



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FISICAS Y MATEMATICAS
DEPARTAMENTO DE INGENIERIA CIVIL

**PRONÓSTICO DE CAUDALES DE DESHIELO A DISTINTAS
ESCALAS TEMPORALES, USANDO REDES NEURONALES
ARTIFICIALES EN LA CUENCA DEL RÍO MAPOCHO EN LOS
ALMENDROS**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL

MONTSERRAT ARTIGAS MUÑOZ

PROFESOR GUÍA:
XIMENA VARGAS MESA

MIEMBROS DE LA COMISIÓN:
MIGUEL ÁNGEL LAGOS ZÚÑIGA
EDUARDO RUBIO ÁLVAREZ.

SANTIAGO DE CHILE
2015

PRONÓSTICO DE CAUDALES DE DESHIELO A DISTINTAS ESCALAS TEMPORALES, USANDO REDES NEURONALES ARTIFICIALES EN LA CUENCA DEL RÍO MAPOCHO EN LOS ALMENDROS

Actualmente se vive una situación de estrechez hídrica prolongada en la mayor parte del territorio nacional, donde se observa que desde la VI región hacia el norte, la demanda de agua dulce supera la oferta. Una de las principales fuentes de agua dulce la constituyen aquellas provenientes del derretimiento de nieves, por lo cual el modelar su derretimiento a escalas temporales finas, es decir, escalas temporales menores a la mensual, con el objeto de gestionar y utilizar el recurso hídrico de forma óptima, resulta de gran importancia.

La presente memoria consiste en la elaboración de distintas redes neuronales artificiales con el objetivo de pronosticar caudales de deshielo a tres escalas temporales, las cuales son la escala diaria, semanal y quincenal, para la cuenca Mapocho en los Almendros. Adicionalmente, se evalúan y analizan los efectos de incluir datos hidrometeorológicos provenientes de la estación en Valle Nevado, tales como humedad del aire, temperatura y precipitación, en las redes neuronales.

La metodología consta de cinco partes, en primera instancia se estudian las redes neuronales artificiales (RNA) mediante revisión bibliográfica, luego se realiza un análisis teórico del fenómeno en estudio con el objetivo de definir las variables significativas y poder formular las RNA para el pronóstico de caudales de deshielo a los distintos niveles temporales y seleccionar la RNA óptima para cada nivel. Finalmente se realiza la inclusión de los datos hidrometeorológicos de la estación Valle Nevado en los modelos RNA, concluyendo con un análisis de resultados, en el cual se simulan las RNA óptimas para la temporada de deshielo 2013 – 2014.

Los resultados indican que se obtuvieron RNA con coeficientes de correlación de Pearson “R²” mayores a 0.99 en el caso de las escalas temporales diaria y quincenal y mayores a 0.98 en el caso de la escala temporal semanal. Al simular las RNA óptimas para la temporada de deshielo 2013-2014, se obtuvieron caudales con errores absolutos promedio de 0.18 m³/s (5.6 %) para la escala temporal diaria, 0.39 m³/s (11.6%) para la escala temporal semanal y 0.38 m³/s (11.5%) para la escala temporal quincenal.

Respecto a los parámetros de entrada, se concluye que aquellos más significativos, son los relacionados al caudal y la temperatura máxima, lo cual se observa tanto para las RNAs entrenadas con datos de la estación Mapocho en Los Almendros como de la estación Valle Nevado.

Por último, debido a la escasa disponibilidad de datos y a la baja calidad de los mismos, los resultados obtenidos a partir de las RNAs entrenadas con datos de la estación Valle Nevado, no permiten decir con certeza si la inclusión de datos provenientes de una estación ubicada a 3.000 m.s.n.m. implican una mejora en los pronósticos de caudales de deshielo.

Tabla de Contenido

Índice de Tablas	v
Índice de Figuras	viii
Capítulo 1.- Introducción	1
1.1 Motivación	1
1.2 Objetivos	2
1.3 Organización del Documento	3
Capítulo 2.- Revisión Bibliográfica	4
2.1 Redes Neuronales Artificiales	4
2.1.1 Estructura de las Redes Neuronales Artificiales	4
2.1.2 Arquitectura de las RNA	7
2.1.3 Procesos de Aprendizaje	8
2.1.4 Algoritmos de Entrenamiento	9
2.1.5 Sobre-entrenamiento, Regularización y Detención Temprana	12
2.3 Hidrología de Nieves	14
2.3.1 Balance Energético.....	14
2.3.2 Balance de Masa.....	16
Capítulo 3.- Zona en Estudio	17
3.1 Caracterización de la Zona en Estudio.....	17
3.2 Clima de la Región	18
3.3 Estaciones Fluviométricas y Meteorológicas	18
Capítulo 4.- Resultados	24
4.1 Calibración con datos de estación Mapocho en Los Almendros	25
4.1.1 RNA a escala Diaria.....	27
4.1.2 RNA a escala Semanal	31
4.1.3 RNA a escala Quincenal	39
4.2 Calibración con datos de estación Valle Nevado.....	48
4.2.1 RNA a escala Diaria.....	49
4.2.2 RNA a escala Semanal	54
4.2.3 RNA a escala Quincenal	57
Capítulo 5.- Análisis de Resultados	61

5.1 Simulación con RNA óptima a escala Diaria	61
5.2 Simulación con RNA óptima a escala Semanal.....	63
5.1 Simulación con RNA óptima a escala Quincenal	67
Capítulo 6.- Conclusiones	71
6.1 Conclusiones RNA usando datos estación Mapocho en Los Almendros	71
6.2 Conclusiones RNA usando datos estación Valle Nevado.....	72
6.3 Conclusiones generales y Comentarios	73
Capítulo 7.- Bibliografía	75
Capítulo 8.- Anexos	77
Anexo 1. “ <i>Toolbox de RNA de Matlab</i> ”	77
Anexo 2. “ <i>Estadísticas Fluviométricas y Meteorológicas</i> ”	80
2.1 Regresiones Mensuales de Temperaturas Mínimas	81
2.2 Regresiones Mensuales de Temperaturas Máximas.....	85
2.3 Regresiones Mensuales de Precipitaciones	89
2.4 Regresiones Mensuales de Caudales.....	92
Anexo 3. “ <i>Coefficientes de Correlación de Pearson, RNA para Mapocho en los Almendros</i> ”	96
3.1 Coeficientes de Correlación de Pearson, RNA Diarias.....	97
3.2 Coeficientes de Correlación de Pearson, RNA Semanales.	99
3.3 Coeficientes de Correlación de Pearson, RNA Quincenales.....	103
Anexo 4. “ <i>Coefficientes de Correlación de Pearson, RNA para Valle Nevado</i> ”	107
4.1 Coeficientes de Correlación de Pearson, RNA Diarias.....	108
4.2 Coeficientes de Correlación de Pearson, RNA Semanales.	110
4.3 Coeficientes de Correlación de Pearson, RNA Quincenales.....	112

Índice de Tablas

Tabla 3.1 Características de las Estaciones Utilizadas.....	19
Tabla 3.2 Calidad de la información, donde "a" corresponde a 10 meses con información completa, "b" a 11 meses con información completa y "c" a 12 meses con información completa.....	21
Tabla 3.3 Valores de R^2 mensuales para Temperaturas extremas entre estación Mapocho en Los Almendros y Cerro Calán; y para Caudal entre estación Mapocho en Los Almendros y Estero Arrayán en la Montosa.....	22
Tabla 3.4 Valores de R^2 mensuales para las Precipitaciones entre Mapocho en los Almendros y Cerro Calán.....	22
Tabla 4.1 Parámetros de entrada seleccionados para las redes neuronales artificiales.....	25
Tabla 4.2 Tipos de Redes entrenadas para la Serie Diaria.....	27
Tabla 4.3 Parámetros de entrada RNA escala Diaria.....	27
Tabla 4.4 Red Diaria Óptima para el primer caso "Junio-Agosto".....	28
Tabla 4.5 Red Diaria Óptima para el segundo caso "Mayo-Septiembre".....	28
Tabla 4.6 Pesos desde la Capa de Entrada a la Capa Oculta "Pesos 1,1", Red Diaria "Mayo – Sept".....	30
Tabla 4.7 Pesos desde la Capa Oculta a la Capa de Salida "Pesos 2,1", Bias de la Capa Oculta "Bias 1,1" y Bias de la Capa de Salida "Bias 2,1", Red Diaria "Mayo - Sept".....	31
Tabla 4.8 Parámetro de entrada redes 1 y 2, escala Semanal.....	31
Tabla 4.9 Parámetro de entrada redes 3 y 4, escala Semanal.....	32
Tabla 4.10 Configuración óptima para la Red Semanal 1 "Junio - Agosto".....	32
Tabla 4.11 Configuración óptima para la Red Semanal 2 "Mayo - Septiembre".....	33
Tabla 4.12 Configuración óptima para la Red Semanal 3 "T° max día-1".....	33
Tabla 4.13 Configuración óptima para la Red Semanal 4 "T°max día".....	33
Tabla 4.14 Pesos desde la Capa de Entrada a la Capa Oculta "Pesos 1,1", Red Semanal 2 "Mayo – Septiembre".....	35
Tabla 4.15 Pesos desde la Capa Oculta a la Capa de Salida "Pesos 2,1", Bias de la Capa Oculta "Bias 1,1" y Bias de la Capa de Salida "Bias 2,1", Red Semanal 2 "Mayo - Septiembre" ..	36
Tabla 4.16 Pesos desde la Capa de Entrada a la Capa Oculta "Pesos 1,1", Red Semanal 4 "T°max día".....	38

Tabla 4.17 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Semanal 4 "T°max día”	39
Tabla 4.18 Parámetros de entrada Redes 1 y 2, escala Quincenal	40
Tabla 4.19 Parámetros de entrada Redes 3 y 4, escala Quincenal	40
Tabla 4.20 Configuración óptima para la Red Quincenal 1 "Junio - Agosto"	41
Tabla 4.21 Configuración óptima para la Red Quincenal 2 "Mayo - Septiembre"	41
Tabla 4.22 Configuración óptima para la Red Quincenal 3 "T° max día-1"	41
Tabla 4.23 Configuración óptima para la Red Quincenal 4 "T° max día"	41
Tabla 4.24 Pesos desde la Capa de Entrada a la Capa Oculta “Pesos 1,1”	43
Tabla 4.25 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Quincenal 2 "Mayo - Septiembre”	44
Tabla 4.26 Pesos desde la Capa de Entrada a la Capa Oculta “Pesos 1,1”, Red Quincenal 4 “T°max día”	46
Tabla 4.27 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Quincenal 4 "T°max día”	47
Tabla 4.28 Parámetros de entrada para análisis de significancia.	49
Tabla 4.29 Análisis de Variables Significativas, Escala temporal Diaria	50
Tabla 4.30 Parámetros de Entrada, RNA calibradas para la escala temporal diaria	50
Tabla 4.31 Promedios, Desviación Estándar y Mejores Coeficientes de Correlación de Pearson, para las tres redes calibradas.	51
Tabla 4.32 Pesos y Bias para la red óptima Valle Nevado 3	52
Tabla 4.33 Parámetros de entrada, Red Mapocho en Los Almendros escala diaria	52
Tabla 4.34 Pesos y Bias, Mapocho en Los Almendros, Diaria	53
Tabla 4.35 Análisis de Variables Significativas, Escala temporal Semanal	54
Tabla 4.36 Parámetros de Entrada, RNA calibradas para la escala temporal semanal	54
Tabla 4.37 Promedios, Desviación Estándar y Mejores Coeficientes de Correlación de Pearson, para las tres redes calibradas.	55
Tabla 4.38 Pesos y Bias para la red óptima Valle Nevado 2	56
Tabla 4.39 Parámetros de entrada, Red Mapocho en Los Almendros escala semanal	56
Tabla 4.40 Pesos y Bias, Mapocho en Los Almendros, Semanal	57
Tabla 4.41 Análisis de variables significativas, escala temporal quincenal	57
Tabla 4.42 Parámetros de Entrada, RNA calibradas para la escala temporal quincenal.	58

Tabla 4.43 Promedios, Desviación Estándar y Mejores Coeficientes de Correlación de Pearson, para las tres redes calibradas	58
Tabla 4.44 Pesos y Bias, Valle Nevado 2.....	59
Tabla 4.45 Parámetros de entrada, Red Mapocho en Los Almendros escala quincenal.	59
Tabla 4.46 Pesos y Bias, Mapocho en Los Almendros, Quincena.....	60
Tabla 8.1 Características de RNA calibradas para "Junio-Agosto"	97
Tabla 8.2 Coeficientes de Correlación de Pearson, RNA diaria "Junio-Agosto"	97
Tabla 8.3 Características de RNA calibradas para "Mayo - Septiembre"	98
Tabla 8.4 Coeficientes de Correlación de Pearson, RNA diaria "Mayo - Septiembre"	98
Tabla 8.5 Características de RNA calibradas para Red 1 "Junio - Agosto"	99
Tabla 8.6 Coeficientes de Correlación de Pearson, RNA semanal Red 1 "Junio - Agosto"	99
Tabla 8.7 Características de RNA calibradas para Red 2 "Mayo - Septiembre".....	100
Tabla 8.8 Coeficientes de Correlación de Pearson, RNA semanal Red 2 "Mayo - Septiembre".....	100
Tabla 8.9 Características de RNA calibradas para Red 3 "Tmax día - 1"	101
Tabla 8.10 Coeficientes de Correlación de Pearson, RNA semanal Red 3 "Tmax día - 1"	101
Tabla 8.11 Características de RNA calibradas para Red 4 "Tmax día"	102
Tabla 8.12 Coeficientes de Correlación de Pearson, RNA semanal Red 4 "Tmax día"	102
Tabla 8.13 Características de RNA calibradas para Red 1 "Junio - Agosto"	103
Tabla 8.14 Coeficientes de Correlación de Pearson, RNA quincenal Red 1 "junio - Agosto" ..	103
Tabla 8.15 Características de RNA calibradas para Red 2 "Mayo - Septiembre".....	104
Tabla 8.16 Coeficientes de Correlación de Pearson, RNA quincenal Red 2 "Mayo - Septiembre"	104
Tabla 8.17 Características de RNA calibradas para Red 3 "Tmax día -1"	105
Tabla 8.18 Coeficientes de Correlación de Pearson, RNA quincenal Red 3 "Tmax día -1"	105
Tabla 8.19 Características de RNA calibradas para Red 4 "Tamx día"	106
Tabla 8.20 Coeficientes de Correlación de Pearson, RNA quincenal Red 4 "Tmax día"	106
Tabla 8.21 Coeficientes de Correlación de Pearson para Variables significativas, RNA Diarias	108
Tabla 8.22 Coeficientes de Correlación de Pearson, RNA diarias	109
Tabla 8.23 Coeficientes de Correlación de Pearson para Variables significativas, RNA Semanales.....	110
Tabla 8.24 Coeficientes de Correlación de Pearson, RNA semanales	111

Tabla 8.25 Coeficientes de Correlación de Pearson para Variables significativas, RNA Quincenales	112
Tabla 8.26 Coeficientes de Correlación de Pearson, RNA quincenales.....	113

Índice de Figuras

Figura 1.1 Generación de energía eléctrica por distintas fuentes para el año 2011	1
Figura 1.1 Generación de energía eléctrica por distintas fuentes para el año 2011	1
Figura 2.1 Esquema de funcionamiento de una Red Neuronal Artificial.	4
Figura 2.2 Capas de una Red Neuronal Artificial	5
Figura 2.3 Principales tipos de Funciones de Transferencia, donde la columna llamada “función” se refiere al nombre o función en el Toolbox de Matlab.	6
Figura 2.4 Tres arquitecturas de RNA: a) Red feedforward, b) Red competitiva, c) Red recurrente.	7
Figura 2.5 Balance Energético de una capa de Nieve.	16
Figura 3.1 Cuenca Mapocho en Los Almendros, estaciones fluviométricas “Mapocho en los Almendros”, “Estero Arrayán en la Montosa” y estaciones meteorológicas “Mapocho en Los Almendros”, “Cerro Calán”.	17
Figura 3.2 Curvas de Variación Estacional, Mapocho en Los Almendros	19
Figura 3.3 Curvas de Variación Estacional, Estero Arrayán en La Montosa	19
Figura 3.4 Curvas de Variación Estacional, Cerro Calán	20
Figura 4.1 Arquitectura RNA Diaria óptima "Mayo-Septiembre"	29
Figura 4.2 Coeficientes de correlación de Pearson, Red Diaria "Mayo - Sept"	29
Figura 4.3 Histograma de Errores, Red Diaria "Mayo - Sept"	30
Figura 4.4 Arquitectura RNA Semanal 2 "Mayo-Septiembre"	33
Figura 4.5 Coeficientes de correlación de Pearson, Red Semanal 2 "Mayo - Septiembre"	34
Figura 4.6 Histograma de Errores, Red Semanal 2 "Mayo - Septiembre"	34
Figura 4.7 Arquitectura RNA Semanal 4 "Tmax día"	36
Figura 4.8 Coeficientes de correlación de Pearson, Red Semanal 4 "T° max día"	37
Figura 4.9 Histograma de Errores, Red Semanal 4 "T° max día"	37
Figura 4.10 1 Arquitectura RNA Quincenal 2 "Mayo-Septiembre"	42
Figura 4.11 Coeficientes de correlación de Pearson, Red Quincenal 2 "Mayo – Septiembre"	42

Figura 4.12 Histograma de Errores, Red Quincenal 2 "Mayo - Septiembre"	42
Figura 4.13 Arquitectura RNA Quincenal 4 "Tmax día"	45
Figura 4.14 Coeficientes de correlación de Pearson, Red Quincenal 4 "T° max día"	45
Figura 4.15 Histograma de Errores, Red Quincenal 4 "T° max día"	45
Figura 4.16 Esquema RNA entradas con los datos de Valle Nevado y Mapocho en Los Almendros, temporada 2013-2014.	48
Figura 4.17 Coeficientes de correlación de Pearson, Valle Nevado 3.	51
Figura 4.18 Histograma de Errores, Valle Nevado 3	52
Figura 4.19 Coeficientes de correlación de Pearson, Mapocho en Los Almendros Diaria.	53
Figura 4.20 Histograma de Errores, Mapocho en Los Almendros, Diaria	53
Figura 4.21 Coeficientes de correlación de Pearson, Valle Nevado 2.	55
Figura 4.22 Histograma de Errores, Valle Nevado 2	55
Figura 4.23 Coeficientes de correlación de Pearson, Mapocho en Los Almendros, Semanal	56
Figura 4.24 Histograma de Errores, Mapocho en Los Almendros, Semanal	57
Figura 4.25 Coeficientes de correlación de Pearson, Valle Nevado 2	58
Figura 4.26 Histograma de Errores, Valle Nevado 2	59
Figura 4.27 Coeficientes de correlación de Pearson, Mapocho en Los Almendros, Quincena	60
Figura 4.28 Histograma de Errores, Mapocho en Los Almendros, Quincena	60
Figura 5.1 Caudales Medios Diarios Observados y Simulados, Temporada de deshielo 2013 - 2014	61
Figura 5.2 Serie temporal de errores diarios en [m ³ /s]	62
Figura 5.3 Caudal medio diario observado versus error	62
Figura 5.4 Serie temporal de error porcentual absoluto diario.	63
Figura 5.5 Caudales medios semanales observados y simulados, Temporada de deshielo 2013 - 2014	64
Figura 5.6 Serie temporal de errores semanales en [m ³ /s]	64
Figura 5.7 Caudal medio semanal observado versus error	65
Figura 5.8 Serie temporal de error porcentual absoluto semanal	65
Figura 5.9 Pronóstico de caudales medios semanales extremos, con 3 y 1 día de anticipación, para la temporada de deshielo 2013 – 2014, Red 4.	66
Figura 5.10 Caudales Medios Quincenales Observados y Simulados, Temporada de deshielo 2013 – 2014.	67
Figura 5.11 Serie temporal de errores quincenales en [m ³ /s].	68

Figura 5.12 Caudal medio quincenal observado versus error.	68
Figura 5.13 Serie temporal de error porcentual absoluto quincenal	69
Figura 5.14 Pronóstico de caudales medios quincenales extremos, con 7 y 3 días de anticipación, para la temporada de deshielo 2013 – 2014.	70
Figura 5.15 Pronóstico de caudales medios diarios, semanales y quincenales, Temporada 2013 - 2014	70
Figura 8.1 Regresión Temperatura mínima Enero	81
Figura 8.2 Regresión Temperatura mínima Febrero	81
Figura 8.3 Regresión Temperatura mínima Marzo	81
Figura 8.4 Regresión Temperatura mínima Abril	82
Figura 8.5 Regresión Temperatura mínima Mayo	82
Figura 8.6 Regresión Temperatura mínima Junio	82
Figura 8.7 Regresión Temperatura mínima Julio	83
Figura 8.8 Regresión Temperatura mínima Agosto	83
Figura 8.9 Regresión Temperatura mínima Septiembre	83
Figura 8.10 Regresión Temperatura mínima Octubre	84
Figura 8.11 Regresión Temperatura mínima Noviembre	84
Figura 8.12 Regresión Temperatura mínima Diciembre	84
Figura 8.13 Regresión Temperatura máxima Enero	85
Figura 8.14 Regresión Temperatura máxima Febrero	85
Figura 8.15 Regresión Temperatura máxima Marzo	85
Figura 8.16 Regresión Temperatura máxima Abril	86
Figura 8.17 Regresión Temperatura máxima Mayo	86
Figura 8.18 Regresión Temperatura máxima Junio	86
Figura 8.19 Regresión Temperatura máxima Julio	87
Figura 8.20 Regresión Temperatura máxima Agosto	87
Figura 8.21 Regresión Temperatura máxima Septiembre	87
Figura 8.22 Regresión Temperatura máxima Octubre	88
Figura 8.23 Regresión Temperatura máxima Noviembre	88
Figura 8.24 Regresión Temperatura máxima Diciembre	88
Figura 8.25 Regresión de Precipitaciones Diciembre - Marzo	89
Figura 8.26 Regresión de Precipitaciones Abril	89
Figura 8.27 Regresión de Precipitaciones Mayo	89

Figura 8.28 Regresión de Precipitaciones Junio	90
Figura 8.29 Regresión de Precipitaciones Julio	90
Figura 8.30 Regresión de Precipitaciones Agosto	90
Figura 8.31 Regresión de Precipitaciones Septiembre	91
Figura 8.32 Regresión de Precipitaciones Octubre	91
Figura 8.33 Regresión de Precipitaciones Noviembre	91
Figura 8.34 Regresión de Caudales Enero	92
Figura 8.35 Regresión de Caudales Febrero	92
Figura 8.36 Regresión de Caudales Marzo	92
Figura 8.37 Regresión de Caudales Abril	93
Figura 8.38 Regresión de Caudales Mayo	93
Figura 8.39 Regresión de Caudales Junio	93
Figura 8.40 Regresión de Caudales Julio	94
Figura 8.41 Regresión de Caudales Agosto	94
Figura 8.42 Regresión de Caudales Septiembre	94
Figura 8.43 Regresión de Caudales Octubre	95
Figura 8.44 Regresión de Caudales Noviembre	95
Figura 8.45 Regresión de Caudales Diciembre	95

Capítulo 1.- Introducción

1.1 Motivación

El agua en forma de nieve y/o hielo que se acumula año a año durante los meses de invierno en la cordillera de los Andes y que luego se derrite durante las estaciones de primavera y verano, corresponde a una reserva natural del recurso hídrico, la cual es altamente utilizada por todos los sectores económicos, especialmente por los sectores agrícola y energético, específicamente el sector hidroeléctrico, los cuales presentan sus mayores demandas durante los meses de primavera y verano (*Figura 1.1 Generación de energía eléctrica por distintas fuentes para el año 2011*). Por lo mismo resulta de gran importancia el modelar su almacenamiento y derretimiento con el objetivo de conocer cuál será la disponibilidad de agua y así gestionar y utilizar de forma óptima el recurso hídrico.

