipo de 3 capas NN(11-3-1)

Siguiendo una configuración típica y ampliamente probada en la literatura, se utiliza como función de activación en la capa de entradas y salidas, la función lineal, mientras que en la capa oculta se usa la función sigmoideal (eq. [8.3]), ofreciendo a la red la posibilidad de capturar las relaciones complejas no lineales entre las entradas y salidas.

$$f(y) = \frac{1}{1 + e^{-y}} \quad (0;1)$$

[8.3]

La Figura 8.16 muestra un ejemplo de la topología de RNA utilizada en este trabajo. En este esquema la capa de entradas tiene nodos pasivos, de tal forma que permitan la presentación de diferentes variables (ej. caudales pasados en diferentes secciones y precipitación acumulada). Mientras que la capa de salida realiza las predicciones a 10 días de los caudales en la estación de “Chapetón”.

La entrada de cada nodo de la capa oculta y de la capa de salida consiste en una combinación lineal, generalmente llamada PSP (*Post-Synaptic-Potential*), de las salidas de los nodos en la capa anterior (eq [8.4]),

$$y_j = \sum_{i=1}^n w_{i,j} x_i - b_j$$

[8.4]

donde,

$w_{i,j}$ son los pesos del nodo j provenientes del nodo i de la capa anterior

b_j es el umbral del nodo j

x_i es la entrada del nodo j proveniente del nodo i de la capa anterior

Más información sobre los detalles del algoritmo de entrenamiento y la operación de esta configuración de RNA puede ser encontrada en Wasserman, 1989 y Fausett, 1994.

Modelo Autorregresivo de media móvil con variable exógena

Contrastando a la aproximación de redes neuronales se usa la modelación clásica para predicción de caudales en términos de modelo estocástico ARMAX.

La forma analítica del modelo ARMAX (p, r_1, r_2, q) es la siguiente:

$$Q_{t+1}^{pred} = \sum_{i=1}^p \phi_i Q_{t-k-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} SP_{t+1-L-i} + \sum_{i=0}^{r_2-1} \lambda_{i+1} MF_{t+1-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+1-i}$$

[8.5]

donde,

Q_t : Caudales en la estación de “Chapetón”

SP_t : Precipitación en la estación pluviométrica de “Batel-Paso Cerrito”

MF_t : Caudales en la estación de “Corrientes”

ε_i : Ruido del modelo con $N(0; \sigma_\varepsilon)$; $\varepsilon_i = Q_{t+k}^{pred} - Q_{t+k}$

k : Horizonte de predicción

p, r_1, r_2 y q : Órdenes del modelo

ϕ, γ, λ and θ : Parámetros del modelo. Éstos se calculan con el programa Matlab™ 7.0, que utiliza el método de los errores de predicción

L y J : Factores para SP y MF respectivamente, para considerar los diferentes desfases de tiempo

El término de media móvil se fija a cero para esta aplicación ($q = 0$).

Más detalles sobre este tipo de modelos se puede encontrar en Box y Jenkins, 1970.

El procedimiento de predicción es el siguiente:

$$Q_{t+1}^{pred} = \sum_{i=1}^p \phi_i Q_{t-k+2-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} SP_{t+1-L-i} + \sum_{i=0}^{r_2-1} \lambda_{i+1} MF_{t+1-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+1-i}$$

$$Q_{t+2}^{pred} = \sum_{i=1}^p \phi_i Q_{t-k+3-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} SP_{t+2-L-i} + \sum_{i=0}^{r_2-1} \lambda_{i+1} MF_{t+2-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+2-i}$$

$$Q_{t+3}^{pred} = \sum_{i=1}^p \phi_i Q_{t-k+4-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} SP_{t+3-L-i} + \sum_{i=0}^{r_2-1} \lambda_{i+1} MF_{t+3-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+3-i}$$

...

$$Q_{t+k}^{pred} = \sum_{i=1}^{k-1} \phi_i Q_{t+k-i}^{pred} + \sum_{i=1}^p \phi_i Q_{t+1-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} SP_{t+k-L-i} + \sum_{i=0}^{r_2-1} \lambda_{i+1} MF_{t+k-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+k-i} + \varepsilon_{t+k}$$

[8.6]

En la Figura 8.17 se muestran las variables de entrada al modelo ARMAX.




Figura 8.17: Variables de entrada al modelo ARMAX

Modelo modular SOM-MLP

El concepto de modelos modulares está adquiriendo mucho interés entre los investigadores estos últimos años. La causa principal es que, un fenómeno tan complejo como la transformación de lluvia escorrentía, no es el mismo para diferentes situaciones hidrológicas de una cuenca. Por lo tanto, se requiere la división del problema en múltiples subproblemas que se encarguen de resolver por separado los diferentes fenómenos físicos de generación de escorrentía.

El modelo propuesto para este caso de estudio consiste en una red neuronal auto-organizativa (*SOM*) para la clasificación automática de los datos y un conjunto de redes neuronales perceptrón multicapa (*MLP*) para la modelación de cada subgrupo.

Teniendo en cuenta que la serie total de datos se divide en grupos, cada MLP dispone de una cantidad muy pequeña de datos, lo cual hace que se sobre-entrenen y no representen la generalidad del problema a modelar. Por esta causa se precisó una serie de datos más larga correspondiente al período 30/06/1978 - 31/08/2006.




Figura 8.18: Descomposición de un hidrograma (fuente: Jain y Srinivasulu, 2006)

La primera dificultad de este tipo de problemas es la elección de las variables de entradas a la red SOM para la clasificación de los datos, de tal forma que los grupos representen de mejor forma a los diferentes fenómenos físicos de generación de escorrentía. El objetivo es lograr una separación de grupos como los indicados en la Figura 8.16.

Modelo de Clasificación (*SOM*)

La idea principal de este tipo de modelo es identificar, en el momento de realizar la predicción, en qué momento hidrológico nos encontramos. La elección de las variables a utilizar como entrada al modelo no es nada fácil. por lo que se debe realizar previamente una numerosa cantidad de pruebas entre diferentes combinaciones de variables, llegando a la elección de las siguientes:

$$dQ_t = Q_t - Q_{t-1}$$

$$dQ_{t-1} = Q_{t-1} - Q_{t-2}$$

$$Q_t$$

Con las primeras dos variables se pretende identificar si estamos en las ramas ascendentes o descendentes del hidrograma en el momento de realizar la predicción.

Se utilizan dos intervalos consecutivos para poder considerar mejor la pendiente del hidrograma, ya que teniendo en cuenta un solo intervalo, se podría interpretar como rama ascendente a zonas de la rama descendente con pendiente positiva, debida a pequeñas fluctuaciones que no interesa tener en cuenta para la clasificación inicial. La variable (Q_t) sirve para identificar el estado actual y poder clasificar entre niveles de caudal altos o bajos.

Antes de ingresar estas variables a la red SOM es necesario escalarlas para igualar su peso. En este caso se escalan entre 0 y 1.

La red neuronal auto-organizativa (ver Figura 8.19) elegida es una red con un mapa de salida compuesto por seis nodos, donde cada uno de ellos representa una situación hidrológica distinta. Las redes MLP utilizadas para la modelación de cada grupo tendrán la misma estructura a la utilizada en el modelo único MLP.




Figura 8.19: Red auto-organizativa (SOM) utilizada para la clasificación de los datos de entrada

En la Figura 8.20 se puede observar la distribución de los grupos a lo largo del hidrograma (de validación) para el instante en el que se realizan las predicciones.




Figura 8.20: Gráfico de separación de grupos utilizando la red SOM para la serie de validación




Figura 8.21: Distribución de las variables por grupo

Según la Figura 8.20 y la Figura 8.21, los grupos se distribuyen de la siguiente forma:

Grupo 1: Rama descendente y caudales altos

Grupo 2: Rama descendente y caudales medios

Grupo 3: Rama descendente y caudales bajos

Grupo 4: Rama ascendente y caudales altos

Grupo 5: Rama ascendente y caudales medios

Grupo 6: Rama ascendente y caudales bajos

La red SOM utilizada se encarga de determinar, en el momento de realizar una predicción a 10 días, la situación en la que se encuentra el hidrograma según los seis grupos descritos anteriormente.

En la Figura 8.22 se pueden observar los caudales predichos en función de los observados. Asimismo se pueden identificar los grupos clasificados por la red SOM.

Para hacer un análisis del comportamiento de la red auto-organizativa se procede a la separación manual de los datos y se comparan los resultados generales del modelo modular.

La separación manual parte de la separación previa realizada por la red, corrigiendo los puntos que, a criterio hidrológico, no pertenecen al mismo grupo. Las correcciones realizadas son mínimas, ya que la separación utilizada como base es muy exacta. En la Figura 8.24 se muestra la separación realizada manualmente, que puede ser comparada con representada en la Figura 8.20.




Figura 8.22: Caudales predichos en función de los observados con la identificación de los diferentes grupos




Figura 8.23: Gráfico de separación de grupos realizada manualmente

8.2.4 Análisis de resultados

Primero, para validar los resultados del modelo estocástico ARMAX, es necesario demostrar que los residuos sean independientes y normales, con media 0 y desvío σ_ε , y asimismo independientes con respecto a las otras variables. Para ello se grafica la función de autocorrelación de la serie de errores para el período de validación y las correlaciones cruzadas entre los errores y las demás variables. Este proceso se repite con mejores modelos ARMAX para cada horizonte de predicción.

La media y desvío estándar de los errores del modelo ARMAX son:

$$\mu_\varepsilon = -40.6 \text{ m}^3/\text{s} ; \quad \sigma_\varepsilon = 659 \text{ m}^3/\text{s}$$




Figura 8.24: Función de autocorrelación de los errores y correlaciones cruzadas entre las variables y los errores del modelo ARMAX




Figura 8.25: Distribución de los errores para el modelo ARMAX

De la Figura 8.24 se puede decir que la serie de los errores del modelo ARMAX es independiente entre sí y entre las variables de entrada al modelo, ya que las funciones de correlación están próximas a los límites de Anderson. La Figura 8.25 muestra que los errores son aproximadamente normales, ya que se mantienen muy próximos a la recta roja de normalidad.

A continuación se presentan los índices de fiabilidad de los resultados obtenidos con los tres modelos. Se muestran sólo los resultados para la serie de validación y los de calibración de exponen en el Apéndice A.

Se comparan también los resultados del modelo modular con una separación de datos manual, para poder comprobar el comportamiento del sistema de separación automático.

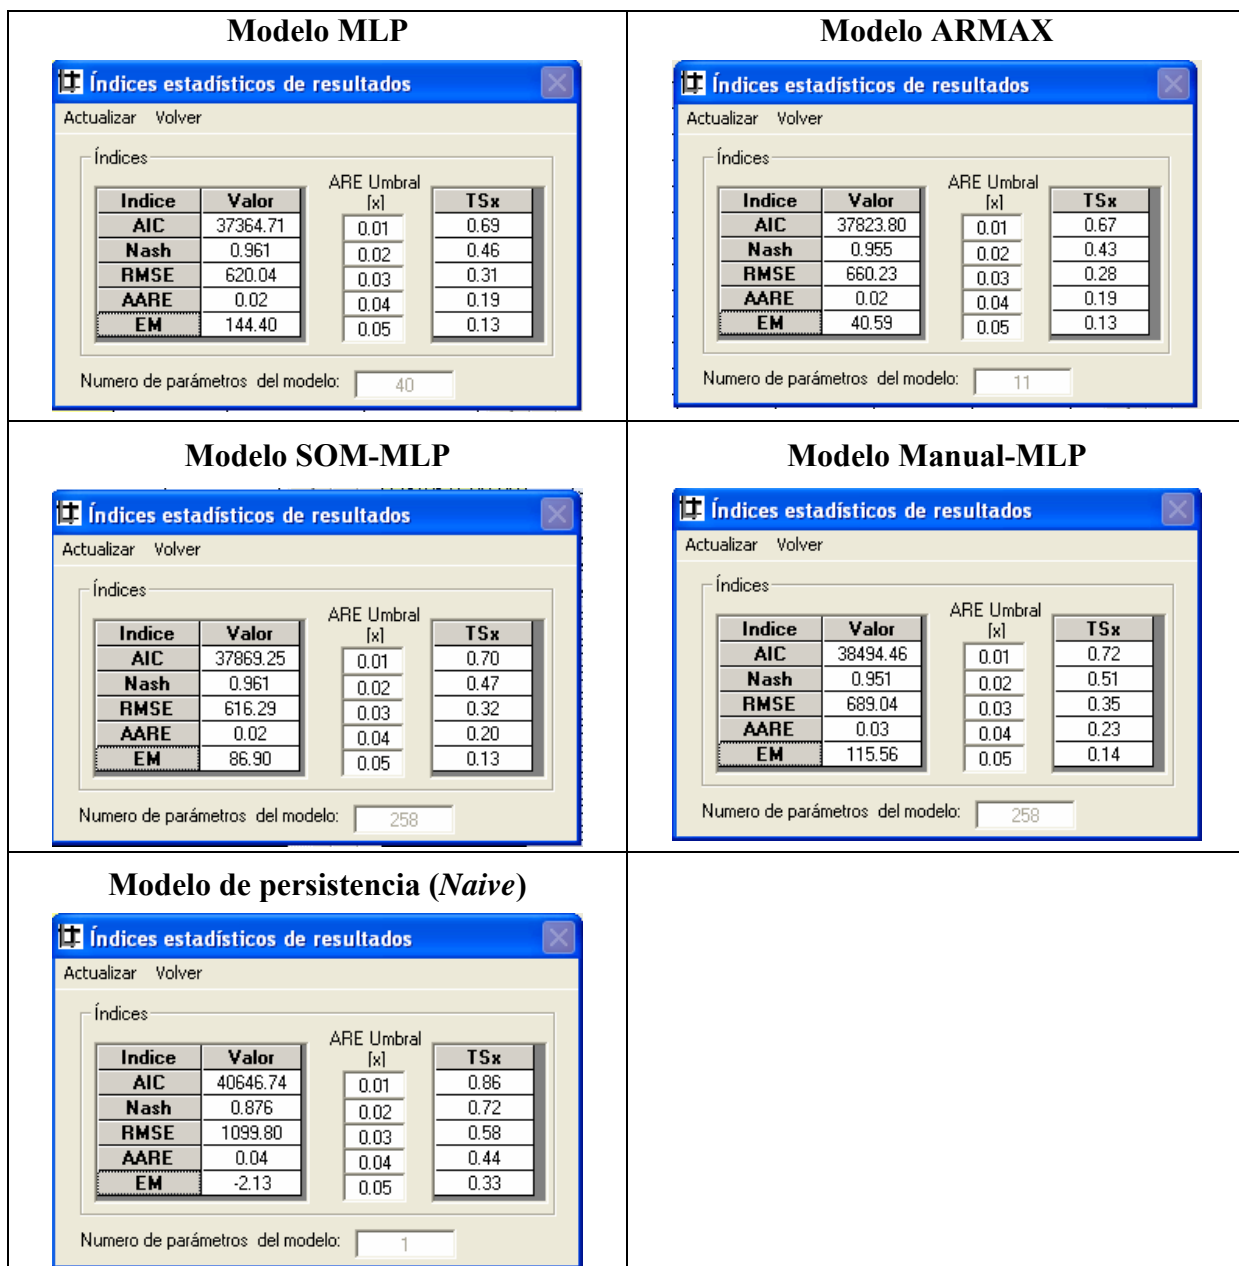


Figura 8.26: Índices estadísticos de los resultados de validación para los cuatro modelos analizados

Si se comparan los índices de *Nash and Sutcliffe (Nash)*, el modelo SOM-MLP y el MLP tienen el mismo valor 0.961. En cambio el modelo ARMAX tiene un valor de 0.956.

Los estadísticos de umbral (*TSx*) son muy parecidos entre los tres modelos. El error relativo absoluto (*ARE*) de 0.05 sólo es superado en un 13% de las predicciones y el 0.01, en un 70% aproximadamente. Esto refleja la igualdad de la distribución del ARE de los tres modelos.

El modelo con menor raíz del error cuadrático medio (*RMSE*) es el SOM-MLP, aunque todos los modelos tienen un RMSE entre 615 y 660 m³/s. La diferencia es mayor en los errores medios (*EM*) donde el mínimo se obtiene con el modelo ARMAX. Este último índice no es un buen indicador, ya que se contrarrestan los errores negativos con los positivos, en cambio el *RMSE* los considera por igual. Por ejemplo, un modelo de predicción donde el resultado sea siempre la media de los valores observados, tendrá *EM* igual a cero y también un *Nash* igual a cero. Esto quiere decir que valores de errores medios cercanos a cero no siempre suponen que el modelo sea apropiado.

El coeficiente del criterio de Akaike (*AIC*) con menor valor se obtiene con el modelo MLP y valores similares para el modelo SOM-MLP y ARMAX. Este índice depende de la varianza del error y de la cantidad de parámetros del modelo. Por lo tanto, nos da una idea de lo fiable que es el modelo SOM-MLP, ya que se obtienen valores muy cercanos a los de los otros dos modelos teniendo una cantidad de parámetros seis veces superior a los demás.

El índice *PFC (Peak Flow Criteria)* sugiere la habilidad de los modelos para predecir los picos de un hidrograma. Para su cálculo se hace primero una elección de los picos a considerar, como se puede ver en la Figura 8.27.




Figura 8.27: Elección de los picos para el cálculo del PFC de los datos de validación

En la Tabla 8.2 se pueden observar los coeficientes PFC calculados para cada uno de los modelos, incluyendo el modelo de persistencia. Se puede comprobar que el modelo modular SOM-MLP es el que mejor predice los picos, ya que su valor es el mínimo entre todos los comparados.

Tabla 8.2: Peak Flow Criteria. Índice de habilidad de predicción de picos

	PFC
SOM-MLP	25.50
MLP	29.50
Separa manual-MLP	32.36
ARMAX	39.32
Persistencia	45.76

La Figura 8.26 muestra los índices para un modelo de persistencia ($Q_{i+10}^{pred} = Q_i$). Éstos se utilizan para tener una base de valores mínimos que se deben conseguir con los modelos para que puedan ser considerados aceptables.

La comparación del modelo modular con separación de los datos manual y el modelo SOM-MLP indica una pequeña diferencia a favor del modelo SOM-MLP, presentando una mejoría en todos los índices.

Análisis de la incertidumbre

Es importante, además del análisis de los índices de fiabilidad de los resultados, realizar un análisis de la incertidumbre general de cada uno de los modelos. Se calculan los intervalos de confianza del 90% utilizando la función de distribución bivariada meta-gaussiana [Kelly y Krzysztofowicz, 1997] (ver Figura 8.28) con las mismas funciones de densidad de probabilidad marginales para todos los modelos, en este caso lognormales. En el Apéndice A se muestran los parámetros para las funciones de distribución de cada uno de los modelos.

En la Figura 8.29 se pueden observar las curvas de igual probabilidad de la función de distribución de probabilidades bivariada, junto con las líneas de los cuantiles del 5% y 95%, las cuales indican que entre las dos líneas se encuentran los valores con un 90% de probabilidad.




Figura 8.28: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza.
Modelo SOM-MLP calibración

Se calculan los intervalos de confianza con los datos de calibración y luego se validan con los datos de validación, comprobando que dentro de los límites esté contenido el 90% de las predicciones.




Figura 8.29: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza junto con las líneas de cuantiles del 5% y 95%. Datos de calibración del modelo SOM-MLP

En la Figura 8.30 se muestra la evolución de los errores de predicción a lo largo de los diferentes caudales predichos. Las líneas rojas marcan el intervalo del 90% de confianza de los resultados del modelo estocástico ARMAX, las celestes representan los límites del modelo MLP y el área gris, el del modelo modular SOM-MLP.

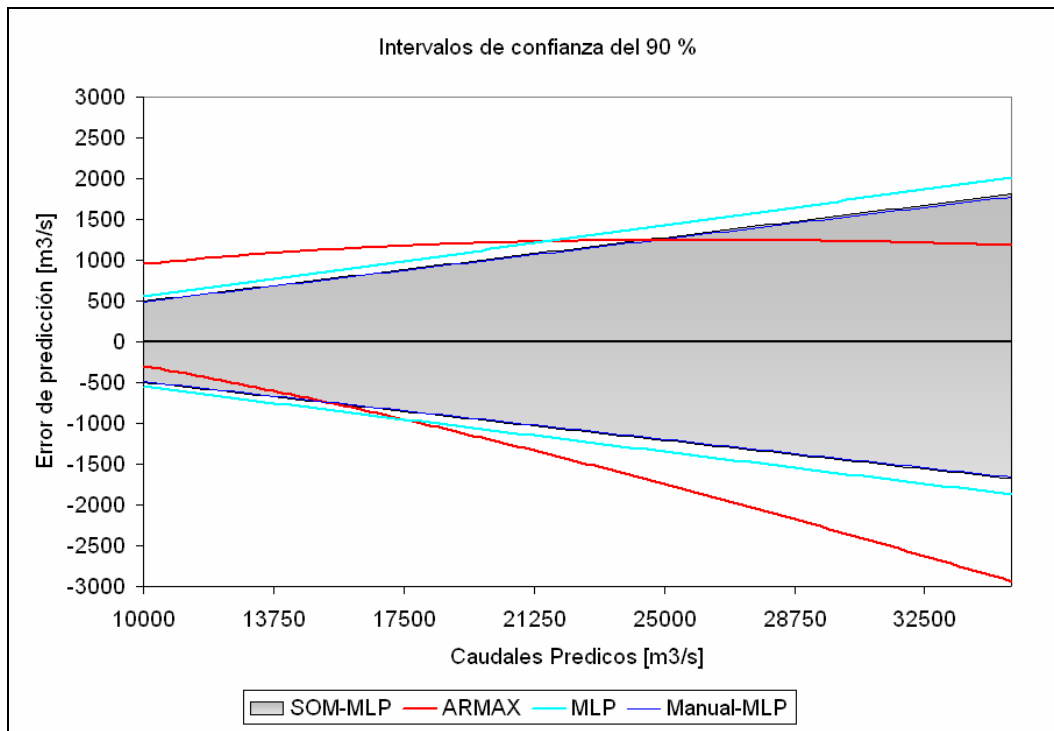


Figura 8.30: Errores en función de los caudales predichos para los intervalos de confianza del 90% para los tres modelos

Se puede comprobar que el modelo SOM-MLP presenta intervalos de confianza más estrechos, reflejando la mejor calidad de sus resultados. Los dos modelos de redes neuronales artificiales tienen una media de errores muy cercana a cero. Por otro lado, se puede comprobar en la Figura 8.31, que para el modelo ARMAX la línea roja, que indica el 50% de probabilidad, se aleja a cero.




Figura 8.31: Errores en función de los caudales predichos para el cuantil del 50% de los tres modelos

Este tipo de análisis da una idea muy buena de la distribución de la habilidad de los modelos a lo largo de diferentes valores de caudales. Se puede deducir simplemente que los modelos de redes neuronales artificiales presentan un mejor comportamiento que el modelo estocástico ARMAX y que el modelo modular ligeramente más eficaz que el modelo MLP.

La comparación del modelo SOM-MLP y el modelo modular con separación manual muestra resultados muy parecidos, llegando a la conclusión de que el modelo de separación de datos automático funciona de manera muy eficaz.

Análisis gráfico

En las siguientes figuras se representan los resultados gráficos de los tres modelos para las series de validación.




Figura 8.32: Predicción a 10 días del modelo ARMAX para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior




Figura 8.33: Predicción a 10 días del modelo MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior




Figura 8.34: Predicción a 10 días del modelo SOM-MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior




Figura 8.35: Predicción a 10 días del modelo modular con separación de datos manual y redes MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior

8.2.5 Conclusiones

En este caso estudiado existe una alta correlación lineal entre los caudales en “Corrientes” y “Chapetón”, por lo tanto es difícil analizar los resultados de distintos modelos, ya que la mayoría realizan predicciones de muy buena calidad con coeficientes de *Nash* del orden de 0.96.

Se ha utilizado una amplia cantidad de indicadores para poder analizar los resultados de los modelos, llegando a la conclusión de que el modelo modular SOM-MLP presenta el mejor comportamiento, obteniendo el RMSE y PFC menor y un coeficiente de *Nash and Sutcliffe* mayor. Aunque con este modelo se obtengan mejores índices de fiabilidad, el comportamiento global del modelo no supera notablemente al modelo MLP. Teniendo en cuenta la mayor cantidad de esfuerzo y tiempo que se necesita para calibrar y validar el modelo SOM-MLP, se considera que en este caso el mejor modelo es el MLP.

En general, los tres modelos se comportan muy bien si observamos los indicadores estadísticos de los resultados, los cuales permiten una visión global del rendimiento general de los modelos. Para poder estudiar con más detalle los resultados, es aconsejable analizar la incertidumbre de los mismos y extraer conclusiones más directas para la elección del modelo adecuado.

El análisis de la incertidumbre de los modelos pone de manifiesto la clara superioridad de los modelos de redes neuronales artificiales frente al modelo ARMAX; teniendo en cuenta que los errores con un 50% de probabilidad para los modelos de redes neuronales son muy cercanos a cero y los de ARMAX se alejan bastante (ver Figura 8.31).

La incertidumbre de las predicciones se calcula mediante la función de distribución de los caudales observados condicionados a los predichos. Esta aproximación se realiza con la distribución meta-gaussiana [Kelly y Krzysztofowicz, 1997] que tiene en cuenta un coeficiente de correlación general entre las dos variables. Sería interesante en futuras investigaciones la utilización de funciones que impliquen coeficientes de correlación variables, de tal forma que los intervalos de confianza varíen según los caudales predichos. Por ejemplo, en la Figura 8.34 se puede ver que los intervalos de confianza crecen con los caudales predichos. Esta aproximación no es del todo real, ya que para caudales bajos debería existir una separación mayor.

8.3 Predicción de caudales en el río Neuquén

A fines del siglo XVIII comienza a conocerse el peligro real que representan las crecidas del río Negro (ver Figura 8.38), ocasionadas por sus afluentes, Neuquén y Limay. Cien años después, a medida que va cobrando intensidad la colonización de los valles de los ríos Limay, Neuquén y Negro, surge la preocupación por la integridad de las personas y bienes de los asentamientos litorales, altamente vulnerables a la acción de estos eventos.

Como consecuencia de ello, a principios de este siglo, se realizan una serie de estudios para determinar la magnitud de las crecidas extraordinarias y para la definición de las obras de regulación necesarias que atenúen sus efectos. En la Figura 8.36 se puede observar la situación actual de las obras de control ubicadas sobre el río Neuquén, donde se indican las capacidades de desagüe de cada una. Estas obras permiten reducir el pico de una avenida de 11,500 m³/s (en “Paso de los Indios”) a 2,300 m³/s aguas abajo de las obras donde se ubica la zona metropolitana del “Alto valle”, con una población superior a los 300,000 habitantes.

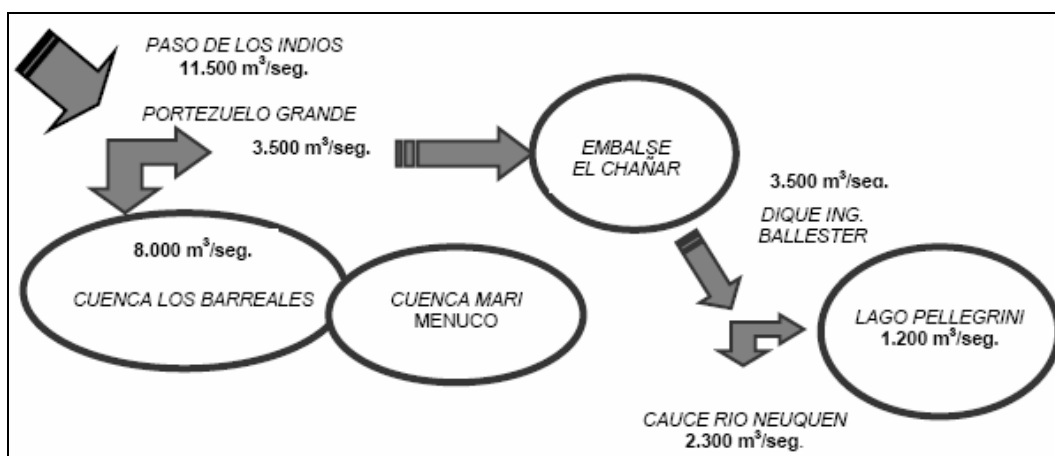


Figura 8.36: Esquema actual de las obras de control ubicadas sobre el río Neuquén (fuente: Valicenti, 2001)

El conocimiento de los caudales en la estación de “Paso de los Indios” es fundamental, dado que las operaciones de todas las obras de control mencionadas anteriormente se basan en los caudales en este punto de control. Por ello se ha elegido dicho punto para realizar los modelos de predicción (Figura 8.37).