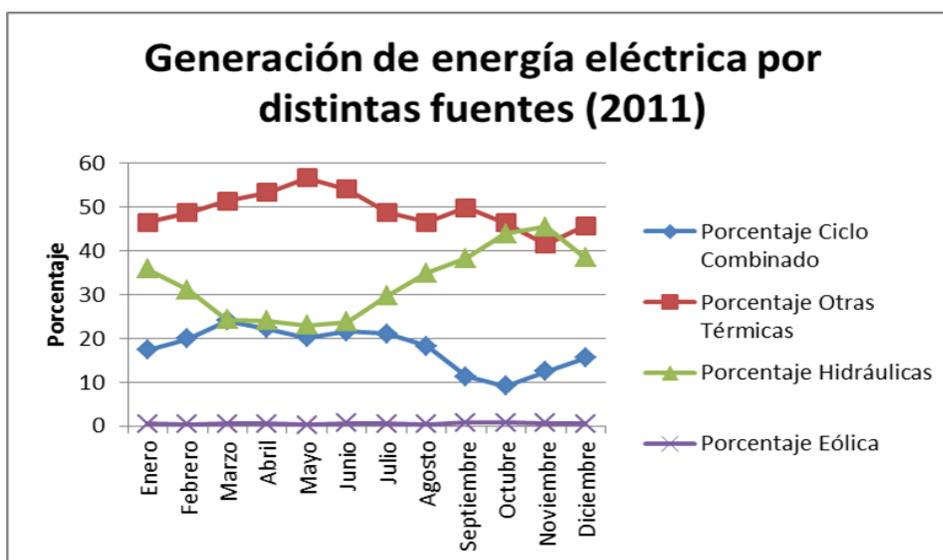


Figura 1.1 Generación de energía eléctrica por distintas fuentes para el año 2011

Fuente: <https://generacionelectricaenchile.wordpress.com/2014/05/17/investigacion-sobre-consumo-generacion-y-distribucion-de-energia-electrica/>

La Dirección General de Aguas (DGA) realiza anualmente un informe, donde detalla el pronóstico de disponibilidad de agua para la temporada de riego de Septiembre a Marzo. Este pronóstico se elabora con datos provenientes de las estaciones fluviométricas ubicadas en las zonas altas de las cuencas pertenecientes a la Red Hidrométrica de la DGA. El pronóstico consiste en determinar volúmenes de deshielo, caudales medios mensuales y caudales máximos instantáneos. Sin embargo, la DGA destaca que la distribución mensual de caudales medios puede tener fluctuaciones apreciables, en la medida que las variables meteorológicas presenten comportamientos irregulares en el período de deshielo. Con mayor razón puede presentarse variaciones muy significativas a nivel diario, en relación con el valor medio mensual, por lo que el pronóstico realizado no es estricto para aquellos usuarios cuyas necesidades de caudales diarios

son determinantes para su producción, como lo es el caso de las empresas de generación eléctrica, (Nazarala 2010).

Además de los pronósticos que realiza la DGA anualmente, a nivel nacional se han desarrollado variadas investigaciones en relación al pronóstico de caudales de deshielo. Dentro de los primeros estudios destacan las tesis de Gonzales (1970) y Espinoza (1973), en las cuales se desarrollaron modelos estocásticos en base a registros de precipitación y rutas de nieve principalmente. Más recientemente se han desarrollado modelos de pronóstico de caudales de deshielo usando redes neuronales artificiales (RNA), las cuales corresponden a modelos estocásticos de mayor complejidad (Barría, 2010) y modelos que utilizan RNA junto con imágenes satelitales (Cartes, 2009). Sin embargo, tanto éstos como los numerosos pronósticos elaborados por la DGA (desde 1999) corresponden a pronósticos de caudales medios mensuales.

Por otro lado, a escalas temporales menor a la mensual, se han desarrollado modelos de redes neuronales recurrente aplicados al pronóstico de caudales de crecidas, tanto pluviales como de deshielo, en tiempo real (Muñoz 2008) y modelos que involucran funciones de transferencia para el pronóstico de crecidas en tiempo real en la cuenca del Río Mapocho. (Márquez, 1991).

El pronosticar caudales de deshielo para la cuenca alta del Mapocho a escalas temporales menores a la mensual, resulta de gran interés dado que la metodología a desarrollar podría implementarse en otras cuencas de Chile con fines en generación hidroeléctrica, donde el conocimiento de los caudales futuros a niveles diarios y semanales conlleva a mejoras significativas en la operación de sus embalses, lo cual a su vez optimiza el uso y gestión del recurso hídrico.

1.2 Objetivos

El objetivo principal de la presente memoria consiste en pronosticar los caudales de deshielo de la cuenca del río Mapocho en los Almendros para distintas escalas temporales, específicamente a escalas diarias, semanales y quincenales, usando redes neuronales artificiales, y analizar los efectos de la incorporación de datos hidrometeorológicos provenientes de la estación en Valle Nevado en los pronósticos.

Los objetivos específicos se nombran a continuación:

- Analizar la influencia de los distintos parámetros hidrológicos registrados en la estación Mapocho en Los Almendros en el fenómeno en estudio para las distintas escalas temporales.
- Construir distintas redes neuronales artificiales para cada escala temporal y seleccionar la red neuronal artificial óptima para el pronóstico a nivel diario, semanal o quincenal.
- Calibrar las redes neuronales óptimas mediante los datos registrados en las estaciones Valle Nevado y Mapocho en los Almendros.

1.3 Organización del Documento

A continuación se describen brevemente los capítulos que forman parte de este informe.

En el capítulo 2, referente a la revisión bibliográfica, se muestran las redes neuronales artificiales, resumiendo sus características en cuanto a estructura, arquitectura y las funciones o algoritmos que las componen. Por otro lado, se muestran las ecuaciones que determinan los procesos de acumulación y derretimiento de un manto de nieve.

En el capítulo 3, referente a la zona de estudio, se resumen las principales características de la zona en estudio, como el área de la cuenca y el clima. Además, se muestran los registros fluviométricos y meteorológicos utilizados en la investigación.

En el capítulo 4, referente a los resultados, se muestran los resultados obtenidos al calibrar las distintas RNA, tanto para los datos de la estación Mapocho en Los Almendros como Valle Nevado, y se mencionan las RNA óptimas para cada caso y cada escala temporal.

En el capítulo 5, referente al análisis de resultados, se sintetizan los resultados obtenidos al simular las RNA óptimas, para las tres escalas temporales, con los datos de la temporada de deshielo 2013-2014.

En el capítulo 6, referente a las conclusiones, se realiza un análisis profundo de los resultados obtenidos, tanto para las RNA óptimas calibradas con los datos de la estación Mapocho en Los Almendros, como las RNA óptimas calibradas con los datos de la estación hidrometeorológica Valle Nevado.

Capítulo 2.- Revisión Bibliográfica

2.1 Redes Neuronales Artificiales

Las redes neuronales artificiales (RNA) son sistemas pertenecientes a la inteligencia artificial y, como su nombre lo indica, intentan simular el funcionamiento y estructura del cerebro humano, es decir, buscan imitar, aunque de manera mucho más simplista, el sistema nervioso central del ser humano.

La importancia y principal ventaja del uso de las Redes Neuronales Artificiales es que éstas “aprenden la relación previamente desconocida entre las entradas y salida a través de un proceso de entrenamiento, sin un conocimiento previo de las características de la cuenca.” (Rajurkar, et al. 2002). En el caso de la presente memoria se busca modelar la compleja relación entre las precipitaciones sólidas ocurridas durante los meses de invierno y los caudales de deshielo a ocurrir durante los meses de primavera y verano.

2.1.1 Estructura de las Redes Neuronales Artificiales

La unidad o elemento básico de procesamiento de las RNA es la neurona. En la *Figura 2.1* se observa la estructura de una neurona, donde sus componentes principales son los datos de entrada “ X_i ”, los cuales se multiplican por los pesos “ W_i ”, creándose las entradas ponderadas, las cuales entran a las funciones de red y función de activación o de transferencia, obteniéndose las variables de salida. Estas últimas se comparan con los datos observados. Dependiendo de la diferencia entre éstas o error, se van modificando los valores de los pesos, hasta obtener sesgos pequeños entre las series modelada y observada. Esta última diferencia o sesgo corresponde al error máximo permitido.

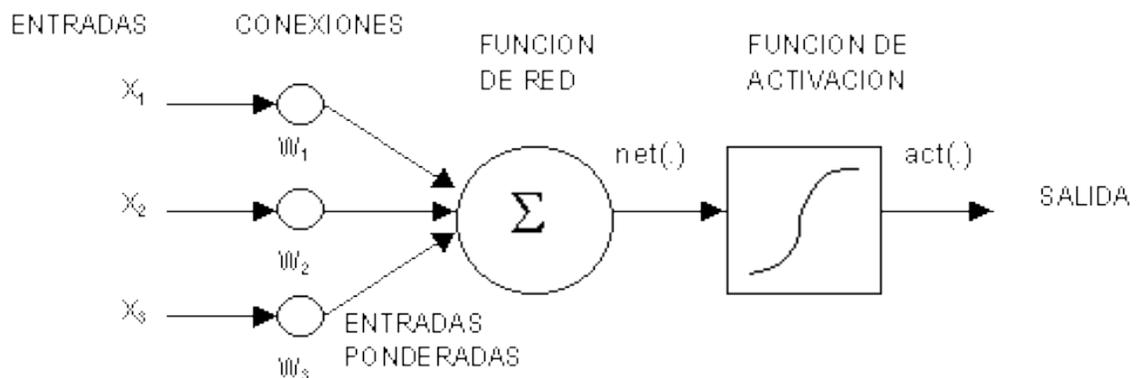


Figura 2.1 Esquema de funcionamiento de una Red Neuronal Artificial.
Fuente: http://magomar.webs.upv.es/rna/tutorial/RNA_marcos.html.

La estructura de una red neuronal, se puede definir básicamente en tres capas, la capa de entrada, las capas ocultas y la capa de salida (*Figura 2.2*); y las funciones de red y de activación que unen las diferentes capas.

- *Capa de Entrada*: su función es recibir la información desde el exterior,
- *Capas Ocultas*: su función es procesar y transmitir la información
- *Capa de Salida*: procesan la información proveniente de las capas ocultas y generan las salidas del modelo.

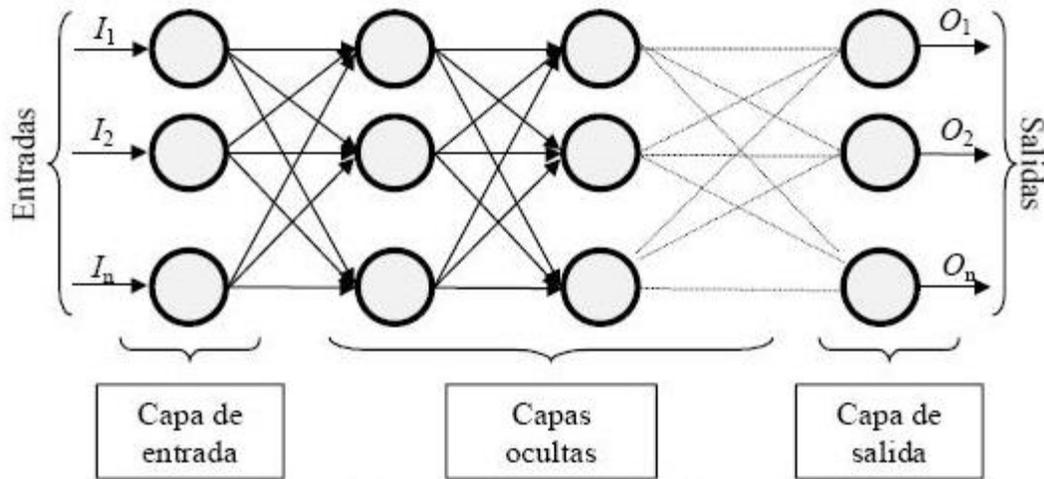


Figura 2.2 Capas de una Red Neuronal Artificial

Fuente: <https://advancedtech.wordpress.com/2008/08/07/redes-neuronales-rna/>

La función de red o la entrada ponderada de la neurona, tiene la forma de la ecuación (1).

$$S_j = \sum_{i=1}^m X_i * W_{ij} + b_j \quad (1)$$

donde:

S_j = función de red

X_i = entrada a la neurona j

W_{ij} = peso entre las neuronas i de la capa de entrada y j de la capa oculta

b_j = valor umbral entre la capa de entrada y la capa oculta, “*bías*” en inglés.

m = número de neuronas en la capa de entrada

El valor umbral de la neurona o *bías* “ b_j ”, es “similar a un peso, excepto porque tienen una entrada constante e igual a uno.” (Hudson et al. 2014); sin embargo, es posible omitir los *bías* en una neurona si se desea.

Los principales tipos de funciones de activación o funciones de transferencia son las funciones de transferencia Lineal, Escalón y Sigmoide, que se muestran en la **Figura 2.3**. La función de transferencia Sigmoide Logarítmico presenta un rango de salida entre cero y uno, y es “la función de transferencia comúnmente utilizada en las capas ocultas de redes multicapas, en parte porque es diferenciable” (Hudson et al. 2014)

Nombre	Relación Entrada /Salida	Icono	Función
Limitador Fuerte	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$		<i>hardlim</i>
Escalón	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$		<i>hardlims</i>
Lineal Positiva	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$		<i>poslin</i>
Lineal	$a = n$		<i>purelin</i>
Lineal Saturado	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$		<i>satlin</i>
Lineal Saturado Simétrico	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = +1 \quad n > 1$		<i>satlins</i>
Sigmoide Logarítmico	$a = \frac{1}{1 + e^{-n}}$		<i>logaritmo sigmoide</i>
Tangente Sigmoide Hiperbólica	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		<i>tangente sigmoide</i>
Competitiva	$\alpha = 1$ Neurona con n max $\alpha = 0$ El resto de neuronas		<i>compet</i>

Figura 2.3 Principales tipos de Funciones de Transferencia, donde la columna llamada “función” se refiere al nombre o función en el Toolbox de Matlab.

Fuente: <http://proton.ucting.udg.mx/posgrado/cursos/idc/neuronales2/Transferencia.htm>

2.1.2 Arquitectura de las RNA

La arquitectura de una red neuronal artificial se refiere a la organización y disposición de las neuronas en la red. Si se tiene una red multicapa, es decir, con dos o más capas, su arquitectura puede ser básicamente de tres tipos (Figura 2.3):

- *Redes “prealimentadas” o “feedforward”*: los nodos van ordenados por el orden en que reciben la señal desde la entrada hasta la salida. Es decir, una capa no puede tener conexiones a otra que reciba la señal antes que ella, de éste modo, la señal fluye unidireccionalmente desde la capa de entrada a la de salida. “A las redes con conexiones unidireccionales y totalmente conectadas se les denomina *perceptrones multicapa* o redes *feedforward* y son, junto con las redes competitivas las más utilizadas en análisis de datos.” (García 2002).
- *Redes “competitivas”*: al igual que en las redes prealimentadas, una capa no puede tener conexiones a otra que reciba la señal antes que ella, sin embargo si existen conexiones entre las neuronas de una misma capa, salvo en la capa de entrada.
- *Redes “Recurrentes” o “feedback”*: donde las capas pueden crear conexiones con las neuronas que reciban la señal antes que ellas. Es decir, la información puede volver a lugares por los que ya había pasado, formando bucles.

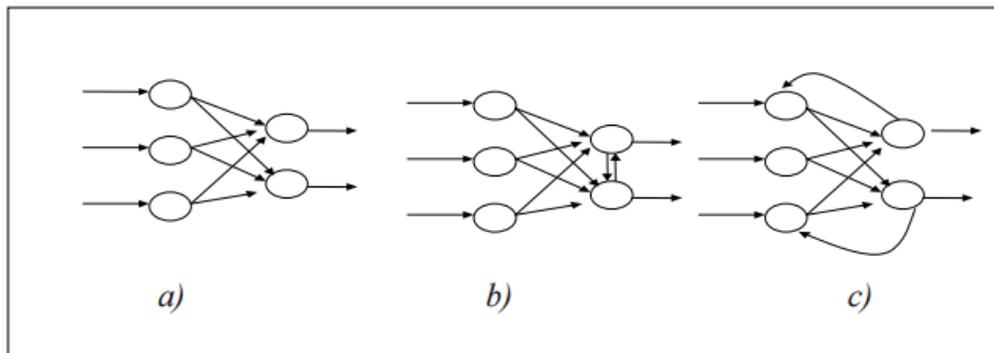


Figura 2.4 Tres arquitecturas de RNA: a) Red feedforward, b) Red competitiva, c) Red recurrente.
Fuente: García et al. (2002)

2.1.3 Procesos de Aprendizaje

El aprendizaje o entrenamiento de una red neuronal artificial consiste en la modificación de los pesos de las conexiones, según alguna regla de aprendizaje, la cual tiene por objetivo optimizar la respuesta de la RNA. Existen dos tipos de aprendizajes:

- *Aprendizaje Supervisado*: en éste caso la red requiere un instructor, el cual puede ser un set de datos de salida deseados u observados, o bien el instructor puede ser un experto, el cual indica el correcto o incorrecto desempeño de la red.
- *Aprendizaje No Supervisado*: no se requieren presentar patrones de salida deseados, sin embargo, el algoritmo y la regla de modificación de las conexiones producen vectores de salida consistentes. Esto es, la presentación de un patrón aprendido o parecido a él, produce siempre la misma salida.

Generalmente los pasos a seguir en un aprendizaje supervisado son los siguientes (González 2003):

1. Asignar en forma aleatoria los pesos de todas las conexiones (preferentemente con valores pequeños).
2. Seleccionar un par de entrenamiento, es decir, un patrón de entrada y el patrón de salida deseado correspondiente.
3. Presentar el patrón de entrada y calcular la salida total de la red.
4. Se calcula el error o discrepancia entre la salida obtenida y la deseada. El error (función objetivo a minimizar) se suele definir como la suma de los cuadrados de las diferencias entre las salidas reales obtenidas y las deseadas. El criterio de detención puede ser que se alcanzó el número máximo de iteraciones o se obtiene un nivel de error previamente definido.
5. Aplicar la regla de aprendizaje, es decir, ajustar los pesos de las conexiones tratando de disminuir el error, generalmente mediante el cálculo de tasas de variación o gradientes del error.
6. Volver al paso 2.

Es importante notar que existen varias formas de actualizar los pesos, éstos se pueden actualizar cada vez que se presenta un ejemplo a la RNA o una vez que se presentan todos los ejemplos a la RNA, y por último, se pueden actualizar una vez que se ha presentado el set de datos por varios ciclos consecutivos. Ésta última “resulta ser la metodología más utilizada en la práctica” (González 2003).

2.1.4 Algoritmos de Entrenamiento

Los algoritmos de entrenamiento indican cómo se modifican los pesos en función de las entradas y salidas deseadas, dentro de los algoritmos más utilizados se encuentran:

1 Algoritmo Perceptrón

Se tienen los vectores de entrada (p) y salida (t) observados, se define el error como $e = t - a$ donde “ t ” es la salida deseada y “ a ” la salida calculada. De éste modo, los pesos varían según la ecuación (2):

$$\Delta w = (t - a)p^T = e * p^T \quad (2)$$

2 Algoritmo de Retropropagación o Backpropagation

Éste algoritmo permite entrenar redes neuronales no lineales de dos o más capas. El proceso de entrenamiento se compone de un ciclo de propagación-adaptación de dos fases:

- Hacia adelante o *Forward*: con los pesos fijos se calculan salidas y se determina el error.
- Hacia atrás o *Backward*: la señal de error es propagada hacia las capas ocultas, usando los pesos actuales de la red, para luego ajustar los pesos.

La modificación de los pesos en el algoritmo *Backpropagation* se basa en minimizar la función objetivo, definida como el error o diferencia entre las salidas observadas y simuladas. Para lo anterior, se determina el gradiente negativo del error con respecto a los pesos, lo cual entrega una dirección de descenso.

Considerando una red neuronal con una capa oculta, la ecuación de entrada a una neurona en la capa oculta es la función de red, ecuación (1), y la ecuación de salida de la misma neurona es la ecuación (3).

$$i_j = f(S_j) \quad (3)$$

donde:

$f()$ = función de transferencia elegida para la neurona “ j ”

Finalmente, las ecuaciones de entrada y salida de la neurona en la capa de salida se muestran en las ecuaciones (4) y (5) respectivamente.

$$S_j = \sum_{i=1}^n w_{ij} * i_j + b_j \quad (4)$$

donde:

w_{ij} = peso entre la neurona i de la capa oculta y la neurona j de la capa de salida.

b_j = valor umbral entre la capa oculta y la capa de salida

n = número de neuronas en la capa oculta

$$I = f(S) \quad (5)$$

donde:

$f(\)$ = función de transferencia elegida para la neurona de salida

Definiendo el error total cometido por la red "E_p" según la ecuación (6), se determina el gradiente del error ∇E_p según los pesos "w", obteniéndose la ecuación (7) y derivando se llega a la ecuación (11).

$$E_p = \frac{1}{2} \sum_{a=1}^T (y_a - S_a)^2 \quad (6)$$

donde:

y_a = salida Observada

S_a = salida Simulada

T = número de pares de datos de entrada-salida disponibles para en entrenamiento.

$$\frac{\partial E_p}{\partial w_{ij}} = \frac{\partial E_p}{\partial S} * \frac{\partial S}{\partial I} * \frac{\partial I}{\partial w} \quad (7)$$

Pero

$$\frac{\partial E_p}{\partial S} = -(y_a - S_a) \quad (8)$$

$$\frac{\partial S}{\partial I} = f'(S) \quad (9)$$

$$\frac{\partial I}{\partial w} = i_j \quad (10)$$

Resumiendo

$$-\nabla E_p = - \frac{\partial E_p}{\partial w_{ij}} = (y_a - S_a) * f'(S) * i_j \quad (11)$$

La actualización de los pesos se considera proporcional al gradiente negativo, luego, los pesos entre la capa oculta y la capa de salida se actualizan según la siguiente ecuación:

$$w_{ij}^{\wedge}(t + 1) = w_{ij}^{\wedge}(t) + \Delta p * w_{ij}^{\wedge}(t) \quad (12)$$

$$\Delta p * w_{ij}^{\wedge}(t) = \eta * (y_a - S_a^{\wedge}) * f'(S^{\wedge}) * i_j \quad (13)$$

donde:

η = tasa de aprendizaje

Dado lo anterior, se observa que las funciones de transferencia a utilizar tanto en las neuronas de la capa oculta como la capa de salida, deben ser diferenciables. Por otro lado, se observa que para determinar la actualización de los pesos entre la capa de entrada y la capa oculta, se debe calcular el gradiente negativo del error con respecto a los pesos correspondientes.

3 Variaciones al Algoritmo de Retropropagación o *Backpropagation*

Considerando una expresión genérica del algoritmo de *backpropagation*, dada por:

$$w(k + 1) = w(k) + \alpha_k * D_k \quad (14)$$

donde:

$w(k + 1)$ = vector de pesos en la iteración k+1

α_k = tasa de aprendizaje

D_k = dirección de búsqueda en la iteración k

De acuerdo a González (2003) “Los distintos métodos de optimización basados en el gradiente se diferencian en la forma de obtener la dirección de búsqueda D_k , a partir de la información de primer orden contenida en el gradiente ∇E_k , y en algunos casos, de la estimación de la información adicional de segundo orden.” Entre las variaciones al algoritmo de *backpropagation* destacan las siguientes:

- Método del Descenso del Gradiente

$$D_k = -\nabla E_k \quad (15)$$

- Métodos de gradiente conjugado, que tiene la forma general:

$$D_k = -\nabla E_k + \gamma_k * D_{k-1} \quad (16)$$

De acuerdo a Socha (2005) “En los algoritmos de gradiente conjugado, la búsqueda se realiza a lo largo de direcciones conjugadas que producen generalmente una convergencia más rápida que las direcciones de descenso”

- Métodos Cuasi-Newton: el método de Newton consiste en determinar la matriz de Hessianos o segunda derivada; éste “converge a menudo más rápidamente que los métodos de gradiente conjugado, pero es complejo y requiere de alta capacidad computacional” (Socha D. 2005). Los métodos cuasi-Newton se basan en el método de Newton, pero no requieren el cálculo de la segunda derivada, dado que aproximan la matriz Hessiana en cada iteración. Su expresión general es:

$$\alpha_k * D_k = -B_k * \nabla_k \quad (17)$$

Donde B_k es una estimación del inverso de la matriz Hessiana de E dada por:

$$\nabla^2 E = \left| \frac{\partial^2 E}{\partial w_i \partial w_j} \right| \quad (18)$$

- Método de Levenberg-Marquardt: similar a los métodos cuasi-Newton, el cual aproxima el gradiente y la matriz Hessiana por las ecuaciones (19) y (20) respectivamente. “La matriz de Jacobianos puede computarse a través de retropropagación normal, lo cual es mucho menos complejo de computar que la matriz de Hessianos.” (Socha D. 2005)

$$\nabla E_k = J^T * e \quad (19)$$

$$H = J^T * J \quad (20)$$

donde:

J^T = matriz Jacobiana traspuesta

e = vector de errores de la red neuronal

H = aproximación de la matriz Hessiana

2.1.5 Sobre-entrenamiento, Regularización y Detención Temprana

El sobre-entrenamiento es uno de los principales problemas que pueden ocurrir durante el entrenamiento de una red neuronal, el cual consiste en que la red se sobre-ajusta a los datos con los cuales está siendo entrenada, entregando un error muy bajo al simular la red con éstos datos; sin embargo al simular la red con nuevos datos, el error es bastante mayor al obtenido con los datos de entrenamiento. Lo anterior se puede mejorar de dos maneras, con regularización o detención temprana.

La regularización consiste básicamente en modificar la función objetivo, la cual es usualmente el error cuadrático medio cometido por la red, ecuación (21), agregando un término que corresponde al promedio de la suma de los cuadrados de los pesos y bías de la red, ecuación (22).

$$mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 \quad (21)$$

$$mse^* = \gamma * mse + (1 - \gamma) * msw \quad (22)$$

$$msw = \frac{1}{n} \sum_{j=1}^n w_j^2 \quad (23)$$

Con γ la razón de desempeño.

La detención temprana consiste en dividir el conjunto de datos en tres grupos, datos para entrenamiento, datos para validación y datos de prueba. La idea es que al final de cada iteración, la red se simule con los datos de validación y se compare el error obtenido versus el error obtenido con los datos de entrenamiento en la última iteración. Normalmente el error de validación decrece durante la fase inicial del entrenamiento, al igual, que el error de entrenamiento, sin embargo, cuando la red comienza a sobre ajustar los datos, el error de validación comienza a aumentar, luego, el entrenamiento se detiene.

Usualmente, de tener un set de datos contundente, el 50% de los datos se usa para entrenamiento, el 25% para validación y el 25% restante para prueba. “Los datos de entrenamiento se usan para ajustar los pesos, los de validación se usan para monitorear el proceso de entrenamiento y los datos de prueba sólo se usan para observar el desempeño del modelo frente a datos totalmente desconocidos.” (González 2003)

Por otro lado, los datos de entrenamiento deben ser elegidos de manera inteligente, dado que las “redes multicapa pueden ser entrenadas para rendir bien dentro del rango de datos de entrada con el que fueron entrenadas, sin embargo no tienen la habilidad de extrapolar fuera de éste rango, por lo que es muy importante que los datos de entrenamiento cubran todo el rango de posibilidades”. (Hudson et al. 2014).

2.3 Hidrología de Nieves

La nieve es un componente importantísimo del ciclo hidrológico, ésta se genera debido a la precipitación sólida y sus procesos principales son los de acumulación y derretimiento. Para poder modelar minuciosamente dichos procesos, es necesario determinar y calcular los balances de masa y energía que ocurren entre el manto nival y el exterior. Sin embargo un método más simple corresponde al Método Grado Día, el cual permite determinar la tasa de derretimiento mediante un factor y la diferencia entre la temperatura base y la temperatura media del aire (ecuación 24).

$$M = DDF(T_a - T_b) \quad (24)$$

Donde:

M: tasa de derretimiento

DDF: factor grado-día

T_a : temperatura media del aire

T_b : temperatura base del manto de nieve

2.3.1 Balance Energético

El balance energético es un modelo de derretimiento de nieve y queda determinado a partir de la ecuación 25, donde cada componente de la ecuación representa un flujo de energía, se expresa en unidades de Joule/s/m² o Watt/m² en el sistema MKs y toma valores, positivo, negativo o nulo dependiendo de las condiciones que se tengan:

$$Q_i = Q_{ns} + Q_{nl} + Q_h + Q_e + Q_p + Q_g + Q_m \quad (25)$$

Donde:

Q_i = cambio en el almacenamiento interno de calor latente y sensible. Puede tomar valores tanto positivos como negativos.

Q_{ns} = intercambio neto de radiación de onda corta. Tiene valores mayores o iguales a cero.

Q_{nl} = intercambio neto de radiación de onda larga. Toma tanto valores positivos como negativos.

Q_h = intercambio convectivo de calor sensible con la atmósfera. Tiene valores positivos como negativos.

Q_e = intercambio convectivo de calor latente de vaporización y sublimación con la atmósfera. Tiene valores positivos y negativos.

Q_p = calor latente y sensible de precipitación. Tiene valores mayores o iguales a cero.

Q_g = intercambio de calor con el suelo. Puede ser tanto positivo como negativo.

Q_m = pérdida de calor latente de fusión debido a agua derretida saliendo del manto, tiene valores menores o iguales a cero.

Para el cálculo de Q_h y Q_e , se tienen las ecuaciones 26 y 27.

$$Q_h = \rho_a C_a C_H u_a (T_a - T_s) \quad (26)$$

donde:

ρ_a : densidad del aire.

C_a : calor específico del aire.

C_H coeficiente de transferencia de masa para calor sensible.

u_a : velocidad del viento

T_a : temperatura del aire

T_s : temperatura de la superficie del manto

$$Q_e = \left(\rho_a 0.622 \frac{L}{P_{atm}} \right) C_e u_a (e_a - e_o) \quad (27)$$

donde:

ρ_a : densidad del aire

u_a : velocidad del viento

C_e : coeficiente de transferencia de masa para calor latente.

e_a : presión de vapor a una altura "z"

e_o : presión de vapor en la superficie del manto

L: calor latente de vaporización o sublimación

Ls = calor latente de sublimación

Lv = calor latente de vaporización

Según Cornwell (2012), se tiene que el aporte energético del suelo en contacto con la base del manto nival puede considerarse a priori despreciable frente a los otros términos del balance energético, dado que, carece de sentido la inclusión de dicha fuente energética al no modelar el manto nival como un sistema estratificado en donde se puedan identificar estratos de nieve y hielo, los cuales poseen distintas conductividades térmicas. Por lo que el término Q_g es eliminado de la ecuación 24, además el cambio en el almacenamiento interno de calor latente y sensible (Q_i) también es nulo, por lo que finalmente la ecuación queda:

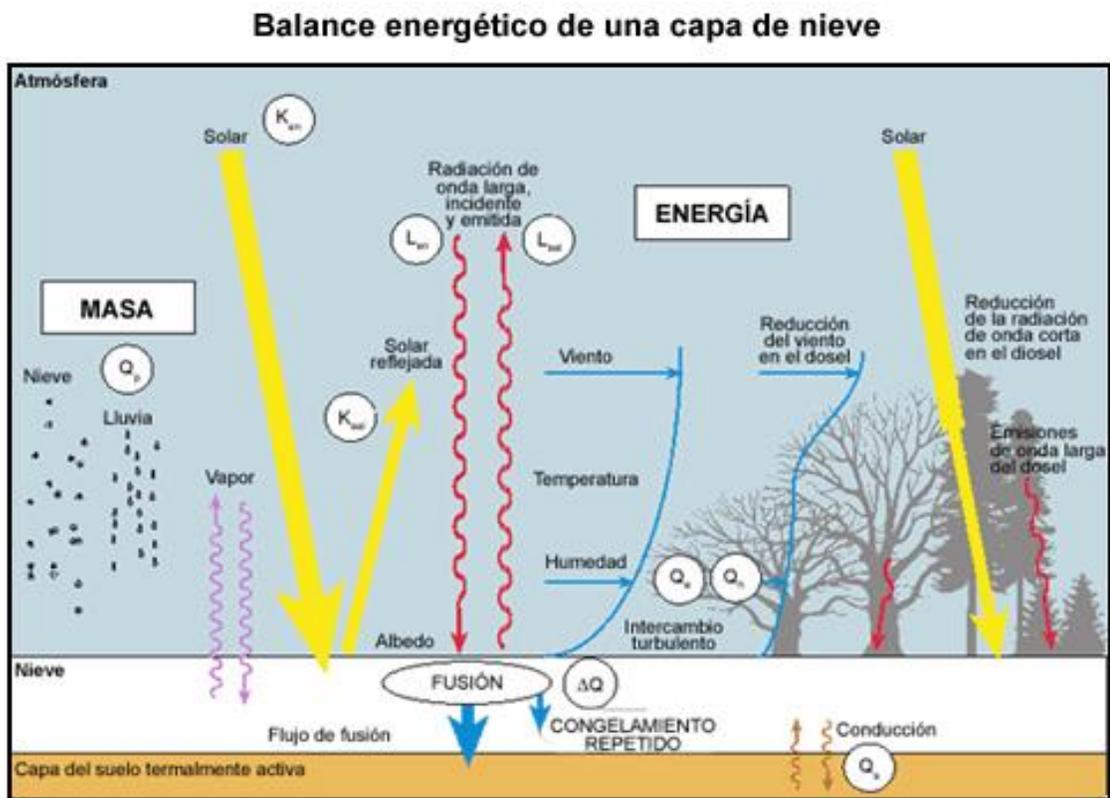
$$Q_m = Q_{ns} + Q_{nl} + Q_h + Q_e + Q_p \quad (28)$$

Según la ecuación 28, los principales factores que tienen incidencia en el proceso de derretimiento del manto nival, son aquellos referentes a las radiaciones de onda corta y onda larga, el intercambio de calor sensible con la atmósfera, intercambio de calor latente de vaporización y sublimación con la atmósfera y el calor latente y sensible de precipitación.

2.3.2 Balance de Masa

Dentro de las componentes de entrada del balance de masa se encuentran la precipitación, tanto sólida como líquida, y la condensación de vapor de agua. Dentro de las componentes de salida, se encuentran la sublimación y el derretimiento de agua, el cual puede salir del manto nival como escorrentía superficial o infiltrarse al subsuelo. Además, se destaca el transporte por viento, el cual incluye el arrastre, saltación y suspensión de la nieve y puede considerarse tanto una entrada como una salida, dependiendo de la ocasión y ladera en que se encuentre el manto nival principalmente.

La **Figura 2.5** muestra esquemáticamente los balances de masa y energético que ocurren en un manto nival. En éste esquema los términos K representan la radiación solar entrante y saliente, los términos L corresponden a la radiación de onda larga, entrante y saliente. La transferencia de calor latente y sensible se indican mediante los términos Q_e y Q_h y la conducción de calor del suelo en el fondo de la capa de nieve, por Q_g . Finalmente, Q_p representa el calor transportado por advección cuando llueve sobre la nieve.



Don Cline / NOAA

Figura 2.5 Balance Energético de una capa de Nieve.
Fuente: https://www.meted.ucar.edu/hydro/basic_int/snowmelt_es.

Capítulo 3.- Zona en Estudio

3.1 Caracterización de la Zona en Estudio

La zona en estudio corresponde a la cuenca “Mapocho en los Almendros” ubicada en la Región Metropolitana, Chile; Específicamente entre los 33° 05´ y 33° 3´ de latitud sur y entre los 70° 25´ y 70° 10´ de longitud oeste. Un esquema general de la cuenca se muestra en la **Figura 3.1**

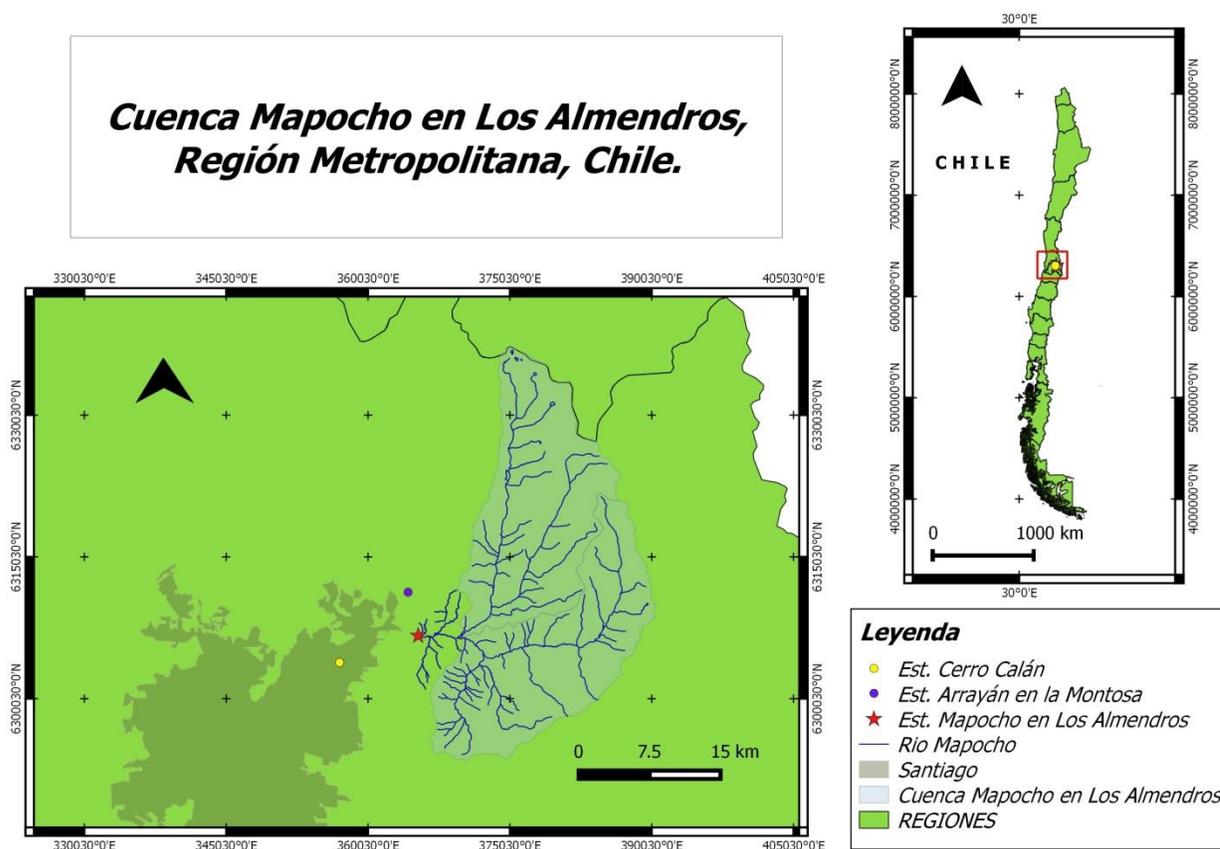


Figura 3.1 Cuenca Mapocho en Los Almendros, estaciones fluviométricas “Mapocho en Los Almendros”, “Estero Arrayán en la Montosa” y estaciones meteorológicas “Mapocho en Los Almendros”, “Cerro Calán”.

La cuenca Mapocho en Los Almendros está formada por dos subcuencas principales, las cuales son la cuenca del río Molina, y la cuenca del río San Francisco. (**Figura 3.1**), tiene un área de 635,46 Km² y está determinada por la estación fluviométrica “Mapocho en los Almendros”, perteneciente a la Dirección General De Aguas, la cual se encuentra 6 Km aprox. aguas abajo de la confluencia de los ríos Mapocho y San Francisco; y 2 Km aprox. aguas arriba de la confluencia del río Mapocho con el Estero Arrayán.