Figura 8.37: Foto de la sección de predicción en “Paso de los Indios”

8.3.1 Caso de Estudio

La cuenca del río Neuquén, ubicada al sur de Argentina, al noroeste de la provincia del Neuquén, tiene una extensión aproximada de 32,500 km² (ver Figura 8.38).

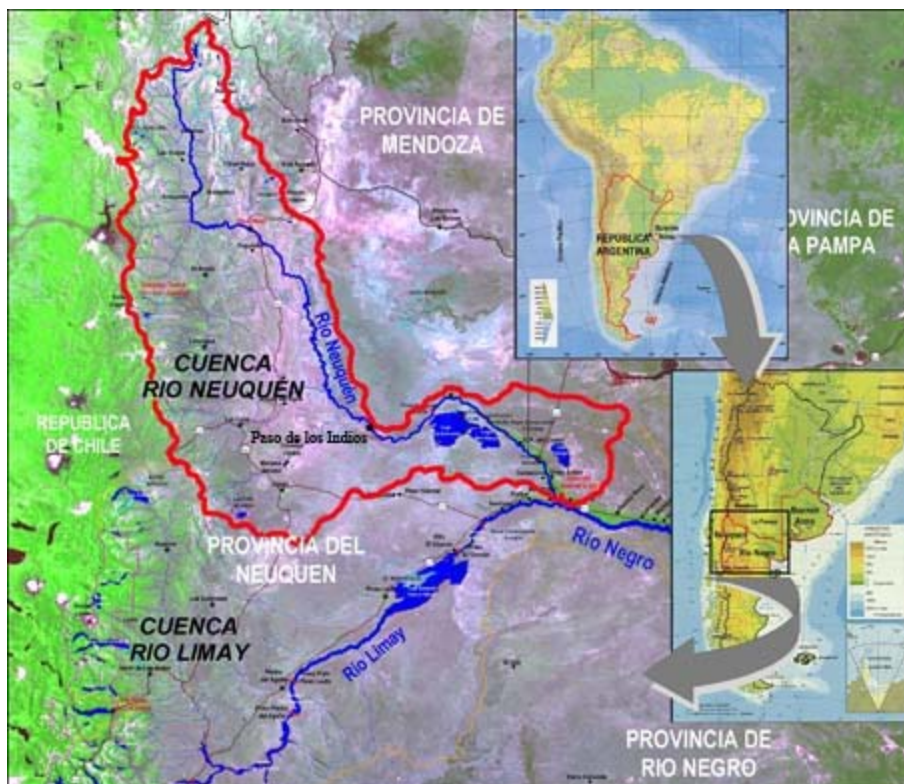


Figura 8.38: Ubicación de la cuenca del Neuquén

Está caracterizada principalmente por poseer escasa cobertura vegetal, un relieve de laderas empinadas y carencia de reguladores naturales. Se producen significativos torrentes en las zonas altas y crecidas preocupantes para los habitantes de la parte inferior. Los torrentes de la parte superior han producido, y continúan generando, un proceso creciente de erosión hídrica, componente fundamental del fenómeno de desertización que se ha instalado en casi toda la Patagonia [Valicenti, 2001].

El mecanismo meteorológico que provoca las precipitaciones en esta parte de la cordillera de los Andes halla explicación en el ingreso de masas de aire húmedo provenientes del océano Pacífico que, obligadas a ascender por la cadena montañosa, se enfrían adiabáticamente por disminución de la presión atmosférica, se condensan y precipitan en forma de lluvia o nieve.

Las precipitaciones más importantes, del orden de 3,000 mm anuales, ocurren en la parte alta de la cordillera, en el límite con Chile. En la parte oriental de la cuenca la precipitación media anual es sólo 200 mm (ver Figura 8.39). Esta brusca variación es causada por la pérdida de gran parte de la humedad de las masas de aire en la muralla montañosa y en otras barreras orográficas que se interponen entre uno y otro extremo de la cuenca.

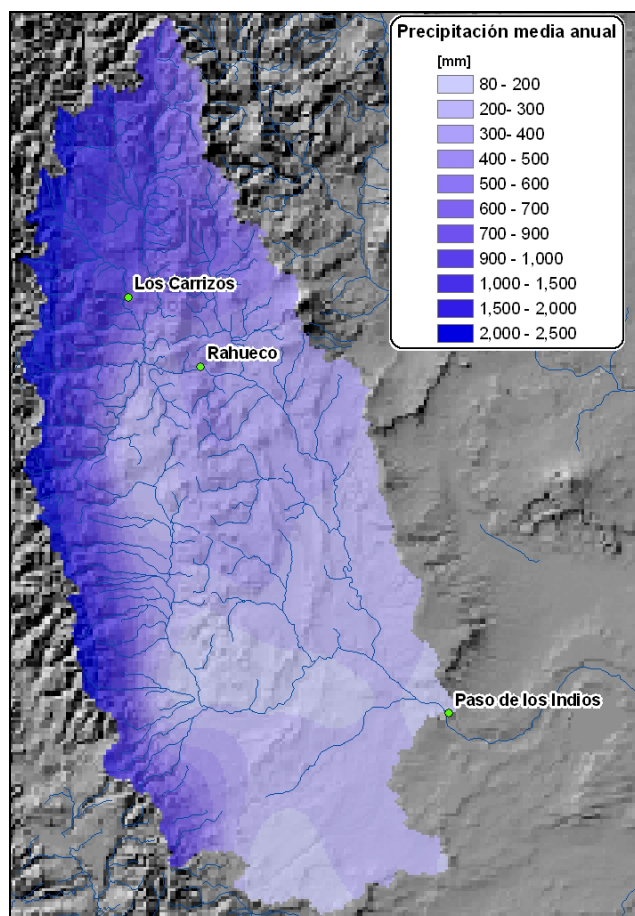


Figura 8.39: Estimación de la distribución de la precipitación media anual en la cuenca

El régimen hidrológico del río Neuquén, de rasgo pluvionival, se caracteriza por poseer doble onda de crecida anual (ver Figura 8.40). La primera ocurre en época invernal, principalmente en el período mayo - agosto, época en que se produce el 70% al 80% del total de precipitaciones en la cuenca. Por su distribución areal, una parte importante de estas precipitaciones, bajo forma de nieve, se acumula en la parte alta de la cuenca.




Figura 8.40: Distribución anual de la precipitación media mensual en la estación “Los Carrizos” y de los caudales medios mensuales en “Paso de los Indios”




Figura 8.41: Distribución anual de la precipitación media mensual en la estación “Los Carrizos” y de los caudales máximos mensuales en “Paso de los Indios”

La porción que precipita bajo forma de lluvia es la que produce la onda invernal, caracterizada por poseer un pico de gran magnitud con relación al volumen escurrido. Los derrames medios estimados para el período mayo - agosto representan el 34% del total anual. En la Figura 8.41 se puede ver cómo los caudales máximos se dan en la época invernal, mientras que en la Figura 8.40, los caudales medios mensuales máximos se producen en la época de verano cuando ocurre el derretimiento de la nieve.

La segunda onda de crecida, habitual hacia fines de la primavera (noviembre - diciembre), se origina principalmente por la fusión de la nieve. Se caracteriza por resultar más moderada que las invernales. En promedio, el aporte medio entre octubre y marzo es 54% del derrame medio anual.

Los estiajes son habituales hacia fines del verano y comienzo del otoño (febrero - abril).

Análisis geomorfológico

El objetivo a alcanzar en un análisis geomorfológico es la representación de la configuración de los caminos de drenaje naturales que siguen los flujos en la cuenca en estudio. Dichos caminos se obtienen a partir de un análisis exhaustivo del terreno, mediante técnicas de análisis espacial, empleando metodologías propias de los Sistemas de Información Geográfica (SIG).

Para el análisis geomorfológico se ha utilizado el Modelo Digital del Terreno (MDT) proporcionado por la NASA. Esta información se obtiene del GeoPortal CGIAR-CSI [Jarvis et al., 2008] que provee los modelos digitales del terreno SRTM (*Shuttle Radar Topographic Mission*) 90 m de todo el mundo. Estos modelos tienen una resolución de 90 metros (3 segundos de arco) en el ecuador y un error vertical menor a 16 m. Se distribuye en diferentes formatos en grados decimales y datum WG84 (*World Geodetic System*). Esta información es suficientemente buena para el uso en modelos hidrológicos [Jarvis et al., 2008].

Para poder utilizar estos datos debe transformarse el sistema de coordenadas original (Geográficas) a UTM19 (*Transverse Mercator* huso 19), manteniendo el Datum original WGS84 con la ayuda de las herramientas de ESRI ArcToolbox.

Se ha calculado la red de drenaje para la zona en estudio (comparándola también con las coberturas obtenidas de <http://www.maproom.psu.edu/dcw>) y la delimitación de la cuenca, haciendo uso de los programas ArcView GIS y ESRI ArcMap. Estas herramientas son un apoyo muy útil para el análisis espacial necesario para los estudios geomorfológicos,

permitiendo calcular áreas, distancias, direcciones de drenaje, celdas drenantes acumuladas, pendientes, redes de drenaje, longitudes de drenaje y todo tipo de cálculos necesarios para entender mejor el tipo de cuenca a estudiar.

Se calcula para cada celda la dirección con mayor gradiente descendente del terreno. Para calcular el gradiente en cada dirección se utiliza el algoritmo *eight-point pour* (ocho puntos de vertido o D8) de Moore, mediante el cual se obtiene el gradiente en cada dirección del modo ilustrado en la siguiente figura:




Figura 8.42: Esquema de cálculo del gradiente para cada dirección de flujo

De esta manera se calcula la dirección con mayor gradiente en cada celda y se obtiene el campo de dirección de flujo resultante para cada una de las celdas, codificándolo como sigue:


32	64	128
16		1
8	4	2

Figura 8.43: Códigos de direcciones de flujo

En la Figura 8.44 se muestran las direcciones de drenaje para cada celda según la codificación anterior.

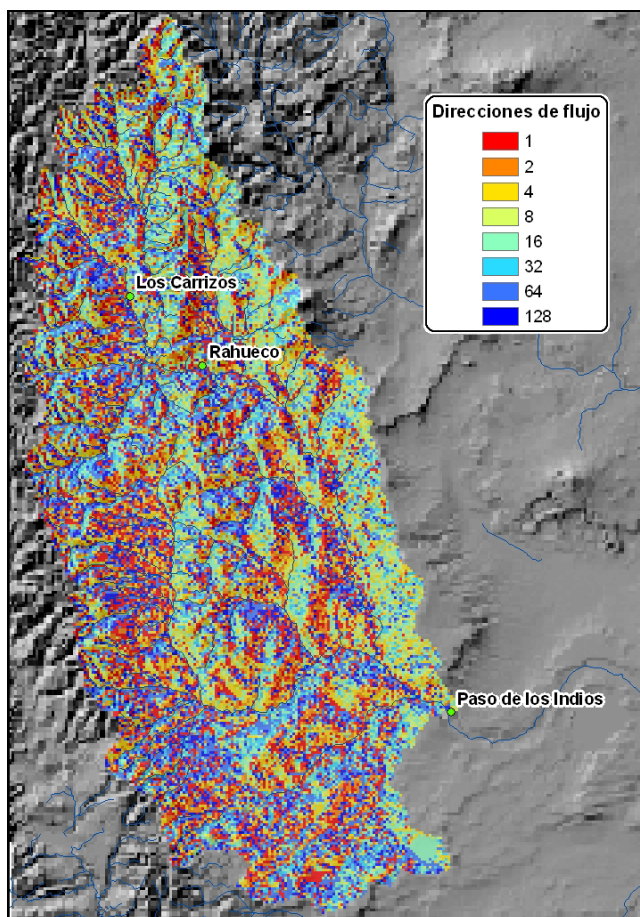


Figura 8.44: Direcciones de flujo en la cuenca del Neuquén hasta “Paso de los Indios”

Para cada celda se calcula el número de celdas que están situadas aguas arriba y drenan a ella. Conocida el área de cada celda se obtiene fácilmente el área drenante en cada una. La Figura 8.45 muestra un ejemplo del cálculo de las celdas drenantes acumuladas a partir de las direcciones de flujo.




Figura 8.45: Cálculo de las celdas drenantes acumuladas

Con el mapa de celdas drenantes acumuladas se obtiene fácilmente la red de drenaje. Basta con definir sobre el mapa, el número de celdas acumuladas a partir del cual se considera que comienza el flujo en canal y termina el flujo en ladera.




Figura 8.46: Red de drenaje obtenida a partir del MDT 90 m x 90 m

El mapa de pendientes junto a la red de drenaje nos permite obtener una primera aproximación de la respuesta de la cuenca.

Se define la forma, como la configuración geométrica de la cuenca tal como está proyectada sobre el plano horizontal. Este aspecto es de gran importancia; no basta tan sólo con el conocimiento de la superficie, pues dos cuencas de igual área y con perímetros bien diferentes, obviando otros factores, no se comportan igual. La forma de la cuenca (relación área-perímetro) afecta directamente al tiempo de respuesta de la misma; es decir, al tiempo de recorrido de las aguas a través de la red de drenaje y, por consiguiente, a la forma del hidrograma resultante de una lluvia dada.

Para determinar la forma de una cuenca se utilizan varios índices. Los más habitualmente citados entre los diversos autores son:

- *Índice o coef. de compacidad K_c* . Se debe a Gravelius y lo determina la relación entre el perímetro de la cuenca y el perímetro de un círculo de igual área que la cuenca. Llamas (1993) propone la siguiente expresión:

$$K_c = 0.28 \frac{P}{\sqrt{A}}$$

[8.7]

donde P y A son el perímetro y el área de la cuenca, respectivamente.

El coeficiente será mayor que la unidad cuanto más irregular sea la cuenca. Cuanto más próximo sea a 1, más se asemejará la forma de la cuenca a un círculo, pudiendo alcanzar valores próximos a 3 en cuencas muy alargadas.

- *Factor de forma R_f* . Definido por Horton, es el cociente entre la superficie de la cuenca y el cuadrado de su longitud máxima:

$$R_f = \frac{A}{L_m^2}$$

[8.8]

donde L_m es la longitud máxima o recorrido principal de la cuenca, entendiendo como tal, la distancia entre el punto de desagüe y el punto más alejado de la cuenca siguiendo la dirección de drenaje.

El factor de forma da alguna indicación de la tendencia de las avenidas en el cauce. Una cuenca con un factor de forma bajo, tiene menos tendencia a concentrar las lluvias que una cuenca de igual área, pero con un factor de forma más alto.

- *Radio de elongación R_e* . Definido por Schumm, es la relación entre el diámetro de un círculo que tenga la misma superficie que la cuenca y la longitud máxima de la cuenca. Expresándolo en función del área de la cuenca queda:

$$R_e = 1.128 \frac{\sqrt{A}}{L_m}$$

[8.9]

donde, A y L_m son los definidos anteriormente.

- *Radio de circularidad R_{ci}* . Es el cociente entre el área de la cuenca y la del círculo cuyo perímetro es igual al de la cuenca:

$$R_{ci} = \frac{4\Pi A}{P^2}$$

[8.10]

donde, P y A son el área y el perímetro de la cuenca.

Para la estimación del tiempo de concentración se ha optado por la fórmula de Témez, una derivación de la fórmula del *U.S. Army Corps of Engineers*.

$$T_c = 0.3 \left(\frac{L}{J^{1/4}} \right)^{0.76}$$

[8.11]

donde, L es la longitud del cauce principal de la cuenca en Km, J es la pendiente promedio de dicho recorrido en m/m y T_c es el tiempo de concentración de la cuenca en horas.

La cuenca de “Paso de los Indios” tiene un área de 31,661 km² y un perímetro de 1,198,185 km de forma alargada ($K_c = 1,885.0$, $R_f = 0.15$, $R_e = 0.44$, $R_{ci} = 2.7 \times 10^{-7}$) con orientación norte-sur. Su extensión máxima ronda en los 450 km. En la Figura 8.47 se puede ver una imagen de la cuenca sobre la imagen LandSat Circa 2000 obtenida de la Nasa (<https://zulu.ssc.nasa.gov/mrsid/mrsid.pl>). Los puntos que se indican son las estaciones elegidas para hacer predicciones en “Paso de los Indios”. “Los Carrizos” es una estación meteorológica que se considera representativa para toda la cuenca. “Rahueco” es una estación hidrométrica que mide niveles y caudales sobre el río Neuquén. “Paso de los Indios” es la estación donde se harán las predicciones.

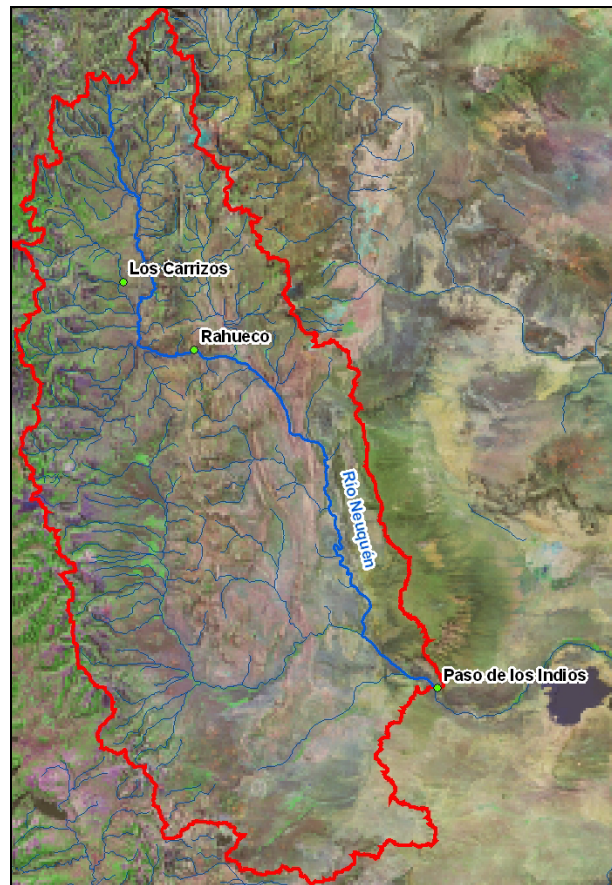


Figura 8.47: Cuenca del río Neuquén hasta “Paso de los Indios”

Aguas abajo de “Rahueco” (ver Figura 8.48) en las proximidades de la localidad de Chos Malal, el río Neuquén recibe al Curi Leuvú por la margen izquierda con una aportación de $17.4 \text{ m}^3/\text{s}$ alcanzando, aguas abajo de la confluencia, un caudal medio anual de $247 \text{ m}^3/\text{s}$. En los próximos 180 km los aportes de los tributarios son de escasa relevancia, ya que el caudal aportado no compensa las pérdidas que se producen por infiltración. Al final de este tramo se encuentra con el río Agrio, su más importante afluente, que le aporta por la margen derecha un caudal medio de $60 \text{ m}^3/\text{seg}$. Luego, también por la margen derecha, confluye el río Covunco que contribuye con un caudal aproximado de $7 \text{ m}^3/\text{seg}$. En “Paso de los Indios” el módulo del río es $310 \text{ m}^3/\text{seg}$ [Valicenti, 2001].

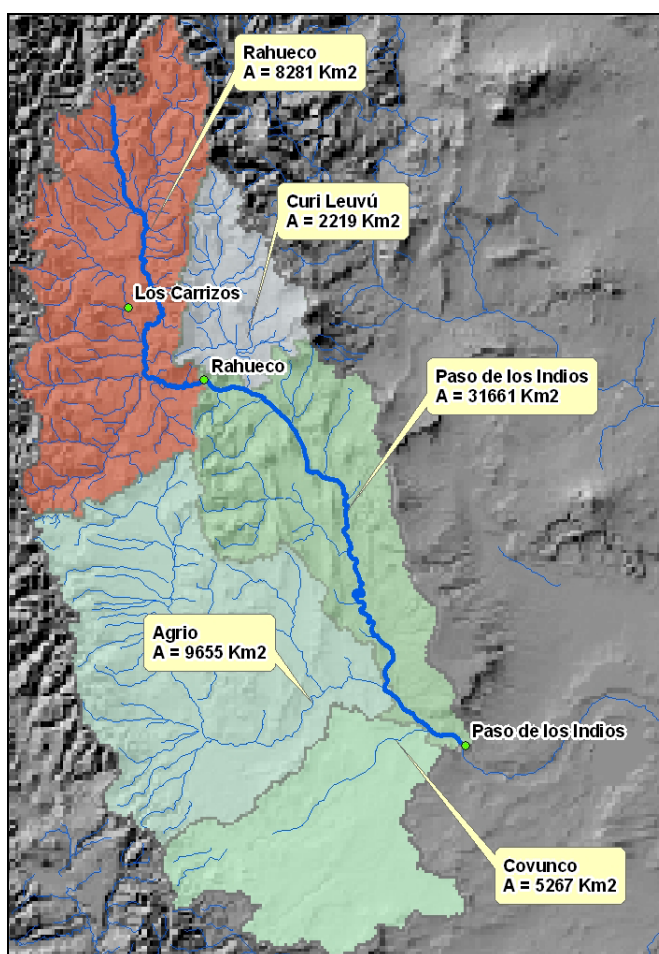


Figura 8.48: Cuencas vertientes al río Neuquén

En la Figura 8.50 se pueden observar las longitudes de drenaje de cada punto de la cuenca hasta su desembocadura en “Paso de los Indios”, con una longitud máxima de 451 km.

El tiempo de concentración (según Témez) de la cuenca a “Paso de los Indios” es de 84 horas. Esto quiere decir que el tiempo estimado que tarda una gota desde que cae en el punto más alejado de la cuenca hasta producir escorrentía en “Paso de los Indios” es de 84 horas. Según la experiencia de profesionales de la zona, la cuenca tiene una respuesta de 36 horas desde que empieza a llover en “Los Carrizos” hasta producir escorrentía en “Paso de los Indios”.

Tiempo de concentración			
Cota máxima [msnm] =	<input type="text" value="2964"/>	Longitud [km] =	<input type="text" value="451.55934"/>
Cota mínima [msnm] =	<input type="text" value="498"/>	Tiempo de concentración [h] =	<input type="text" value="84.07"/>
			<input type="button" value="Calcular"/>

Figura 8.49: Cálculo del tiempo de concentración de la cuenca drenante a “Paso de los Indios”

Teniendo en cuenta que la estimación de Témez sobreestima los tiempos, se corrigen éstos multiplicándolos por 0.45, obteniendo el siguiente mapa de tiempos de concentración en la cuenca (ver Figura 8.51).

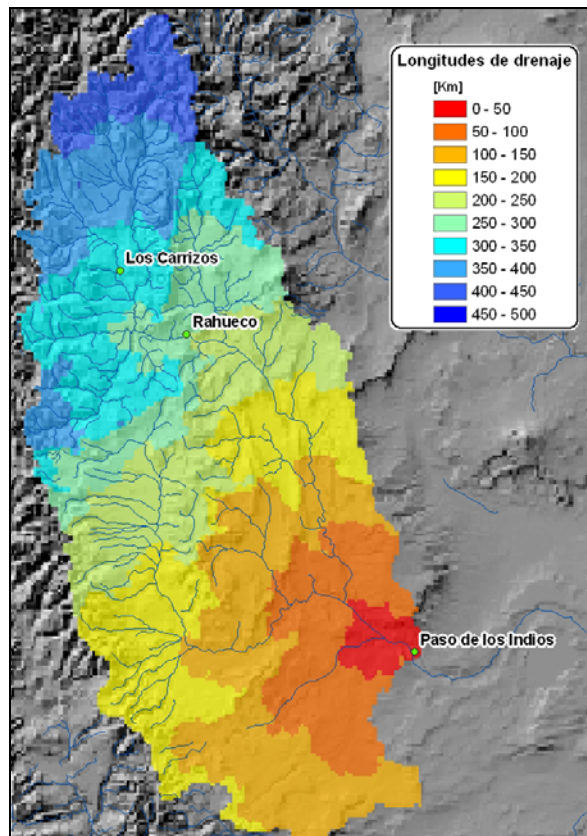


Figura 8.50: Longitudes de drenaje a “Paso de los Indios”

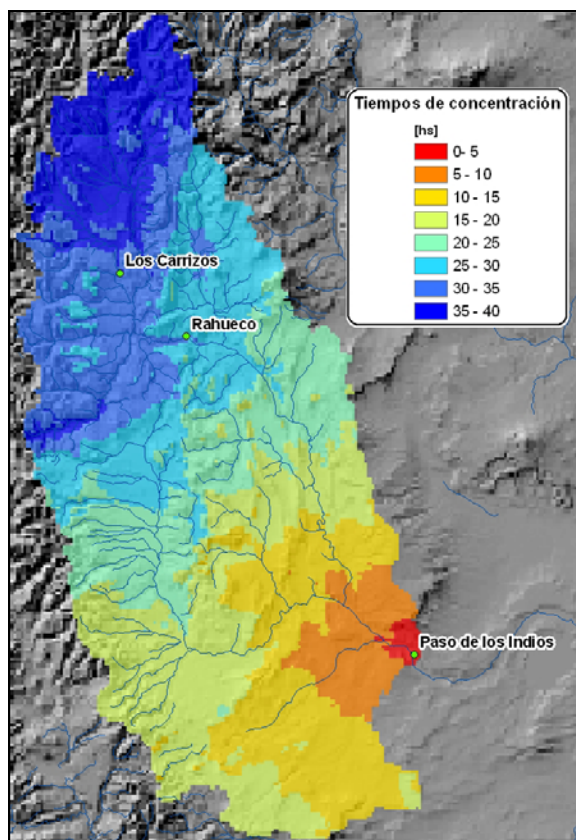


Figura 8.51: Tiempos de concentración corregidos para cada punto de la cuenca

La longitud de drenaje entre la estación de “Rahueco” y “Paso de los Indios” es de 251.36 km. La cota mínima de la sección en “Rahueco” es de 876.7 msnm y en “Paso de los Indios” de 499.35 msnm (datos obtenidos del modelo digital del terreno de 90m x 90m). La pendiente media de este tramo del río es de 0.0015 m/m (0.15%).




Figura 8.52: Sección del río en la estación de “Rahueco” obtenida del MDT 90 x 90 m




Figura 8.53: Sección del río en la estación de “Paso de los Indios” obtenida del MDT 90m x 90m

Utilizando una sección media del cauce y con las características medias del tramo del río analizado (pendiente media, número de manning, longitud, ver Figura 8.55) se calcula la velocidad media del agua. Con esta velocidad se calcula el tiempo que tarda una onda en propagarse entre las secciones de “Rahueco” y “Paso de los Indios”.

Una onda se define como una variación en el flujo que se caracteriza por una velocidad de propagación, que corresponde a la velocidad con que ésta viaja a lo largo del cauce. Esta velocidad de propagación depende del tipo de onda que se está considerando y puede ser sustancialmente diferente de la velocidad del escurrimiento. Por lo tanto se considera que la onda de crecida se transporta con una celeridad igual a 1.5 veces la velocidad media del agua en la sección tipo. Esta simplificación propuesta y comprobada en el año 1900, da la velocidad de tránsito de una avenida que no se lamina. En cauces prismáticos, o en cauces muy anchos, de pendiente mayor a 0.2%, el tránsito de avenidas cumple estas propiedades [Vide, 2002].

Para el cálculo de la velocidad media del agua se utiliza la ecuación de manning, asumiendo la simplificación de régimen uniforme (ecu. [8.12])

$$V = \frac{1}{n} R^{2/3} \sqrt{J} \tag{8.12}$$

donde,

- n es el coeficiente de rugosidad de manning del cauce [s/m^{1/3}]
- J la pendiente media del cauce (cota máxima-cota mínima)/longitud total [m/m]
- R el radio hidráulico = A/P (área mojada de la sección/perímetro mojado) [m]




Figura 8.54: Sección tipo del río Neuquén entre “Paso de los Indios” y “Rahueco”

Propagación en Cauce

Volver

Sección Media

x [m]	z [m]
0.000	785.071
82.855	785.846
165.709	786.314
248.564	786.085
331.419	786.805
414.273	787.076
497.128	786.682
579.983	785.982
662.838	785.690
745.692	785.192
828.547	785.000
911.402	784.468
994.256	783.069
1077.111	781.705
1159.966	779.983
1242.820	776.034
1325.675	769.990
1408.530	759.692
1491.384	747.811
1574.239	739.320
1657.094	730.117
1739.948	719.456
1822.803	710.966
1905.658	703.378
1988.513	684.755
2071.367	668.977
2154.222	670.340
2237.077	679.250

Datos de entrada

Q = Caudal [m3/s]

J = Pendiente [m/m]

n = Número de manning [s/m^(1/3)]

L = Longitud del cauce [m]

Datos de salida

A = Superficie mojada [m2]

P = Perímetro mojado [m]

B = Ancho [m]

h = Calado medio [m]

V = Velocidad media [m/s]

c = Celeridad canal suficientemente ancho [m/s]

c = Celeridad de onda cinemática [m/s]

T = Tiempo de respuesta [hs]

$Q = A \frac{1}{n} R^{2/3} \sqrt{J}$

Graficar

Figura 8.55: Cálculo del tiempo de respuesta para una sección media del cauce y un caudal dado




Figura 8.56: Tiempos de respuesta en función de los caudales

Toda esta información obtenida de la cuenca junto con el análisis de los datos que se hace en el siguiente apartado es muy importante para la elección de las variables de entrada a los modelos de predicción. Es importante conocer el tipo de cuenca a modelar, los tiempos de respuesta, cuales son sus mayores tributarios, la distribución de la precipitación, etc.

8.3.2 Preparación y análisis de datos

La cuenca en estudio es una cuenca muy monitorizada por la AIC (Autoridad Interjurisdiccional de Cuencas de los ríos Limay, Neuquén y Negro). De todas las estaciones disponibles (ver Figura 8.57) se eligieron las más representativas y las que se consideraron fundamentales para ser utilizadas como variables de entrada a los modelos de predicción.

Se ha elegido la estación de “Rahuco” sobre el río Neuquén, 250 km aguas arriba de “Paso de los Indios”. Como se ha explicado anteriormente las aportaciones al río por las cuencas intermedias entre estas dos estaciones no es muy importante ya que la gran mayoría del caudal viene aportado por la zona norte de la cuenca. Por esta misma razón, y teniendo en cuenta opiniones de expertos de la AIC, se ha elegido la estación de “Los Carrizos” como pluviómetro más representativo de la zona de la cuenca que más escorrentía produce.

La escala de tiempo con la que se trabaja es de seis horas (caudales a las 00h, 06h, 12h y 18h), ya que trabajar a escala diaria no permite predecir eventos de crecida muy abruptos, donde los picos de las crecidas se alcanzan en sólo un día. Los datos de precipitación de que se dispone están a escala diaria (precipitación acumulada diaria a las 6:00h de la mañana).

En la AIC se dispone de datos, en algunas estaciones, desde 1903. Pero no todas las estaciones elegidas disponen de datos cada 6 horas desde esa época. Para poder construir un modelo es necesario disponer de todas las series necesarias en la misma escala de tiempo y lo más completas posibles. Por lo tanto el período de tiempo utilizado es entre 30/05/2000 - 27/03/2008, un total de 11,430 datos por serie.

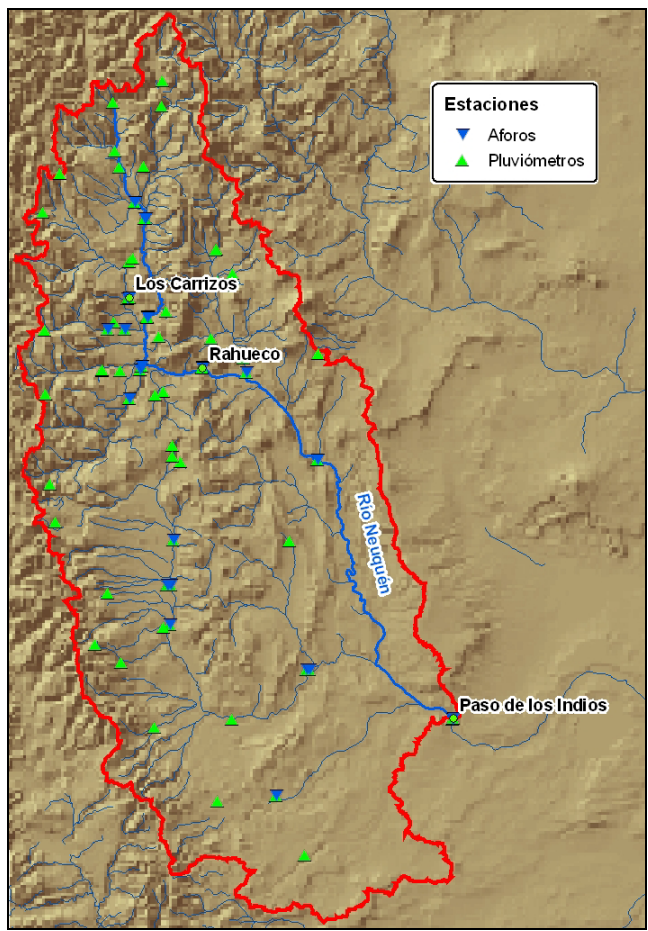


Figura 8.57: Estaciones de medición monitorizadas por la AIC

La totalidad de los datos se divide en tres grupos los cuales tienen diferentes finalidades a la hora de los entrenamientos de los modelos. Se dividen en datos de validación (30/05/2000 - 01/01/2003), verificación (30/05/2000 - 01/01/2000) y calibración (01/01/2003 - 27/03/2008) (ver Figura 8.58). Esta separación se realiza de tal forma que se obtengan suficientes datos en los grupos de calibración (67% de los datos) y validación (33% de los datos), también se tiene en cuenta que dentro del grupo de calibración exista la mayor variedad de eventos posibles. En la Figura 8.58 se pueden observar las series de tiempo de la precipitación en “Los Carrizos” y de caudales en “Paso de los Indios”. Antes de hacer uso de los datos es necesario validar las series rellenando los espacios huecos y verificando que no existan datos erróneos. En los siguientes puntos se explica la preparación y el análisis de los datos.




Figura 8.58: Series de datos de caudales en “Paso de los Indios” y precipitación en “Los Carrizos”

Preparación de datos

La preparación y validación de los datos es una tarea muy importante para la modelación con modelos “*data driven*”, ya que la calidad de éstos está directamente relacionada con la calidad de los datos. Si se construye un modelo con datos de mala calidad el modelo resultante nunca será bueno. Por lo tanto es necesario realizar el trabajo de rellenar los huecos faltantes en la serie y verificar que no existan datos irreales. Se utiliza el programa Delft-Fews desarrollado por Deltares para el manejo de los datos y completado de las series. Este tiene herramientas muy útiles para el manejo de los datos (ver Figura 8.59).

Las series de caudales se rellenan haciendo interpolaciones lineales entre los valores conocidos. En general las dos series analizadas tienen una calidad de datos muy buena.

La serie de precipitación “Los Carrizos” se completa haciendo interpolación espacial (inversa a la distancia al cuadrado). En la Figura 8.60 se puede ver un ejemplo de rellenado de huecos interpolando con la estación de “Andacollo” y “Chos Malal”. Con color magenta se indican los puntos donde se realiza el llenado.




Figura 8.59: Ubicación de pluviómetros con datos en la cuenca de "Paso de los Indios", en el entorno Fewes




Figura 8.60: Ejemplo de falta de datos (color magenta) en "Los Carrizos", rellenado interpolando con la estación "Andacollo" y "Chos Malal"

Análisis de datos

Una vez completada las series de datos es necesario un riguroso análisis de las mismas para poder entender la relación entre cada una y su distribución estadística y así tener una ayuda para la elección de las variables de entrada a los modelos.

Se realiza entonces un análisis de correlación cruzada entre los caudales en la estación “Paso de los Indios”, la precipitación en la estación de “Los Carrizos” y los caudales en “Rahueco”.

En la Figura 8.61 muestra la correlación cruzada a escala seis horaria. Se puede ver la alta correlación que existe entre las estaciones de “Rahueco” y “Paso de lo Indios” en las primeras 18 horas ($k = 0, 1$ y 2). Con la correlación máxima en $t-1$ (-6 horas) de 0.931. Se ha realizado el mismo análisis considerando sólo los períodos de eventos, obteniendo resultados muy similares.




Figura 8.61: Análisis de correlación cruzada. La escala de tiempo es de 6 horas. Caudal en “Paso de los Indios” ($PasoQ$) y caudal en “Rahueco” ($RahuecoQ$)

Como se puede ver en la Figura 8.62, los tiempos de desfases de los picos de caudales entre la estación de “Rahueco” y la de “Paso de los Indios” varía entre 12 y 24 horas, llegando en algunos casos extremos a 6 horas. Estos varían con los caudales, como se había anticipado en la Figura 8.56, donde se puede ver que los tiempos de respuesta para caudales de $3,000 \text{ m}^3/\text{s}$ son de aproximadamente 20h y para $1,000 \text{ m}^3/\text{s}$ de 30 h.




Figura 8.62: Tiempos de desfase de los picos entre la estación de “Rahueco” y “Paso de los Indios”

Dado que los datos de precipitación se disponen a escala diaria, se realiza la correlación cruzada entre los caudales medios diarios en “Paso de los Indios” y la precipitación diaria acumulada a las 6h de la mañana.




Figura 8.63: Correlación cruzada a escala diaria entre la precipitación en “Los Carrizos” y los caudales medios diarios en “Paso de los Indios”

Al mismo tiempo se realizan las correlaciones cruzadas entre la precipitación diaria a las 06h de la mañana y los caudales observados en “Paso de los Indios” a las 00h, 06h, 12h y 18h. Las correlaciones máximas para las 00h y 06h se producen con un desfase de 2 días (0.511 y 0.486, respectivamente) y para las 12h y 18h con un desfase de 1 día (0.456 y 0.490, respectivamente). Las correlaciones máximas entre la precipitación diaria y los caudales diarios, como se puede ver en la Figura 8.63, se producen con un desfase de 2 días y tienen un valor de 0.461.

En la Figura 8.64 se pueden ver los estadísticos principales de las tres series analizadas.

Cantidad de datos por variable: 11430

Estadísticos

Nom Var.	PasoQ	CarrizosP	RahuecoQ
Media	357.56	3.04	241.31
Desvio	346.76	11.42	251.16
Sk	4.45	5.74	4.72
Max	6277.76	158.00	3407.48
Min	48.76	0.00	19.73

Figura 8.64: Análisis de las series. Caudal en “Paso de los Indios” (PasoQ), precipitación diaria en “Los Carrizos” (CarrizosP) y caudal en “Rahueco” (RahuecoQ)

Para poder identificar el orden de los posibles modelos estocásticos y para tener una idea de cuales podrían ser las variables de entrada en la red neuronal artificial, se grafica la función de autocorrelación parcial (Figura 8.65) con sus límites de Anderson.

Los límites de probabilidad de 95% para un correlograma de series independientes se calculan según Anderson (1941) de la siguiente manera:

$$r_k(95\%) = \frac{-1 \pm 1.96\sqrt{N - k - 1}}{N - k}$$

[8.13]

donde,

N es la cantidad total de datos de la serie

k es el tiempo de desfase (seis horario)

Que una serie sea independiente significa que, por ejemplo, si se toma un punto de la serie al azar y se observa el próximo punto, éste tendrá la misma probabilidad de estar situado sobre o por debajo de la media sin tener en cuenta la referencia del punto anterior.

Otra forma de representar la estructura de dependencia con el tiempo de la serie del modelo es analizando la función de autocorrelación parcial. Para que un proceso sea de orden p , los $\Phi_{k,k}$, para $k > p$, tienen una distribución normal con media cero y varianza $1/N$ (N : número total de datos).




Figura 8.65: Autocorrelación parcial. Escala de desfase seis horaria

El análisis de autocorrelación parcial (Figura 8.65) muestra que un posible modelo estocástico a utilizar es un autorregresivo de orden 5. A partir de $k = 5$ (30 horas) la autocorrelación parcial se acerca mucho a los límites de Anderson, indicando la independencia de la serie a partir de ese punto, y su función de autocorrelación es superior a 0.8.

Los modelos de predicción a realizar en esta aplicación tienen un horizonte de predicción de 1 día.

El análisis de los tiempos de respuesta de la cuenca ($T_c = 32h$) y de correlación cruzada entre la precipitación en “Los Carrizos” y los caudales en “Paso de los Indios” (máximas para desfases de 1 y 2 días) muestran que las variables de precipitación a utilizar como entradas al modelo son: precipitación diaria del día 0 y del día -1, teniendo en cuenta que la predicción se hace al día +1. En las figuras siguientes se muestran los esquemas de las variables de precipitación utilizadas para la predicción de caudales a 1 día. Cuando la hora de predicción es las 00h (Figura 8.66) se utilizan las precipitaciones del día -2 y -1, ya que la precipitación del día 0 empieza a las 06h.




Figura 8.66: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 00:00 h




Figura 8.67: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 06:00 h




Figura 8.68: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 12:00 h




Figura 8.69: Precipitación diaria en “Los Carrizos” (azul), utilizada para la predicción de caudales en “Paso de los Indios” a un día, a partir de la hora 18:00 h

Para la elección de la ventana de tiempo a utilizar para los caudales en la estación de “Rahueco” se analizan los resultados obtenidos anteriormente, donde se puede observar que las relaciones máximas entre los caudales en “Rahueco” y “Paso de los Indios” dependen de la dimensión de los mismos, y varían entre las 6h y 24 horas.

Por lo tanto para el modelo de predicción a 1 día, la única información relevante que puede aportar esta variable son los caudales medidos en el tiempo t (momento de realizar la predicción (con correlación con los caudales en “Paso de los Indios” para $t+4$ de 0.866), ya que la información más importante que puede aportar está contenida entre el tiempo t y $t+4$, cuyo valor no es conocido en el momento de realizar la predicción (ver Figura 8.70). Cualquier información de los caudales en “Rahueco” anterior a t aportará información sobre los posibles caudales en “Paso de los Indios” en el intervalo no conocido entre t y $t+4$.




Figura 8.70: Rango de tiempo (azul), donde los caudales en “Rahueco” aportan información sobre los caudales en “Paso de los Indios” en el tiempo $t+4$

Se utilizarán como variables de entrada a los modelos los caudales en “Paso de los Indios” en el tiempo t , $t-1$ y $t-2$ cuyas correlaciones con los caudales a $t+4$ son 0.881, 0.835 y 0.79, respectivamente. Estas variables se eligen según el análisis de correlación previo para obtener información sobre el estado actual de la cuenca.

Por lo tanto las variables a utilizar como entradas a los modelos de predicción son las indicadas en la Tabla 8.3.

Tabla 8.3: Variables de predicción utilizadas en los modelos ARMAX, MLP y SOM-MLP

Caudales en “Paso de los Indios” [m ³ /s]	Caudales en “Rahueco” [m ³ /s]	Precipitación acumulada diaria en “Los Carrizos” [mm]
QP _t	QR _t	PC _{día0}
QP _{t-1}	QR _{t-1}	PC _{día-1}
QP _{t-2}	QR _{t-2}	

Para mejorar la eficiencia de los tres modelos se aplica una transformación que permite la reducción del sesgo y la homogenización de los rangos de variación para las diferentes variables. Varios criterios diferentes se pueden aplicar con este mismo propósito. Tras probar con distintas funciones de transformación (indicadas en la Figura 8.71), se decide utilizar la función empleada en García-Bartual, 2002, definida por dos parámetros:

$$x'_i = \left[\frac{x_i}{M_x} \right]^a$$

[8.14]

donde, x es la variable y M es un valor de referencia cercano al máximo de la serie. Los parámetros empleados son los indicados en la Figura 8.71.

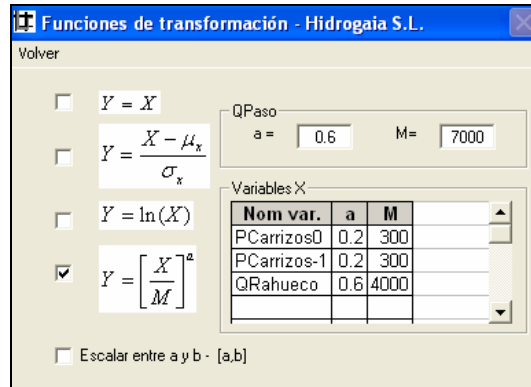


Figura 8.71: Parámetros de la función de transformación elegida

Para la utilización de los datos en un modelo estocástico es necesario primero comprobar que la serie siga una distribución normal (*gaussiana*). Para ello se realizan diferentes análisis.

Se grafican los datos en un papel de probabilidad normal y se verifica que los puntos graficados sigan aproximadamente una línea recta (Figura 8.72). También se comprueba que el coeficiente de asimetría o *skewness* (s_k) esté dentro de un rango específico (ver Apéndice C). Para $N = 7,700$ datos se considera que una serie es 90% simétrica si el coeficiente de asimetría (s_k) se encuentra entre -0.053 y 0.053.

La Figura 8.72 muestra que las series de caudales presentan una distribución aproximadamente normal y la serie de precipitación se aleja de la distribución normal. Por otro lado, los índices de asimetría no están dentro de los rangos de la normalidad. Estos resultados son determinantes para el modelo estocástico ARMAX, ya que una de sus hipótesis es suponer que las series utilizadas se distribuyen de forma normal. Por el contrario, dicha circunstancia no es significativa cuando se trabaja con modelos de redes neuronales artificiales.

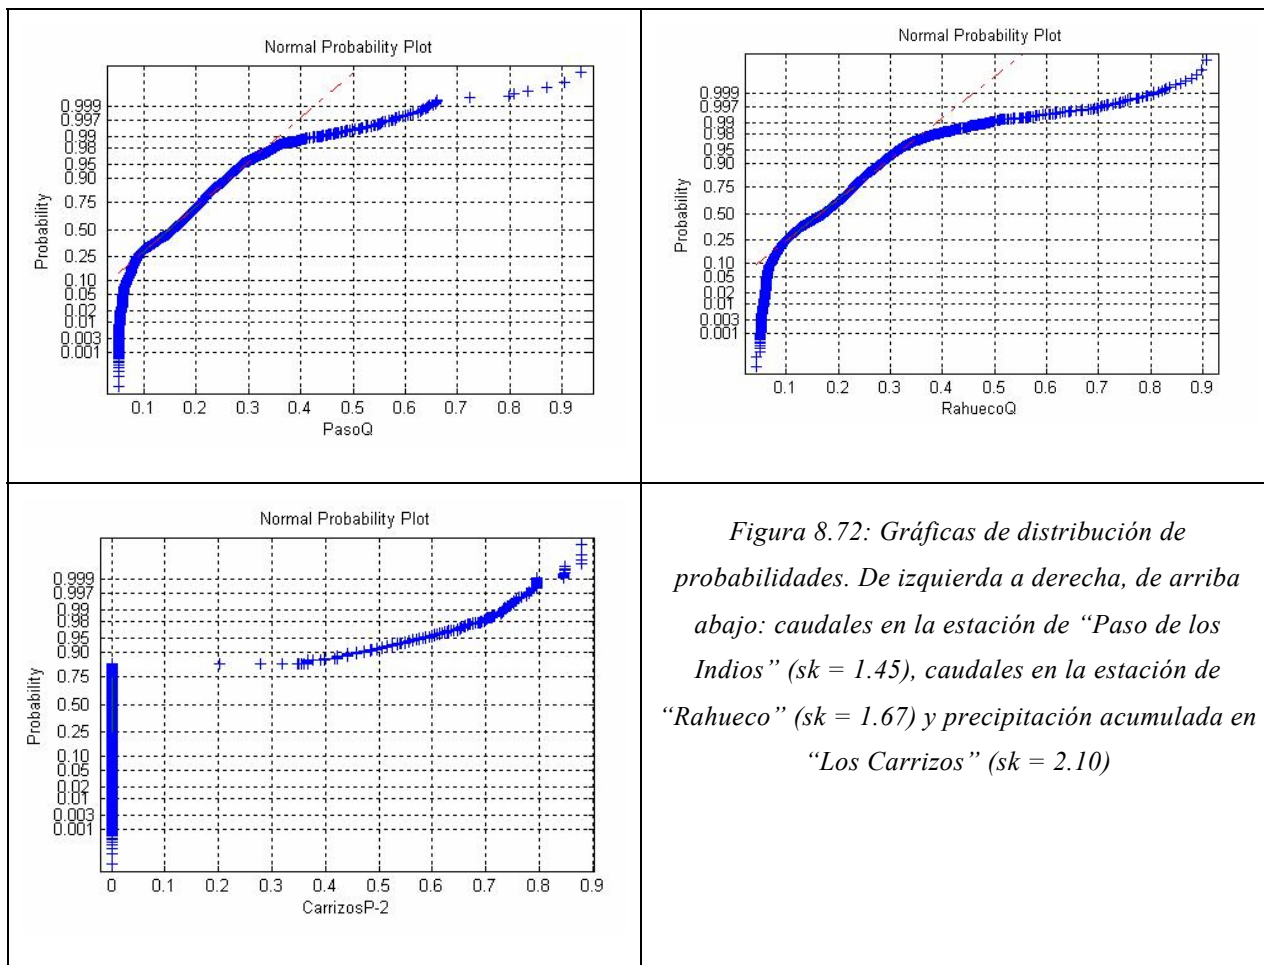


Figura 8.72: Gráficas de distribución de probabilidades. De izquierda a derecha, de arriba abajo: caudales en la estación de “Paso de los Indios” ($sk = 1.45$), caudales en la estación de “Rahueco” ($sk = 1.67$) y precipitación acumulada en “Los Carrizos” ($sk = 2.10$)

8.3.3 Determinación de los modelos

En esta aplicación se comparan tres tipos de modelos: una red neuronal artificial perceptrón multicapa (MLP), un modelo estocástico autorregresivo con variables exógenas (ARMAX) y un modelo modular donde se combina una red neuronal auto-organizativa con redes neuronales del tipo MLP (SOM-MLP).

Las variables de entrada a los modelos son las indicadas en la Tabla 8.3. Se analizan cuatro grupos diferentes de variables de entrada alternándose entre ellas (ver Tabla 8.4).

Tabla 8.4: Grupos de variables de entrada analizados

	Caudales en “Paso de los Indios” [m ³ /s]	Caudales en “Rahueco” [m ³ /s]	Precipitación acumulada diaria en “Los Carrizos” [mm]
Q _P Q _R P _C	SI	SI	SI
Q _P P _C	SI	-	SI
Q _P Q _R	SI	SI	-
Q _P	SI	-	-

Red Neuronal Artificial MLP

Para la búsqueda de la red óptima se siguen los pasos indicados en la introducción de este apartado. Se fijan las siguientes características de la red:

- *función de activación*: función log-sigmoidal $f(y) = \frac{1}{1 + e^{-y}}$ (0;1)
- *número de capas*: una capa oculta y una de salida
- *función de transformación de datos*: función García-Bartual, 2002 (ver Figura 8.71)
- *algoritmo de entrenamiento*: algoritmo BPNN (*BackPropagation learning algorithm*)
- *función objetivo*: función MSE (*Mean Squared Error* - error cuadrático medio)

Se analiza la influencia de estos elementos de la red sobre los resultados, mostrando poca variabilidad entre ellos. Cambiando el algoritmo de entrenamiento por el de *Levenberg Marquardt*, los resultados presentan mayor sobre-entrenamiento que con el algoritmo BPNN y su velocidad de entrenamiento es mucho menor. Cambiando la función objetivo por SSE (*Sum Squared Error* - suma de los errores al cuadrado) no se consiguen mejoras en los resultados, obteniendo, en general, coeficientes de *Nash* inferiores que con la función MSE. Se analizan también las redes con función de activación tangencial-sigmoidal, obteniendo resultados muy similares a los conseguidos con la función log-sigmoidal.

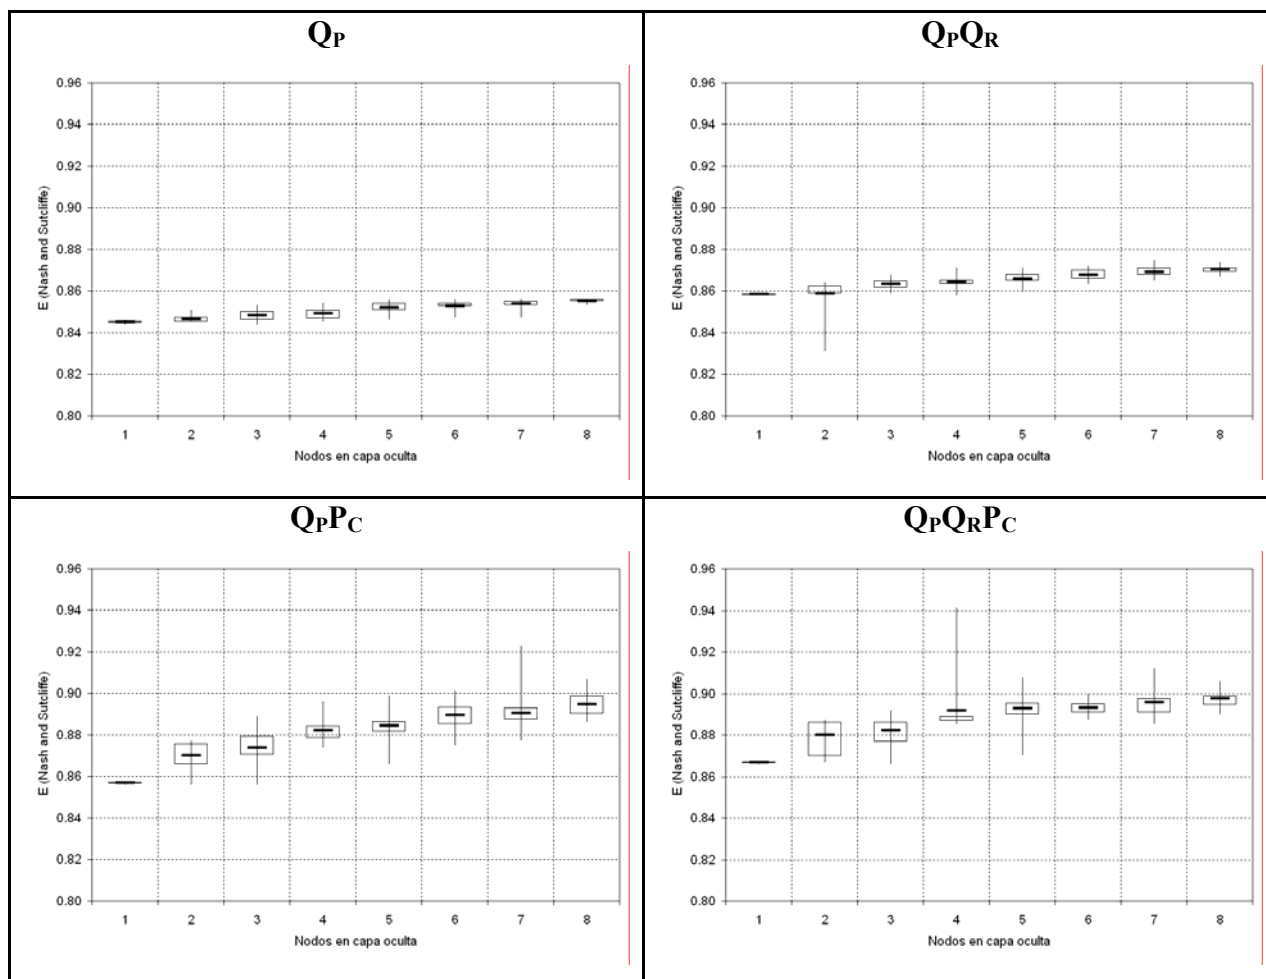
Para cada grupo de variables de entrada (Tabla 8.4) se varía la cantidad de nodos en la capa oculta entre 1 y 8 y para cada topología se entrena la red 20 veces, inicializando los pesos de manera aleatoria. Se calculan los coeficientes de *Nash and Sutcliffe* de los resultados de calibración, verificando, con la serie de verificación, que no se produzcan sobre-entrenamientos. Se obtienen las gráficas de cajas representadas en la Tabla 8.5, las cuales resumen los resultados de las calibraciones sin sobre-entrenamientos. Para cada nodo de la capa oculta se obtienen 20 diferentes coeficientes de *Nash*. En los gráficos de caja se grafica la media con la línea horizontal gruesa, los percentiles del 75% y 25% indicados por los extremos de las cajas y el máximo y mínimo indicados por los extremos superior e inferior de las líneas verticales.