3.2 Clima de la Región

En la zona central de Chile existe un ciclo anual de precipitación bien definido, caracterizado por un máximo invernal y un período estival con un monto significativamente menor que va aumentando hacia el sur. Este régimen se conoce como clima templado mediterráneo y abarca desde los 30°S hasta los 40°S aproximadamente. Además, en la zona cordillerana se puede diferenciar el clima de frío en altura. Para ambos tipos climáticos, los valores registrados de precipitación, son mayores durante las temporadas invernales especialmente durante los meses de mayo, junio, julio y agosto.

Clima Templado Mediterráneo

Su característica principal es la presencia de una estación seca prolongada y un invierno bien marcado con temperaturas extremas que llegan a cero grados. Santiago registra una temperatura media anual de 14,5° C, pero los contrastes térmicos son fuertes. En verano las máximas alcanzan valores superiores a 30° C durante el día. Los montos de precipitación media anual registrados en el sector costero de la cuenca alcanzan valores aproximados de 404 mm/año y temperaturas de 14,9° C. Por efectos del relieve, en el sector centro de la cuenca (estación Quinta Normal), se presentan áreas de mayor sequedad y montos menores de precipitación (300 mm/año). En sectores más elevados, las precipitaciones aumentan alcanzando valores medios anuales de 536 mm (San José de Maipo) y temperaturas medias anuales de 14,2°C (Las Melosas).

Clima Frío de Altura

Se localiza en la Cordillera de los Andes por sobre los 3.000 metros de altura, las bajas temperaturas y las precipitaciones sólidas caracterizan este tipo climático, permitiendo la acumulación de nieve y campos de hielo de tipo permanentes en cumbres y quebradas de la alta Cordillera.

3.3 Estaciones Fluviométricas y Meteorológicas

En la Error! Reference source not found. se presentan las estaciones fluviométricas y meteorológicas utilizadas en este estudio. Las estaciones fluviométricas utilizadas son las estaciones “Mapocho en los Almendros” y “Estero Arrayan en la Montosa”, además, las estaciones meteorológicas seleccionadas son “Mapocho en los Almendros”, “Cerro y Calán” y “Valle Nevado”; todas pertenecientes a la Dirección General de Aguas, salvo la última, Valle Nevado, la cual pertenece al Departamento de Ingeniería Civil, División Recursos Hídricos y Medio Ambiente, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile.

Tabla 3.1 Características de las Estaciones Utilizadas.

	Mapocho en los Almendros	Estero Arrayan en la Montosa	Mapocho en los Almendros	Cerro Calán
Tipo de Estación	Fluviométrica	Fluviométrica	Meteorológica	Meteorológica
Código BNA	05722002-3	05722001-5	05722002-3	05730012-4
UTM Este	363553	364179	364824	356880
UTM Norte	6307101	6311278	6306345	6303490
Año Inicio	1948	1952	1999	1975
Altitud [m.s.n.m.]	966	1013	966	848

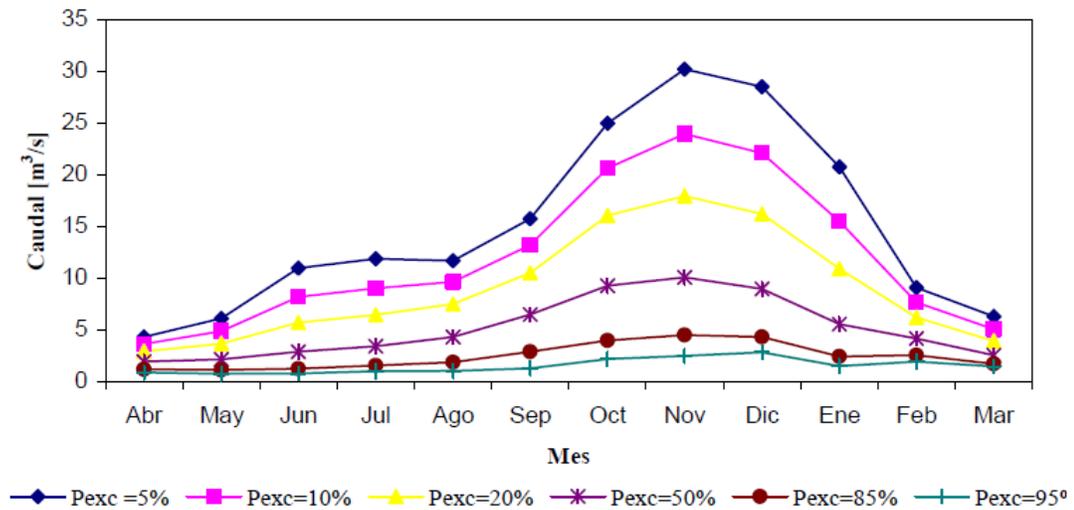


Figura 3.2 Curvas de Variación Estacional, Mapocho en Los Almendros
Fuente: Muñoz (2008)

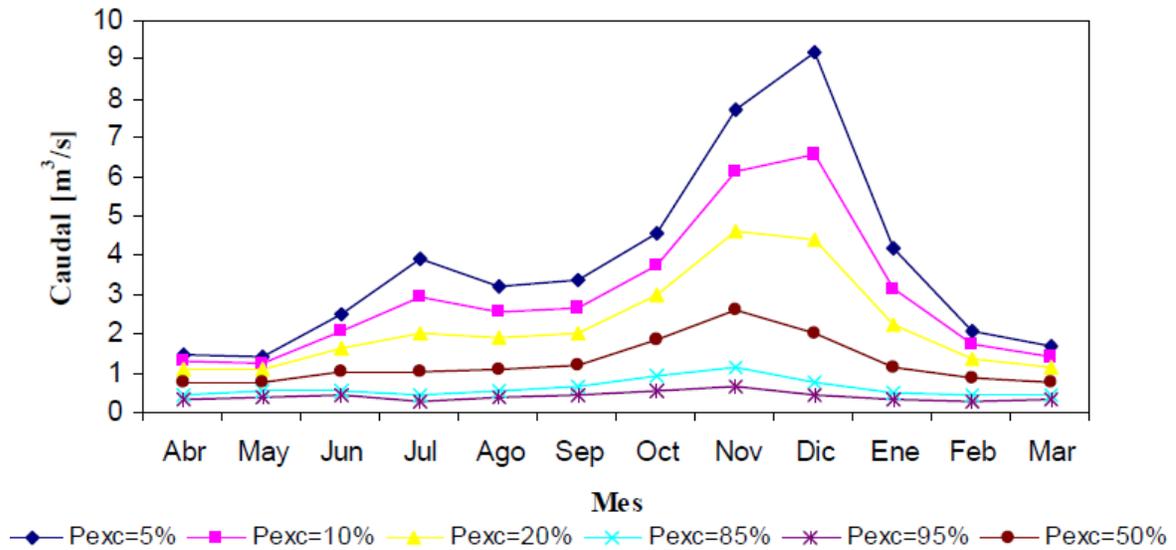


Figura 3.3 Curvas de Variación Estacional, Estero Arrayán en La Montosa
Fuente: Muñoz (2008)

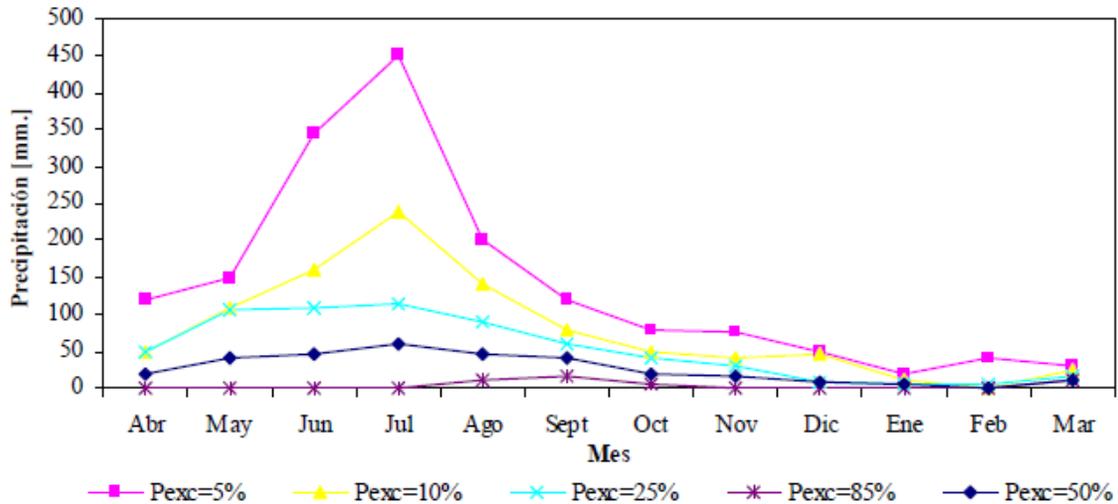


Figura 3.4 Curvas de Variación Estacional, Cerro Calán
Fuente: Muñoz (2008)

La información utilizada para el entrenamiento de las redes neuronales, corresponde a caudales medios diarios, temperaturas extremas diarias y precipitación diaria de las estaciones fluviométrica y meteorológica “Mapocho en los Almendros”. Dado que no se contaba con un registro completo para treinta años (1982 a 2012), se rellenaron y expandieron las series utilizando las estaciones “Estero Arrayán en la Montosa” para el caso de los caudales medios diarios y “Cerro Calán” para el caso de las temperaturas extremas diarias y las precipitaciones diarias. La calidad de la información utilizada se muestra en la Error! Reference source not found., mientras que el registro completo de la información se encuentra en el Anexo 2.

A partir de la Error! Reference source not found. se observa que la calidad de la información de la estación fluviométrica Mapocho en los Almendros es bastante buena, con 26 años con información completa, tres años con 11 meses completos y 1 año con 9 meses completos. Por otro lado, para la estación meteorológica Mapocho en los Almendros se cuenta con sólo 6 o 7 años con información, por lo que las series de precipitación y temperaturas extremas, tanto temperatura máxima como mínima, se rellenaron y expandieron utilizando la estación Cerro Calán, la cual cuenta con una muy buena calidad de la información.

Los valores de los coeficientes de correlación (Error! Reference source not found. y Error! Reference source not found.), son bastante buenos para las regresiones lineales de las Temperaturas extremas y precipitaciones, obteniéndose valores de R^2 entre 0.7 y 0.99. Por otro lado, los coeficientes de correlación obtenidos para las regresiones mensuales de caudal entre las estaciones Mapocho en los Almendros y Estero Arrayan en la Montosa, para los meses de marzo, abril y mayo son bastante malos, obteniéndose valores de R^2 entre 0.45 y 0.57. Sin embargo cabe observar que la cantidad de datos a rellenar para la serie de caudales en Mapocho en los Almendros es bastante baja, dado que se cuenta con un registro prácticamente completo entre 1982 y el 2012. Las regresiones se encuentran en el Anexo 2.

Tabla 3.2 Calidad de la información, donde "a" corresponde a 10 meses con información completa, "b" a 11 meses con información completa y "c" a 12 meses con información completa.

Mapocho en los Almendros					Cerro Calán				Estero Arrayán	
AÑO	Pp	T° max	T° min	Q	AÑO	Pp	T° max	T° min	AÑO	Q
1982				b	1982	c	c	c	1982	c
1983				b	1983	c	c	c	1983	c
1984				c	1984	c	c	c	1984	c
1985				c	1985	c	c	c	1985	c
1986				c	1986	c	c	c	1986	c
1987				c	1987	c	c	c	1987	c
1988				c	1988	c	c	c	1988	c
1989				c	1989	c	c	c	1989	c
1990				c	1990	c	c	c	1990	c
1991				c	1991	c	c	c	1991	c
1992				c	1992	c	c	c	1992	c
1993				c	1993	c	c	c	1993	b
1994				c	1994	c	c	c	1994	c
1995				c	1995	c	c	c	1995	c
1996				c	1996	c	c	c	1996	c
1997				c	1997	c	c	c	1997	c
1998				c	1998	c	c	c	1998	c
1999	5	3		b	1999	c	c	c	1999	c
2000	c	7	6	c	2000	c	b	b	2000	c
2001	c	7	7	c	2001	c	c	c	2001	c
2002	c	9	8	c	2002	c	b	b	2002	c
2003	c	c	a	c	2003	c	c	c	2003	c
2004	c	b	a	c	2004	c	c	c	2004	a
2005	c	8	6	c	2005	c	c	c	2005	c
2006	c			c	2006	c	c	c	2006	c
2007				c	2007	c	c	c	2007	c
2008				c	2008	c	c	c	2008	a
2009				c	2009	c	c	c	2009	c
2010				c	2010	c	c	c	2010	c
2011				c	2011	c	c	c	2011	a
2012				9	2012	c	b	b	2012	b

Tabla 3.3 Valores de R^2 mensuales para Temperaturas extremas entre estación Mapocho en Los Almendros y Cerro Calán; y para Caudal entre estación Mapocho en Los Almendros y Estero Arrayán en la Montosa.

Mes	Tmax R^2	Tmin R^2	Caudal R^2
Enero	0,81	0,69	0,88
Febrero	0,88	0,70	0,76
Marzo	0,80	0,70	0,50
Abril	0,86	0,79	0,45
Mayo	0,81	0,66	0,57
Junio	0,75	0,80	0,73
Julio	0,85	0,79	0,64
Agosto	0,83	0,84	0,72
Septiembre	0,90	0,79	0,66
Octubre	0,92	0,71	0,74
Noviembre	0,90	0,74	0,80
Diciembre	0,93	0,72	0,92

Para el caso de las regresiones de precipitaciones diarias se agruparon los meses de diciembre, enero, febrero y marzo, dado que durante los meses mencionados las precipitaciones son muy escasas y no son suficientes para realizar regresiones mensuales. Los coeficientes de correlación obtenidos entre las estaciones Mapocho en Los Almendros y Cerro Calán, a escala mensual, se muestran en la Error! Reference source not found..

Tabla 3.4 Valores de R^2 mensuales para las Precipitaciones entre Mapocho en los Almendros y Cerro Calán

Mes	Pp R^2
Dic-Marzo	0,82
Abril	0,83
Mayo	0,78
Junio	0,88
Julio	0,88
Agosto	0,92
Septiembre	0,82
Octubre	0,92
Noviembre	0,99

Por otro lado, los días donde no existe información de temperaturas extremas diarias en la estación Cerro Calán, para rellenar la estadística de temperaturas extremas en la estación Mapocho en Los Almedros, se realiza lo siguiente:

- Si es sólo un día faltante, se rellena el dato diario de la estación Cerro Calán, promediando los datos del día anterior y el siguiente, luego se rellena el dato de la estación Mapocho en Los Almedros utilizando la regresión. Esto sólo sucede en 6 días de temperatura mínima (31 Diciembre 1995, 28 Enero 1998, 22 Enero 1999, 13 Enero 2007, 6 Abril 2009 y 1 Enero 2012) y 3 días de temperatura máxima (13 Enero 2007, 6 Abril 2009 y 1 Enero 2012). Se observa que no se rellena promediando directamente los datos de los días anterior y siguiente de la estación Mapocho en Los Almedros, dado que éstos también fueron rellenos usando la regresión con la estación Cerro Calán.
- Si es más de un día faltante, no se rellenan los datos y se eliminan de la serie de datos disponibles para el entrenamiento, validación y prueba de las redes neuronales. Esto sucede en 10 días, para los datos de temperaturas extremas, del 19 al 24 de Enero del 2012 y del 29 al 31 de Enero del 2012.

Se observa que en las series de caudales y precipitación no existen datos faltantes; lo anterior implica que se cuenta con datos de temperaturas extremas, precipitación y caudal, para aproximadamente 5600 días.

Finalmente, la estación Valle Nevado está ubicada a los 3040 m.s.n.m. aproximadamente y mide diariamente T° media, T° máxima, T° mínima, humedad relativa, velocidad del viento, precipitación acumulada, precipitación diaria, radiación de onda corta incidente y reflejada, “SWE” o equivalente en agua de nieve y radiación neta.

Capítulo 4 .- Resultados

Para el entrenamiento y selección de las redes neuronales óptimas se utiliza el *toolbox* de RNA de Matlab y se siguieron las siguientes recomendaciones del manual del *toolbox* de RNA, (Hudson et all. 2014):

- “Redes feedforward usualmente tienen una o más capas ocultas de neuronas con funciones de transferencia sigmoidales, seguidas de una capa de salida con función de transferencia lineal. Múltiples capas de neuronas con funciones de transferencia no lineales permiten a la red aprender relaciones no lineales entre los vectores de entradas y las salidas. La capa de salida con función de transferencia lineal es comúnmente usada para problemas de ajuste de funciones o regresiones no lineales.”
- “Para el entrenamiento de redes “feedforward” de múltiples capas, cualquier algoritmo estándar de optimización puede ser usado, pero existen algunos que han mostrado un excelente rendimiento para el entrenamiento de redes neuronales. Éstos métodos de optimización usan el gradiente negativo de la función objetivo con respecto a los pesos, o bien el Jacobiano de los errores con respecto a los pesos. El gradiente y el Jacobiano son calculados usando una técnica llamada *backpropagation* o retropropagación”
- “En general, para problemas de ajuste de función y con redes que contienen hasta unos pocos cientos de pesos, el método de Levenberg-Marquardt (*LM* o *trainlm*), tendría la convergencia más rápida...En muchos casos el algoritmo LM es capaz de obtener menores errores cuadráticos medios que cualquier otro algoritmo existente. El método cuasi-newton (*trainbfg*), es también bastante rápido. Ambos métodos tienden a ser menos eficientes en redes muy largas, con miles de pesos, dado que requieren más memoria y tiempo computacional en estos casos. Además el algoritmo LM rinde mejor en problemas de ajuste de una función, que en problemas de reconocimiento de patrones.”
- El método o algoritmo del Rezago (*trainrp*) es rápido en problemas de reconocimiento de patrones, pero no funciona bien en aproximaciones de funciones”
- El método del Gradiente Conjugado Escalado (*SCG* o *trainscg*) tiene un buen rendimiento en variedad de problemas, particularmente en redes con un gran número de pesos; y es casi tan rápido como el algoritmo LM en problemas de aproximación de funciones.
- “Una capa oculta generalmente produce excelentes resultados, pero se puede probar con dos capas ocultas si los resultados obtenidos con una capa oculta no son satisfactorios. ... Incrementar el número de neuronas en la capa oculta produce una red más poderosa, pero requiere más trabajo computacional y es más tendente a producir sobreentrenamiento.”

Según lo anterior y dado que el problema a resolver corresponde a un ajuste de función o regresión no lineal, se prueba entrenando diferentes redes, en las cuales se varía:

- Función de transferencia entre capas ocultas = tangente sigmoideal “tansig” ó logaritmo sigmoideal “logsig”
- Función de transferencia en capa de salida = lineal “purelin” o tangente sigmoideal “tansig”.
- Función de entrenamiento = Levenberg-Marquardt “LM” ó Gradiente Conjugado Escalado “SCG” (todas basadas en el método de retropropagación).
- Número de neuronas en la capa oculta = 5, 10 ó 20

El número máximo de neuronas en la capa oculta, considerando sólo una capa oculta, es 20 dado que se deben tener mínimo 10 pares de “dato entrada – dato salida observado” por cada peso a calibrar; de éste modo, si se tienen 2300 pares de datos de entrenamiento (50% del total de los datos), se tiene un máximo de 230 pesos más bias. Si se consideran 9 parámetros de entrada y 20 neuronas en la capa oculta, se tienen 200 pesos y 21 bias,

4.1 Calibración con datos de estación Mapocho en Los Almendros

Las distintas redes neuronales artificiales entrenadas en esta sección tienen como parámetros de entrada algunos o todos los parámetros nombrados en la *Tabla 4.1*.

Tabla 4.1 Parámetros de entrada seleccionados para las redes neuronales artificiales

Parámetro	Descripción	Unidades	Escala Temporal
Qinv.	Caudal medio de invierno	[m3/s]	Todas
Tmax inv.	Temperatura máxima promedio de invierno	[°C]	Todas
Tmin inv.	Temperatura mínima promedio de invierno	[°C]	Todas
Pp inv.	Precipitación acumulada durante el invierno	[mm]	Todas
Suma Qant.	Suma de caudales diarios de deshielo anteriores ¹	[m3/s]	Todas
Qt-1	Caudal del día, semana o quincena anterior	[m3/s]	Todas
Tmax t-1	Temperatura máxima del día semana o quincena anterior	[°C]	Todas
Tmin t-1	Temperatura mínima del día, semana o quincena anterior	[°C]	Todas
Pp t-1	Precipitación acumulada en el día, semana o quincena anterior	[mm]	Todas
Qdía-1	Caudal del día anterior	[m3/s]	Semanal y Quincenal
Tmax día-1	Temperatura máxima del día anterior	[°C]	Semanal y Quincenal
Tmax t	Temperatura máxima del día	[°C]	Semanal y Quincenal

¹ La suma de caudales diarios de deshielo anteriores considera el primer día de la temporada de deshielo, el 1 de Octubre, de éste modo, la suma de caudales anteriores el 5 de Octubre corresponde a la suma de los caudales medios diarios de los días 1, 2, 3 y 4 de Octubre.

Es posible notar que los primeros cuatro parámetros de entrada, “Qinv.”, “Tmax inv.”, “Tmin inv.”, y “Pp inv.” muestran a la red una proporción de la nieve acumulada durante el invierno en la cuenca. El quinto parámetro, “Suma Qant.”, muestra a la red una proporción de la nieve derretida hasta la fecha y finalmente, los últimos seis parámetros de entrada, “Q t-1”, “Tmax t-1”, “Tmin t-1”, “Pp t-1”, “Q día-1” y “Tmax t”, muestran a la red las condiciones del día y/o período anterior.