Se puede observar en la Tabla 8.5 que las redes Q_P y $Q_P Q_R$ son muy estables, ya que las cajas no presentan mucha variabilidad entre los máximos y mínimos y las medias se mantienen dentro de los percentiles del 25% (cuartil inferior) y 75% (cuartil superior). Estas redes casi sufren sobre-entrenamientos. Los coeficientes de *Nash* se mantienen entre 0.84 y 0.86 para Q_P y entre 0.86 y 0.88 para $Q_P Q_R$, aumentando con la cantidad de nodos en la capa oculta y mostrando una pequeña mejora al incorporar los caudales en “Rahueco” (Q_R).

La incorporación de la precipitación ($Q_P P_C$) supone una considerable mejora en los resultados, llegando a coeficientes de *Nash* de 0.923 con 7 nodos en la capa oculta. A partir de 4 nodos en la capa oculta, los coeficientes de *Nash* se mantienen entre 0.88 y 0.9.

Por último, la incorporación de las tres variables ($Q_P Q_R P_C$) muestra un alto grado de sobre-entrenamientos a partir de 4 nodos en la capa oculta. Su mayor coeficiente de *Nash* (0.941) se obtiene con 4 nodos en la capa oculta.

Tabla 8.5: Variación del coeficiente de Nash and Sutcliffe en función de los nodos en la capa oculta para la series de calibración. Eliminando los entrenamientos con sobreentrenamientos



Para la elección de la red óptima hay que buscar la red con menor incertidumbre en los entrenamientos, esto es, que la variabilidad entre todos los entrenamientos sea la mínima y con el mayor coeficiente de *Nash* posible. Entre todos los casos la red $Q_P Q_R P_C$ con 8 nodos en la capa oculta es la red con mayor coeficiente de *Nash* y con muy poca variabilidad (máximo 0.906, percentil 75% = 0.899, media = 0.898, percentil 25% = 0.895, mínimo = 0.890). Esto quiere decir que el 50% de los valores están entre 0.895 y 0.899 (el 25% son menores a 0.895 y el otro 25% mayores a 0.899) y que la media no esta centrada, sino más cerca del cuartil superior.

Para este caso, de los 20 entrenamientos se produce un sobre-entrenamiento. La red elegida es la red con un *Nash* para el período de calibración igual a la media (0.898).

Haciendo un análisis de *prunning* se determina que, teniendo en cuenta la precipitación en el *día0* y *día-1* en “Los Carrizos”, la información que aportan los caudales en “Rahueco” para *t-1* y *t-2* no es significativa. Por lo tanto, las variables a utilizar son: *PCarrizos Día-1*, *PCarrizos Día0* y los caudales en “Paso de los Indios” para los tres pasos de tiempo considerados. Eliminando como variables de entrada *QRahueco t-2* y *QRahueco t-1* la red neuronal resultante (*Nash* = 0.897 para calibración) queda:




Figura 8.73: Red neuronal artificial MLP utilizada para predecir caudales en “Paso de los Indios” con una antelación de 24 horas. El intervalo de tiempo de los datos es de 6 horas

Modelo Autorregresivo de media móvil con variable exógena

Para la determinación de las variables de entrada al modelo estocástico, se realiza un procedimiento de prueba y error similar al llevado a cabo con el modelo de redes neuronales artificiales MLP. Para identificar el modelo ARMAX analizado se emplea la nomenclatura ARMAX(QPaso, PCarrizosDía0, PCarrizosDía-1, QRahueco). De las diferentes pruebas se destacan los siguientes resultados:

- Considerando un modelo autorregresivo sin variables exógenas (sólo caudales en “Paso de los Indios”), el mejor modelo es un AR(1), el cual tiene un coeficiente de *Nash* (0.731) similar al modelo de persistencia. Aumentando la cantidad de parámetros los resultados del modelo empeoran.
- Utilizando un modelo autorregresivo con la precipitación diaria en el día 0 en “Los Carrizos” como única variable exógena (ARMAX(1,1,0,0)), el coeficiente de *Nash* aumenta a 0.736.
- Agregando la variable de precipitación del día -1 (ARMAX(1,1,1,0)), el coeficiente de *Nash* aumenta a 0.74.

- Utilizando un modelo autorregresivo con los caudales en “Rahueco” como única variable exógena, se observa que, considerando cuatro intervalos de tiempo (ARMAX(1,0,0,4)), se consigue un coeficiente de *Nash* de 0.741.
- Combinando todas las variables de entrada, tanto la precipitación como los caudales en “Rahueco” (ARMAX(1,1,1,4)), el mejor modelo tiene un coeficiente de *Nash* de 0.746.

Dados estos resultados se decide utilizar el modelo ARMAX(1,1,1,4). Aunque la hipótesis de normalidad para las series de tiempo no se cumple, se construye el modelo de todas formas.

La forma analítica del modelo ARMAX (p, r₁, r₂, r₃, q) es la siguiente:

$$P_{t+1}^{pred} = \sum_{i=1}^p \phi_i P_{t-k-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} C_{t+1-L-i} + \sum_{i=0}^{r_2-1} \gamma_{i+1} C_{1_{t+1-L-i}} + \sum_{i=0}^{r_3-1} \lambda_{i+1} R_{t+1-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+1-i} \quad [8.15]$$

donde,

- P_t : Caudales en la estación de “Paso de los Indios”
- C_t : Precipitación en la estación pluviométrica de “Los Carrizos” para el día 0
- C_{1_t} : Precipitación en la estación pluviométrica de “Los Carrizos” para el día -1
- R_t : Caudales en la estación de “Rahueco”
- ε_i : Ruido del modelo con $N(0; \sigma_\varepsilon)$; $\varepsilon_i = P_{t+k}^{pred} - P_{t+k}$
- k : Horizonte de predicción
- p, r_1, r_2, r_3 y q : Órdenes del modelo
- $\phi, \gamma, \gamma_1, \lambda$ y θ : Parámetros del modelo. Éstos se calculan con el programa Matlab™ 7.0 que utiliza el método de los errores de predicción
- L y J : Factores para C y R respectivamente, para considerar los diferentes desfases de tiempo

El término de media móvil se fija a cero para esta aplicación ($q = 0$).

El procedimiento de predicción es el siguiente:

$$\begin{aligned} P_{t+1}^{pred} &= \sum_{i=1}^p \phi_i P_{t-k+2-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} C_{t+1-L-i} + \sum_{i=0}^{r_2-1} \gamma_{i+1} C_{1_{t+1-L-i}} + \sum_{i=0}^{r_3-1} \lambda_{i+1} R_{t+1-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+1-i} \\ P_{t+2}^{pred} &= \sum_{i=1}^p \phi_i P_{t-k+3-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} C_{t+2-L-i} + \sum_{i=0}^{r_2-1} \gamma_{i+1} C_{1_{t+2-L-i}} + \sum_{i=0}^{r_3-1} \lambda_{i+1} R_{t+2-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+2-i} \\ P_{t+3}^{pred} &= \sum_{i=1}^p \phi_i P_{t-k+4-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} C_{t+3-L-i} + \sum_{i=0}^{r_2-1} \gamma_{i+1} C_{1_{t+3-L-i}} + \sum_{i=0}^{r_3-1} \lambda_{i+1} R_{t+3-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+3-i} \\ &\dots \\ P_{t+k}^{pred} &= \sum_{i=1}^{k-1} \phi_i P_{t+k-i}^{pred} + \sum_{i=1}^p \phi_i P_{t+1-i} + \sum_{i=0}^{r_1-1} \gamma_{i+1} C_{t+k-L-i} + \sum_{i=0}^{r_2-1} \gamma_{i+1} C_{1_{t+k-L-i}} + \sum_{i=0}^{r_3-1} \lambda_{i+1} R_{t+k-J-i} + \sum_{i=1}^q \theta_i \varepsilon_{t+k-i} + \varepsilon_{t+k} \end{aligned} \quad [8.16]$$

En las siguientes figuras se esquematizan los pasos para realizar una predicción a 1 día ($t+4$). Se dibujan con color azul las variables utilizadas como entrada al modelo y con rojo la predicción.

En el paso 1 se realiza la predicción a $t+1$ para luego, en el paso 2, utilizar este resultado como entrada y así hasta llegar al último paso.




Figura 8.74: Paso 1. Predicción a $t+1$ de los caudales en “Paso de los Indios”




Figura 8.75: Paso 2. Predicción a $t+2$ de los caudales en “Paso de los Indios”, utilizando la predicción realizada en el paso 1 como variable de entrada




Figura 8.76: Paso 3. Predicción a $t+3$ de los caudales en “Paso de los Indios”, utilizando la predicción realizada en el paso 2 como variable de entrada




Figura 8.77: Paso 4 y último. Predicción a $t+4$ de los caudales en “Paso de los Indios”, utilizando la predicción realizada en el paso 3 como variable de entrada

Modelo modular SOM-MLP

El modelo propuesto para este caso de estudio consiste de una red neuronal auto-organizativa (SOM) para la clasificación automática de los datos y un conjunto de redes neuronales perceptrón multicapa (MLP) para la modelación de cada subgrupo.

La tarea más importante ante este tipo de problemas es determinar cuál es la separación de datos que representa de mejor forma los diferentes fenómenos físicos de generación de escorrentía. Esta cuenca es torrencial con caudales medios bajos (300 m³/s), pero con caudales máximos muy altos (6,000 m³/s) y de respuesta muy rápida. La mayor parte del año los caudales del río varían muy suavemente, debido al derretimiento de la nieve y a lluvias débiles. Sólo en la época invernal se producen fuertes lluvias generando grandes escorrentías en el desagüe de la cuenca. Es importante poder determinar cuándo se está generando un episodio de este tipo para poder modelarlo de la mejor manera posible, ya que durante la mayor parte del año la generación de escorrentía es más previsible. Como se sabe, de análisis anteriores, que los caudales en “Paso de los Indios” dependen en gran medida de la precipitación en “Los Carrizos” en el *día0* y *día-1*, se considera que una separación de grupos en función de estos valores nos ayudará a determinar cuándo nos encontramos en un episodio de precipitación fuerte, mediano, bajo o nulo.

Por lo tanto, el objetivo es separar los datos en 4 grupos que permitan distinguir si el episodio de lluvias es fuerte, medio y bajo.

Modelo de Clasificación (SOM)

Para determinar los episodios de precipitación utilizamos la variable de precipitación en “Los Carrizos” en los días 0 y -1. Estas variables se escalan entre 0 y 1 para introducirlas en la red de Kohonen (SOM).

La red SOM (ver Figura 8.78) elegida es una red con un mapa de salida compuesto por 4 nodos, donde cada uno de ellos representa una situación hidrológica distinta. La estructura de las redes MLP utilizadas para la modelación variará según el grupo a modelar.




Figura 8.78: Red auto-organizativa (SOM) utilizada para la clasificación de los datos de entrada

En la Figura 8.79 se puede comprobar la distinción entre los tres grupos, distribuyéndose de la siguiente forma:

Grupo 1: Episodio con grandes precipitaciones (612 datos)

Grupo 2: Episodio con precipitaciones bajas en aumento (460 datos)

Grupo 3: Episodio con precipitaciones bajas en descenso (448 datos)

Grupo 4: Episodios sin precipitaciones o con precipitaciones muy bajas (6,119 datos)




Figura 8.79: Distribución de las variables por grupo

La red auto-organizativa utilizada se encarga de determinar, en el instante de realizar una predicción a 1 día, en qué tipo de episodio nos encontramos. En la Figura 8.80 se puede ver un ejemplo de la separación realizada para el evento del 2006.




Figura 8.80: Ejemplo de separación de grupos para el evento del 2006 en “Paso de los Indios”

Para la determinación de los modelos a utilizar para cada grupo se realiza el mismo procedimiento explicado en la introducción para determinar el modelo MLP.

Se puede observar en la Tabla 8.6 que los grupos 1 y 2 son los que menor coeficiente de *Nash* tienen. Estos dos grupos indican que la cuenca se encuentra en una situación de eventos tanto fuertes como débiles, respectivamente. En cambio los grupos 3 y 4 reflejan ya la terminación de un evento y la situación normal sin evento, por lo tanto resultan más fáciles de modelar.

En los primeros tres grupos las variables de entrada son las mismas que en el caso del modelo MLP explicado anteriormente, en cambio en el grupo 4, como la precipitación no tiene casi influencia sobre los caudales, siendo ésta muy baja o nula, no se incorporan las dos variables de precipitación en “Los Carrizos”

Finalmente, de los resultados obtenidos en la Tabla 8.6, las redes neuronales artificiales para modelar cada grupo son las indicadas en la Figura 8.81. Para el grupo 1 se utiliza una red MLP con 8 nodos en la capa oculta con un coeficiente de *Nash* de 0.83. Para el grupo 2 se elige una red con 7 nodos en la capa oculta y un coeficiente de *Nash* para el entrenamiento de 0.927. En el caso del grupo 3 se utilizan 8 nodos con un coeficiente de 0.979 y finalmente para el grupo 4, 8 nodos en la capa oculta y un coeficiente de *Nash* de 0.991. El modelo modular elegido tiene un coeficiente de *Nash and Sutcliffe* de 0.911 para el entrenamiento.

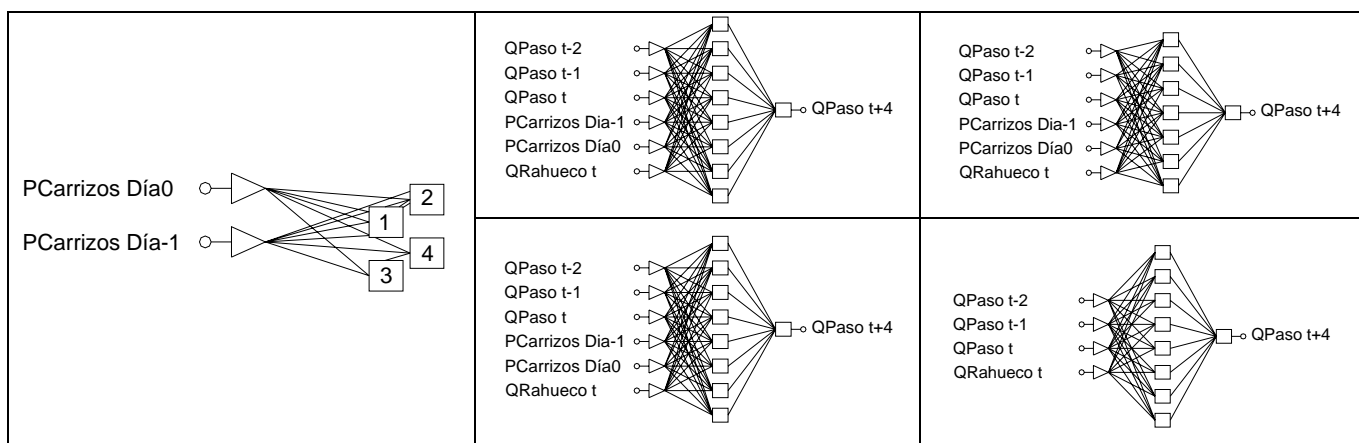
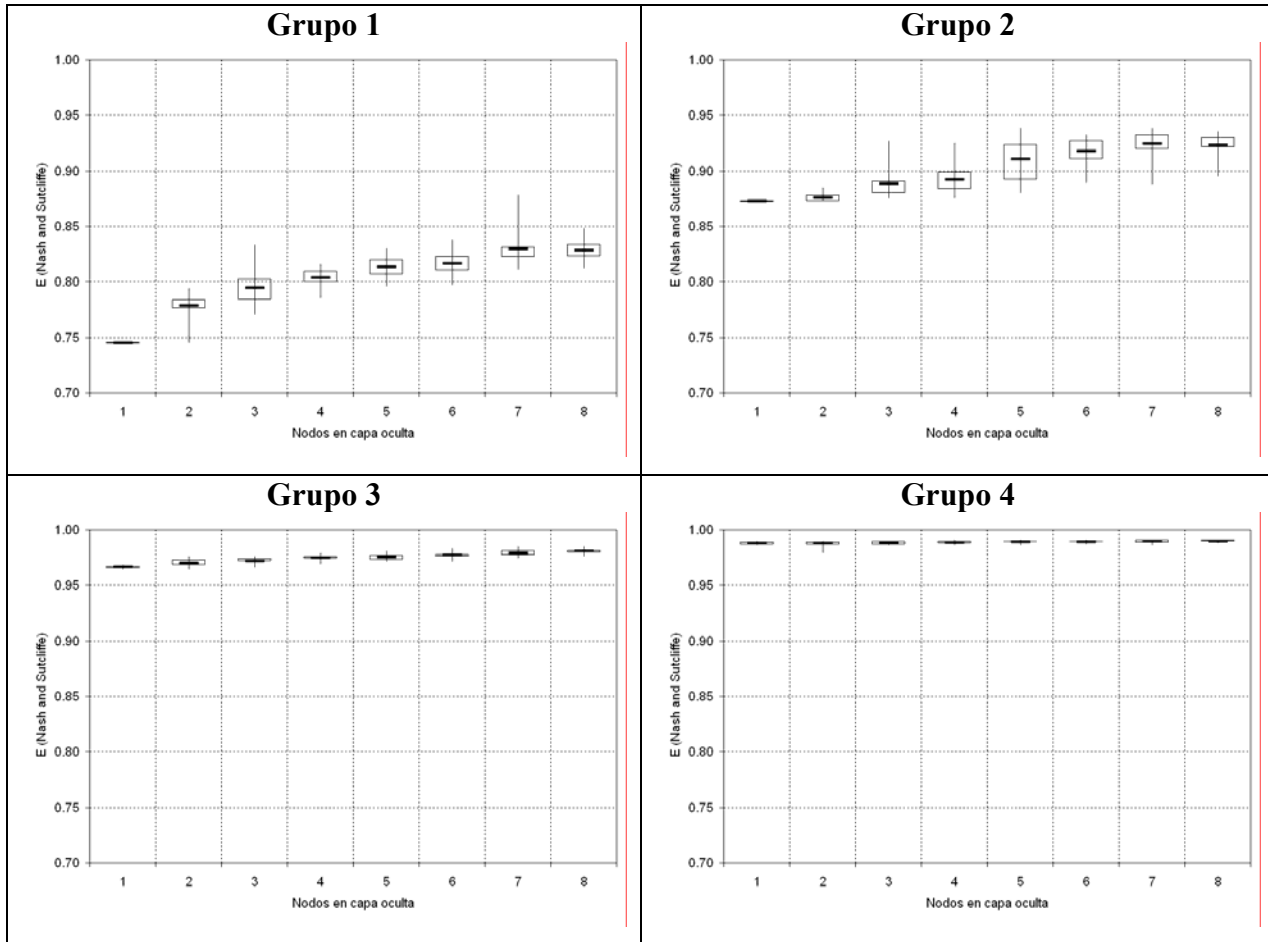


Figura 8.81: Modelo modular SOM-MLP, para predicción de caudales a 1 día en “Paso de los Indios”

Tabla 8.6: Análisis de cantidad de nodos en la capa oculta para el modelo MLP de cada grupo, para el entrenamiento, sin considerar los casos de sobreentrenamiento



8.3.4 Análisis de resultados

Análisis global

En la Figura 8.82 se muestran los índices estadísticos calculados para analizar los resultados de los tres modelos descritos anteriormente y el modelo de persistencia (*Naive*) ($Q_{i+4}^{pred} = Q_i^{obs}$), el cual se utiliza para la comparación y para obtener unos límites mínimos de los coeficientes.

El error medio (*EM*) es una medida que no indica de ninguna forma la bondad del modelo, ya que un modelo con error medio igual a cero puede ser un modelo cuyo resultado sea una constante igual a la media.

La distribución del error absoluto relativo (*ARE*) se puede analizar observando la tabla *TSx*, la cual indica el porcentaje de valores cuyo ARE sea mayor a un umbral *x*. Por tanto, se puede decir que el 51% de las predicciones del modelo SOM-MLP tienen un *ARE* superior a 0.03, en el modelo ARMAX un 80% y en el modelo MLP, sólo un 45% de los valores presentan un ARE superior al 0.03.

El coeficiente *AIC* (*Akaike criterion*) da una idea de la relación entre la cantidad de parámetros del modelo y la *RMSE* (raíz del error cuadrático medio). Un valor más pequeño de éste indica un mejor modelo. Por lo tanto, un modelo con igual *RMSE* pero con menos parámetros, se considera más apropiado según este criterio. En este caso comparando el modelo MLP y SOM-MLP, ambos con comportamientos globales muy similares, se puede decir que según este indicador el modelo MLP sería más apropiado, con un coeficiente *AIC* menor y un *RMSE* también menor.

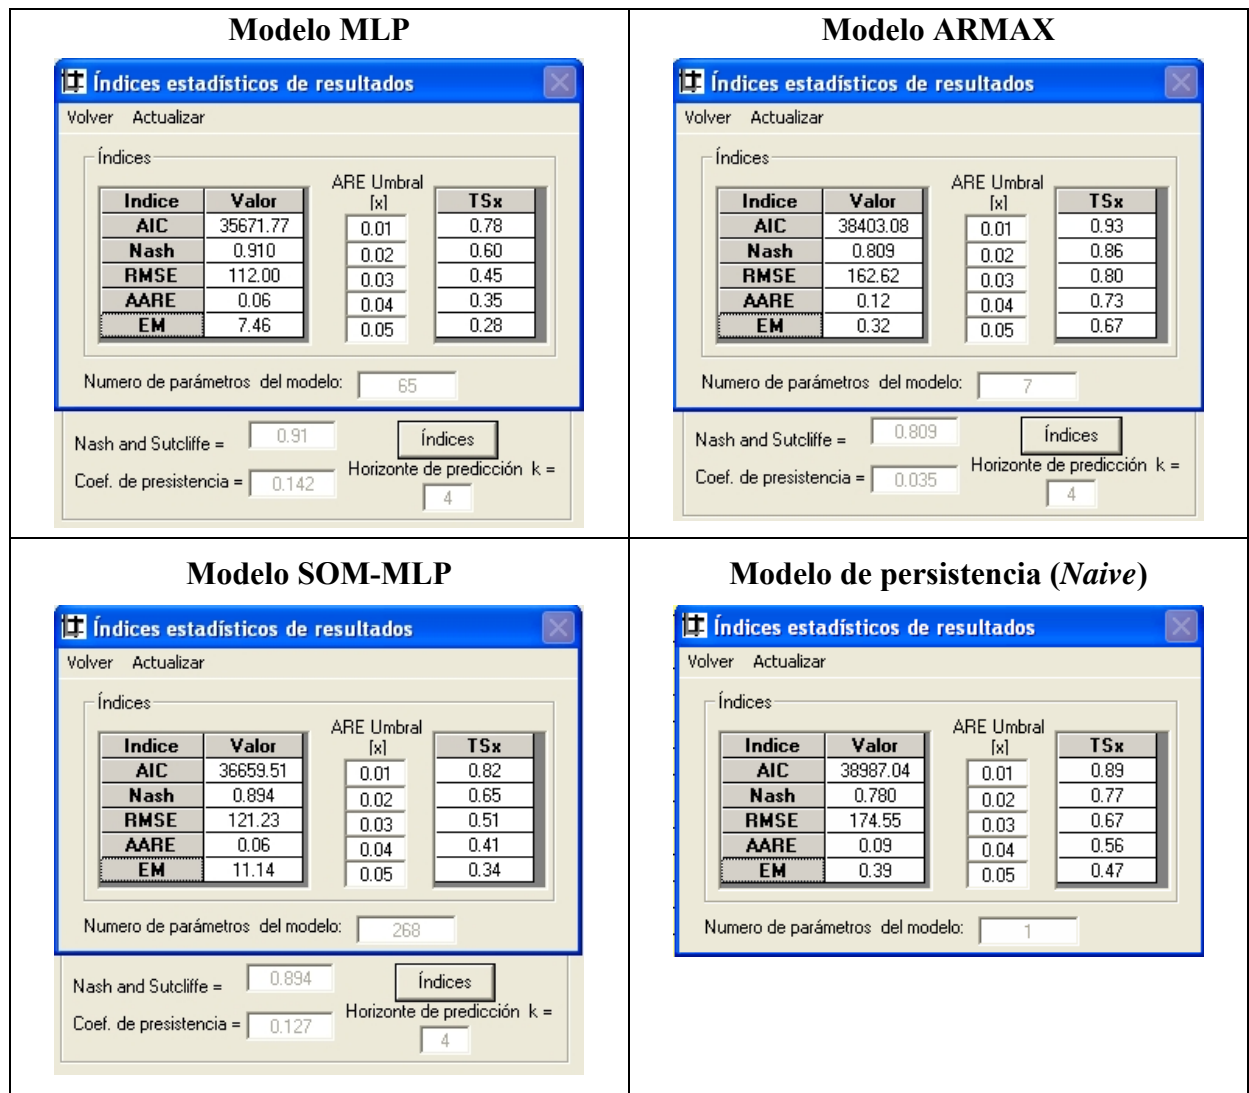


Figura 8.82: Índices estadísticos de los resultados de validación para los tres modelos analizados

El coeficiente *Nash* da una idea global de la bondad del modelo, teniendo como objetivo el modelo perfecto con un valor igual a 1. Se puede observar que los modelos MLP y SOM-MLP tienen un coeficiente *Nash* de 0.91 y 0.894 respectivamente y un coeficiente de persistencia de 0.142 y 0.127, indicando nuevamente la superioridad del modelo MLP frente al SOM-MLP.

En todos los casos analizados los coeficientes de fiabilidad superan a los del modelo de persistencia, lo cual es un requerimiento mínimo que debe cumplir cualquier tipo de modelo de predicción.

Análisis de tiempos

Para poder analizar el desfase de los caudales predichos con los caudales observados se calcula la correlación cruzada entre ellos, obteniendo los resultados que se muestran en la Figura 8.83. El coeficiente de *Nash* para un desfase igual a 0 corresponde al comportamiento actual del modelo, la serie de tiempos de los caudales predichos se desplaza en el tiempo con respecto a la serie de caudales observados, calculando en cada desfase un coeficiente nuevo. El tiempo de desfase con el mayor coeficiente de *Nash* es una expresión del desfase medio del modelo [Conway et al., 1998; De Vos y Rientjes, 2005].

Según este análisis se puede decir que el modelo ARMAX tiene un desfase medio de 24 horas, igual al horizonte de predicción. Esta característica es muy similar al modelo de persistencia, con un coeficiente de *Nash* muy cercano a la unidad y un desfase igual al horizonte de predicción.

Por otro lado, el modelo SOM-MLP tiene un desfase medio de 6 horas y el modelo MLP de 12 horas, lo cual quiere decir que los caudales predichos a 24 horas con estos modelos conllevan un retardo medio en el tiempo de entre 6 y 12 horas.




Figura 8.83: Correlación cruzada entre los caudales predichos y los observados, para diferentes modelos

Análisis de picos

El índice *PCF* (*Peak Flow Criteria*) refleja la eficacia de los modelos para predecir los picos de caudales. En la Figura 8.84 se han seleccionado una cantidad de picos determinada para poder calcular este coeficiente para cada uno de los modelos. El modelo con menor valor de *PCF* es el MLP, como se puede ver en la Tabla 8.7.

Tabla 8.7: Coeficientes *PCF* de los resultados de validación

	PFC
MLP	31.21
SOM-MLP	32.15
ARMAX	33.91
Naive	34.15




Figura 8.84: Elección de los picos, en la serie de validación, para el cálculo del coeficiente *PCF*

Análisis por grupos

En este análisis se comparan los coeficientes de *Nash* de los resultados de validación para cada uno de los grupos del modelo SOM-MLP. Se utiliza la misma separación de grupos para dividir los resultados del modelo MLP y ARMAX y, de este modo, analizar también el comportamiento de los modelos en cada uno de estos grupos.

Tabla 8.8: Análisis de los coeficientes de *Nash* para cada uno de los grupos del modelo modular. Validación

	Validación			
	Coficiente de Nash and Sutcliffe			
Grupo	ARMAX	MLP	SOM-MLP	Cantidad
1	0.577	0.789	0.772	420
2	0.832	0.898	0.759	240
3	0.936	0.974	0.975	228
4	0.944	0.985	0.978	2880
Global	0.809	0.91	0.894	3768

La Tabla 8.8 indica el buen comportamiento del modelo MLP en cada uno de los grupos, mostrando una superioridad frente a los otros dos modelos. Aunque en la etapa de calibración (ver Tabla 8.9) el modelo SOM-MLP muestra mejor comportamiento que el MLP, en la etapa de validación estos resultados no se repiten.

Tabla 8.9: Análisis de los coeficientes de Nash para cada uno de los grupos del modelo modular. Calibración

Grupo	Calibración			
	Coeficiente de Nash and Sutcliffe			
	ARMAX	MLP	SOM-MLP	Cantidad
1	0.535	0.807	0.83	612
2	0.616	0.867	0.927	460
3	0.866	0.958	0.979	448
4	0.962	0.989	0.991	6119
Global	0.764	0.897	0.897	7639

Análisis de la incertidumbre

Es importante, además de analizar los índices de fiabilidad de los resultados, realizar un análisis de la incertidumbre general de cada uno de los modelos. Por lo tanto se calculan los intervalos de confianza del 90%, utilizando la función de distribución bivariada meta-gaussiana [Kelly y Krzysztofowicz, 1997] (ver Figura 8.85) con las mismas funciones de densidad de probabilidad marginales para todos los modelos (en este caso lognormales). Los intervalos de confianza se calculan obteniendo los cuantiles del 0.05 y 0.95 de la función de distribución de los caudales observados condicionados a los predichos. En el Apéndice A se muestran los parámetros para las funciones de distribución de cada uno de los modelos.




Figura 8.85: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza

En la Figura 8.86 se muestran las curvas de igual probabilidad de la función de distribución de probabilidades bivariada junto con las líneas de los cuantiles del 5% y 95%, las cuales indican que entre ambas líneas se encuentran los valores con un 90% de probabilidad.




Figura 8.86: Función de distribución bivariada utilizada para el cálculo de los intervalos de confianza junto con las líneas de cuantiles del 5% y 95%

Se calculan los intervalos de confianza con los datos de calibración y luego se validan con los datos de validación comprobando que dentro de los límites se contengan aproximadamente el 90% de los resultados.

En la Figura 8.87 se muestra la evolución de los errores de predicción a lo largo de los diferentes caudales predichos. Las líneas rojas marcan el intervalo del 90% de confianza de los resultados del modelo estocástico ARMAX, las celestes marcan los límites del modelo MLP y el área gris, el del modelo SOM-MLP.

Se puede ver que los modelos SOM-MLP y MLP tienen los intervalos de confianza más estrechos, lo que supone un mejor rendimiento que el del modelo ARMAX, cuyo límite superior se desplaza muy por encima de los otros modelos. El porcentaje medio de error del modelo MLP para cualquier caudal tiene un 90% de probabilidad de ser inferior a un 18.3% y superior a un -16.8%. Por otro lado el modelo SOM-MLP tiene una media porcentual de errores de +16.5% y -17.1%. Esto quiere decir que, con un 90% de probabilidad, los caudales predichos con el modelo SOM-MLP no sobrestimarán a los caudales observados en más de un 16.5% y no los subestimarán en menos de un 17.1%.




Figura 8.87: Errores de predicción en función de los caudales predichos para los intervalos de confianza del 90% en los tres modelos

En la Figura 8.88 se muestran los errores de predicción de los tres modelos con una probabilidad del 50%. Los dos modelos de redes neuronales artificiales, MLP y SOM-MLP, tienen una media del error muy cercana a cero (-1%, y -2% respectivamente). También se observa que para el modelo ARMAX la línea roja que indica los errores con un 50% de probabilidad, se aleja de la línea recta horizontal, la cual representa el error igual a cero.




Figura 8.88: Errores de predicción en función de los caudales predichos para el cuantil del 50% en los tres modelos

Cálculo de los intervalos de confianza del modelo ARMAX

Se calculan los intervalos de confianza del modelo ARMAX según el Apartado 6.3:

$$P_{t+k} = P_{t+k}^{pred} \pm \mu_{\alpha/2} \left[\left(\sum_{j=0}^{k-1} v_j^2 \right) \sigma_C^2 + \left(\sum_{j=0}^{k-1} \eta_j^2 \right) \sigma_R^2 + \left(\sum_{j=1}^k \psi_j^2 \right) \sigma_\varepsilon^2 \right]^{1/2}$$

[8.17]

donde,

- P_t caudales en la estación de “Paso de los Indios”
- C_t precipitación en la estación pluviométrica de “Los Carrizos”
- R_t caudales en la estación de “Rahueco”
- σ_C desvío estándar de la precipitación en “Los Carrizos” (11.42)
- σ_R desvío estándar de los caudales en “Rahueco” (251.17)
- σ_ε desvío estándar de los errores del modelo (161.7)

Para poder aplicar esta metodología hay que demostrar que las series de caudales en “Rahueco”, de precipitación en “Los Carrizos” y de los errores del modelo son independientes y que siguen una distribución normal. Estas condiciones de normalidad no se cumplen, como se puede comprobar en la Figura 8.72.

El coeficiente de asimetría de los errores es de -9.14, lo cual no está dentro de los límites de asimetría ($-0.065 < S_k < 0.065$) para considerar, con un 90% de probabilidad, que su distribución sea normal. Según la Figura 8.89 la distribución de los errores no es normal, alejándose en los extremos de la línea punteada roja.




Figura 8.89: Gráfica a escala normal para determinar la normalidad de la serie de los errores del modelo




Figura 8.90: Correlaciones cruzadas de la serie de los errores del modelo con la de caudales en “Rahueco” (amarillo) y la de precipitación en “Los Carrizos” (morado)

De la Figura 8.90 se puede deducir que los errores del modelo son independientes con respecto a las otras dos series de tiempo. Por otro lado, se puede observar también una pequeña correlación entre la precipitación y los caudales en “Rahueco” que provoca que estas series no sean independientes.

Aunque las hipótesis principales para aplicar esta metodología no se cumplan, la aplicamos de todas formas para analizar los resultados.




Figura 8.91: Correlación cruzada entre la serie de los caudales en “Rahueco” y la de precipitación en “Los Carrizos” (morado). Con azul se muestra la auto-correlación de los caudales en “Rahueco”

Para el cálculo de los intervalos de confianza del modelo ARMAX es necesario encontrar los coeficientes ν , η y ψ resolviendo el siguiente sistema de ecuaciones:

$$\frac{\gamma(B)}{\phi(B)} = \nu(B) \Rightarrow \gamma(B) = \nu(B)\phi(B)$$

$$\frac{\lambda(B)}{\phi(B)} = \eta(B) \Rightarrow \lambda(B) = \eta(B)\phi(B)$$

$$\frac{\theta(B)}{\phi(B)} = \psi(B) \Rightarrow \theta(B) = \psi(B)\phi(B)$$

donde,

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3$$

$$\gamma(B) = 0 + 0B + 0B^2 + 0B^3 + \gamma_4 B^4 + 0B^5 + 0B^6 + 0B^7 + \gamma_8 B^8$$

$$\lambda(B) = 0 + 0B + 0B^2 + 0B^3 + \lambda_4 B^4 + \lambda_5 B^5 + \lambda_6 B^6 + \lambda_7 B^7$$

$$\theta(B) = 1 \Rightarrow 1 = \psi_0$$

Los sistemas de ecuaciones a resolver son:

$$\begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ -\phi_1 & 1 & 0 & 0 & 0 & 0 \\ -\phi_2 & -\phi_1 & 1 & 0 & 0 & 0 \\ -\phi_3 & -\phi_2 & -\phi_1 & 1 & 0 & 0 \\ 0 & -\phi_3 & -\phi_2 & -\phi_1 & 1 & 0 \\ 0 & 0 & -\phi_3 & -\phi_2 & -\phi_1 & 1 \\ 0 & 0 & 0 & -\phi_3 & -\phi_2 & -\phi_1 \\ 0 & 0 & 0 & 0 & -\phi_3 & -\phi_2 \\ 0 & 0 & 0 & 0 & 0 & -\phi_3 \end{bmatrix} \begin{bmatrix} \nu_0 \\ \nu_1 \\ \nu_2 \\ \nu_3 \\ \nu_4 \\ \nu_5 \\ \nu_6 \\ \nu_7 \\ \nu_8 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ \gamma_4 \\ 0 \\ 0 \\ 0 \\ \gamma_8 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ -\phi_1 & 1 & 0 & 0 & 0 \\ -\phi_2 & -\phi_1 & 1 & 0 & 0 \\ -\phi_3 & -\phi_2 & -\phi_1 & 1 & 0 \\ 0 & -\phi_3 & -\phi_2 & -\phi_1 & 1 \\ 0 & 0 & -\phi_3 & -\phi_2 & -\phi_1 \\ 0 & 0 & 0 & -\phi_3 & -\phi_2 \\ 0 & 0 & 0 & 0 & -\phi_3 \end{bmatrix} \begin{bmatrix} \eta_0 \\ \eta_1 \\ \eta_2 \\ \eta_3 \\ \eta_4 \\ \eta_5 \\ \eta_6 \\ \eta_7 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ \lambda_4 \\ \lambda_5 \\ \lambda_6 \\ \lambda_7 \end{bmatrix}$$

Obteniendo la suma de los coeficientes al cuadrado, los intervalos de confianza quedan:

$$P_{t+k} = P_{t+k}^{pred} \pm \mu_{\alpha/2} \left[3.45 \times 10^{-5} \sigma_{\hat{C}_{t+k}}^2 + 0.054 \sigma_{R_{t+k}}^2 + \sigma_{\varepsilon}^2 \right]^{1/2}$$

[8.18]

$$P_{t+k} = P_{t+k}^{pred} \pm \mu_{\alpha/2} 162.75$$

[8.19]

Para un 90% de probabilidad, $\mu_{\alpha/2} = 1.64$, entonces las predicciones de caudales en “Paso de los Indios” tiene un intervalos de $\pm 266.91 \text{ m}^3/\text{s}$.

$$P_{t+k} = P_{t+k}^{pred} \pm 266.91$$

[8.20]




Figura 8.92: Intervalos de confianza calculados con la metodología propuesta (rojo) y según metodología de los modelos estocásticos ARMAX (verde)




Figura 8.93: Intervalos de confianza calculados con la metodología propuesta (rojo) y según metodología de los modelos estocásticos ARMAX (verde) en escala logarítmica




Figura 8.94: Errores de predicción en función de los caudales predichos, para los límites de confianza del 90%, calculados con la metodología propuesta, y en verde, según metodología de los modelos estocásticos ARMAX

Como se indica en la Figura 8.94, los intervalos de confianza (línea verde) son constantes para todos los caudales predichos y, si se comparan con la distribución de la Figura 8.92 y Figura 8.93, no representan de manera satisfactoria los intervalos de confianza a lo largo de todo el espacio. La distribución de los errores de predicción varía según la magnitud del error predicho.

Análisis gráfico

En las figuras de las páginas siguientes se representan los resultados gráficos de los tres modelos para las series de validación.




Figura 8.95: Predicción a 1 día del modelo ARMAX para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior




Figura 8.96: Predicción a 1 día del modelo MLP para el periodo de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior

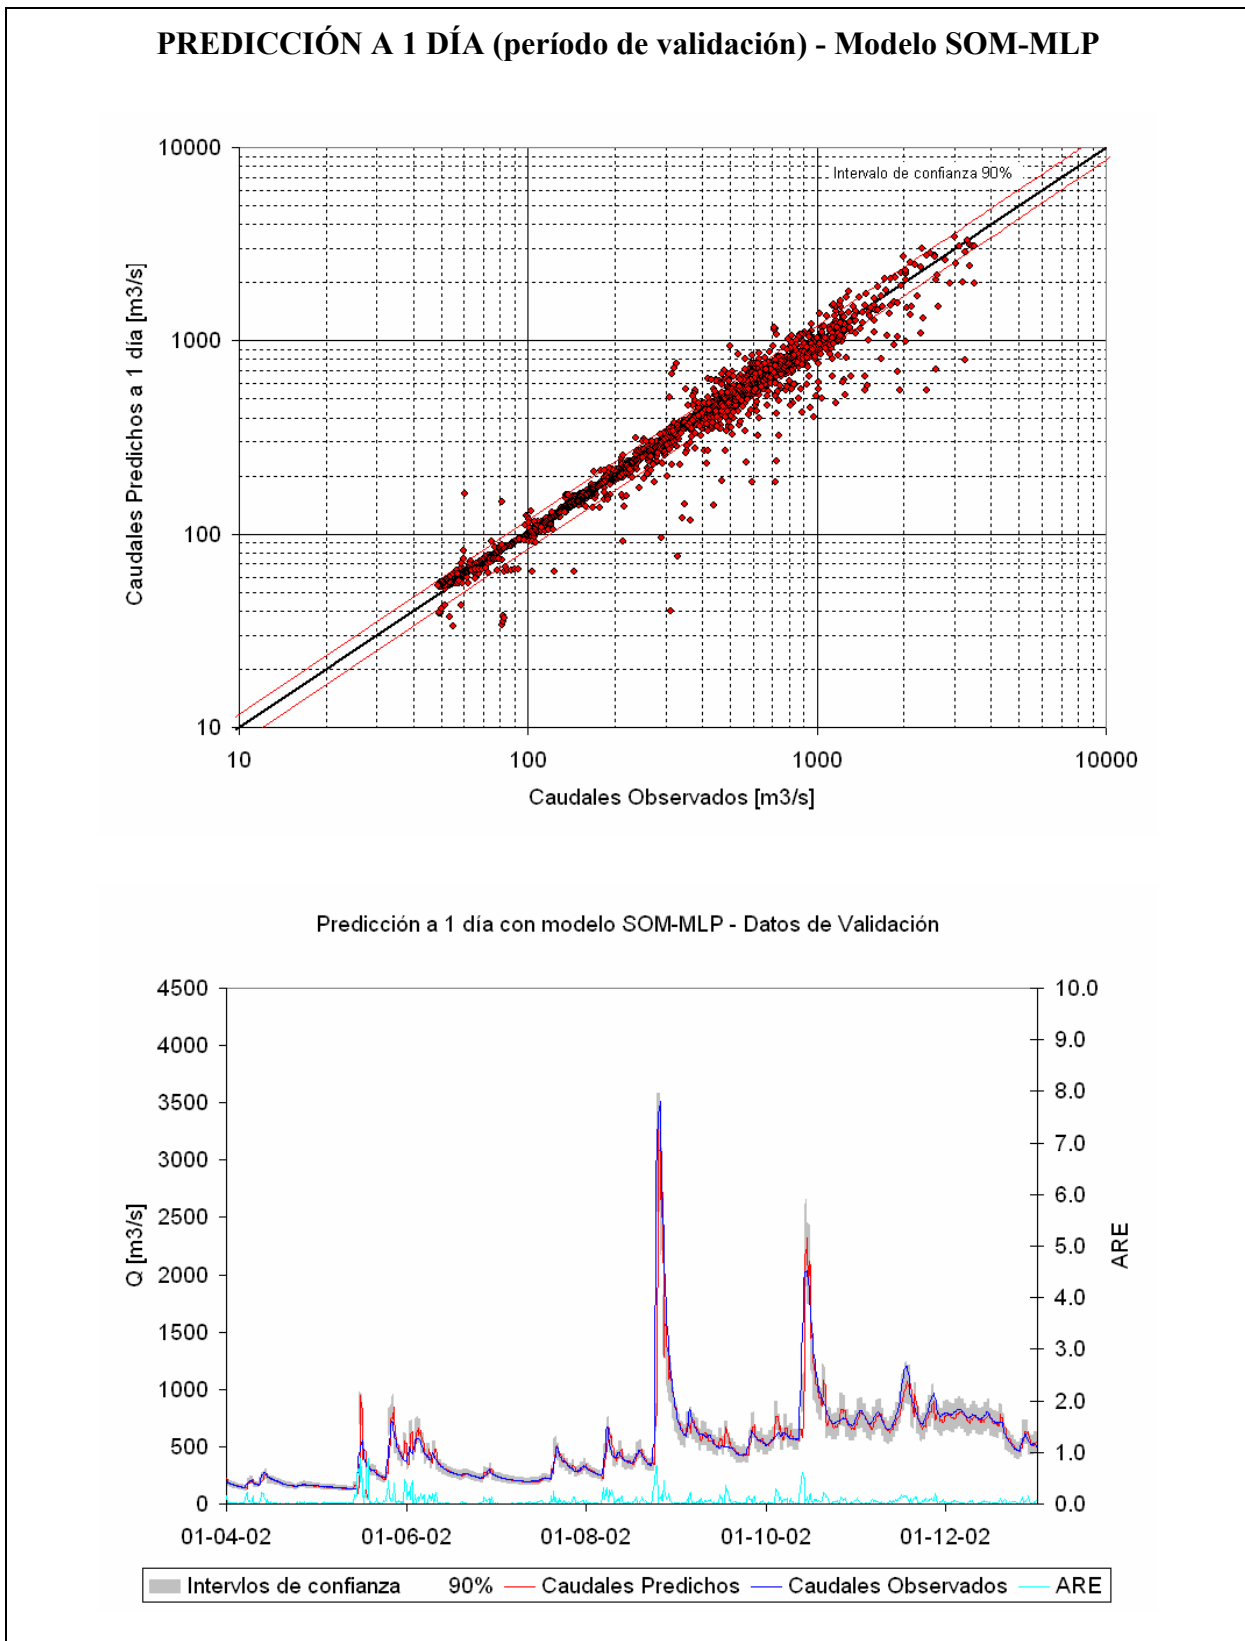


Figura 8.97: Predicción a 1 día del modelo SOM-MLP para el período de validación. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior

8.3.5 Conclusiones

Se han analizado tres modelos de características muy diferentes. El modelo estocástico ARMAX lineal, un MLP y un modelo modular SOM-MLP. Para el análisis de los resultados se han tenido en cuenta seis aspectos diferentes (análisis global, de tiempos, de los picos, por grupos, de incertidumbre y gráficos) para obtener una visión general del comportamiento de los modelos.

De los resultados obtenidos se pueden destacar las siguientes conclusiones:

- El modelo ARMAX presenta un comportamiento muy inferior frente a los dos modelos de redes neuronales artificiales analizados. Se puede demostrar este hecho en todos los análisis realizados.
- El modelo MLP muestra una pequeña superioridad frente a los otros dos modelos, tanto en la determinación de los picos como en la distribución general de los errores.
- Las predicciones del modelo SOM-MLP muestran menos desfase global frente a los caudales observados, sufriendo un retardo general de aproximadamente 6 horas, mientras que en el modelo MLP es de 12 horas.
- El análisis de la incertidumbre de los modelos es muy importante para la elección del modelo a utilizar en un sistema de predicción en tiempo real. De él se desprende que los dos modelos de redes neuronales tienen un comportamiento muy similar.
- El modelo MLP es muy eficaz para predecir caudales en cualquier situación hidrológica, demostrando una ligera superioridad, en los resultados de validación, frente a los modelos expertos que componen el SOM-MLP.
- Los grupos 1 y 2 son los que peor se comportan en el modelo modular. Una mejora de estos dos grupos puede provocar que el modelo modular destaque sobre el MLP. La detección de este problema proporciona una ventaja muy importante en el uso del modelo modular.

La separación de los grupos del modelo modular aporta información de la situación en que se encuentra la cuenca a la hora de realizar la predicción, pero no de la situación futura de la misma. Puede ser interesante realizar una separación de grupos que permita conocer de antemano dicha situación futura.

El análisis geomorfológico e hidrológico de la cuenca y de los datos es un punto clave en la elección de las variables de entrada a la red. Esta elección es la más importante del proceso, pues determina la calidad de los resultados del modelo de predicción.

Se debe proceder con una metodología sistemática, como la realizada en esta aplicación, para la construcción de los modelos de redes neuronales. Esto permite establecer una comparación entre modelos que sólo dependa de su habilidad para la predicción y no de la forma de calibrar o de la elección de sus elementos.

CONCLUSIONES Y DISCUSIONES

Capítulo 9

Capítulo 9

9 Conclusiones y discusiones

En esta tesis se han planteado varios objetivos que puedan contribuir al estado del arte de la predicción hidrológica con redes neuronales artificiales. Durante el proceso han surgido diferentes conclusiones y nuevas posibles líneas de investigación para la mejora de las ideas planteadas. En los siguientes puntos se enumeran las ideas y conclusiones obtenidas:

- Es muy importante a la hora de construir un modelo de predicción identificar qué proceso físico se va a modelar, dependiendo de los datos disponibles. Por ejemplo, si se dispone de datos de caudales en estaciones aguas arriba del punto a predecir, el modelo deberá ser capaz de modelar la propagación de una onda en cauce y no el proceso de transformación de lluvia escorrentía. El problema de utilizar sólo estos datos es que el horizonte máximo de predicción dependerá del tiempo que tarda la onda de crecida en viajar de la estación aguas arriba a la estación donde se realizan las predicciones. La incorporación de la precipitación medida en las partes altas de la cuenca prolonga el horizonte de predicción pero complica el modelo. En tal caso éste debe ser capaz de modelar todos los procesos de transformación de lluvia escorrentía y de propagación en cauce. Y para ello es necesario conocer los tiempos de respuesta de la cuenca, analizando tanto la geomorfología de la cuenca como los datos numéricos de precipitación y caudal. Siguiendo las recomendaciones de esta tesis, se ha utilizado este tipo de modelo en aplicaciones reales en varias cuencas mediterráneas española (rambla del Poyo, río Vernissa, embalse de Beniarrés y rambla de Benipila) [Francés et al., 2008] conectadas con sistemas automáticos de adquisición de datos llegando a resultados muy prometedores.
- El elemento más importante de una RNA, que hace que ésta sea lo suficientemente eficiente, es la capa de entrada. En este punto, donde se eligen las variables de entrada, es donde es necesario prestar más atención. En la metodología propuesta, para la construcción de un modelo de RNA, se plantea una solución muy acertada para la elección de cada uno de los elementos más importantes que componen a una red, dando ideas para la elección de las variables de entrada y metodologías sistemáticas para los demás elementos.

- Se ha detectado en las aplicaciones realizadas que el modelo simple MLP es capaz de modelar todos los procesos físicos que se producen en la cuenca obteniendo muy buenos resultados, igualando a los generados con el modelo modular SOM-MLP, donde se modelan por separado cada uno de los procesos identificados.
- Para obtener un mejor modelo modular se requiere una cantidad de datos muy superior a la necesaria para el modelo simple MLP. Esto es debido a que cada grupo necesita más datos para poder generalizar e interpretar mejor el proceso a modelar, sin llegar a sobre-entrenamientos. Por lo tanto para elegir la cantidad de grupos del modelo SOM-MLP hay que tener en cuenta los procesos físicos que se quieran modelar y la cantidad de datos disponibles.
- Una característica que aventaja al modelo modular sobre los demás es la posibilidad de detectar las situaciones que hacen que los resultados globales no sean lo óptimos. Para resolver un problema es necesario encontrarlo primero, y éste modelo permite hacerlo.
- La metodología propuesta para el cálculo de la incertidumbre de las predicciones ha resultado ser de gran utilidad. Es susceptible de mejoras cambiando la metodología del cálculo de la función de distribución bivariada, mediante la incorporación de la variabilidad del coeficiente de correlación para cada caudal predicho.

Como futuras líneas de investigación se propone:

- Profundizar en el cálculo de la incertidumbre desarrollando metodologías que se ajusten mejor a la distribución de los datos.
- Analizar en profundidad la influencia de cada uno de los elementos de la RNA sobre los resultados, y centrarse en los más importantes para mejorarlos. En esta tesis se considera que la elección de las variables de entrada es el paso más importante para obtener una red de buena calidad. Una vez elegidas éstas, se varía la cantidad de nodos en la capa oculta hasta obtener el resultado óptimo. Es importante también profundizar en la elección de la serie de datos utilizada para la calibración y las funciones de transformación de los datos de entrada.
- Analizar la eficiencia del filtro de Kalman utilizado para la adaptación en tiempo real de los parámetros de la red. Esta metodología, no descrita en esta tesis, permite a la red auto adaptarse automáticamente a posibles cambios de la cuenca o a situaciones no vistas anteriormente pudiendo generalizar mejor que una red con parámetros fijos.

REFERENCIAS

Referencias

- Abebe A. J. y Price Roland K., 2004. Information theory and neural networks for managing uncertainty in flood routing. *Journal of Computing in Civil Engineering* 18(4), 373-380.
- Abrahart R. J. y See L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrological Process.* 14, 2157–2172.
- Abrahart R. J., 2001. Single-model-bootstrap applied to neural network rainfall-runoff forecasting. *Proceedings of the 6th International Conference on GeoComputation.*
- Abrahart R. J., See L., y Kneale P. E., 2001. Applying saliency analysis to neural network rainfall-runoff modelling. *Computing Geoscience*, 27, 921–928.
- Abrahart R. J., Kneale P. E. y See L. M., 2004. Neural Networks for Hydrological Modelling. *A.A. Balkema Publishers.*
- Ancil F. y Rat A., 2005. Evaluation of neural network stream flow forecasting on 47 watersheds. *Journal of Hydrologic Engineering* 10(1), 85-88.
- Ancil François, Lauzon Nicolas, Andreassian Vazken, Oudin Ludovic and Charles Perrin, 2006. Improvement of rainfall-runoff forecasts through mean areal rainfall optimization. *Journal of Hydrology* 328, 717– 725.
- Anmala Jagadeesh, Zhang Bin y Govindaraju Rao S., 2000. Comparison of ANNs and empirical approaches for predicting watershed runoff. *Journal of Water Resources Planning and Management*, 156-166.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000a. Artificial neural networks in hydrology. I: preliminary concepts. *Journal of Hydrologic Engineering* 5(2), 115-123.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, 2000b. Artificial neural networks in hydrology. II: hydrologic applications. *Journal of Hydrologic Engineering* 5(2), 124-137.
- Awwad H. M. y Valdés J. B., 1992. Adaptive parameter estimation for multisite hydrologic forecasting. *Journal of Hydraulic Engineering, ASCE*, 118(9), 1201-1221.
- Beven K. J. y Kirby M. J., 1979. A Physically Based, Variable Contributing Area Model Basin Hydrology. *Hydrological Science. Journal* 24(1). 43-69.

- Beven K. J. y Binley A. M., 1992. The future of distributed models: model calibration and uncertainty prediction. *Hydrological Processes* 6, 279–298.
- Bezdek, J. C., 1981. Pattern Recognition with Fuzzy Objective Function Algorithms. *Plenum Press, New York*.
- Birikundavyi S., Labib R., Trung H. T. y Rousselle J., 2002. Performance of neural networks in daily streamflow forecasting. *Journal of Hydrologic Engineering* 7(5), 392-398.
- Bordignon, S. y Lisi, F., 2000. Nonlinear analysis and prediction of river flow time series. *Environmetrics* 11, 463–477.
- Bowden Gavin J., Dandy Graeme C. y Maier Holger R., 2005. Input determination for neural network models in water resources applications. Part 1 - background and methodology. *Journal of Hydrology* 301, 75–92.
- Box G. E. P. y Jenkins G.M., 1970. Time series analysis forecasting and control. *Holden Day, San Francisco, USA*.
- Bruni G., Pujol L., Ortiz E., Cifres E. y García-Bartual R., 2007. A practical flood warning system based on rainfall threshold in ungauged basins. *Geophysical Research Abstracts, Vol. 9, 11011, SRef-ID: 1607-7962/gra/EGU2007-A-11011* © European Geosciences Union.
- Burn D. H. y McBean E. A., 1985. River flow forecasting model for Sturgeon River. *Journal of Hydraulic Engineering, ASCE, 111(2), 316-333*.
- Chang I., Rapi Raju S., Whiteside M., Hwang G., 1991. A neural network to time series forecasting. *Proceedings of the Decision Science Institute, 3, 1716–1718*.
- Chau K. W., Wu C. L. y Li Y. S., 2005. Comparison of Several Flood Forecasting Models in Yangtze River. *Journal of Hydrologic Engineering* 10(6), 485-491.
- Chiang Yen-Ming, Chang Li-Chiu y Chang Fi-John, 2004. Comparison of static-feedforward and dynamic-feedback neural networks for rainfall–runoff modelling. *Journal of Hydrology* 290, 297-311.
- Chow V., Maidment D. R. y Mays L. W., 1994. Hidrología Aplicada. *Ed McGraw-Hill. Pag 131-139*.
- Cigizoglu H. K., 2003. Incorporation of ARMA models into flow forecasting by artificial neural networks. *Environmetrics* 14 (4), 417-427.