Además, algunos de los parámetros de entrada, como la precipitación líquida acumulada durante el invierno, medida en la estación meteorológica Mapocho en los Almendros, consideran el período invernal de junio a agosto o de mayo a septiembre; la consideración del período invernal de junio a agosto o de mayo a septiembre afecta los parámetros de “Qinv”, “Tmax inv.”, “Tmin inv.” y “Pp inv.”

Los datos disponibles para el entrenamiento, validación y prueba, de todas las redes neuronales, van desde el 1 de octubre de 1982 al 31 de marzo del 2013. El período de deshielo considerado de un año hidrológico, comienza el 1 de Octubre y termina el 31 de marzo, por otro lado los meses de mayo a septiembre son utilizados para determinar los parámetros de invierno, “Qinv”, “Tmax inv.”, “Tmin inv.” y “Pp inv.”, por lo que el mes de abril no se utiliza para los cálculos.

Se entrenan 6 tipos de redes neuronales (*Tabla 4.2*), tanto para la serie diaria, semanal como quincenal, en las cuales se varía la cantidad de neuronas en la capa oculta, la función de transferencia y la función de entrenamiento; la eficiencia de las redes es evaluada según el coeficiente de correlación de Pearson.

Dado que al inicio del entrenamiento se inicializan los pesos y bias de manera aleatoria, al entrenar una misma red varias veces, se observa que los valores de los pesos y bias entregados al final del entrenamiento varían y el valor del coeficiente de correlación de Pearson también varía levemente. Por lo anterior, cada una de las 6 redes se calibra 5 veces, luego se calcula el promedio y desviación estándar de los coeficientes de Pearson. Finalmente, se determina la red óptima eligiendo la red con el mejor promedio de coeficientes de Pearson y menor desviación estándar.

En la *Tabla 4.2* se observa que las redes “Red 1” a “Red 3” tienen la misma función de transferencia, tangente sigmoideal, y la misma función de entrenamiento, “LM”, dado que según el manual del *toolbox* de Matlab, ésta configuración es la que entrega los mejores resultados para problemas de ajuste de función, por lo que sólo se varía el número de neuronas en la capa oculta. Además, en las tres últimas redes, “Red 4” a “Red 6”, no se tiene a priori un número de neuronas, dado que éste dependerá de las eficiencias de las tres redes anteriores; luego, las redes 4 a 6 tendrán el número de neuronas de la red con mejor eficiencia entre las redes 1, 2 y 3. De éste modo se observa si la red óptima dentro de las tres primeras, mejora al cambiar la función de transferencia en la capa oculta, “Red 4”, la función de entrenamiento, “Red 5” o la función de transferencia en la capa de salida “Red 6.

Tabla 4.2 Tipos de Redes entrenadas para la Serie Diaria

Red 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoidal LM
Red 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoidal LM
Red 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoidal LM
Red 4	n° neuronas f(x) transferencia f(x) entrenamiento	- logaritmo sigmoidal LM
Red 5	n° neuronas f(x) transferencia f(x) entrenamiento	- tangente sigmoidal SCG
Red 6	n° neuronas f(x) transferencia f(x) entrenamiento	- lineal LM

Dado que se cuenta con una gran cantidad de datos, se trabaja con la división de datos estándar, es decir, el 50% de los datos para entrenamiento, un 25% para validación y el 25% restante para prueba.

4.1.1 RNA a escala Diaria

Para el caso de la red neuronal a escala temporal diaria se utilizaron 9 parámetros de entrada (Tabla 4.3), lo que implica que la capa de entrada cuenta con nueve neuronas.

Tabla 4.3 Parámetros de entrada RNA escala Diaria

Parámetro	Descripción	Unidades
Qinv.	Caudal medio de invierno	[m3/s]
Tmax inv.	Temperatura máxima promedio de invierno	[°C]
Tmin inv.	Temperatura mínima promedio de invierno	[°C]
Pp inv.	Precipitación acumulada durante el invierno	[mm]
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m3/s]
Qt-1	Caudal del día anterior	[m3/s]
Tmax t-1	Temperatura máxima del día anterior	[°C]
Tmin t-1	Temperatura mínima del día anterior	[°C]
Pp t-1	Precipitación acumulada durante el día anterior	[mm]

Los seis tipos de redes mostrados en la *Tabla 4.2* se entrenan para dos casos, en los cuales se varían los parámetros de entrada, “Qinv”, “Tmax inv.”, “Tmin inv.” y “Pp inv.”. En un primer caso, los parámetros mencionados consideran el período pluvial desde Junio a Agosto (3 meses) y en el segundo caso de Mayo a Septiembre (5 meses).

El vector de salida observado, corresponde a la serie de caudales medios diarios de deshielos, es decir a los caudales medios diarios del 1 de octubre al 31 de marzo de cada año hidrológico, desde 1982 al 2013. En resumen se cuenta con 5.600 datos, de pares de vectores de entrada-salida, para el entrenamiento, validación y prueba de las redes neuronales aproximadamente.

Las redes óptimas para cada uno de los dos casos mencionados se muestran en las *Tabla 4.4* y *Tabla 4.5*. Finalmente, la red óptima para la serie diaria es la red 2 “Mayo-Septiembre” compuesta por 10 neuronas en la capa oculta, función de transferencia tangente sigmooidal y función de entrenamiento “LM”, dado que tiene mayor coeficiente de correlación de Pearson y menor desviación estándar, en anexos se añaden las eficiencias del resto de las redes entrenadas.

Tabla 4.4 Red Diaria Óptima para el primer caso "Junio-Agosto".

Junio-Agosto		
Red Diaria 3	n° neuronas	20
	f(x) transferencia	tangente sigmooidal
	f(x) entrenamiento	LM
	Promedio R ²	0,9932
	Desv. Est. R ²	0,0007
	Mejor R ²	0,9406

Tabla 4.5 Red Diaria Óptima para el segundo caso "Mayo-Septiembre".

Mayo - Septiembre		
Red Diaria 2	n° neuronas	10
	f(x) transferencia	tangente sigmooidal
	f(x) entrenamiento	LM
	Promedio R ²	0,9936
	Desv. Est. R ²	0,0005
	Mejor R ²	0,9940

La *Figura 4.2* muestra la arquitectura de la red óptima, Red diaria “Mayo-Septiembre”; la *Figura 4.2* muestra los coeficientes de Pearson para los datos de entrenamiento, validación, prueba y todos los datos juntos, mientras que la *Figura 4.3* muestra el histograma de error de la misma red.

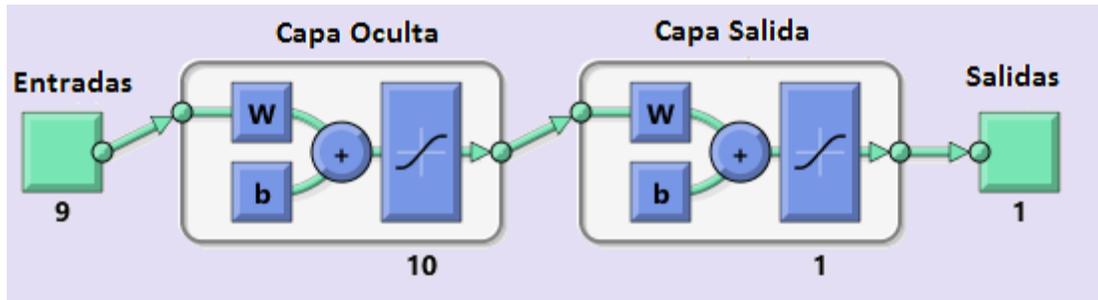


Figura 4.1 Arquitectura RNA Diaria óptima "Mayo-Septiembre"

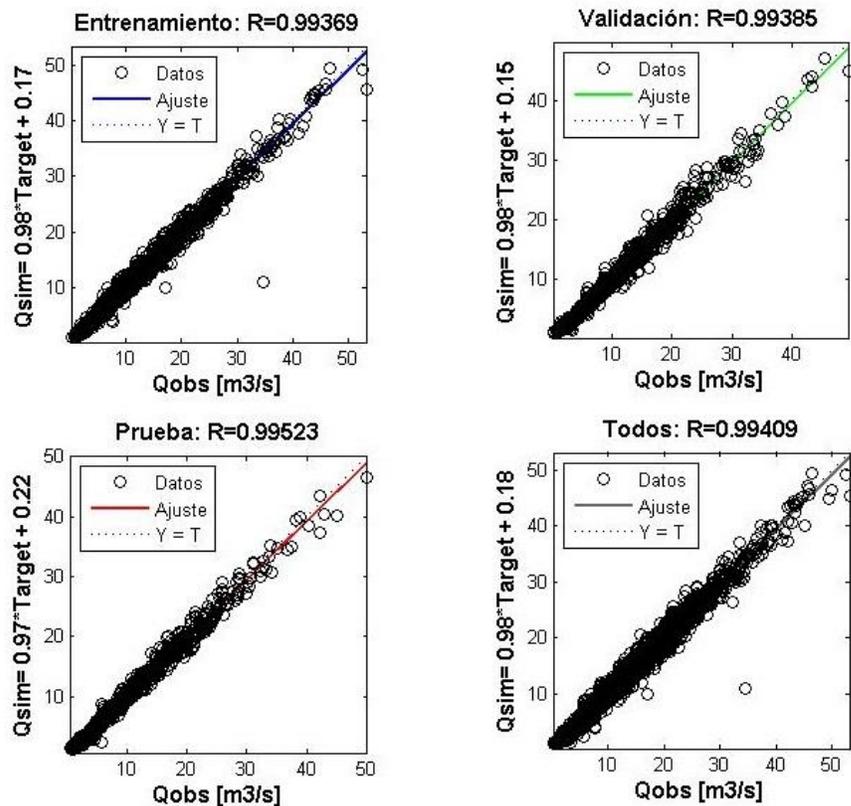


Figura 4.2 Coeficientes de correlación de Pearson, Red Diaria "Mayo - Sept"

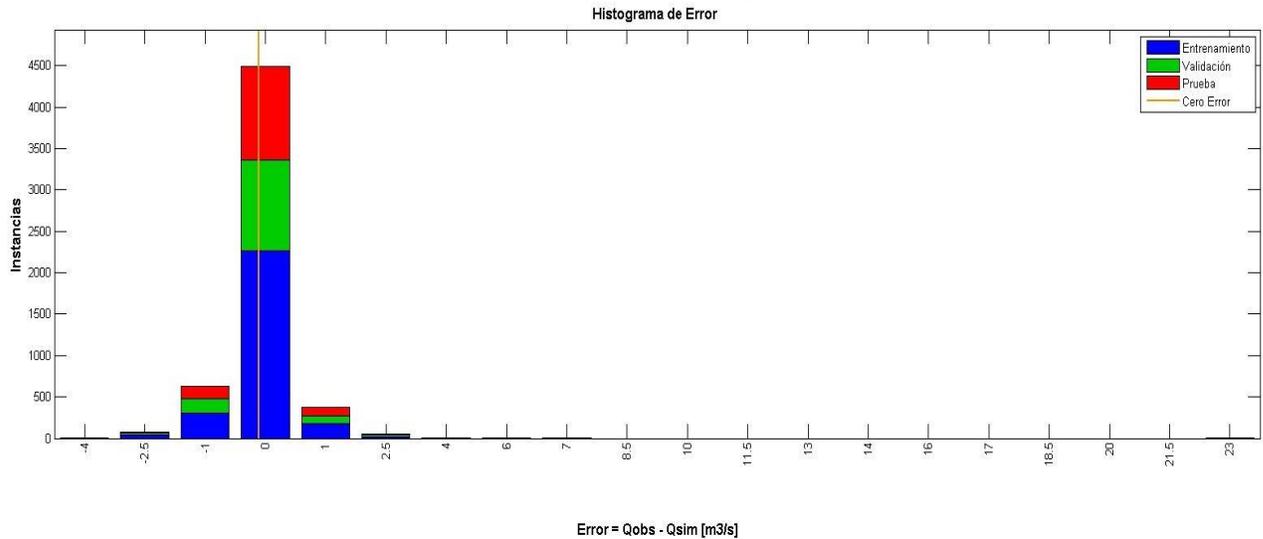


Figura 4.3 Histograma de Errores, Red Diaria "Mayo - Sept"

Las *Tabla 4.6* y *4.7* muestran los pesos y bias de la red óptima para la red neuronal artificial a escala temporal diaria.

Tabla 4.6 Pesos desde la Capa de Entrada a la Capa Oculta "Pesos 1,1", Red Diaria "Mayo – Sept".

Pesos 1,1	Q inv.	Tmax inv.	T° min inv.	Pp mayo-sept	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1
Neurona 1	3,19	-8,08	3,67	5,14	-1,26	-2,76	3,27	-4,45	-0,14
Neurona 2	-11,30	2,76	0,62	0,79	13,94	-3,56	2,66	10,53	-10,74
Neurona 3	0,27	0,14	-0,10	-0,16	0,33	-0,42	-0,21	-0,12	-0,81
Neurona 4	-0,22	-0,02	-0,02	0,13	-0,17	-3,75	0,21	0,06	0,14
Neurona 5	-1,76	-2,07	1,24	2,52	-6,40	1,59	-1,59	-0,87	-1,44
Neurona 6	-4,71	-8,05	-3,48	5,06	-0,93	-3,87	-4,32	2,77	0,33
Neurona 7	-0,41	-0,20	0,14	0,26	-0,52	0,79	0,33	0,19	1,27
Neurona 8	-1,88	0,08	-0,69	1,52	-1,16	-4,17	1,10	0,91	0,14
Neurona 9	-0,19	-0,08	0,04	0,19	-0,30	0,62	0,31	0,09	0,57
Neurona 10	0,77	-0,47	-2,82	6,98	-10,54	-1,43	0,86	0,60	0,05

Tabla 4.7 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Diaria “Mayo - Sept”.

	Pesos 2,1	Bias 1,1	Bias 2,1
Neurona 1	0,02	-8,96	-1,07
Neurona 2	0,04	3,21	
Neurona 3	14,22	-1,67	
Neurona 4	-9,95	-5,39	
Neurona 5	0,03	-4,08	
Neurona 6	0,06	-11,53	
Neurona 7	5,81	1,83	
Neurona 8	-0,07	-3,17	
Neurona 9	4,75	-0,97	
Neurona 10	2,19	1,82	

4.1.2 RNA a escala Semanal

Para el caso de las redes neuronales a escala semanal, donde la semana corresponde al promedio móvil de siete días, se calibran 4 tipos de RNA en las cuales se varían los parámetros de entrada y cada una de estas cuatro redes se calibra seis veces, variando el número de neuronas, funciones de transferencia y función de entrenamiento (según la *Tabla 4.2*). En resumen, para la escala semanal se calibran 24 redes, las *Tabla 4.10 a 4.13* muestran la configuración de red óptima para cada uno de los cuatro tipos de redes calibradas.

Las redes 1 y 2 tienen 9 parámetros de entrada, los cuales se muestran en la *Tabla 4.8*.

Tabla 4.8 Parámetro de entrada redes 1 y 2, escala Semanal

Parámetro	Descripción	Unidades
Qinv.	Caudal medio de invierno	[m3/s]
Tmax inv.	Temperatura máxima promedio de invierno	[°C]
Tmin inv.	Temperatura mínima promedio de invierno	[°C]
Pp inv.	Precipitación acumulada durante el invierno	[mm]
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m3/s]
Qt-1	Caudal promedio de la semana anterior	[m3/s]
Tmax t-1	Temperatura máxima promedio de la semana anterior	[°C]
Tmin t-1	Temperatura mínima promedio semana anterior	[°C]
Pp t-1	Precipitación acumulada durante la semana anterior	[mm]

La diferencia entre las redes 1 y 2 es que la red 1 considera el período pluvial de Junio a Agosto, mientras la segunda red considera el período pluvial de Mayo a Septiembre. El vector de salida deseado u observado, corresponde a la serie de caudales medios semanales de deshielos.

Por otro lado, las redes 3 y 4 tienen 8 parámetros de entrada, los cuales se muestran en la *Tabla 4.9*.

Tabla 4.9 Parámetro de entrada redes 3 y 4, escala Semanal

Parámetro	Descripción	Unidades
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m3/s]
Qt-1	Caudal promedio de la semana anterior	[m3/s]
Tmax t-1	Temperatura máxima promedio de la semana anterior	[°C]
Tmin t-1	Temperatura mínima promedio de la semana anterior	[°C]
Pp t-1	Precipitación acumulada durante la semana anterior	[mm]
Qdía-1	Caudal del día anterior	[m3/s]
Tmax día-1	Temperatura máxima del día anterior	[°C]
Tmax t	Temperatura máxima del día	[°C]

La diferencia entre las redes 3 y 4, es que el último parámetro de entrada, el cual en la red 3 es la temperatura máxima del día anterior, mientras que en la red 4 es la temperatura máxima del mismo día que se está simulando; para lo anterior se asume que se cuenta con pronóstico del tiempo, específicamente de la temperatura máxima diaria, de un día para otro con bastante precisión, lo cual es válido actualmente. Además, la precipitación acumulada en invierno, considera el período invernal de Mayo a Septiembre.

Finalmente, la red óptima para la serie semanal es la red 2 “Mayo - Septiembre”, dado que tiene mayor coeficiente de correlación de Pearson y menor desviación estándar, en el Anexo 3 se añaden las eficiencias del resto de las redes entrenadas.

Tabla 4.10 Configuración óptima para la Red Semanal 1 "Junio - Agosto"

Red 1 "Junio-Agosto"		
Red Semanal 3	n° neuronas	20
	f(x) transferencia	tangente sigmoideal
	f(x) entrenamiento	LM
	Promedio R ²	0,9865
	Desv. Est. R ²	0,0021
	Mejor R ²	0,9895

Tabla 4.11 Configuración óptima para la Red Semanal 2 "Mayo - Septiembre"

Red 2 "Mayo - Septiembre"		
Red Semanal 3	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
	Promedio R^2	0,9888
	Desv. Est. R^2	0,0008
	Mejor R^2	0,9898

Tabla 4.12 Configuración óptima para la Red Semanal 3 "T° max día-1"

Red 3 "T° max día-1"		
Red Semanal 6	n° neuronas	20
	f(x) transferencia	lineal
	f(x) entrenamiento	LM
	Promedio R^2	0.9849
	Desv. Est. R^2	0.0013
	Mejor R^2	0.9870

Tabla 4.13 Configuración óptima para la Red Semanal 4 "T° max día"

Red 4 "T° max día"		
Red Semanal 3	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
	Promedio R^2	0,9859
	Desv. Est. R^2	0,0013
	Mejor R^2	0,9882

La *Figura 4.4* muestra la arquitectura de la red óptima, Red semanal 2 en gris; la *Figura 4.5* muestra los coeficientes de Pearson para los datos de entrenamiento, validación, prueba y todos los datos juntos, por último la *Figura 4.6* muestra el histograma de error de la misma red.