- Cigizoglu H. K., 2005. Application of Generalized Regression Neural Networks to Intermittent Flow Forecasting and Estimation. *Journal of Hydrologic Engineering* 10(4), 333-341.
- Clair T. A y Ehrman J. M. 1996. Variations in discharge and dissolved organic carbon and nitrogen export from terrestrial basins with changes in climate: a neural network approach. *Limnology and Oceanography* 41(5), 921-927.
- Colosimo C. y Mendicino G., 1996. GIS for distributed rainfall – runoff modeling. In: V. P. Singh e Fiorentino M. (Eds.), *Geographical Information Systems in Hydrology, Water Science and Technology Library, Kluwer Academic Publisher, The Netherlands*.
- Conway A. J., Macpherson K. P. y Brown J. C., 1998. Delayed time series predictions with neural networks. *Neuro computing* 18, 81-89.
- Corani G. y Guariso G., 2005. Coupling Fuzzy modeling and Neural Networks for River Flood Prediction. *IEEE Transactions on Systems, Man and Cybernetics-PartC: Applications and reviews, Vol 35 N°3*, 382-390.
- Coulibaly P., Anctil F. y Bobeé B., 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology* 230, 244–257.
- Coulibaly Paulin, Haché Mario, Fortin Vincent y Bobée Bernard, 2005. Improving Daily Reservoir Inflow Forecasts with Model Combination. *Journal of Hydrologic Engineering* 10(2), 92-99.
- Crespo J. L. y Mora E., 1993. Drought estimation with neural networks. *Advances in Engineering Software*, 18 (3), 167-170.
- Cuadras C. M., 1992. Probability distributions with given multivariate marginals and given dependence structure. *Journal of multivariate analysis*, 42(1), 51-66.
- Cybenko G., 1989. Approximation by superposition of a sigmoidal function. *Mathematical Control Signals Systems* 2, 303-314.
- De Vos N. J. y Rientjes, 2005. Constraints of artificial neural networks for rainfall-runoff modelling: trade-offs un hydrological state representation and model evaluation. *Hydrology and Earth System Sciences*, 9, 111-126.
- Demuth H. y Beale M., 1992. Neural Network Toolbox User's Guide for use with MATLAB™. *The Math Works, Inc*.
- Daniell T. M., 1991. Neural networks – applications in hydrology and water resources engineering. *Proceedings of the International Hydrology and Water Resources Symposium. National Conference Publication 91/92 Institute of Engineering, Barton, Australia*, 3, 797-802.

- Dawdy D. R., Gupa V. y Singh V., 1978. Stochastic simulation of droughts. *Paper presented at the US-Argentinean Workshop on Drought, Mar del Plata, Argentina.*
- Dawson C. W. y Wilby R. L., 1998. An artificial neural network approach to rainfall runoff modelling. *Hydrological Sciences Journal* 43(1), 47-66.
- Dawson C. W., Abrahart R. J., Shamseldin A. Y. y Wilby R. L., 2006. Flood Estimation at ungauged sites using artificial neural networks. *Journal of Hydrology* 319, 391-409.
- Deka P. y Chandramouli V., 2005. Fuzzy Neural Network Model for Hydrologic Flow Routing. *Journal of Hydrologic Engineering* 10(4), 302-314.
- Diamantopoulou M. J., Georgiou P. E y Papamichail D. M., 2006. A time delay artificial neural network approach for flow routing in a river system. *Hydrology and Earth System Sciences Discussions* 3, 2735–2756.
- Dibike Yonas B. y Solomatine Dimitri P., 1999. River flow forecasting using artificial neural networks. *EGS journal of Physics and Chemistry of the Earth.*
- Dolling Oscar R. y Varas Eduardo A., 2002. Artificial neural networks for stream flow prediction. *Journal of Hydraulic Research* 40(5), 547-554.
- Dunne T., 1978. Field studies processes, in Hillslope Hydrology. *Editado por M. J. Kirby, 227-293, John Wiley, Nueva York.*
- Elshorbagy Amin, Simonovic S. P. y Panu U. S., 2000. Performance evaluation of artificial neural networks for runoff prediction. *Journal of Hydrologic Engineering* 5(4), 424-427.
- Efron B. y Tibshirani R., 1993. An Introduction to the Bootstrap. *Chapman & Hall.*
- Faggin F., 1991. VLSI implementation of neural networks. *International Joint Conference on Neural Networks.* Seattle, WA.
- Fahlman Scott E. y Lebiere Christian, 1991. The cascade-correlation learning architecture. *School of Computer Science Carnegie Mellon University Pittsburgh, PA 15213.*
- Fausett L., 1994. Fundamentals of neural networks. *Prentice Hall, Englewood Cliffs, N.J.*
- Fernando Achela y Jayawardena A. W., 1998. Runoff forecasting using RBF networks with OLS algorithm. *Journal of Hydrologic Engineering* 3(3), 203-209.
- Flood Ian y Kartam Nabil, 1994a. Neural networks in civil engineering I: principles and understanding. *Journal of Computing in Civil Engineering* 8(2), 131-148.

- Flood Ian y Kartam Nabil, 1994b. Neural networks in civil engineering II: systems and application. *Journal of Computing in Civil Engineering* 8(2), 149-162.
- Francés M., Arbáizar J. y Ortiz E., 2008. Development of a DSS to improve flood control in the Spanish Nacional River Authorities. *River flow 2008 – Altınakar, Kokpınar, Darama, Yegen y Harmancıoğlu (eds)*. ISBN 978-605-60136-3-8. 1825-1833.
- French M. N., Krajewski W. F., y Cuykendall R. R., 1992. Rainfall forecasting in space and time using a neural network. *Journal of Hydrology, Amsterdam* 137, 1–31.
- Furundzic D., 1998. Application example of neural networks for time series analysis: rainfall runoff modelling. *Signal Process* 64, 383–396.
- Garbrecht Jurgen D., 2006. Comparison of three alternative ANN designs for monthly rainfall-runoff simulation. *Journal of Hydrologic Engineering* 11(5), 502-505.
- García-Bartual R., 2002. Short term river flood forecasting with neural networks. *The International Environmental Modelling and Software Society*.
- Genz A., 1992. Numerical computation of Multivariate Normal Probabilities. *J. Comp Graph Stat.* 1, 141-149.
- Golob R., Stokelj T. y Grgic D., 1998. Neural network based water inflow forecasting. *Control Engineering Practice* 6(5), 593-600.
- Govindaraju R. S. y Rao A. R., 2000. (Eds) Artificial Neural Networks in Hydrology. *Dordrech: Kluwer Academic*.
- Granger C. W. J., Anderson A. P., 1978. An introduction to bilinear time series models. *Vandenhoeck and Ruprecht, Göttingen*.
- Grepi Mauro, 2005. Idrologia. *Ulrico Hoepli Editore S.p.S.*. ISBN 88-203-3425-9.
- Hall M. J. y Minns A. W., 1993. Rainfall runoff modelling as a problem in artificial intelligence: experience with a neural network. *Proceedings of the Fourth National Hydrological Symposium, Cardiff*, 5.51-5.57.
- Haykin S., 1994. Neural Networks: A Comprehensive Foundation. *NY: Macmillan*.
- Hecht-Nielsen R., 1989. Neurocomputing. *Addison-Wesley Publishing Company*.
- Hech-Nielsen R., 1990. On the algebraic structure of feedforward network spaces. *Advanced neural computers (R. Eckmiller, ed.)*, 129-135. *North-Holland, Amsterdam, Netherlands*.

- Hewlett J. D., 1996. Soil moisture as a source of base flow from steep mountain watersheds, USDA. *For. Serv. Res. Pap. SE, 132, 1-10.*
- Hipel K. W. y McLeod A. I., 1994. Time series modelling of water resources and environmental systems. *Elsevier Science B.V., Development in Water Science, No. 45.*
- Hornik K., Stinchcombe M. y White H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks 2, 359-366.*
- Horton R. E., 1933. The role of infiltration in the hydrologic cycle. *Eos Trans. AGU, 14,460-466.*
- Hossain Faisal y Anagnostou Emmanouil N., 2005. Assessment of a probabilistic scheme for flood prediction. *Journal of Hydrologic Engineering 10(2), 141-150.*
- Hu T. S., Lam K. C. y Ng T. G., 2001. River flow forecasting with a range dependent network. *Hydrological Science Journal 45(5), 729-745.*
- Hush R. y Horne B., 1992. An overview of neural networks. *Informática y Automática, vol.25 - 1 y 2.*
- Hsu K. L., Gao X. G. y Sorooshian S., 1995. Artificial neural network modelling of the rainfall runoff process. *Water Resources Research 31(10), 2517-2530.*
- Hsu K., Sorooshian S., Gupta H. V., Gao X. y Imam B., 2002. Hydrologic modelling and analysis using a self-organizing linear output network. *The University of Arizona, Tucson, AZ 85715, USA.*
- Imrie C. E., Durucan S., Korre A., 2000. River flow prediction using artificial neural networks: generalisation beyond the calibration range. *Journal of Hydrology 233, 138-153.*
- Iyer Mahesh y Rhinehart Russel R., 1999. A Method to Determine the Required Number of Neural-Network Training Repetitions. *IEEE Transactiones on neural networks, Vol 10, N° 2, 427-432.*
- Irie B. y Miyake S., 1988. Capabilities of three-layered perceptrons. *Proceedings of the IEEE International Conference on neural networks: Neural Networks, I, 641-648.*
- Irving H. Shames, 1995. Mecánica de fluidos. *Mc Graw-Hill 3ª edición ISBN 958-600-246-2.*
- Jacobs R. A., Jordan M. I., Nowlan S. J. y Hinton G.E., 1991. Adaptive mixtures of local experts. *Neural Comput. 3, 79-87.*

- Jacobs R. A. y Jordan M. I., 1993. Learning piecewise control strategies in a modular neural network architecture. *IEEE Trans. Syst. Man Cybern.* 23 (2), 337–345.
- Jaime P. R. y Menéndez A. N., 1997. Modelo hidrodinámico del Río Paraná desde Yacyretá hasta la ciudad de Paraná. *Informe LHA 01-165-97 INA*.
- Jain A. e Indurthy Prasad S. K. V., 2003. Comparative analysis of event-based rainfall-runoff modelling techniques-deterministic, statistical, and artificial neural networks. *Journal of Hydrologic Engineering* 8(2), 93-98.
- Jain A. y Srinivasulu S., 2004. Development of effective and efficient rainfall-runoff models using integration of deterministic, real-coded genetic algorithms, and artificial neural network techniques. *Water Resources Research* 40 (4), W04302. doi: 10.1029/2003WR002355.
- Jain A., Sudheer K. P. y Srinivasulu S., 2004a. Identification of physical processes inherent in artificial neural network rainfall runoff models. *Hydrological Processes* 18(3), 571-581.
- Jain A., Sudheer K. P. y Srinivasulu S., 2004b. Discussion of “Performance of Neural Networks in Daily Streamflow Forecasting” by S. Birikundavyi, R. Labib, H. T. Trung, and J. Rousselle. *Journal of Hydrologic Engineering*, Vol 9 N° 6, 553-554.
- Jain A., 2005. Comment on ‘Comparison of static-feedforward and dynamic-feedback neural networks for rainfall-runoff modeling’ by Chiang Y.M., Chang L.C. and Chang F.J., 2004. *Journal of Hydrology* 290, 297–311. *Journal of Hydrology* 314, 207–211.
- Jain A. y Srinivasulu S., 2006. Integrated approach to model decomposed flow hydrograph using artificial neural network and conceptual techniques. *Journal of Hydrology* 317, 291–306.
- Jarvis A., Reuter H. I., Nelson A. y Guevara E., 2008. Hole-filled seamless SRTM data V4, International Centre for Tropical Agriculture (CIAT), obtenido de <http://srtm.csi.cgiar.org>.
- Jayawardena A. W., Fernando D. y Achela K., 1998. Use of Radial Basis function type artificial neural networks for runoff simulation. *Computer-Aided Civil and Infrastructure Engineering Volume* 13(2), 91-99.
- Jordan M. I. y Jacobs R. A., 1994. Hierarchical mixture of experts and the EM algorithm. *Neural Comput.* 6, 181–214.
- Kang K. W., Park C. Y. y Kim J. H., 1993. Neural network and its application to rainfall-runoff forecasting. *Korean Journal of Hydrosciences* 4, 1-9.

- Karunanithi Nachimuthu, Grenney William J., Whitley Darrell y Bovee Ken, 1994. Neural networks for river flow prediction. *Journal of Computing in Civil Engineering* 8(2), 201-220.
- Kelly K. S. y Krzysztofowicz R., 1997. A bivariate meta-Gaussian density for use in hydrology. *Stochastic Hydrology and Hydraulics* 11, 17-31.
- Kerh Tienfuan y Lee C. S., 2006. Neural networks forecasting of flood discharge at an unmeasured station using river upstream information. *Advances in Engineering Software* 37(8), 533-543.
- Kisi Özgür, 2004. River flow modelling using artificial neural networks. *Journal of Hydrologic Engineering* 9(1), 60-63.
- Klemes V., 1973. Watershed as semi infinite storage reservoir. *ASCE Journal Irrigation and Drain. Div.* 99 IR4, 477-491.
- Kneale Pauline, See Linda y Smith Andrew, 2001. Towards defining evaluation measures for neural network. *Proceedings of the 6th International Conference on GeoComputation*.
- Kohonen T., 1990. The self-organizing map. *Proc. IEEE* 78, 1464-1480.
- Koskela Timo, 2003. Neural network methods in analysing and modelling time varying processes. *Espoo 2003 ReportB35 Finland*.
- Krzysztofowicz R., 1999. Bayesian theory of probabilistic forecasting via deterministic hydrologic model. *Water Resources Research* 35, 2739-2750.
- Kumar A. y Minocha V.K., 2001. Discussion on “Rainfall runoff modelling using artificial neural networks” by Tokar y Johnson, 1999. *Journal of Hydrologic Engineering* 6(2), 176-177.
- Lauzon N., Anctil F. y Baxter C. W., 2006. Classification of heterogeneous precipitation fields for the assessment and possible improvement of lumped neural network models for streamflow forecasts. *Hydrology and Earth System Sciences Discussions* 3, 201–227.
- Lingireddy S. y Brion G. M., 2005. Artificial neural networks in water supply engineering. *ASCE*.
- Linsley R. K., Kohler M. A. y Paulus J.L., 1988. Hidrología para ingenieros. *Ed McGraw-Hill. Pag 182-191*.
- Liong Shie-Yui, Lim Wee-Han y Paudyal Guna N., 2000. River stage forecasting in Bangladesh: neural network approach. *Journal of Computing in Civil Engineering* 14(1), 1-8.
- Lippmann R. P., 1987. An Introduction to Computing with Neural Nets. *IEEE ASSP Magazine*.

- Liu Zhiyu Liu y Todini Ezio, 2002. Towards a comprehensive physically-based rainfall-runoff model. *Hydrology and Earth System Sciences*, 6(5), 859–881.
- Liu Zhiyu Liu, Martina Mario L. V. y Todini Ezio, 2005. Flood forecasting using a fully distributed model: application on the TOPKAPI model to the upper Xixian Catchment. *Hydrology and Earth System Sciences*, 9(4), 347–364.
- Lorrai M. y Sechi G. M., 1995. Neural nets for the modelling rainfall runoff transformations. *Water Resources Management* 9(4), 299-313.
- Maier Holger R. y Dandy Graeme C., 2000. Neural Networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling and Software*, 15, 101-124.
- Mantovan Pietro y Todini Ezio, 2006. Hydrological forecasting uncertainty assessment: Incoherence of the GLUE methodology. *Journal of Hydrology* 330, 368– 381.
- Melching C. S., 1992. An Improved first order reliability approach for assessing the uncertainties in hydrologic modelling. *Journal of Hydrology* 132, 157-177.
- Ministerio de Planificación Federal. Inversión Pública y Servicios. Secretaría de Obras Públicas. Subsecretaría de Recursos Hídricos Argentina, 2004.
(<http://www.hidricosargentina.gov.ar/FormRedHidro.html>)
- Minns A. W. y Hall M. J., 1996. Artificial neural networks as rainfall runoff models. *Hydrological Sciences Journal* 41(3), 399-417.
- Molenberghs Geert y Lesaffre Emmanuel, 1997. Non-Linear Integral Equations to Approximate Bivariate Densities with given Marginals and Dependence Function. *Statistica Sinica* 7, 713-738.
- Montovan P. y Todini E., 2006. Hydrological forecasting uncertainty assesment: Incoherence of GLUE methodology. *Journal of Hydrology*. 300. 368-381.
- Moradkhani Hamid, Hsu Kuo-lin, Gupta Hoshin V. y Sorooshian Soroosh, 2004. Improved stream flow forecasting using self-organizing radial basis function artificial neural networks. *Journal of Hydrology* 295, 246–262.
- Moss M. E. y Bryson M. C., 1974. Autocorrelation structure of monthly stream flow. *Journal of Water Resources Research* 10(4), 737-744.
- Muñoz San Roque A., 1996. Aplicación de técnicas de Redes Neuronales Artificiales al diagnóstico de procesos industriales. *Tesis Doctoral. Universidad Pontificia Comillas Madrid*. 103-125.

- Muttiah R. S., Srinivasan R. y Allen P. M., 1997. Prediction of two year peak stream discharges using neural networks. *Journal of the American Water Resources Association* 33(3), 625-630.
- Nachabe M. H., Illangasekare T. H., Morel-Seytoux H. J., Ahuja L. R. y Ruan H., 1997. Infiltration over Heterogeneous Watershed: Influence of Rain Excess. *Journal of Hydrologic Engineering*, 140-143.
- Nash J. E. y Sutcliffe J. V., 1970. River flow forecasting through conceptual models, part 1 A discussion of principles. *Journal of Hydrology*, 10(3), 282-290.
- Nigrin A., 1993. Neural Networks for Pattern Recognition. *Cambridge, MA: The MIT Press*.
- Obereder A., Scherzer O. y Kovac A., 2007. Bivariate density estimation using BV regularization. *Computational Statistics and Data Analysis*, 51(12): 5622-5634.
- O'Connor K. M., 1976. A discrete linear cascade model for hydrology. *Journal of hydrology* 29, 203-242.
- Olsson J., Uvo C. B., Jinno K., Kawamura A., Nishiyama K., Koreeda N., Nakashima T., y Morita O., 2004. Neural networks for rainfall forecasting by atmospheric downscaling. *Journal of Hydrologic Engineering* 9(1), 1-12.
- Pan Tsung-yi y Wang Ru-yih, 2004. State space neural networks for short term rainfall-runoff forecasting. *Journal of Hydrology* 297, 34-50.
- Papamichail D. M. y Georgiou P. E., 2001. Seasonal ARIMA inflow models for reservoir sizing. *Journal Am. Water Resources Association* 37, 877-88.
- Parker D. B., 1985. Learning-logic: Casting the cortex of the human brain in silicon. *Tech. Rep. TR-47, Center for Computational Research in Economics and Management Science, MIT, Cambridge*.
- Parker D. B., 1987. Optimal algorithms for adaptive networks: Second order backpropagation, second order direct propagation and second order Hebbian learning. *IEEE 1st Int. Conf. on Neural Networks, vol.2*, 593-600.
- Pegram G. S. S., 1978. Physical justification of continuous stream flow model. *Modelling hydrologic Processes. Proceedings of the Fort Collins III International Hydrology Symposium, Edited by H.J. Morel-Seytoux, J.D. Salas, T.G. Sanders and R.E. Smith*, 270-280.

- Poff N. L., Tokar S. y Johnson P., 1996. Stream hydrological and ecological responses to climate change assessed with an artificial neural network. *Limnology and Oceanography* 41(5), 857-863.
- Ponce V. M. y Simons D. B., 1977. Shallow Wave Propagation in Open Channel Flow. *Journal of the Hydraulics division, ASCE, Vol 103, No, Proc Paper 13392, 1461-1476.*
- Ponce V. M., 1989. Engineering hydrology – Principles and Practices. *Prentice Hall, 270-306.*
- Pujol L., Ortiz E., Cifres E. y García-Bartual R., 2007a. Errors analysis in real time flow forecasting for 10-days lead time in the Paraná river. *Geophysical Research Abstracts, Vol. 9, 11011. SRef-ID: 1607-7962/gra/EGU2007-A-11011.© European Geosciences Union.*
- Pujol L., Ortiz E., Cifres E. y García-Bartual R., 2007b. A real-time flow forecasting in the Paraná river: A comparison between ARMAX and ANN models. *Congreso IAHR Venecia, Italia.*
- Pulido-Calvo Inmaculada y Portela Maria Manuela, 2006. Application of neural approaches to one-step daily flow forecasting in Portuguese watersheds. *Journal of Hydrology, doi:10.1016/j.jhydrol.2006.06.015.*
- Quimpo R., 1971. Structural relation between parametric and stochastic hydrology models. *Mathematical Models in Hydrology, Warsaw Symposium 1, 151-157.*
- Rajurkar M. P., Kothyari U. C. y Chaube U. C., 2004. Modelling of the daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology* 285, 96–113.
- Ramman H. y Sunilkumar N., 1995. Multivariate modelling of water resources time series using neural networks. *Hydrological Sciences Journal* 40(2), 145-163.
- Ramón S. y Cajal, 1991. Histología del sistema nervioso del hombre y de los vertebrados. *Consejo Superior de Investigaciones Científicas. Madrid.*
- Ratto M., Young P. C., Romanowicz R., Pappenberge F., Saltelli A. y Pagano A., 2006. Uncertainty, sensitivity analysis and the role of data based mechanistic modeling in hydrology. *Hydrology and Earth System Sciences Discussions. 3, 3099–3146.*
- Reilly D. L. y Cooper L. N., 1990. An overview of neural networks: early models to real world systems. *Zornetzer, S.F., Davis, J.L., Lau, C. (Eds.), An Introduction to Neural and Electronic Networks. Academic Press, New York, 227–248.*

- Ribeiro J., Lauzon N., Rousselle J., Trung H. T. y Salas J. D., 1998. Comparaison de deux modèles pour la prévision journalière en temps réel des apports naturels. *Can. J. Civil Engng* 25, 291–304.
- Romano C., 2002. Calibrating and simulating Copula functions: an application to the Italian stock market *Working paper n. 12, CIDEM, Università degli Studi di Roma*.
- Ronco Eric y Gawthrop Peter, 1995. Modular Neural Networks: a state of the art. *Centre for System and Control University of Glasgow Uk*.
- Rumelhart D. E., Hinton G. E. y Williams R. J., 1986a. Learning representations by back-propagating errors. *Nature (London)*, 323, 533-536.
- Rumelhart D. E., Hinton G. E. y Williams R. J., 1986b. Learning internal representations by error propagation. *Parallel Distributing Processing: Explorations in the Microstructure of Cognition (D.E. Rumelhart, J.L. McClelland, eds), vol.1, chapter 8, Cambridge, MA: MIT Press*.
- Sahoo G. B., Ray C. y De Carlo E. H., 2006. Use of neural network to predict flash flood and attendant water qualities of a mountainous stream on Oahu, Hawaii. *Journal of Hydrology* 327, 525-538.
- Sahoo G. B. y Ray C., 2006. Flow forecasting for a Hawaii stream using rating curves and neural networks. *Journal of Hydrology* 317, 63-80.
- Sajikumar N. y Thandaveswara B. S., 1999. A Non-Linear Rainfall–Runoff Model Using an Artificial Neural Network. *Journal of Hydrology* 216, 32-55.
- Salas J. D., Delleur J. W., Yevjevich V. y Lane W.L., 1980. Applied Modeling of Hydrologic Time Series. *Water Resources Publications. ISBN 0-918334-37-3*.
- See L. y Openshaw S., 1999. Applying soft computing approaches to river level forecasting. *Hydrological Science Journal* 44(5), 763-778.
- Setiono R., Leow W. K. y Zurada J. M., 2002. Extraction of rules from artificial neural networks for nonlinear regression. *IEEE Trans. Neural Networks.*, 13(3), 564–577.
- Shamseldin Asaad Y., 1997. Application of a Neural Network Technique to Rainfall-Runoff Modelling” *Journal of Hydrology* 199, 272-294.
- Shi Jonathan Jingsheng, 2000. Reducing prediction error by transforming input data for neural networks. *Journal of Computing in Civil Engineering* 14(2), 109-116.

- Shukula M. B., Kok R., Prasher S. O., Clak G. y Lacroix R., 1996. Use of artificial neural networks in transient drainage design. *Transactions of the ASAE* 39(1), 119-124.
- Sivakumar B., Berndtsson R. y Persson M., 2001. Monthly runoff prediction using phase space reconstruction. *Hydrological Science Journal* 46(3), 377–387.
- Smith Jason y Eli Robert, 1995. Neural Network models o f rainfall-runoff process. *Water Resources Planning and Management* 121, 499-508.
- Snedecor G. W. y Cochran W. G., 1967. Statistical Methods. *The Iowa State University Press, Iowa*.
- Söderström T., 2002. Discrete-Time Stochastic Systems. *Ed Springer ISBN 1852336498, 9781852336493. 187-191*
- Solomatine Dimitri P. y Xue Yunpeng, 2004. M5 model trees and neural networks: application to flood forecasting in the upper reach of the Huai river in China. *Journal of Hydrologic Engineering* 9(6), 491-501.
- Spear R. C., Grieb T. M. y Shang N., 1994. Parameter uncertainty and interaction in complex environmental models. *Water Resources Research* 30, 3159–3170.
- Sudheer K. P. y Jain A., 2004. Explaining the internal behaviour of artificial neural network river flow models. *Hydrological Process* 118 (4), 833–844.
- Sudheer K. P., 2005. Knowledge extraction from trained neural network river flow models. *Journal of Hydrologic Engineering* 10(4), 264-269.
- Sureerattanana S. y Phien H. N., 1997. Back-propagation networks for the daily stream flow forecasting. *Water Resources Journal December*, 1-7.
- Tawfic M., Ibrahim A. y Fahmy H., 1997. Hysteresis sensitive neural network for modelling rating curves. *Journal of Computing Engineering* 11(3), 206-211.
- Thirumalaiah K. y Deo M. C., 1998a. River stage forecasting using artificial neural networks. *Journal of Hydrologic Engineering* 3(1), 26-32.
- Thirumalaih K. y Deo M. C., 1998b. Real time flood forecasting using neural networks. *Computer Aided Civil and Infrastructure Engineering* 13(2), 101-111.
- Thirumalaiah K. y Deo Makarand C., 2000. Hydrological Forecasting Using Neural Networks. *Journal of Hydrologic Engineering* 5(2), 180-189.
- Todini E., 1996. The ARNO rainfall-runoff model. *J. Hydrol.*, 175, 339–382.

- Todini E., 2004. Role and treatment of uncertainty in real-time flood forecasting. *Hydrological Processes*, 18, 2743–2746.
- Todini E., 2007. Hydrological catchments modelling: past, present and future. *Hydrology and Earth System Sciences* 11(1), 468-482.
- Tokar Sezin A. y Johnson Peggy A., 1999. Rainfall-runoff modelling using artificial neural networks. *Journal of Hydrologic Engineering* 4(3), 232-239.
- Tokar Sezin y Markus Momcilo, 2000. Precipitation-Runoff modelling using artificial neural networks and conceptual models. *Journal of Hydrologic Engineering* 5(2), 156-161.
- Toth E., Brath A. y Montanari A., 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of Hydrology* 239, 132-147.
- Toth E. y Brath A., 2002. Flood forecasting using artificial neural networks in black-box and conceptual rainfall-runoff modelling. *The International Environmental Modelling and Software Society*.
- Valença M. y Ludermir T., 1998. Self-organizing modelling in forecasting daily river flows. *Proceedings of the Vth Brazilian Symposium on Neural Networks* 210.
- Valicenti J. L., 2001. Cuenca del río Neuquén. Análisis de fenómeno Precipitación-Escorrentía. *Secretaría de planificación y desarrollo Autoridad Interjurisdiccional de las Cuencas de los ríos Limay, Neuquén y Negro (AIC)*.
- Valverde Ramírez M. C., Fraga de Campos V. H., Ferreira N. J., 2005. Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. *Journal of Hydrology* 301, 146-162.
- Velásquez D., Dyner I. y Souza R., 2006. Tendencias en la predicción y estimación de los intervalos de confianza usando modelos de redes neuronales aplicados a series temporales. *Dyna*, Año 73, Nro. 149, 141-147. *Medellín, ISSN 0012-7353*.
- Venter Gary G., 2002. Tails of Copulas. *Proceedings of the Casualty Actuarial Society Casualty Actuarial Society - Arlington, Virginia: LXXXIX, 68-113*.
- Vide Juan P. Martín, 2002. Ingeniería de ríos. *Publicado por Editions UPC, 2006. ISBN8483019000, 9788483019009*
- Vijay P. Singh, 1988. Hydrologic systems Rainfall-Runoff Modeling *Volume I. Ed. Prentice Hall, Engle Cliffs, New Jersey. 86- 90*.

- Wan Eric A., 1990. Temporal for back propagation for FIR neural networks. *Neural Networks, IJCNN International Joint Conference on Neural Networks, 1575-1780*.
- Wang Wen, Van Gelder Pieter H. A. J. M., Vrijling J. K. y Ma Jun, 2006. Forecasting daily streamflow using hybrid ANN models. *Journal of Hydrology 324, 383-399*.
- Wangwongwiroj N. y Sukluan A., 2004. Applying artificial neural networks for forecasting and estimation of river levels. *Water Resources Research Center, Disaster Prevention Research Institute, Kyoto University, Japan*.
- Ward T. C. y Robinson M., 1990. Principles of Hydrology. 3° Edición. *McGraw Hill, Maidenhead, UK*.
- Warren S. Sarle, 2005. Neural Network FAQ, part 1 of 7: introduction. *Cary, NC, USA*
<ftp://ftp.sas.com/pub/neural/FAQ.html#A2>.
- Wasserman, 1989. Neural computing: theory and practice. *Van Nostrand Reinhold, NY*.
- Werbos P., 1974. Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Science. *Ph. D. dissertation, Harvard University, Cambridge*.
- Werbos P., 1988. Generalization of backpropagation with application to a recurrent gas model. *Neural Networks, vol.1, 339-356*.
- Werbos P., 1989. Backpropagation and neurocontrol: A review and prospectus. *Proc. Int. Joint Conf. on Neural Networks, Washington DC*.
- Werbos P., 1990. Backpropagation through time: What it does and how to do it. *Proceedings of the IEE 78(10), 1550-1560*.
- Wilby R. L., Abrahart R. J. y Dawson C. W., 2003. Detection of conceptual mode rainfall-runoff processes inside an artificial neural network. *Hydrological Sciences Journal 48(2), 163-181*.
- Witten I. H. y Frank E., 2000. Data mining, *Morgan Kaufmann, San Francisco*.
- Wu J. y S., Han Jun, Annambhotla Shastri y Bryant Scott, 2005 Artificial Neural Networks For Forecasting Watershed Runoff Y Stream Flows” *Journal of Hydrologic Engineering 10(3), 216-222*.
- Yang C. C., Prasher S. O. y Lacroix R., 1996. Applications of artificial neural networks to land drainage engineering. *Transactions of the ASAE 39(2), 525-533*.

- Yakowitz S. y Karlsson M., 1987. Nearest neighbour methods for time series with application to rainfall-runoff prediction. *In: MacNeil, J.B., Umphrey, G.J. (Eds.), Stochastic Hydrology. D. Reidel, Dordrecht, 149-160.*
- Yu P. S., Yang T. C. y Chen S. J., 2001. Comparison of uncertainty analysis methods for distributed rainfall runoff model. *Journal of Hydrology 244, 43-59.*
- Zealand Cameron M., Burn Donald H. y Simonovic Slobodan P., 1999. Short term stream flow forecasting using artificial neural networks. *Journal of Hydrology 214, 32-48.*
- Zhang B. y Govindaraju R. S., 2000a. Modular neural network for watershed runoff. *In R.S. Govindaraju and R.A. Ramanchandra (Eds.), Artificial Neural Networks in Hydrology. Kluwer Academic Publisher, The Netherlands.*
- Zhang B. y Govindaraju R. S., 2000b. Prediction of watershed runoff using Bayesian concepts and modular neural networks. *Water Resources Research 36 (3), 753-762.*
- Zhang B. y Govindaraju R. S., 2003. Geomorphology-Based artificial neural networks (GANNs) for estimation of direct runoff over watersheds. *Journal of Hydrology 273, 18-34.*
- Zhang Guoqiang Patuwo, Eddy B. y Hu Michael Y., 1998. Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting 14, 35-62.*
- Zurada J.M., 1992. Introduction to artificial neural systems. *Boston: PWS Publishing Company.*

APÉNDICES

Apéndices

A Tablas y parámetros de las aplicaciones

A.1 Aplicación sobre el río Paraná

A.1.1 Parámetros de los modelos

Parametros - Hidrogaia S.L.
 Importar/Exportar Parametros Volver

Parámetros

Parámetros entre capa oculta y capa de salida

	nodo 1	nodo 2	nodo 3	umbral
Q t + 10	-0.20	-0.22	0.58	0.55

Parámetros entre capa de entrada y capa c

	nodo 1	nodo 2	nodo 3
umbral	12.91	-16.84	-3.87
Q t - 0	0.22	4.35	14.67
Q t-1 t - 0	3.14	1.35	-0.12
Q t-2 t - 0	-2.35	1.33	-9.28
MF t-5 t - 0	-10.62	-1.72	4.43
MF t-10 t - 0	-6.25	7.94	-7.50
MF t-15 t - 0	2.67	4.49	6.55
MF t-20 t - 0	-0.79	-3.96	-3.78
MF t-25 t - 0	0.19	2.99	1.27
SP t t - 0	-0.20	-0.08	0.03
SP t-10 t - 0	-0.41	0.39	0.00
SP t-20 t - 0	-0.40	0.94	-0.01

Figura A. 1: Parámetros del modelo MLP del modelo del río Paraná

Parametros ARMAX
 Importar/Exportar Parametros Volver

Parámetros

	Q	Q t	Q t-1	Q t-2	MF t-5	MF t-10	MF t-15	MF t-20	MF t-25	SP t	SP t-10	SP t-20
1		3.916	-3.491	0.55797	0.60995	-0.9581	0.701	-0.397	5.46784E+12	0.002384	-0.001244	-0.00264
2												
4												
5												
6												
7												
8												
9												
10												
11												
12												
13												
14												
15												
16												
17												
18												
19												

Figura A. 2: Parámetros del modelo ARMAX del modelo del río Paraná

Parámetros

Parámetros entre capa oculta y capa de salida

	nodo 1	nodo 2	nodo 3	umbral
Q t + 10	0.24	-0.04	-0.22	0.71

Parámetros entre capa de entrada y capa c

	nodo 1	nodo 2	nodo 3
umbral	-30.32	39.58	-24.91
Q t - 0	11.94	-35.54	18.70
Q t-1 t - 0	43.10	-57.84	26.28
Q t-2 t - 0	-9.08	39.53	-0.94
MF t-5 t - 0	11.14	-5.59	-10.99
MF t-10 t - 0	-15.85	-0.61	14.41
MF t-15 t - 0	3.91	2.86	-20.41
MF t-20 t - 0	-0.03	-1.96	14.04
MF t-25 t - 0	1.61	3.99	-3.04
SP t t - 0	-0.65	-1.35	-0.67
SP t-10 t - 0	-3.30	1.63	-4.18
SP t-20 t - 0	0.69	-0.03	0.86

Figura A. 5: Parámetros del modelo MLP2 del modelo del río Paraná

Parámetros

Parámetros entre capa oculta y capa de salida

	nodo 1	nodo 2	nodo 3	umbral
Q t + 10	0.22	0.01	0.02	0.49

Parámetros entre capa de entrada y capa c

	nodo 1	nodo 2	nodo 3
umbral	-10.36	2.80	6.64
Q t - 0	19.43	3.91	1.83
Q t-1 t - 0	-5.27	0.40	3.94
Q t-2 t - 0	-1.79	8.90	-1.93
MF t-5 t - 0	27.11	-3.07	20.21
MF t-10 t - 0	-43.99	-14.71	6.93
MF t-15 t - 0	36.54	-21.50	-22.92
MF t-20 t - 0	-21.58	-22.50	-4.60
MF t-25 t - 0	8.09	-17.85	9.64
SP t t - 0	0.25	9.70	-46.97
SP t-10 t - 0	-0.05	40.17	-30.83
SP t-20 t - 0	0.09	11.59	-35.46

Figura A. 6: Parámetros del modelo MLP3 del modelo del río Paraná

Parámetros entre capa oculta y capa de salida				
	nodo 1	nodo 2	nodo 3	umbral
Q t + 10	-0.21	-0.30	0.71	0.63
Parámetros entre capa de entrada y capa c				
	nodo 1	nodo 2	nodo 3	
umbral	15.99	-14.61	-4.18	
Q t - 0	9.50	10.03	15.93	
Q t-1 t - 0	12.13	1.86	-5.92	
Q t-2 t - 0	-5.53	-15.58	-5.66	
MF t-5 t - 0	-13.17	-3.81	2.56	
MF t-10 t - 0	-9.07	17.98	-2.52	
MF t-15 t - 0	-3.27	-0.70	2.00	
MF t-20 t - 0	-4.30	1.76	-1.14	
MF t-25 t - 0	-1.87	2.86	0.28	
SP t t - 0	-1.12	0.48	0.00	
SP t-10 t - 0	-0.95	0.58	0.02	
SP t-20 t - 0	-2.72	1.91	0.00	

Figura A. 7: Parámetros del modelo MLP4 del modelo del río Paraná

Parámetros entre capa oculta y capa de salida				
	nodo 1	nodo 2	nodo 3	umbral
Q t + 10	-108.00	0.07	-0.03	108.68
Parámetros entre capa de entrada y capa c				
	nodo 1	nodo 2	nodo 3	
umbral	32.29	-42.35	-10.66	
Q t - 0	-2.86	45.73	18.17	
Q t-1 t - 0	-13.37	-0.24	-37.17	
Q t-2 t - 0	-9.20	12.37	9.93	
MF t-5 t - 0	-12.18	36.94	3.18	
MF t-10 t - 0	15.62	-46.32	13.36	
MF t-15 t - 0	-22.88	16.52	28.26	
MF t-20 t - 0	20.32	6.36	21.41	
MF t-25 t - 0	-9.10	-8.73	13.03	
SP t t - 0	-0.17	0.47	-2.99	
SP t-10 t - 0	-0.30	-0.75	-35.68	
SP t-20 t - 0	-0.23	-0.76	-7.66	

Figura A. 8: Parámetros del modelo MLP5 del modelo del río Paraná

Parámetros entre capa oculta y capa de salida				
	nodo 1	nodo 2	nodo 3	umbral
Q t + 10	-0.03	-127.96	-4.85	0.76
Parámetros entre capa de entrada y capa c				
	nodo 1	nodo 2	nodo 3	
umbral	31.08	-13.88	-0.32	
Q t - 0	-12.55	6.40	-4.36	
Q t-1 t - 0	18.60	7.69	2.92	
Q t-2 t - 0	-7.90	-19.26	-3.92	
MF t-5 t - 0	-4.78	-9.76	-12.47	
MF t-10 t - 0	2.72	-12.19	20.51	
MF t-15 t - 0	-49.03	-9.72	-15.06	
MF t-20 t - 0	-18.53	-5.32	9.01	
MF t-25 t - 0	9.07	-8.18	-2.13	
SP t t - 0	-3.28	8.44	0.04	
SP t-10 t - 0	-4.48	12.58	0.15	
SP t-20 t - 0	-2.39	15.93	0.02	

Figura A. 9: Parámetros del modelo MLP6 del modelo del río Paraná

Tabla A. 1: Parámetros funciones de distribución lognormal-lognormal para el cálculo de los intervalos de confianza

Modelos	Función distribución marginal para caudales predichos		Función distribución marginal para caudales observados		Coef. correlación
	a	b	a	b	
ARMAX	9.816	0.174	9.818	0.170	0.976
MLP	9.818	0.170	9.819	0.166	0.980
Manual-MLP	9.819	0.167	9.818	0.170	0.984
SOM-MLP	9.819	0.167	9.818	0.170	0.984

A.1.2 Resultados de calibración

En este apartado se muestran los resultados de calibración.




Figura A. 10: Discretización de picos para el cálculo del PFC en los datos de calibración

Tabla A. 2: Peak Flow Criteria. Índice de habilidad de predicción de picos para la serie de calibración

	PFC
SOM-MLP	21.59
Manual-MLP	19.76
MLP	23.64
ARMAX	35.3

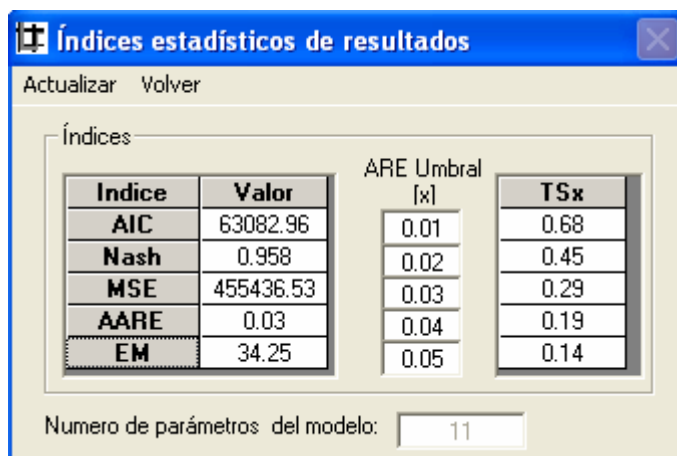


Figura A. 11: Índices de fiabilidad para los resultados de calibración del modelo ARMAX

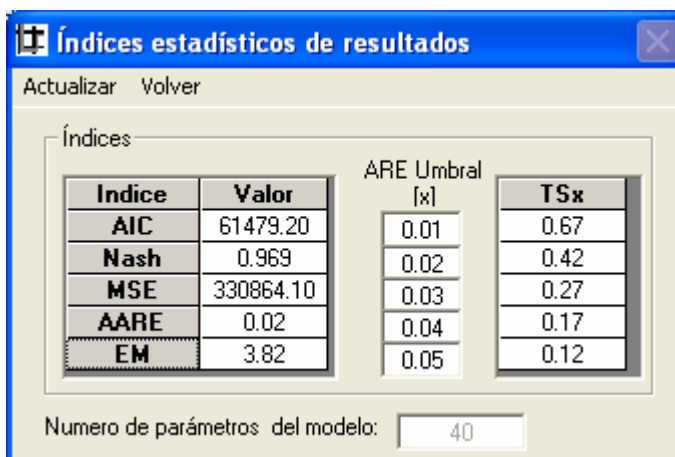


Figura A. 12: Índices de fiabilidad para los resultados de calibración del modelo MLP



Figura A. 13: Índices de fiabilidad para los resultados de calibración del modelo SOM-MLP

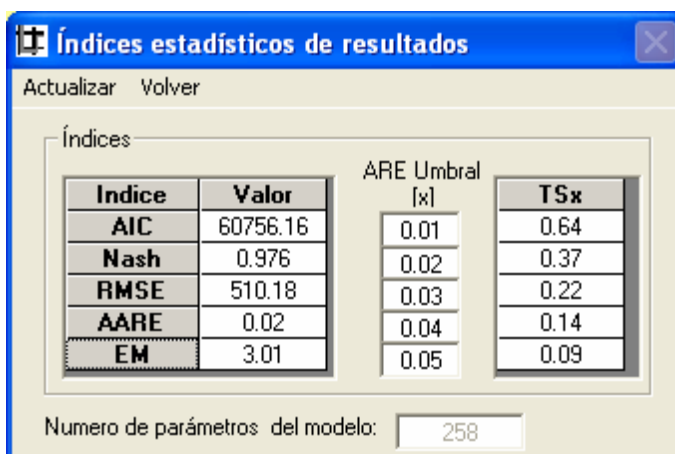


Figura A. 14: Índices de fiabilidad para los resultados de calibración del modelo Manual-MLP




Figura A. 15: Predicción a 10 días del modelo ARMAX para el periodo de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior




Figura A. 16: Predicción a 10 días del modelo MLP para el período de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior

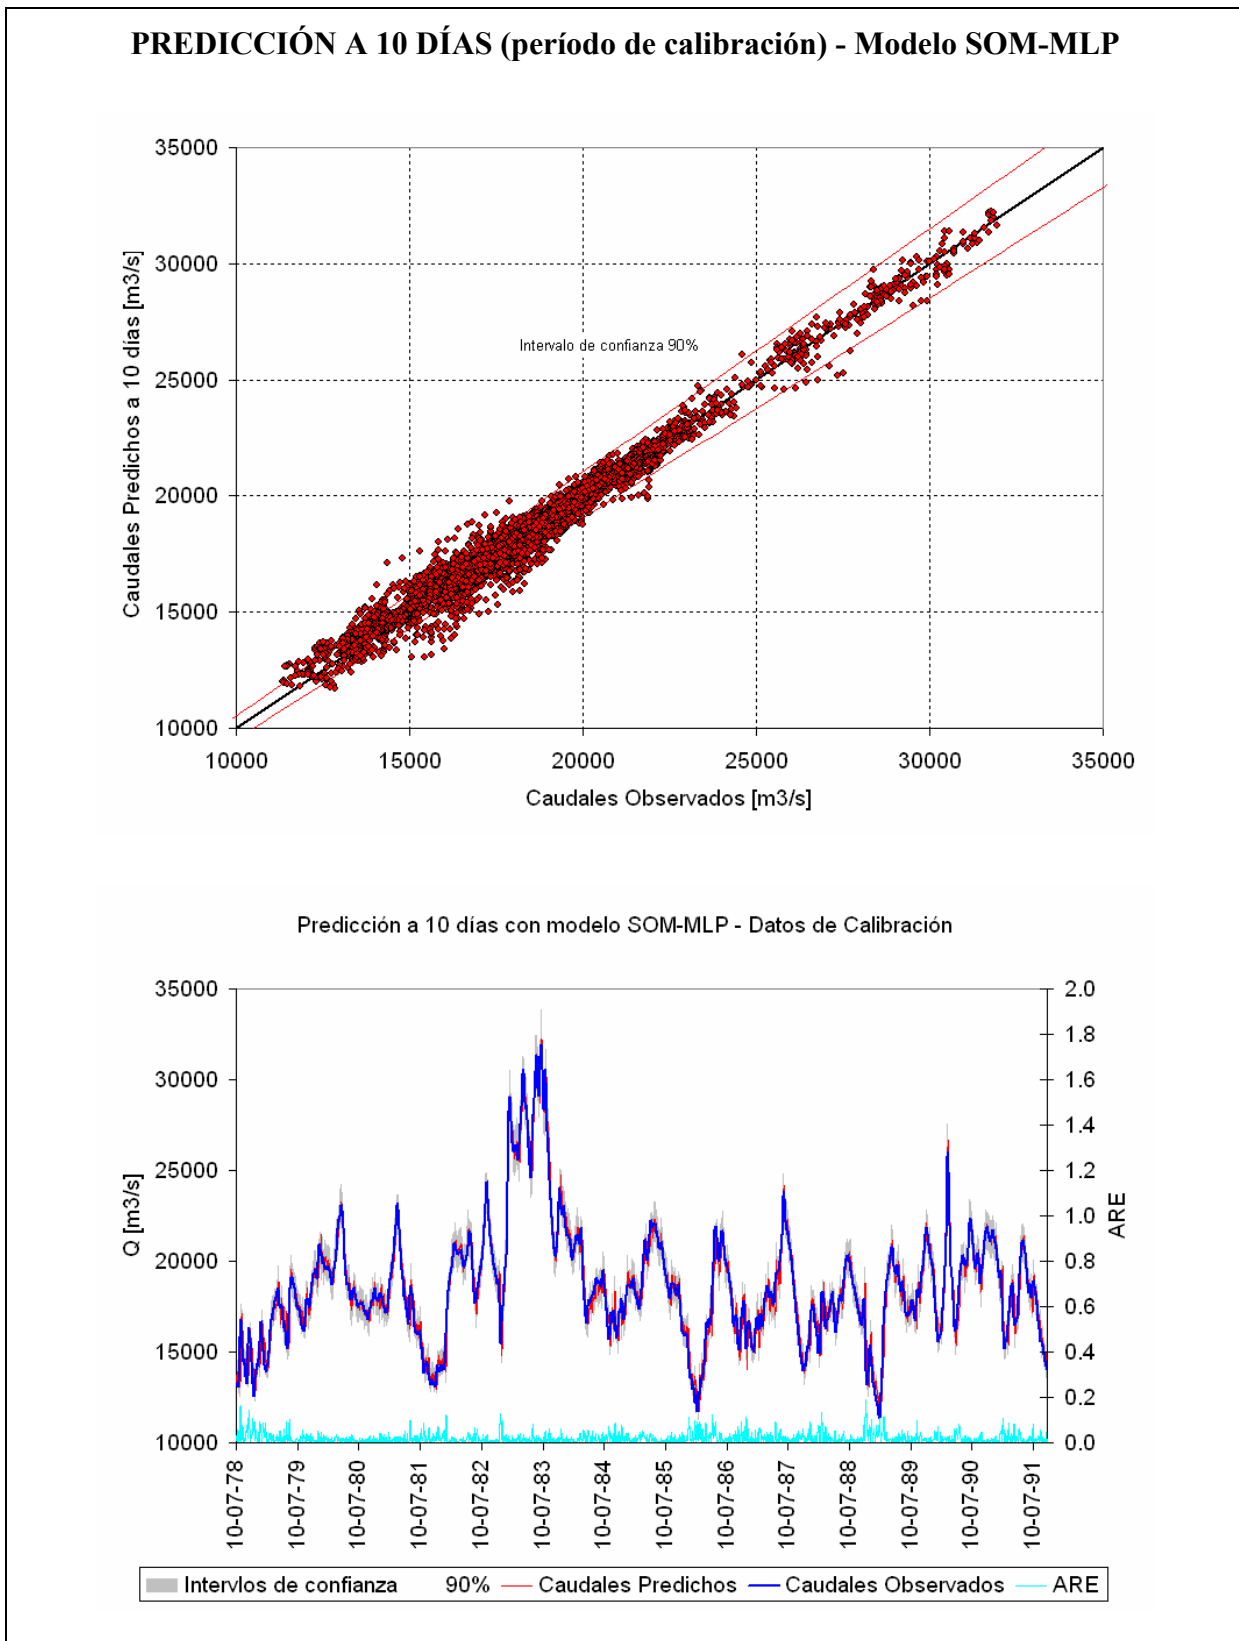


Figura A. 17: Predicción a 10 días del modelo SOM-MLP para el período de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior




Figura A. 18: Predicción a 10 días del modelo modular con separación manual y MLP para el período de calibración. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior

A.2 Aplicación sobre el río Neuquén

A.2.1 Parámetros de los modelos

Parámetros - Hidrogaia S.L.
 Volver Importar/Exportar Parámetros

Parámetros

Parámetros entre capa oculta y capa de salida

	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8	umbral
PasoQ t + 4	-0.66	0.97	-1.64	-0.68	-0.73	-5.25	1.000888594	-0.020040773	4.305934236

Parámetros entre capa de entrada y capa oculta

	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8
umbral	5.99	-11.29	13.27	-6.30	-6.14	0.27032906	11.46687908	2.882142658
PasoQ t - 2	-6.60	-6.49	-1.03	4.22	-2.48	0.02	7.109228657	-4.065223107
PasoQ t - 1	-3.39	-0.82	-5.21	-2.85	1.37	1.691650596	-3.411559733	-2.522249564
PasoQ t - 0	7.43	12.30	-5.65	4.73	-1.03	-2.40	-8.502540329	-4.830602263
CarrizosP-0 t - 0	3.41	10.70	2.33	-4.20	-1.65	-0.011658873	-9.80959462	9.719975493
CarrizosP-1 t - 0	-6.76	0.85	-2.33	6.35	5.90	0.01	-1.827456547	-0.928777813
RahuecoQ t - 0	-2.40	3.72	2.09	1.20	-5.18	-0.016521384	-4.170128801	-5.007411846

Figura A. 19: Parámetros del modelo MLP para el río Neuquén

Parámetros ARMAX
 Volver Importar/Exportar Parámetros

Parámetros

	PasoQ	Carrizos0	Carrizos-1	Rahueco
1	1.024964275	-0.006827398	-0.006510891	-0.052318071
2				0.025717207
4				-0.022473014
5				0.016754292
6				
7				
8				
9				
10				
11				
12				
13				
14				
15				
16				
17				
18				
19				

Figura A. 20: Parámetros del modelo ARMAX para el río Neuquén

	nodo1	nodo2	nodo3	nodo4				
CarrizosP	0.111478	0.019237	0.016516	0.002032				
CarrizosP	0.111363	0.016624	0.019109	0.002054				
Arch MLP	MLP1.txt	MLP2.txt	MLP3.txt	MLP4.txt				
E:\mpujol\Documentos\01_TESIS\07_NEUQUEN\07_Modelos\03_SOM_MLP\02_Modelo								

Figura A. 21: Parámetros del modelo SOM para el río Neuquén

Parámetros entre capa oculta y capa de salida									
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8	umbral
PasoQ t + 4	-0.45	-0.31	0.45	1.94	1.39	-0.44	-2.281011065	-0.863346988	1.377075995
Parámetros entre capa de entrada y capa oculta									
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8	
umbral	-0.40	-5.10	4.06	-2.04	-2.87	1.156871135	-1.090037182	8.409908922	
PasoQ t - 2	-3.61	3.00	-1.05	1.44	5.13	5.05	11.48441831	1.708935329	
PasoQ t - 1	0.77	7.49	-1.03	4.45	-5.18	-0.798541951	3.297346612	-0.705910235	
PasoQ t - 0	5.63	-9.26	-6.28	6.65	5.18	-0.44	-5.274815469	-12.39650076	
CarrizosP-0 t - 0	2.84	1.91	3.37	0.08	-0.14	6.146234218	-0.859673356	4.126706569	
CarrizosP-1 t - 0	2.01	6.42	-6.12	5.64	3.24	-0.14	5.250126139	5.585722532	
RahuecoQ t - 0	4.84	-0.23	5.47	-1.23	-0.76	0.128937535	-1.585668716	-4.453504522	

Figura A. 22: Parámetros del modelo MLP1 para modelo SOM del río Neuquén

Parámetros

Parámetros entre capa oculta y capa de salida

	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	umbral
PasoQ t + 4	67.55	0.09	-22.98	-0.71	-0.56	-0.19	-2.164862653	-43.58826828

Parámetros entre capa de entrada y capa ocul

	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7
umbral	8.96	-0.23	17.68	7.90	-12.14	2.080370357	-7.84486554
PasoQ t - 2	-1.41	2.80	8.02	-2.39	6.88	2.58	-4.709115242
PasoQ t - 1	7.29	5.68	2.30	-5.03	9.31	-5.899611316	9.231946779
PasoQ t - 0	6.66	4.22	-14.69	2.12	-1.01	-3.56	-8.993209414
CarrizosP-0 t - 0	-6.23	-13.23	-23.40	-14.57	20.48	18.36623755	11.53556853
CarrizosP-1 t - 0	-2.35	-3.42	13.07	-7.61	14.39	-6.05	-16.01155359
RahuecoQ t - 0	4.63	14.78	4.53	2.22	-11.23	-4.171881646	2.420991308

Figura A. 23: Parámetros del modelo MLP2 para modelo SOM del río Neuquén

Parámetros

Parámetros entre capa oculta y capa de salida

	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8	umbral
PasoQ t + 4	0.07	0.10	0.18	3.35	-1.18	-1.13	5.137298316	-0.185792482	-6.369096125