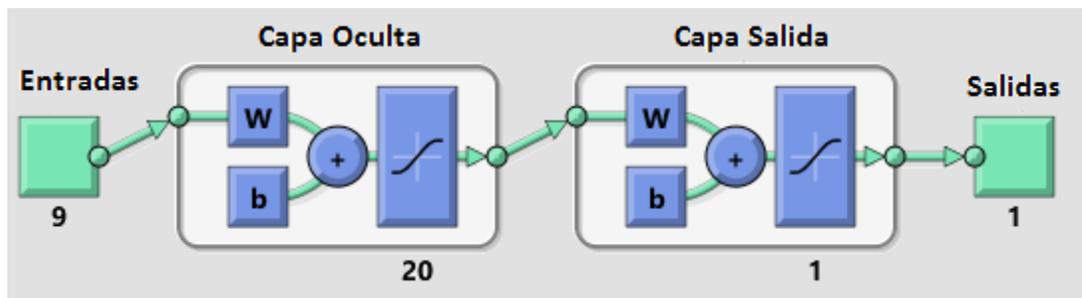


Figura 4.4 Arquitectura RNA Semanal 2 "Mayo-Septiembre"

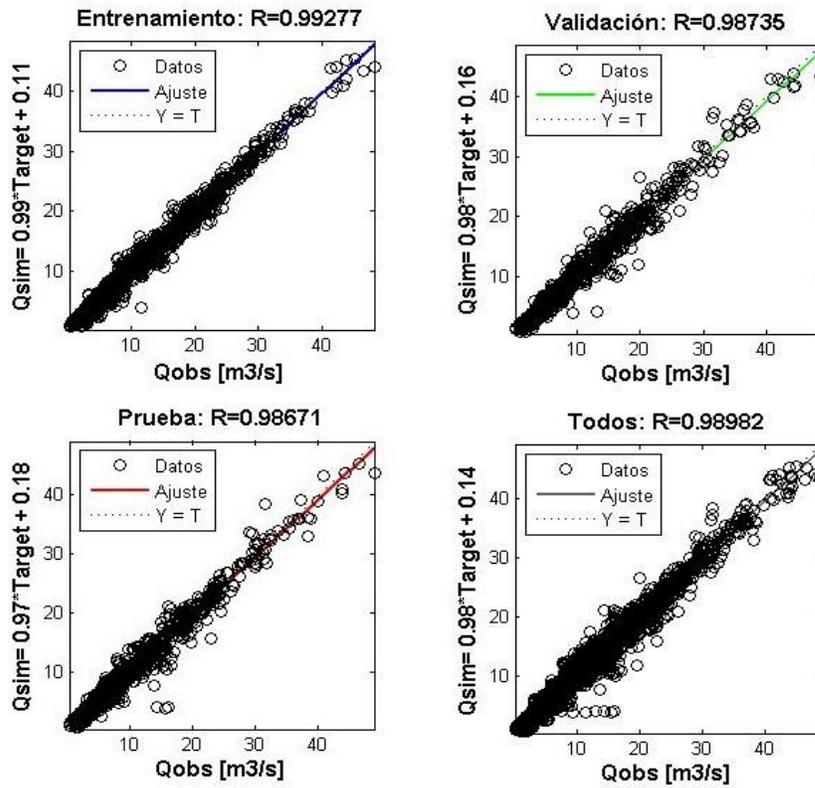


Figura 4.5 Coeficientes de correlación de Pearson, Red Semanal 2 "Mayo - Septiembre"

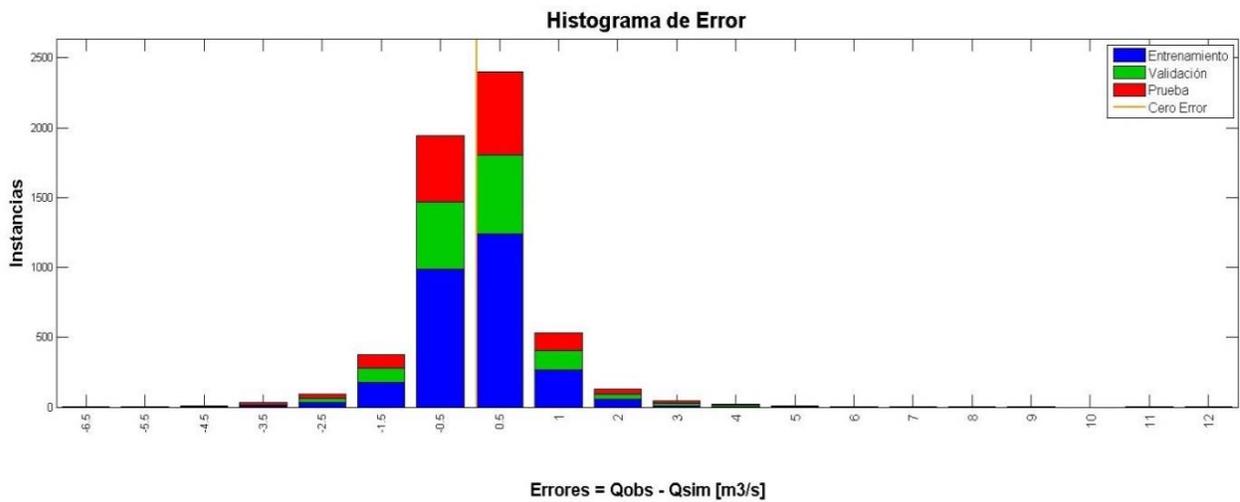


Figura 4.6 Histograma de Errores, Red Semanal 2 "Mayo - Septiembre"

Las *Tabla 4.14* y *4.15* muestran los pesos y bias para la configuración óptima de la Red Semanal 2 “Mayo – Septiembre”.

Tabla 4.14 Pesos desde la Capa de Entrada a la Capa Oculta “Pesos 1,1”, Red Semanal 2 “Mayo – Septiembre”.

Red 2 "Mayo-Septiembre"									
Pesos 1,1	Q inv.	Tmax inv.	T° min inv.	Pp mayo-sept	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1
Neurona 1	-4,75	11,34	8,80	-4,80	-5,00	-1,00	-0,84	2,34	-0,60
Neurona 2	-15,76	-16,66	-1,30	-15,71	-11,81	-2,55	1,06	2,43	3,83
Neurona 3	-0,70	-0,76	0,47	-4,34	8,13	0,60	-0,54	-1,21	-0,58
Neurona 4	1,39	-7,18	-3,12	0,00	3,28	0,15	1,20	-3,01	1,17
Neurona 5	-3,30	-1,34	-3,68	8,40	4,29	-3,45	2,66	1,19	-4,57
Neurona 6	-11,19	-6,56	8,47	9,39	-11,05	-5,93	-2,15	-1,29	-3,91
Neurona 7	-41,09	-50,75	120,30	-26,75	98,26	33,64	58,86	-63,66	33,45
Neurona 8	-1,81	2,97	1,34	0,01	3,58	-1,16	-0,37	-5,59	2,49
Neurona 9	5,36	2,40	-3,23	1,16	-3,87	5,48	0,73	2,34	2,33
Neurona 10	1,34	-5,01	-0,89	1,24	-8,65	-8,85	-1,19	3,68	6,45
Neurona 11	-1,40	-0,48	-8,38	15,58	0,00	-7,33	2,59	3,55	0,65
Neurona 12	-1,41	-11,91	-16,49	-13,22	-43,12	-22,48	-36,81	77,03	-25,41
Neurona 13	-0,18	-0,22	0,16	0,18	-0,21	-2,91	0,04	0,05	0,11
Neurona 14	3,53	1,38	0,75	-7,57	0,61	1,87	-0,18	-1,09	1,33
Neurona 15	1,03	-3,27	-1,97	-4,24	-4,67	8,66	2,49	5,52	-24,91
Neurona 16	-28,00	-34,49	-1,70	-4,15	9,40	10,77	5,03	-3,79	49,03
Neurona 17	1,58	-9,62	-6,17	-3,72	2,92	6,16	-1,12	1,64	2,83
Neurona 18	-0,49	0,21	-1,40	-5,32	1,82	4,61	-1,03	0,21	0,87
Neurona 19	-1,98	0,30	0,76	0,85	2,85	0,10	0,10	-0,14	-1,00
Neurona 20	-2,40	5,93	-10,78	19,30	-18,80	18,07	10,75	-16,26	6,07

Tabla 4.15 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Semanal 2 "Mayo - Septiembre”

Red 2 "Mayo-Septiembre"			
Red 4	Pesos 2,1	Bías 1	Bías 2
Neurona 1	-0,06	9,12	-40,4106
Neurona 2	0,18	-29,96	
Neurona 3	0,31	6,17	
Neurona 4	-0,41	-4,50	
Neurona 5	0,24	-6,97	
Neurona 6	0,15	-8,03	
Neurona 7	0,06	30,07	
Neurona 8	0,32	8,78	
Neurona 9	0,14	3,53	
Neurona 10	0,18	-7,52	
Neurona 11	-0,28	-5,25	
Neurona 12	-0,06	-11,84	
Neurona 13	-39,78	-4,93	
Neurona 14	-0,35	4,27	
Neurona 15	0,19	-30,19	
Neurona 16	-0,13	80,22	
Neurona 17	-0,21	8,04	
Neurona 18	-0,30	2,27	
Neurona 19	-0,55	-0,90	
Neurona 20	0,09	-0,95	

Además de los resultados para la red óptima (Red Semanal 2), se exponen los resultados para la Red Semanal 4 “T^omax día”, la cual es la red óptima para el segundo tipo de redes entrenadas (redes 3 y 4). Luego, la *Figura 4.7* muestra la arquitectura de la red, la *Figura 4.8* los coeficientes de Pearson para los datos de entrenamiento, validación, prueba y todos los datos juntos, y la *Figura 4.9* muestra el histograma de error de la configuración óptima para la Red Semanal 4, en gris en la *Tabla 4.13*.

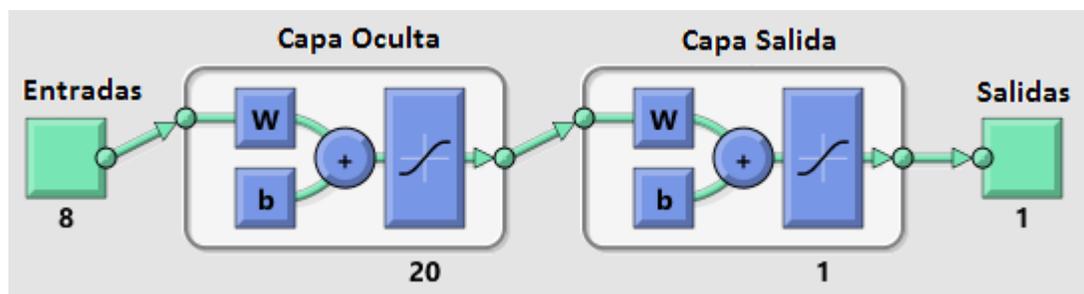


Figura 4.7 Arquitectura RNA Semanal 4 "Tmax día"

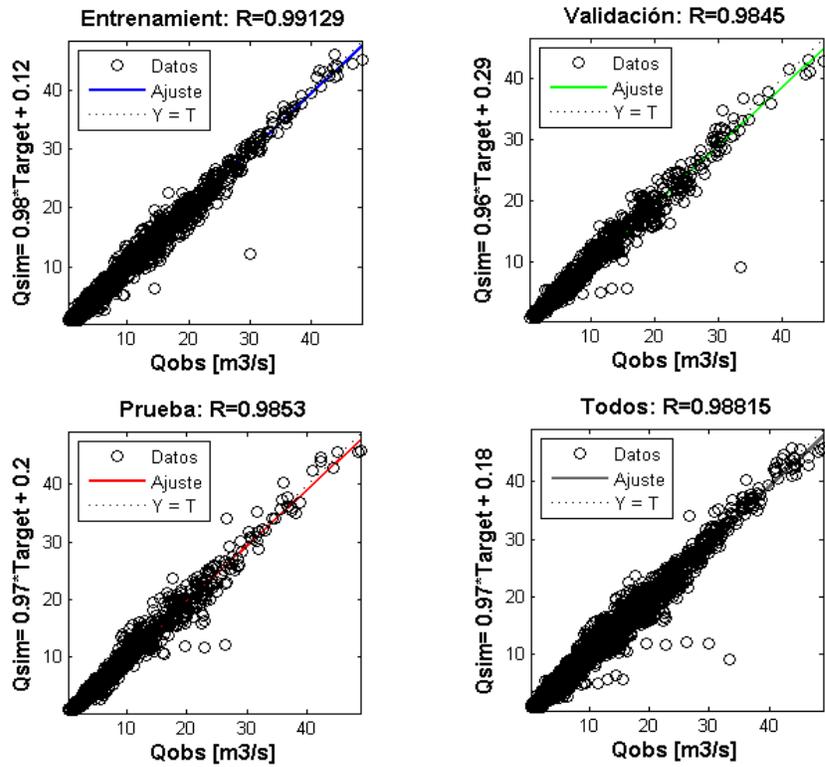


Figura 4.8 Coeficientes de correlación de Pearson, Red Semanal 4 "T° max día"

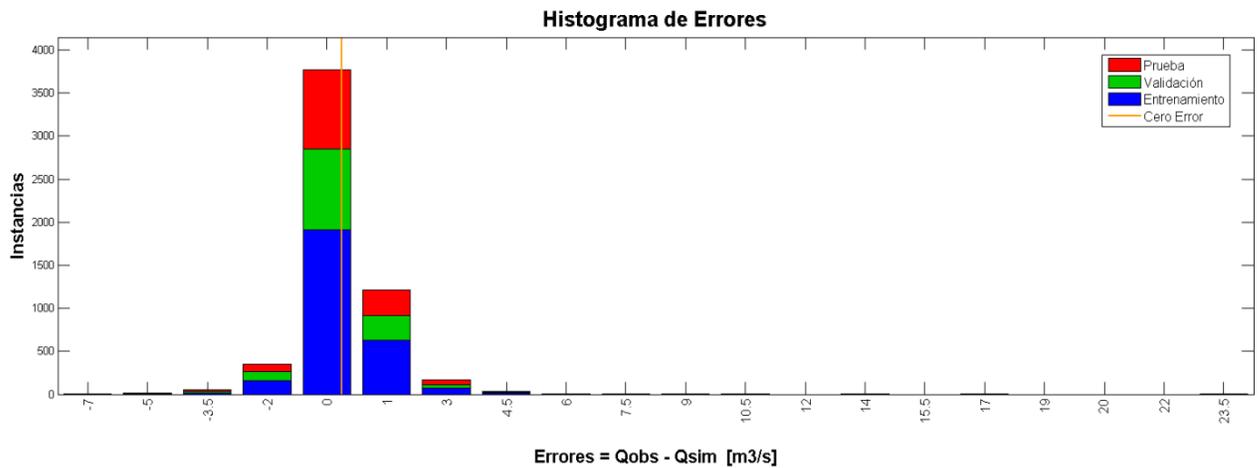


Figura 4.9 Histograma de Errores, Red Semanal 4 "T° max día"

Las *Tabla 4.16* y *4.17* muestran los pesos y bias para la configuración óptima de la Red Semanal 4 “T^omax día”.

Tabla 4.16 Pesos desde la Capa de Entrada a la Capa Oculta “Pesos 1,1”, Red Semanal 4 “T^omax día”.

Red 4 "Tmax día"								
Pesos 1,1	Pp mayo-sept	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1	Q día-1	Tmax t
Neurona 1	0,88	2,28	-4,49	-0,56	1,01	-0,51	-2,23	-0,50
Neurona 2	-0,61	-7,54	0,02	-1,18	-0,69	0,10	0,13	-0,15
Neurona 3	-10,85	2,36	9,72	-0,77	0,19	-1,68	0,61	0,10
Neurona 4	9,63	3,87	8,72	-0,98	1,66	0,04	1,48	0,32
Neurona 5	1,59	-2,05	3,36	-0,97	2,89	-4,75	0,10	-0,14
Neurona 6	-1,37	-1,05	9,85	-0,01	-1,15	-0,16	1,05	0,21
Neurona 7	-12,48	3,08	-12,15	0,62	2,39	-2,18	-1,72	-0,03
Neurona 8	0,58	-1,42	-1,47	1,07	-1,41	0,51	-2,03	-0,77
Neurona 9	2,16	1,07	1,33	-3,13	1,22	2,19	2,42	-0,09
Neurona 10	3,35	0,52	1,97	-1,20	0,73	1,02	1,43	0,28
Neurona 11	-8,02	14,71	0,97	-6,00	1,23	-13,11	-4,47	-4,04
Neurona 12	11,67	-9,91	5,31	-4,72	-3,31	-12,98	3,48	-0,85
Neurona 13	1,17	0,97	-4,59	0,35	1,06	-0,02	-0,76	-0,05
Neurona 14	1,54	-2,08	0,55	-1,37	3,27	-4,17	-0,01	-0,18
Neurona 15	0,82	6,82	-4,05	1,28	0,63	-0,01	-0,27	0,06
Neurona 16	-1,24	2,87	1,51	2,76	0,25	-4,03	-8,51	0,60
Neurona 17	-0,61	-0,71	-2,75	-0,28	-0,94	0,29	0,72	-0,08
Neurona 18	0,21	-0,61	2,63	0,22	-0,14	-0,34	6,00	-0,31
Neurona 19	1,72	3,90	4,76	-1,66	-9,60	-1,34	-3,44	8,91
Neurona 20	1,56	-0,85	-0,68	0,04	-0,34	-0,24	-0,62	-0,36

Tabla 4.17 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Semanal 4 “T^{max} día”

Red 4 "T^{max} día"			
Red 4	Pesos 2,1	Bias 1	Bias 2
Neurona 1	0,88	-3,03	
Neurona 2	-4,34	-8,26	
Neurona 3	-0,81	15,95	
Neurona 4	-0,99	-3,21	
Neurona 5	0,82	-3,18	
Neurona 6	3,91	7,77	
Neurona 7	0,73	-3,07	
Neurona 8	-0,31	-2,69	
Neurona 9	-1,31	-0,36	
Neurona 10	2,40	-1,51	
Neurona 11	-0,07	-0,49	-1,764
Neurona 12	0,07	-9,41	
Neurona 13	7,76	-2,70	
Neurona 14	-0,82	-5,45	
Neurona 15	-4,73	3,71	
Neurona 16	-0,11	-8,91	
Neurona 17	5,24	-3,82	
Neurona 18	1,24	8,35	
Neurona 19	0,05	-0,94	
Neurona 20	0,77	2,09	

4.1.3 RNA a escala Quincenal

Para el caso de las redes neuronales a escala quincenal, donde la quincena corresponde al promedio móvil de quince días; al igual que para el caso de las RNA a escala semanal, se calibran 4 tipos de RNA, en las cuales se varían los parámetros de entrada y cada una de estas cuatro redes se calibra seis veces, variando el número de neuronas, funciones de transferencia y función de entrenamiento (Tabla 4.2). En resumen, para la escala quincenal se calibran 24 redes, las Tabla 4.20 a 4.23 muestran la configuración de red óptima para cada uno de los cuatro tipos de redes.

Las redes 1 y 2 tienen 9 parámetros de entrada, los cuales son:

Tabla 4.18 Parámetros de entrada Redes 1 y 2, escala Quincenal

Parámetro	Descripción	Unidades
Q _{inv.}	Caudal medio de invierno	[m ³ /s]
T _{max inv.}	Temperatura máxima promedio de invierno	[°C]
T _{min inv.}	Temperatura mínima promedio de invierno	[°C]
P _{p inv.}	Precipitación acumulada durante el invierno	[mm]
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m ³ /s]
Q _{t-1}	Caudal promedio de la quincena anterior	[m ³ /s]
T _{max t-1}	Temperatura máxima promedio de la quincena anterior	[°C]
T _{min t-1}	Temperatura mínima promedio quincena anterior	[°C]
P _{p t-1}	Precipitación acumulada durante la quincena anterior	[mm]

Por otro lado, las redes 3 y 4 tienen 8 parámetros de entrada, los cuales son:

Tabla 4.19 Parámetros de entrada Redes 3 y 4, escala Quincenal

Parámetro	Descripción	Unidades
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m ³ /s]
Q _{t-1}	Caudal promedio de la semana anterior	[m ³ /s]
T _{max t-1}	Temperatura máxima promedio de la quincena anterior	[°C]
T _{min t-1}	Temperatura mínima promedio de la quincena anterior	[°C]
P _{p t-1}	Precipitación acumulada durante la quincena anterior	[mm]
Q _{día-1}	Caudal del día anterior	[m ³ /s]
T _{max día-1}	Temperatura máxima del día anterior	[°C]
T _{max t}	Temperatura máxima del día	[°C]

Al igual que para el caso de las redes a escala semanal, la diferencia entre las redes 1 y 2 es que la red 1 considera el período pluvial de Junio a Agosto, mientras la segunda red considera el período pluvial de Mayo a Septiembre y la diferencia entre las redes 3 y 4, es que el último parámetro de entrada de la red 3 es la temperatura máxima del día anterior, mientras que el de la red 4 es la temperatura máxima del día simulado; además, en las redes 3 y 4 la precipitación acumulada en invierno, considera el período pluvial de Mayo a Septiembre.

Tabla 4.20 Configuración óptima para la Red Quincenal 1 "Junio - Agosto"

Red 1 "Junio-Agosto"		
Red Quincenal 6	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
	Promedio R^2	0.9953
	Desv. Est. R^2	0.0005
	Mejor R^2	0.9960

Tabla 4.21 Configuración óptima para la Red Quincenal 2 "Mayo - Septiembre"

Red 2 "Mayo - Septiembre"		
Red Quincenal 3	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
	Promedio	0,9956
	Desv. Est.	0,0009
	Mejor	0,9963

Tabla 4.22 Configuración óptima para la Red Quincenal 3 "T° max día-1"

Red 3 "T° max día-1"		
Red Quincenal 3	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
	Promedio R^2	0,9893
	Desv. Est. R^2	0,0006
	Mejor R^2	0,9897

Tabla 4.23 Configuración óptima para la Red Quincenal 4 "T° max día"

Red 4 "T° max día"		
Red Quincenal 3	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
	Promedio R^2	0,9889
	Desv. Est. R^2	0,0012
	Mejor R^2	0,9905

La *Figura 4.10* muestra la arquitectura de la red óptima, Red Quincenal 2 “Mayo-Septiembre”; la *Figura 4.11* muestra los coeficientes de Pearson para los datos de entrenamiento, validación, prueba y todos los datos juntos, mientras que la *Figura 4.12* muestra el histograma de error de la misma red.