Parámetros entre capa de entrada y capa ocul

	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8
umbral	8.88	-18.87	-6.19	0.75	0.73	-22.97384582	7.886528523	7.369556765
PasoQ t - 2	-7.66	7.73	-4.47	1.10	1.34	7.10	1.158159794	2.030392955
PasoQ t - 1	-6.95	1.34	0.25	0.06	5.71	1.393682494	-8.167672418	10.56429687
PasoQ t - 0	-8.69	-1.46	11.94	-3.55	-15.97	-3.38	-6.187656276	-11.16970125
CarrizosP-0 t - 0	7.33	16.69	5.15	-0.04	0.61	7.965966174	2.39158876	7.649360877
CarrizosP-1 t - 0	-10.77	12.95	10.99	-1.10	-1.75	1.21	12.73062633	-0.319404913
RahuecoQ t - 0	11.60	6.77	-3.94	2.73	6.88	-2.62080186	-3.732794896	5.872583678

Figura A. 24: Parámetros del modelo MLP3 para modelo SOM del río Neuquén

Parámetros entre capa oculta y capa de salida									
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8	umbral
Paso0 t + 4	11.12	-1.83	-0.83	-2.81	0.03	-0.03	-2.722837448	0.036548266	-6.252300429
Parámetros entre capa de entrada y capa oct									
	nodo 1	nodo 2	nodo 3	nodo 4	nodo 5	nodo 6	nodo 7	nodo 8	
umbral	17.56	0.80	1.08	-2.27	-4.86	-4.318088808	4.576313597	-2.177208701	
Paso0 t - 2	-0.15	-7.98	12.17	-0.10	-6.17	14.30	13.49670215	10.73686411	
Paso0 t - 1	-10.63	2.42	-1.60	7.97	11.50	6.663683347	11.11497317	11.33981768	
Paso0 t - 0	1.97	-1.79	-11.45	1.71	7.33	-6.27	-2.80363037	1.101233003	
Rahueco0 t - 0	-5.69	10.42	-6.10	-12.21	8.27	5.439916519	-2.697336968	7.388485611	

Figura A. 25: Parámetros del modelo MLP4 para modelo SOM del río Neuquén

Tabla A. 3: Parámetros funciones de distribución lognormal-lognormal para el cálculo de los intervalos de confianza. Modelos del río Neuquén

Modelos	Función distribución marginal para caudales predichos		Función distribución marginal para caudales observados		Coef. correlación
	a	b	a	b	
ARMAX	5.417	0.755	5.389	0.793	0.980
MLP	5.393	0.787	5.389	0.793	0.991
SOM-MLP	5.391	0.791	5.389	0.793	0.991

A.2.2 Resultados de calibración




Figura A. 26: Discretización de picos para el cálculo del PFC en los datos de calibración del modelo del río Neuquén

Tabla A. 4: Peak Flow Criteria. Índice de habilidad de predicción de picos para la serie de calibración del río Neuquén

	PFC
SOM-MLP	55.85
MLP	57.42
ARMAX	62.41

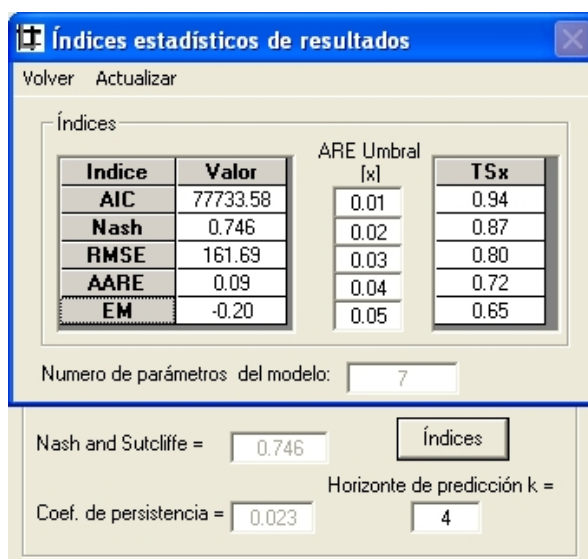


Figura A. 27: Índices de fiabilidad para los resultados de calibración del modelo ARMAX del río Neuquén



Figura A. 28: Índices de fiabilidad para los resultados de calibración del modelo MLP del río Neuquén

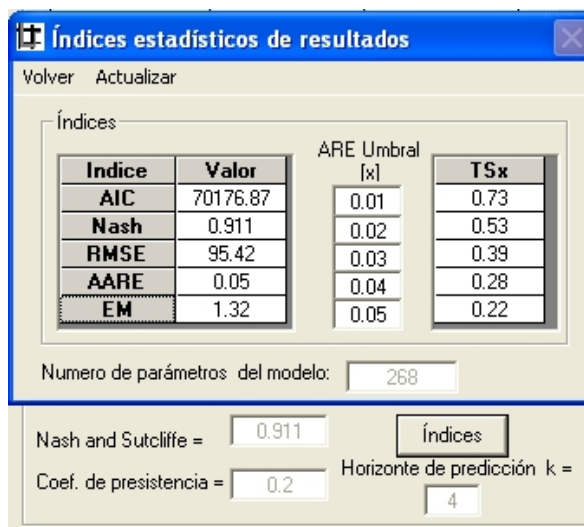


Figura A. 29: Índices de fiabilidad para los resultados de calibración del modelo SOM-MLP del río Neuquén




Figura A. 30: Predicción a 1 día del modelo ARMAX para el período de calibración de la serie del río Neuquén. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior

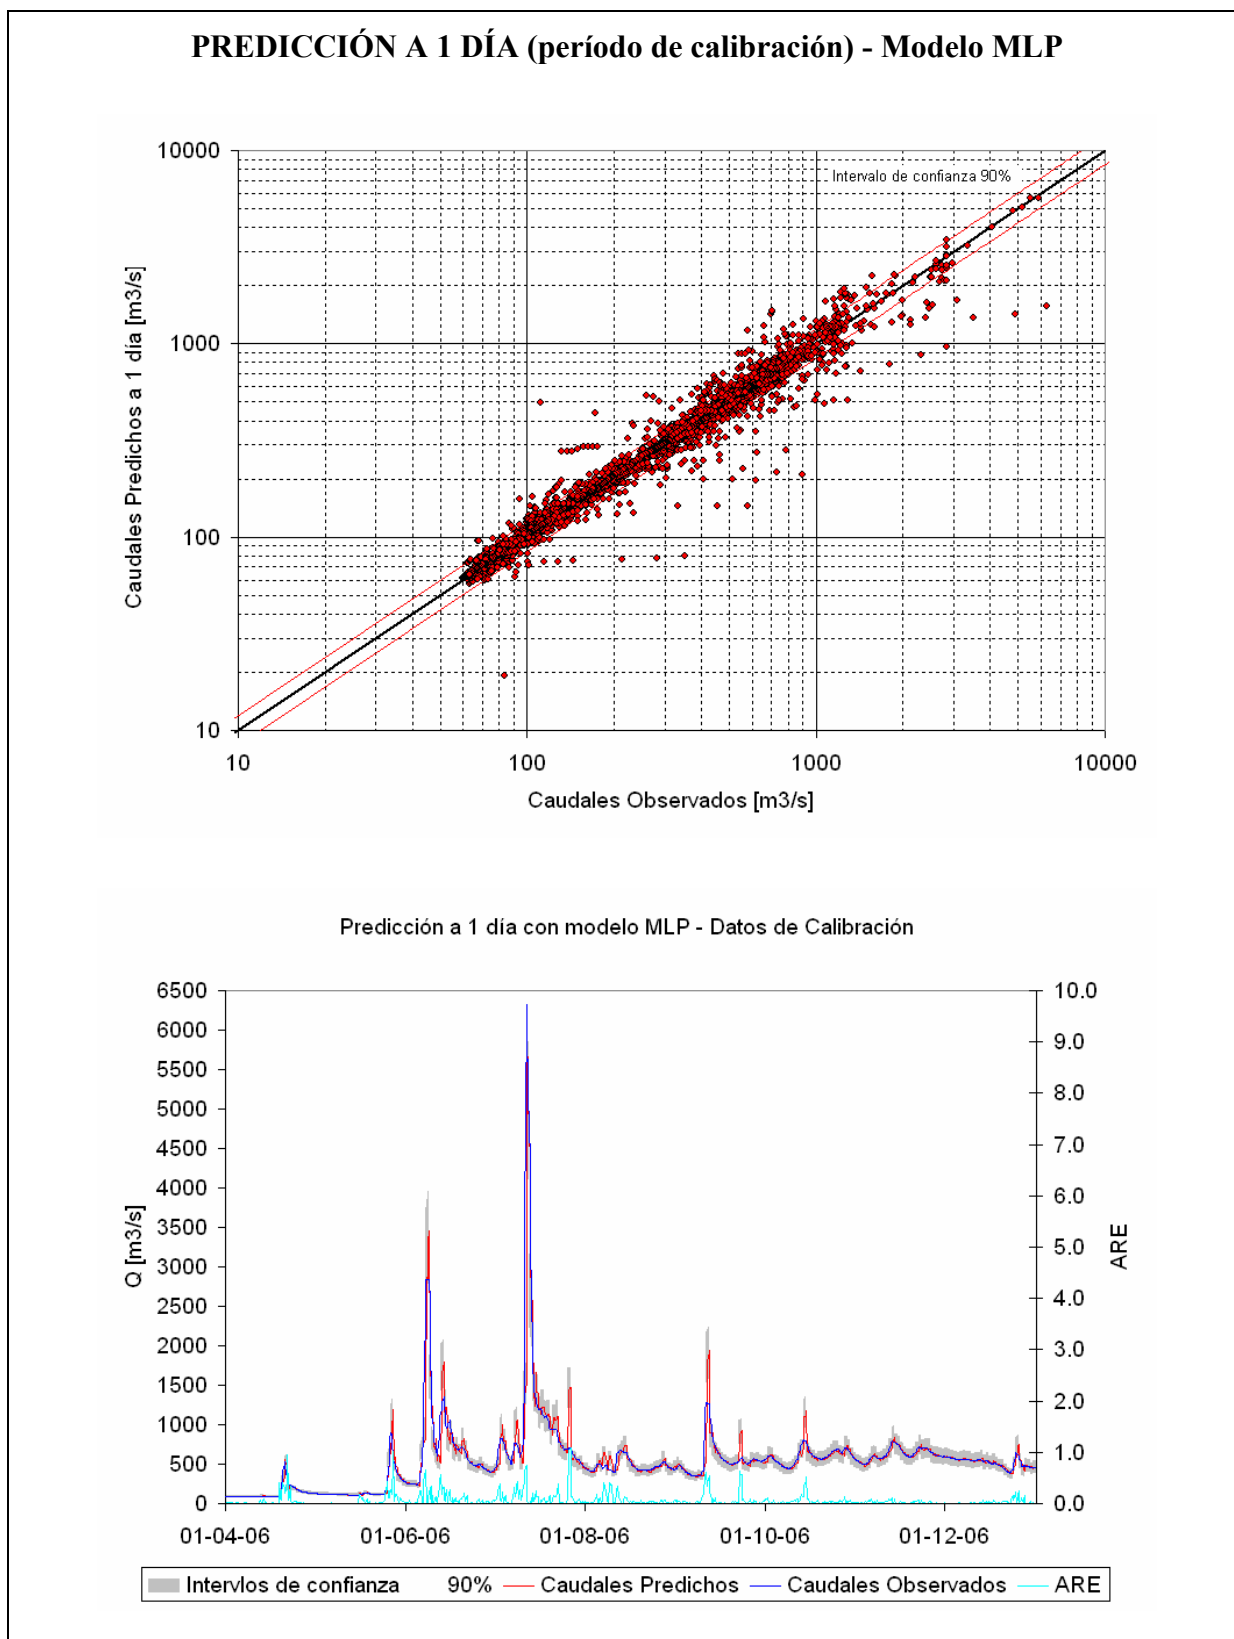


Figura A. 31: Predicción a 1 día del modelo MLP para el período de calibración de la serie del río Neuquén. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior




Figura A. 32: Predicción a 1 día del modelo SOM-MLP para el período de calibración de la serie del río Neuquén. Las líneas rojas en la figura superior representan los intervalos de confianza del 90%, al igual que las sombras grises de la inferior

B Intervalos de confianza

B.1 Introducción

En este apéndice se muestran los resultados de la utilización de la metodología para el cálculo de la incertidumbre de las predicciones de los modelos de redes neuronales.

Se comparan diferentes funciones de densidad de probabilidad y se representan gráficamente los resultados.

El modelo utilizado para esta comparación es un MLP de predicción de caudales a 10 días en la estación de “Chapetón”, Paraná. Para el cálculo de los intervalos de confianza del 90% se utiliza la serie de calibración.

Se calculan las probabilidades del 0.05 y 0.95 de que, dado un cierto caudal predicho (x), el caudal observado sea y . Los cálculos se realizan con el software desarrollado para esta tesis.

Para determinar las funciones marginales más adecuadas para cada serie se prueba entre varias, se calcula el valor de máxima verosimilitud (*Maximum likelihood*) y se elige la distribución de mayor valor.

B.2 Resultados para la serie de calibración del modelo del Paraná

En este caso las distribuciones elegidas son las lognormales, obteniendo los resultados siguientes:




Figura B. 1: Caudales observados en función de los caudales predichos de la serie de calibración. Intervalo de confianza del 90% entre las línea roja y magenta. La línea negra es la línea de predicción exacta y la línea azul, la de 50% de probabilidad. Las curvas circulares representan la función de densidad de probabilidad




Figura B. 2: Función de densidad bivariada entre caudales predichos y caudales observados (de calibración) con marginales lognormales




Figura B. 3: Azul caudal predicho, negro caudal observado (de datos de calibración), magenta y rojo intervalo de confianza del 90%

B.3 Resultados para la serie de validación del modelo del Paraná

Se verifica que los intervalos calculados con los datos de calibración también tengan coherencia para los datos de validación.




Figura B. 4: Caudales observados en función de los caudales predichos de la serie de validación. Intervalo de confianza del 90% entre las línea roja y magenta. La línea negra es la línea de predicción exacta y la línea azul, la de 50% de probabilidad. Las curvas circulares representan la función de densidad de probabilidad




Figura B. 5: Función de densidad bivariada entre caudales predichos y caudales observados (de validación) con marginales lognormales calculados con los datos de calibración





Figura B. 6: Caudal predicho (azul), caudal observado de datos de validación (negro), e intervalo de confianza del 90% (magenta y rojo)

B.4 Comparación con diferentes funciones marginales

Se comparan los resultados de los intervalos de confianza utilizando diferentes funciones marginales para los caudales predichos y observados.

Se utilizan las siguientes funciones: LogLogistic, Gamma, Lognormal, Normal, Logistic e Inverse gaussian.






Figura B. 7: Funciones de distribución de probabilidad para los caudales observados

















Figura B. 8: Funciones de distribución de probabilidad para los caudales predichos

En las siguientes gráficas se muestran los diferentes intervalos de confianza según la función de distribución marginal utilizada.









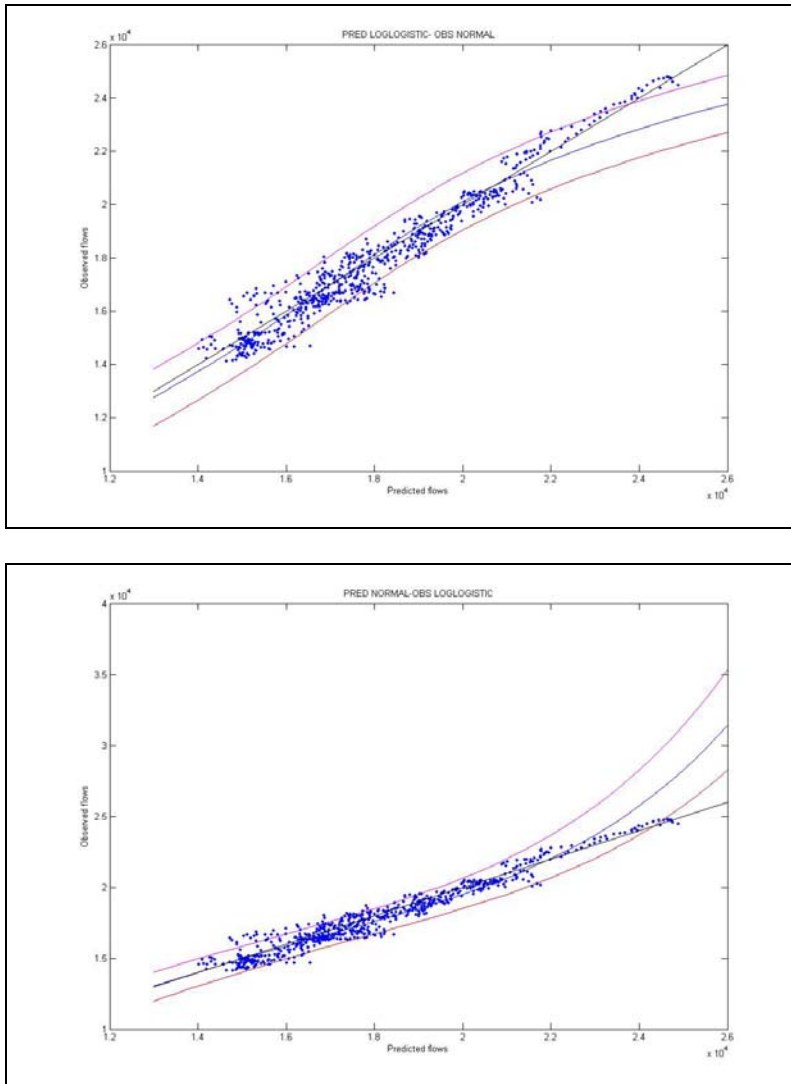


Figura B. 9: Gráficas de diferentes intervalos de confianza variando las funciones de densidad marginales de los caudales observados y predichos




Figura B. 10: Variación, a lo largo de los caudales predichos, de la diferencia entre el límite superior e inferior de los intervalos de confianza, calculados con diferentes funciones de distribución marginales

C Medidas de evaluación de los modelos y test de normalidad

C.1 Medidas de evaluación de los modelos

Para la evaluación del rendimiento de los modelos se utilizan los siguientes índices:

- *Coficiente de Nash and Sutcliffe*, 1970 (E o Nash)

$$E = 1 - \frac{\sum_{i=1}^n (Q_i^{pre} - Q_i)^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2}$$

[C. 1]

donde,

Q_i es el valor i^{smo} de la serie observada

Q_i^{pre} es el valor i^{smo} de la serie predicha

n es el total de elementos de la serie.

$E = 1$ indica una predicción perfecta, mientras que $E = 0$ indica que la predicción es igual a la media de los valores observados.

- *Raíz del error cuadrado medio (RMSE)*

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_i - Q_i^{pre})^2}{n}}$$

[C. 2]

Se ha demostrado en Elshorbagy et al., 2000, que esta medida no es muy adecuada para la indicación de la bondad del modelo. Es necesario utilizar diferentes índices y analizarlos para evaluar correctamente un modelo.

- *Error cuadrático medio (MSE)*

$$MSE = \frac{\sum_{i=1}^n (Q_i - Q_i^{pre})^2}{n}$$

[C. 3]

- *Error Medio (EM)*

$$EM = \frac{\sum_{i=1}^n (Q_i - Q_i^{pre})}{n} \quad [C. 4]$$

Esta medida no es adecuada para la medición del comportamiento de un modelo, ya que un modelo con error medio igual a cero puede ser un modelo con una salida constante igual a la media.

- *Valor absoluto medio del error relativo (AARE)*

$$AARE = \frac{\sum_{i=1}^n \left| \frac{Q_i - Q_i^{pre}}{Q_i} \right|}{n} \quad [C. 5]$$

- *Peak Flow Criterion (PFC)*

$$PFC = \left(\frac{\sum_{i=1}^{n_p} (Q_i^p - Q_i^{pre})^2 Q_i^{p^2}}{\sum_{i=1}^{n_p} Q_i^{p^2}} \right)^{1/4} \quad [C. 6]$$

donde,

Q_i^p es el valor i^{smo} del caudal pico de la serie de caudales observados en el tiempo t

Q_i^{pre} es el valor i^{smo} que corresponde al caudal predicho en el tiempo t

n_p es la cantidad total de caudales pico seleccionados

Valores bajos de PFC indican buenas predicciones de los caudales picos y una predicción perfecta hace a PFC igual a cero.

- *Akaike Information Criterion (AIC)*

$$AIC(p, q, r) = N \ln(\sigma_\varepsilon^2) + 2(q + p + r) \quad [C. 7]$$

donde,

σ_ε^2 es la varianza estimada del error del modelo

p, q y r son los órdenes del modelo (cantidad de parámetros)

Este índice utiliza el “principio de parsimonia” para un modelo tipo ARMAX(p, r, q). Tiene en cuenta la precisión del modelo con la varianza de los errores y la cantidad de parámetros con q, p y r. El mejor modelo es el que tiene menor AIC.

- *Estadístico de umbral (TS)*

$$TS_x = \frac{N_x}{N}$$

[C. 8]

donde,

N_x es el número de predicciones para los cuales el error absoluto relativo (*ARE*) es menor que un cierto umbral x determinado a partir de los resultados.

N es el número total de predicciones

Para poder analizar la calidad de las predicciones, se calculan los mismos coeficientes para el modelo de persistencia (*Naïve*), que es $Q_{t+k}^{pred} = Q_t$.

El MSE y E son estadísticos globales y no proveen ninguna información sobre la distribución de los errores. El MSE sólo da información de la habilidad del modelo para predecir un valor fuera de la media [Hsu et al., 1995]. Por eso es importante utilizar coeficientes diversos como el AARE y TS [Jain et al., 2001] los cuales no sólo son índices de fiabilidad de la predicción de niveles, sino también de la distribución de los errores de predicción. Por otro lado el PFC [Ribeiro et al., 1998] aporta información acerca de la calidad de la predicción de los caudales pico.

C.2 Test de normalidad

Para estudiar la normalidad de la distribución de una serie temporal se pueden utilizar las técnicas que se enumeran a continuación:

- Gráficos: el gráfico de cajas, el histograma, la estimación no paramétrica de la función de densidad, el gráfico de simetría y los gráficos $p - p$ y $q - q$.
- Contrastes de normalidad: contraste de asimetría y curtosis, contraste chi-cuadrado, contraste de Kolmogoroff-Smirnoff-Lilliefors.

El test de normalidad del coeficiente de asimetría se basa en el hecho de que este coeficiente es cero para una variable distribuida de manera normal. El coeficiente de asimetría viene dado por:

$$s_k = \frac{\frac{1}{N} \sum_{t=1}^N (x_t - \bar{x})^3}{\left[\frac{1}{N} \sum_{t=1}^N (x_t - \bar{x})^2 \right]^{3/2}}$$

[C. 9]

donde,

\bar{x} es la media de la muestra

N la cantidad de datos de la variable x

Si las series provienen de una distribución normal, s_k se distribuye asintóticamente normal, con media cero y varianza $6/N$ [Snedecor y Cochran, 1967, p86]. Entonces los límites de probabilidad $(1-\alpha)$ de s_k se definen por:

$$\left[-\mu_{1-\alpha/2} \sqrt{\frac{6}{N}}, \mu_{1-\alpha/2} \sqrt{\frac{6}{N}} \right]$$

[C. 10]

donde, $\mu_{1-\alpha/2}$ es el cuantil $\mu_{1-\alpha/2}$ para límites de probabilidad de la distribución normal estándar.

Para límites del 98%, α es igual a 0.02 y $\mu_{1-\alpha/2} = 2.33$. Para el 90%, α es igual a 0.1 y $\mu_{1-\alpha/2} = 1.64$.

Entonces, si s_k se encuentra entre los límites de esta expresión, la hipótesis de normalidad es aceptada. Si no, es rechazada.

Este test es suficientemente preciso para $N > 150$. Para series de menor tamaño, Snedecor y Cochran sugieren compararlo con los coeficientes de asimetría tabulados (ver Tabla C. 1) que dependen del nivel de probabilidad seleccionado. Si s_k es menor al de la tabla, la hipótesis de normalidad es aceptada.

Tabla C. 1: Coeficientes de asimetría para series con menos de 150 datos (fuente: Salas et al., 1980, pag.93)

	α			α	
N	0.02	0.1	N	0.02	0.1
25	1.061	0.711	70	0.673	0.459
30	0.896	0.662	80	0.631	0.432
35	0.923	0.621	90	0.596	0.409
40	0.870	0.587	100	0.567	0.289
45	0.825	0.558	125	0.508	0.350
50	0.787	0.534	150	0.464	0.321
60	0.723	0.492	175	0.430	0.298

D Distribución Meta-Gaussiana

Para el cálculo de la distribución conjunta de las predicciones con las observaciones, se propone utilizar la distribución meta-gaussiana [Kelly y Krzysztofowicz, 1997].

Dado un vector (X, Y) de variables aleatorias se definen las funciones de distribución marginales F de X y G de Y , las cuales son arbitrarias, estrictamente crecientes y continuas, con funciones de densidad f y g , respectivamente. La función de distribución meta-gaussiana [Kelly y Krzysztofowicz, 1997] H y la densidad h de (X, Y) son:

$$H(x, y) = P(X \leq x, Y \leq y) = B(Q^{-1}(F(x)), Q^{-1}(G(y)); \gamma),$$

[D. 1]

$$h(x, y) = \frac{f(x)g(y)}{\sqrt{1-\gamma^2}} e^{\frac{-\gamma}{2(1-\gamma^2)} \gamma [Q^{-1}(F(x))]^2 - 2 [Q^{-1}(F(x))][Q^{-1}(G(y))] + \gamma [Q^{-1}(G(y))]^2}$$

[D. 2]

donde,

B es la función de distribución bivariada normal estándar

Q^{-1} es la inversa de la distribución normal estándar Q

γ es el coeficiente de correlación de *Pearson* entre las variables W y Z , que se relacionan con las variables originales a través de la transformación normal (*Normal Quantile Transform NQT*)

$$Z = Q^{-1}(F(X))$$

[D. 3]

$$W = Q^{-1}(G(Y))$$

[D. 4]

Las distribuciones marginales F y G se especifican y la NQT garantiza que Z y W sean variables normales estándar. Esto no significa que (Z, W) sea normal bivariada. No existe restricción sobre el tipo de distribución F y G . Dado que se asume una estructura gaussiana de dependencia entre W y Z , se puede determinar la expresión analítica de la densidad bivariada (X, Y) sin importar la forma de sus marginales.

También es posible derivar la expresión analítica para cuantiles de Y condicionados a $X = x$. En el espacio de las variables transformadas, la media condicional $E(W/z) = \gamma z$ y la varianza condicional $VAR(W/z) = 1 - \gamma^2$ definen la distribución W condicionada a $Z = z$. Transformando las variables a su espacio original, la distribución de Y condicionada a $X = x$ tiene la siguiente forma:

$$K(y|x) = \mathcal{Q}\left(\frac{\mathcal{Q}^{-1}(G(y)) - \gamma \mathcal{Q}^{-1}(F(x))}{\sqrt{1 - \gamma^2}}\right)$$

[D. 5]

La probabilidad condicional de Y , dado $X = x$, para $0 < p < 1$ es una observación $y_{p/x}$ de Y , tal que $p = K(y/x)$. Resolviendo esta ecuación para $y_{p/x}$ se obtiene:

$$y_{p/x} = G^{-1}\left(\mathcal{Q}\left(\gamma \mathcal{Q}^{-1}(F(x)) + \sqrt{1 - \gamma^2} \mathcal{Q}^{-1}(p)\right)\right)$$

[D. 6]

Esta expresión demuestra la no linealidad monótona de la estructura de dependencia de la distribución meta-gaussiana: para cada p , la cuantil condicional $y_{p/x}$ es una función de x no lineal y monótona.

Los intervalos de confianza se calculan con la ecuación [D. 6]. Por ejemplo, si se quiere obtener el intervalo de confianza del 90% es necesario calcular la función para los cuantiles 0.05 y 0.95.

Se pueden elegir diferentes funciones de densidad para cada variable. En el Apéndice B se muestran los resultados del cálculo de los límites de confianza para el modelo de predicción de caudales (MLP) a 10 días en la estación “Chapetón”, Paraná. Se compara también la utilización de diferentes funciones marginales G y F .