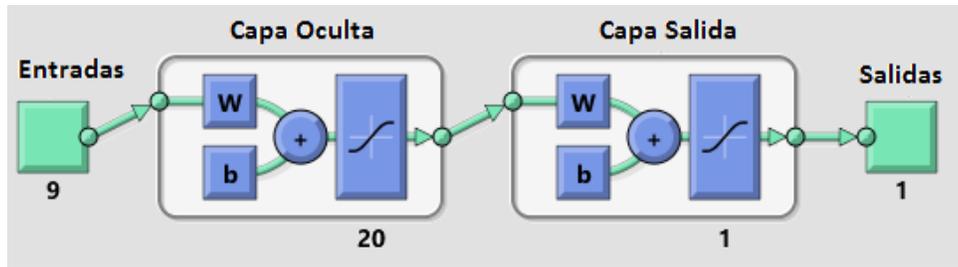


Figura 4.10 1 Arquitectura RNA Quincenal 2 "Mayo-Septiembre"

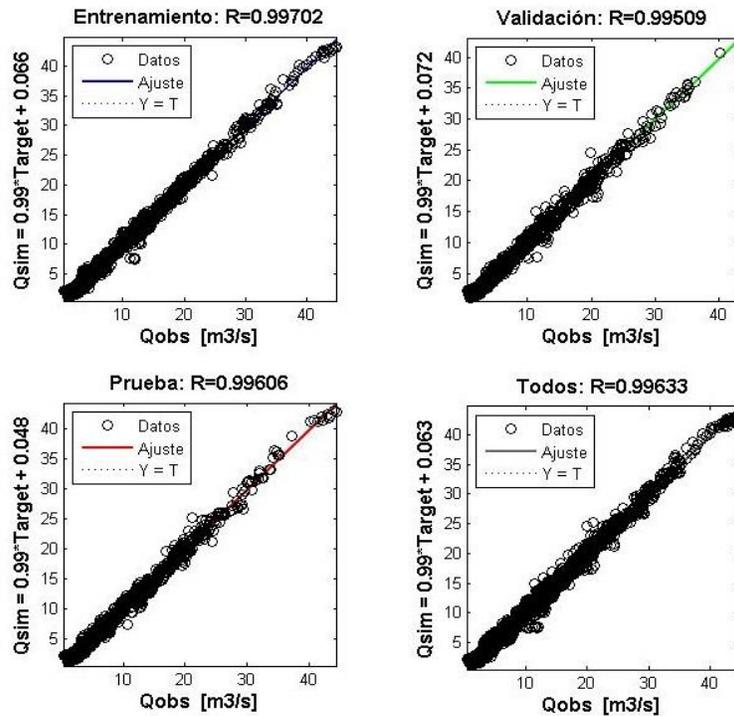


Figura 4.11 Coeficientes de correlación de Pearson, Red Quincenal 2 "Mayo - Septiembre"

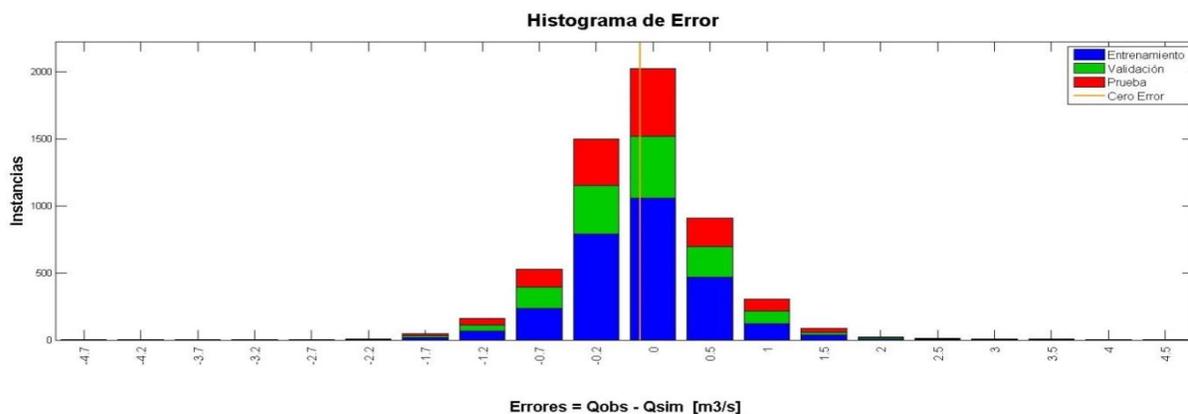


Figura 4.12 Histograma de Errores, Red Quincenal 2 "Mayo - Septiembre"

Las Tabla 4.24 y 4.25 muestran los pesos y bias para la configuración óptima de la Red Quincenal 2 “Mayo - Septiembre”.

Tabla 4.24 Pesos desde la Capa de Entrada a la Capa Oculta “Pesos 1,1”.

Red 2 "Mayo-Septiembre"									
Pesos 1,1	Q inv.	Tmax inv.	T° min inv.	Pp mayo-sept	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1
Neurona 1	0,92	0,47	-0,58	-0,28	-1,70	-0,20	0,09	0,16	0,00
Neurona 2	0,41	-1,83	-1,53	0,68	0,91	0,90	0,32	0,18	-0,01
Neurona 3	-2,69	0,47	1,01	-1,23	0,75	-0,47	-0,23	-0,26	-0,15
Neurona 4	-1,52	2,40	-0,86	0,59	-2,13	0,50	-0,58	1,49	-0,69
Neurona 5	-2,01	2,53	-4,22	5,63	-1,44	2,26	1,46	-0,92	1,59
Neurona 6	-0,33	1,90	-1,11	-0,91	-0,05	-2,16	0,40	0,08	0,34
Neurona 7	-1,30	-1,34	0,87	-0,45	2,74	0,45	0,46	0,17	-0,15
Neurona 8	3,63	-1,60	-2,83	1,17	0,06	2,90	1,73	0,10	0,33
Neurona 9	1,38	0,58	2,19	-4,88	-2,73	-1,37	0,46	-0,31	-0,14
Neurona 10	-3,36	3,19	-10,69	-2,28	1,85	-0,22	-0,46	1,08	0,71
Neurona 11	-1,88	-0,17	-2,31	3,54	0,89	2,61	-0,62	-0,04	0,49
Neurona 12	-1,57	-0,19	-0,16	1,95	2,98	-0,06	0,04	-0,16	0,20
Neurona 13	0,66	-1,98	0,90	-0,49	2,81	-1,76	0,33	1,04	-0,24
Neurona 14	0,60	-1,07	-1,93	1,63	0,50	0,76	0,30	-0,15	0,28
Neurona 15	2,48	3,62	0,94	1,07	-2,56	-3,86	0,67	-0,71	-0,50
Neurona 16	0,55	-0,48	0,04	0,03	-5,21	2,24	-0,16	-0,48	-0,02
Neurona 17	-4,21	-0,39	6,33	-1,71	1,56	0,13	-0,30	0,25	0,08
Neurona 18	1,23	-0,54	-3,58	0,94	0,37	0,97	0,02	-0,06	0,18
Neurona 19	-1,36	-0,30	-2,86	3,79	0,69	1,96	-0,69	-0,30	0,44
Neurona 20	-0,49	2,14	-0,09	-0,48	-0,68	1,00	-0,12	0,07	-0,17

Tabla 4.25 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Quincenal 2 "Mayo - Septiembre”

Red 2 "Mayo-Septiembre"			
Red 4	Pesos 2,1	Bias 1	Bias 2
Neurona 1	-3,72	-2,00	
Neurona 2	1,91	-1,47	
Neurona 3	-1,52	2,67	
Neurona 4	0,56	-1,90	
Neurona 5	-0,51	4,95	
Neurona 6	0,58	-0,19	
Neurona 7	-1,18	0,24	
Neurona 8	0,23	1,18	
Neurona 9	0,73	-1,75	
Neurona 10	-0,65	1,06	-3,3056
Neurona 11	-2,26	-0,70	
Neurona 12	-1,67	3,00	
Neurona 13	-0,95	1,76	
Neurona 14	3,42	1,86	
Neurona 15	0,51	0,03	
Neurona 16	-0,82	-3,68	
Neurona 17	0,84	-0,73	
Neurona 18	-2,16	4,12	
Neurona 19	1,99	-1,13	
Neurona 20	3,51	2,65	

Además de los resultados para la red óptima (Red Quincenal 2), se exponen los resultados para la Red Quincenal 4 “T^omax día”, la cual es la red óptima para el segundo tipo de redes entrenadas (redes 3 y 4). Luego, la *Figura 4.13* muestra la arquitectura de la red, la *Figura 4.14* muestra los coeficientes de Pearson para los datos de entrenamiento, validación, prueba y todos los datos juntos, y la *Figura 4.15* muestra el histograma de error de la configuración óptima para la Red Quincenal 4, en gris en la *Tabla 4.23*.

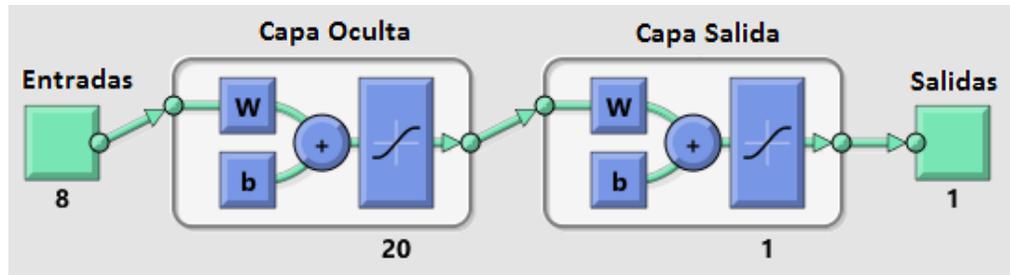


Figura 4.13 Arquitectura RNA Quincenal 4 "Tmax día"

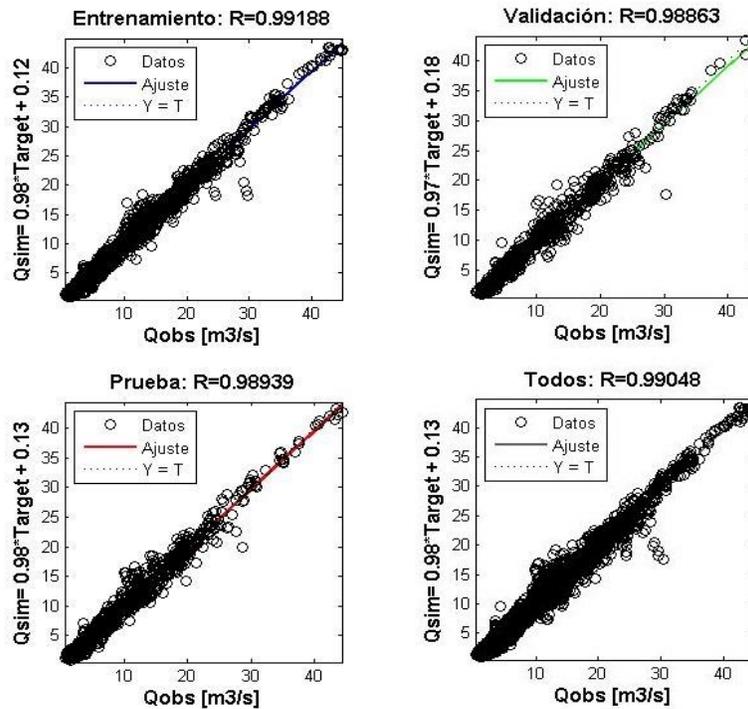


Figura 4.14 Coeficientes de correlación de Pearson, Red Quincenal 4 "T° max día"

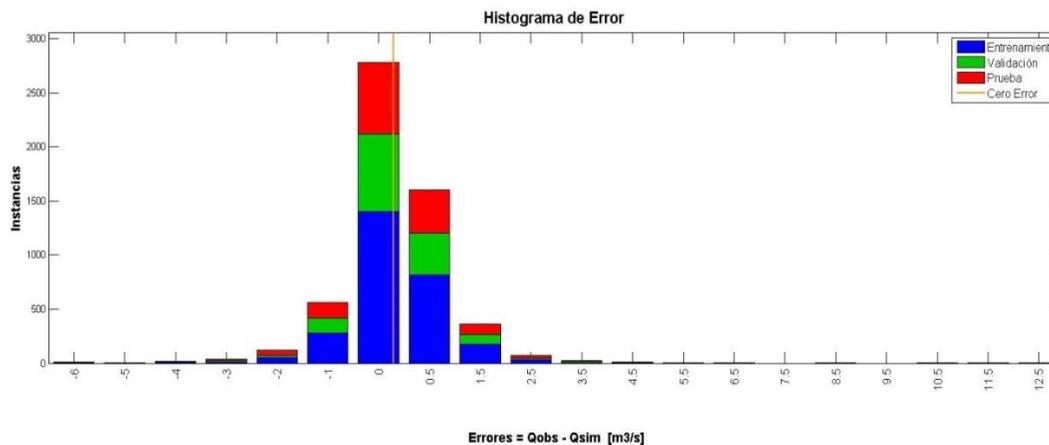


Figura 4.15 Histograma de Errores, Red Quincenal 4 "T° max día"

Las Tablas 4.26 y 4.27 muestran los pesos y bias para la configuración óptima de la Red 4 “T°max día”.

Tabla 4.26 Pesos desde la Capa de Entrada a la Capa Oculta “Pesos 1,1”, Red Quincenal 4 “T°max día”.

Red 4 "Tmax día"								
Pesos 1,1	Pp mayo-sept	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1	Q día-1	Tmax t
Neurona 1	-17,45	35,93	29,00	-6,47	-9,63	13,13	-5,75	0,41
Neurona 2	0,67	-0,56	-0,70	0,85	-1,14	0,22	-19,21	0,00
Neurona 3	-1,24	0,52	-0,88	-1,80	1,74	-0,73	10,96	-0,06
Neurona 4	0,11	0,61	-2,69	1,94	-1,35	1,11	-7,70	0,03
Neurona 5	-0,76	1,14	0,28	0,30	0,10	0,46	8,38	-0,01
Neurona 6	0,75	-2,24	-1,28	-0,50	0,42	-0,49	-9,94	-0,04
Neurona 7	-1,30	6,37	-1,35	-0,67	1,94	-0,21	15,18	0,11
Neurona 8	7,84	-13,11	24,01	8,44	-13,65	-4,04	-10,62	-3,25
Neurona 9	5,25	-24,23	-25,62	-4,54	-5,85	23,13	13,53	-3,23
Neurona 10	14,49	-24,39	2,15	11,54	-4,85	6,84	20,64	0,64
Neurona 11	-1,00	3,63	3,75	0,53	-1,25	-1,37	-0,37	0,01
Neurona 12	6,99	2,58	21,05	-0,42	-2,65	-0,55	-11,54	0,55
Neurona 13	1,08	-1,73	1,99	-1,84	0,82	-1,56	-19,99	0,04
Neurona 14	0,46	-0,11	0,92	-0,61	0,09	-0,50	-10,50	0,00
Neurona 15	-0,55	0,35	1,29	-0,95	1,10	-0,28	18,53	-0,01
Neurona 16	-4,60	-17,52	0,79	6,80	-9,85	0,84	1,12	-0,20
Neurona 17	-0,80	3,65	3,19	1,86	-1,65	2,28	4,36	0,04
Neurona 18	-1,21	5,56	-0,41	-0,77	1,93	-0,03	30,16	0,08
Neurona 19	-12,83	-4,96	31,85	-26,61	12,22	-20,32	1,05	12,64
Neurona 20	-0,82	0,37	-0,62	-1,38	1,44	-0,58	8,89	-0,04

Tabla 4.27 Pesos desde la Capa Oculta a la Capa de Salida “Pesos 2,1”, Bias de la Capa Oculta “Bias 1,1” y Bias de la Capa de Salida “Bias 2,1”, Red Quincenal 4 “T^omax día”

Red 4 "T^omax día"			
Red 4	Pesos 2,1	Bias 1	Bias 2
Neurona 1	0,075	38,56	7,346
Neurona 2	42,230	-20,74	
Neurona 3	-13,269	11,79	
Neurona 4	4,208	-9,72	
Neurona 5	-4,791	9,00	
Neurona 6	-2,829	-11,97	
Neurona 7	1,460	20,85	
Neurona 8	0,089	-11,06	
Neurona 9	-0,070	-16,54	
Neurona 10	0,120	7,02	
Neurona 11	1,121	-1,76	
Neurona 12	-0,100	9,82	
Neurona 13	1,791	-18,56	
Neurona 14	-3,669	-9,69	
Neurona 15	26,457	20,11	
Neurona 16	-0,161	-15,57	
Neurona 17	0,914	7,51	
Neurona 18	3,022	35,37	
Neurona 19	0,046	-10,70	
Neurona 20	25,035	9,68	

4.2 Calibración con datos de estación Valle Nevado

Los datos de la estación Valle Nevado utilizados corresponden a T° media, T° máxima, T° mínima, humedad relativa, velocidad del viento, precipitación acumulada, precipitación diaria, radiación de onda corta incidente y reflejada y “SWE” o equivalente en agua de nieve, todas a escala diaria. La estación Valle Nevado fue instalada el año 2013 por lo que sólo se cuenta con datos para la temporada 2013-2014, lo cual implica que se tienen 180 pares de datos de “entrada - salida observada”.

Dado que se cuenta con muy poco datos, la calibración se realiza utilizando el 70% de los datos para entrenamiento, 15% para validación y 15% para prueba. Lo anterior implica que se tienen 120 datos para el entrenamiento y como se deben tener mínimo 10 pares de datos por cada peso o bias a calibrar, el número máximo de pesos más bias es 12, por lo que se debe disminuir el número de parámetros de entrada a 4 y el número de neuronas en la capa oculta a 2.

Por otro lado, para determinar y analizar los efectos de incluir datos hidrometeorológicos provenientes de la estación Valle Nevado en las redes neuronales, se deben comparar los rendimientos de dos redes de características similares, es decir, con el mismo número de parámetros de entrada, la misma cantidad de neuronas en la capa oculta, la misma función de entrenamiento y la misma cantidad de datos para el entrenamiento, validación y prueba; de manera tal de comparar exclusivamente la calidad de la información. Por lo tanto, el entrenamiento de las redes neuronales tanto usando datos de la estación Valle Nevado como de la estación Mapocho en los Almendros, se realiza para la temporada de deshielo 2013-2014, con cuatro parámetros de entrada, dos neuronas en la capa oculta y la función de entrenamiento “LM” (Figura 4.16).

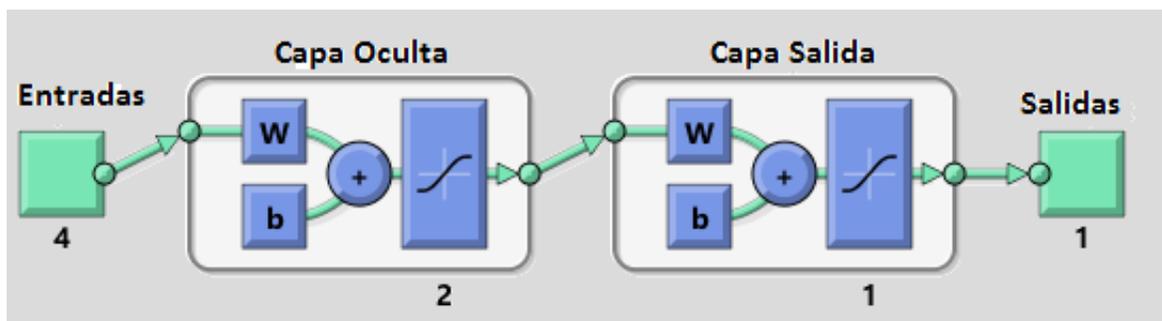


Figura 4.16 Esquema RNA entradas con los datos de Valle Nevado y Mapocho en Los Almendros, temporada 2013-2014.

4.2.1 RNA a escala Diaria

Para determinar qué parámetros de entrada son menos relevantes y cuales son más relevantes, se realiza un análisis de parámetros, el cual consiste en entrenar la red utilizando una neurona en la capa oculta y sólo dos parámetros de entrada y comparar los coeficientes de correlación de Pearson que se obtienen.

Uno de los parámetros de entrada es el caudal del día anterior, dado que al entrenar las redes utilizando sólo el caudal del día anterior se obtienen coeficientes de correlación de Pearson de 0.968, por lo que es el parámetro de entrada más significativo, y el segundo se varía entre los parámetros de entrada de la *Tabla 4.28*

Tabla 4.28 Parámetros de entrada para análisis de significancia.

Parámetro	Descripción	Unidades
Qinv.	Caudal medio de invierno	[m3/s]
Tmax inv.	Temperatura máxima promedio de invierno	[°C]
Tmin inv.	Temperatura mínima promedio de invierno	[°C]
Pp inv.	Precipitación acumulada durante el invierno	[mm]
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m3/s]
Tmax t-1	Temperatura máxima promedio del día anterior	[°C]
Tmin t-1	Temperatura mínima promedio del día anterior	[°C]
Pp t-1	Precipitación acumulada durante el día anterior	[mm]
H.R. t-1	Humedad Relativa del día anterior	[%]
Vviento t-1	Velocidad del viento del día anterior	[m/s]
SWE	SWE o equivalente en agua de nieve, al comienzo de la temporada de deshielo.	[mm]

Se observa que no se usan los datos de radiación incidente, reflejada y/o neta, dado que falta una gran cantidad de datos, además, se cuenta con datos de SWE hasta el 26 de Septiembre, por lo que sólo es posible obtener el equivalente en agua de nieve al 26 de Septiembre, y no el equivalente en agua de nieve día a día durante la temporada de deshielo.

Los resultados obtenidos del análisis de las variables de entrada, para la escala temporal diaria, se muestran en la *Tabla 4.29*; Se observa que las variables de invierno, “Qinv”, “Tmax inv.”, “Tmin inv.” y “Pp inv.”, no tienen valores de R^2 dado que al entrenar la red con estas variables se obtiene sólo un peso, lo cual implica que la red al optimizar los pesos descarta una variable. Lo anterior se debe a que estas variables son constantes durante la temporada de deshielo, y en este caso se tiene sólo una temporada, por lo que son constantes para todo el set de datos de entrenamiento.

Tabla 4.29 Análisis de Variables Significativas, Escala temporal Diaria

Variable	R ² Mejor	R ² Promedio	Desv. Est. R ²	Lugar
Q t-1	0,9687	0,9683	0,0002	-
Q t-1 Tmax	0,9695	0,9694	0,0003	2
Q t-1 Tmin	0,9693	0,9685	0,0008	6
Q t-1 Tmed	0,9694	0,9691	0,0003	3
Q t-1 Pp	0,9693	0,9685	0,0007	5
Q t-1 Qant	0,9694	0,9689	0,0009	4
Q t-1 H.R.	0,9716	0,9715	0,0002	1
Q t-1 Vviento	0,9689	0,9685	0,0004	7
Q t-1 H nieve				8
Q t-1 Q inv				8
Q t-1 Tmax inv				8
Q t-1 Tmin inv				8
Q t-1 Pp inv				8

Luego, los parámetros más significativos son los destacados en gris (*Tabla 4.29*), es decir, el caudal del día anterior, la humedad relativa del día anterior, la temperatura máxima del día anterior, la suma de caudales de deshielo anteriores, la temperatura media del día anterior y la precipitación acumulada en el día anterior. Por lo que en vez de tener 9 posibles parámetros de entrada, éstos se reducen a 6.

Además, se observa que dos de los seis parámetros seleccionados son prácticamente la misma variable, los cuales son la temperatura máxima del día anterior y la temperatura media del día anterior, por lo que se descarta la temperatura media, dado que tiene peor rendimiento. Por lo que finalmente, se tienen 5 posibles variables de entrada.

4.2.1.1 RNA a Escala Diaria Valle Nevado

Se calibran 3 tipos de redes, dado que se tienen máximo 4 parámetros de entrada, se prueba la combinación de los cinco parámetros seleccionados (*Tabla 4.30*). Se observa que la temperatura máxima del día anterior siempre forma parte de los parámetros de entrada en las redes neuronales artificiales que se entrenan, debido a que según el método Grado Día, el derretimiento de nieve puede determinarse con tan sólo tres parámetros, uno de los cuales es la temperatura media del aire, de lo cual se deduce que la temperatura es un parámetro significativo. Además el número de neuronas en la capa oculta es siempre 2.

Tabla 4.30 Parámetros de Entrada, RNA calibradas para la escala temporal diaria

	Parámetros de Entrada				Entrenamiento
Valle Nevado 1	Q t-1	H.R. t-1	Tmax t-1	Pp t-1	LM
Valle Nevado 2	Q t-1	H.R. t-1	Tmax t-1	Suma Qant	LM
Valle Nevado 3	Q t-1	Suma Qant	Tmax t-1	Pp t-1	LM

Los rendimientos para cada una de las tres redes calibradas se muestra en la *Tabla 4.31*, donde se observa que la red con mejor rendimiento es “Valle Nevado 3”, los valores de R^2 para la red seleccionada (en gris), se muestran en la *Figura 4.17*, el histograma de errores se muestra en la *Figura 4.18*, mientras que, los pesos y bias se muestran en la *Tabla 4.32*.

Tabla 4.31 Promedios, Desviación Estándar y Mejores Coeficientes de Correlación de Pearson, para las tres redes calibradas.

	Promedio R^2	Desv. Est. R^2	Mejor R^2
Valle Nevado 1	0,9730	0,0043	0,9781
Valle Nevado 2	0,9818	0,0032	0,9842
Valle Nevado 3	0,9832	0,0014	0,9846

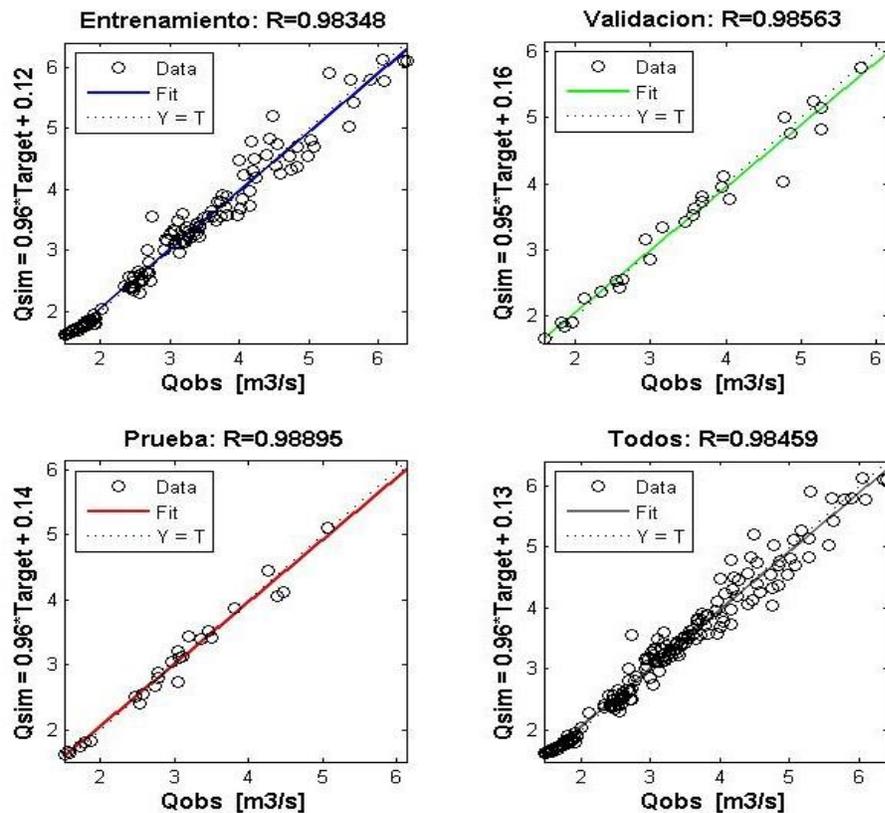


Figura 4.17 Coeficientes de correlación de Pearson, Valle Nevado 3.

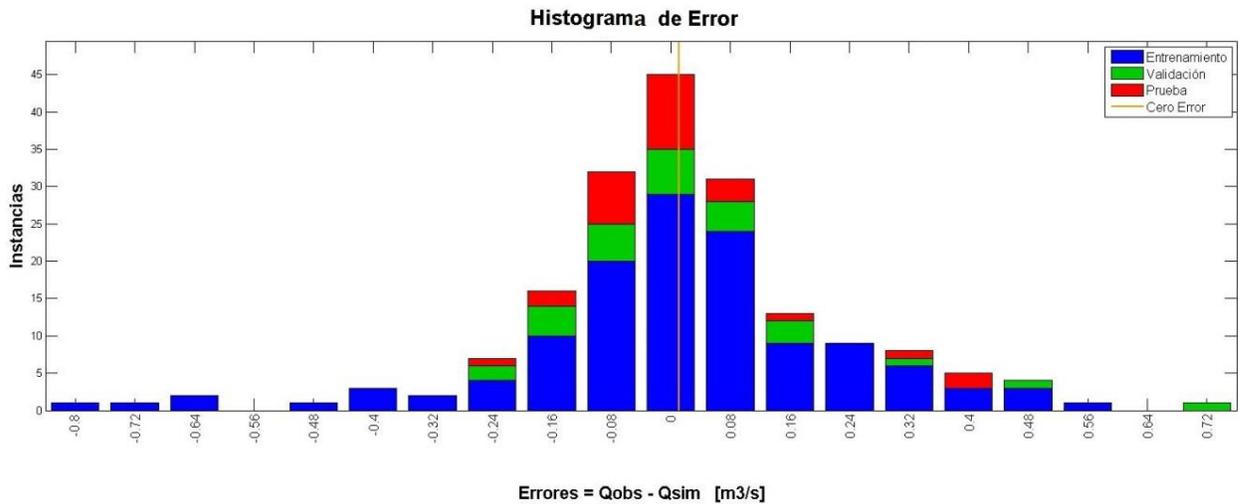


Figura 4.18 Histograma de Errores, Valle Nevado 3

Tabla 4.32 Pesos y Bias para la red óptima Valle Nevado 3

Pesos y Bias	Q t-1	Suma Qant	Tmax t-1	Pp t-1	Pesos 2	Bias 1	Bias 2
Neurona 1	1,177	0,005	-0,005	0,001	199,82	3,919	-197,67
Neurona 2	0,712	0,187	0,700	-0,787	2,251	-1,418	

4.2.1.2 RNA a escala Diaria Mapocho en los Almendros

En el caso de Mapocho en los Almendros, se tienen sólo cuatro parámetros de entrada significativos, dado que la estación Mapocho en los Almendros no mide humedad relativa, por lo tanto se calibra sólo una red cuyos parámetros de entrada se muestran en la *Tabla 4.33*.

Tabla 4.33 Parámetros de entrada, Red Mapocho en Los Almendros escala diaria

Parámetro	Descripción	Unidades
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m3/s]
Qt-1	Caudal del día anterior	[m3/s]
Tmax t-1	Temperatura máxima del día anterior	[°C]
Pp t-1	Precipitación acumulada durante el día anterior	[mm]

Las *Figuras 4.19* y *4.20* muestran los valores de R^2 para los datos de entrenamiento, validación, prueba y todos, y el histograma de errores respectivamente. La *Tabla 4.34* muestra los valores de los pesos y bias para la red óptima.

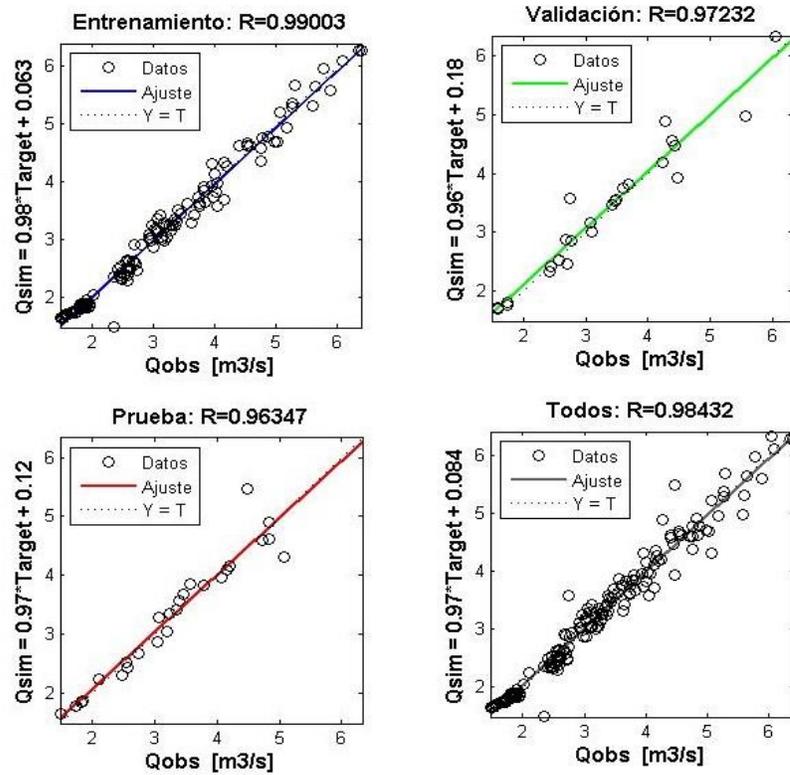


Figura 4.19 Coeficientes de correlación de Pearson, Mapocho en Los Almendros Diaria.

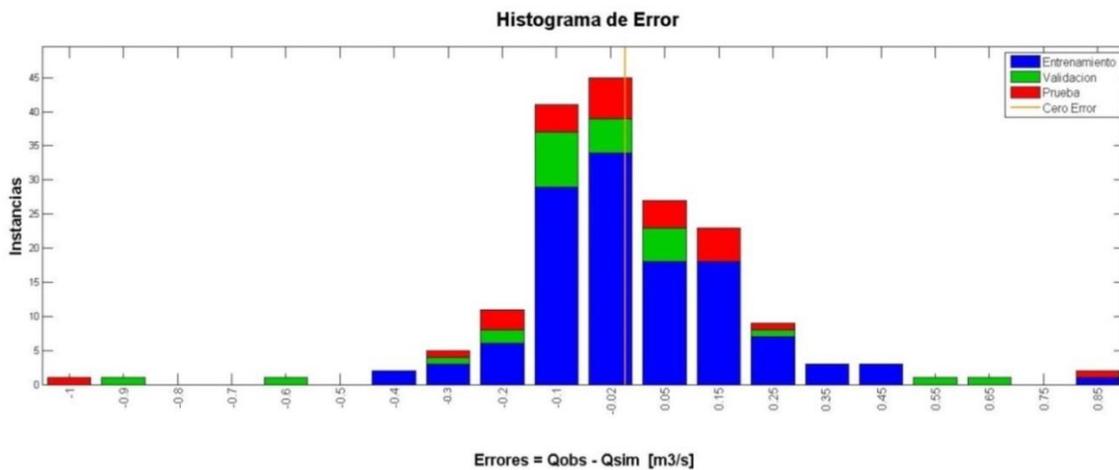


Figura 4.20 Histograma de Errores, Mapocho en Los Almendros, Diaria

Tabla 4.34 Pesos y Bias, Mapocho en Los Almendros, Diaria

Pesos y Bias	Q t-1	Suma Qant	Tmax t-1	Pp t-1	W 2	Bias 1	Bias 2
Neurona 1	-0,947	0,781	0,868	1,635	3,632	-0,819	1,098
Neurona 2	-0,069	1,052	0,060	-1,999	2,659	-0,549	

4.2.2 RNA a escala Semanal

Para la escala semanal, se realiza un análisis de parámetros de entrada, determinando que variables son más significativas entre los promedios semanales y los promedios diarios, por ejemplo, el caudal promedio de la semana anterior “Q t-1” versus el caudal promedio del día anterior “Q día-1”. Es conveniente notar que no se realiza el análisis para las variables “Tmin”, “Tmedia”, “V viento”, “Qinv”, “Pp inv.”, “Hnieve”, “Tmax. inv.” y “Tmin”, dado que fueron eliminadas en el análisis realizado para la escala diaria y su eliminación es válida para la escala temporal semanal. Las variables seleccionadas se muestran destacadas en gris. (Tabla 4.35)

Tabla 4.35 Análisis de Variables Significativas, Escala temporal Semanal

Variable	Promedio R ²	Desv. Est. R ²
Q t-1	0,8964	0,0001
Q día -1	0,9217	0,0063
Q día-1 Tmax t-1	0,9498	0,0002
Qdía -1 Tmax día-1	0,9314	0,0008
Qdía-1 Tmax día	0,9271	0,0004
Q dia-1 Qant	0,9599	0,0007
Q dia-1 Pp t-1	0,9242	0,0019
Q día-1 Pp día-1	0,9238	0,0008
Q dia-1 H.R. t-1	0,9236	0,0007
Q dia-1 H.R. día-1	0,9196	0,0020

4.2.2.1 RNA a escala Semanal Valle Nevado

Al igual que para la escala diaria, se calibran tres tipos de redes neuronales, todas con dos neuronas en la capa oculta (Tabla 4.36). Los rendimientos para cada una de las tres redes calibradas se muestra en la Tabla 4.37, donde claramente se observa que la red con mejor rendimiento es “Valle Nevado 2”, los valores de R² para la red seleccionada (en gris), se muestran en la Figura 4.21, el histograma de errores se muestra en la Figura 4.22, mientras que, los pesos y bias se muestran en la Tabla 4.38.

Tabla 4.36 Parámetros de Entrada, RNA calibradas para la escala temporal semanal

	Parámetros de Entrada				Entrenamiento
Valle Nevado 1	Q día-1	H.R. t-1	Tmax t-1	Pp t-1	LM
Valle Nevado 2	Q día-1	H.R. t-1	Tmax t-1	Suma Qant	LM
Valle Nevado 3	Q día-1	Suma Qant	Tmax t-1	Pp t-1	LM

Tabla 4.37 Promedios, Desviación Estándar y Mejores Coeficientes de Correlación de Pearson, para las tres redes calibradas.

	Promedio R ²	Desv. Est. R ²	Mejor R ²
Valle Nevado 1	0,959	0,007	0,966
Valle Nevado 2	0,967	0,010	0,976
Valle Nevado 3	0,966	0,004	0,971

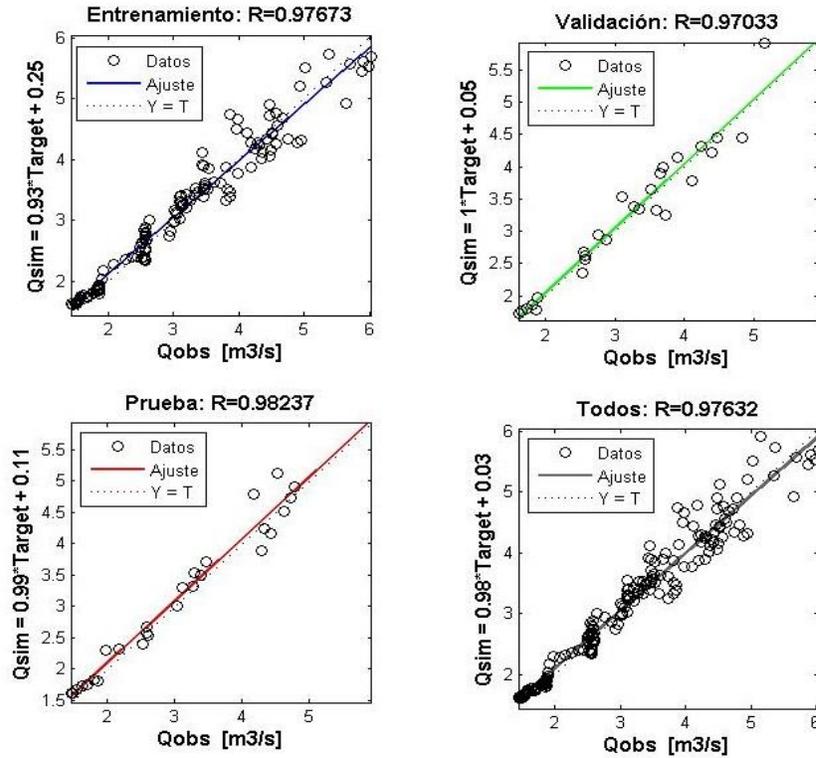


Figura 4.21 Coeficientes de correlación de Pearson, Valle Nevado 2.

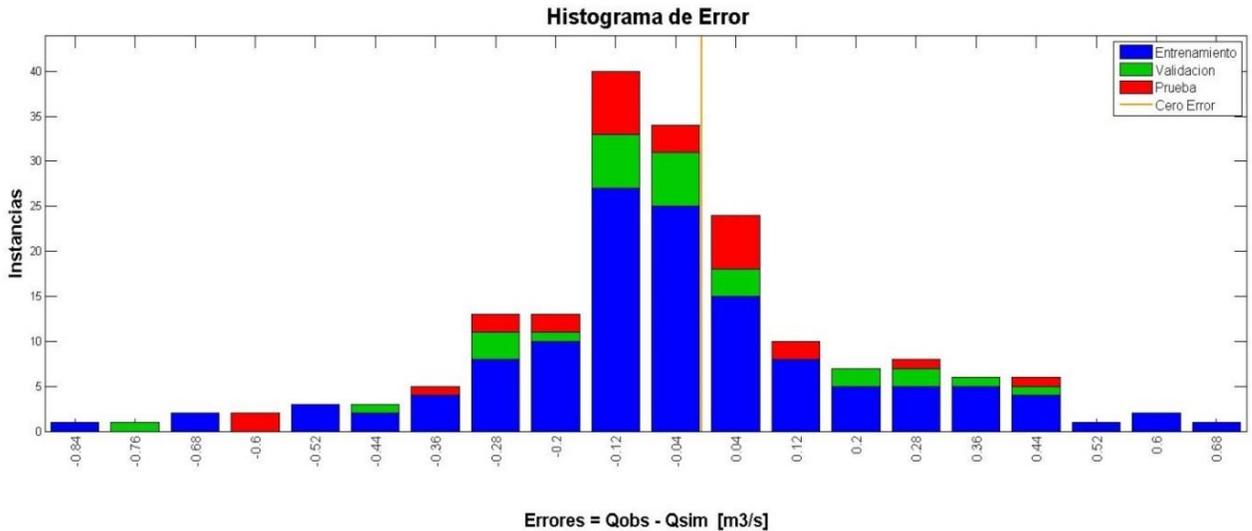


Figura 4.22 Histograma de Errores, Valle Nevado 2

Tabla 4.38 Pesos y Bias para la red óptima Valle Nevado 2

Pesos y Bias	Q día -1	Tmax t-1	H.R. t-1	Suma Qant	W 2	Bias 1	Bias 2
Neurona 1	0,348	1,490	1,596	-3,641	2,671	-3,268	1,168
Neurona 2	0,870	0,057	0,084	-0,562	1,661	1,400	

4.2.2.2 RNA a escala Semanal Mapocho en los Almendros

Las variables de entrada de la red neuronal para Mapocho en los Almendros se muestran en la *Tabla 4.39*.

Tabla 4.39 Parámetros de entrada, Red Mapocho en Los Almendros escala semanal.

Parámetro	Descripción	Unidades
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m3/s]
Qt-1	Caudal del día anterior	[m3/s]
Tmax t-1	Temperatura máxima de la semana anterior	[°C]
Pp t-1	Precipitación acumulada durante la semana anterior	[mm]

Las *Figuras 4.23* y *4.24* muestran los valores de R^2 para los datos de entrenamiento, validación, prueba y todos, y el histograma de errores respectivamente. La *tabla 4.40* muestra los valores de los pesos y bias para la red óptima.

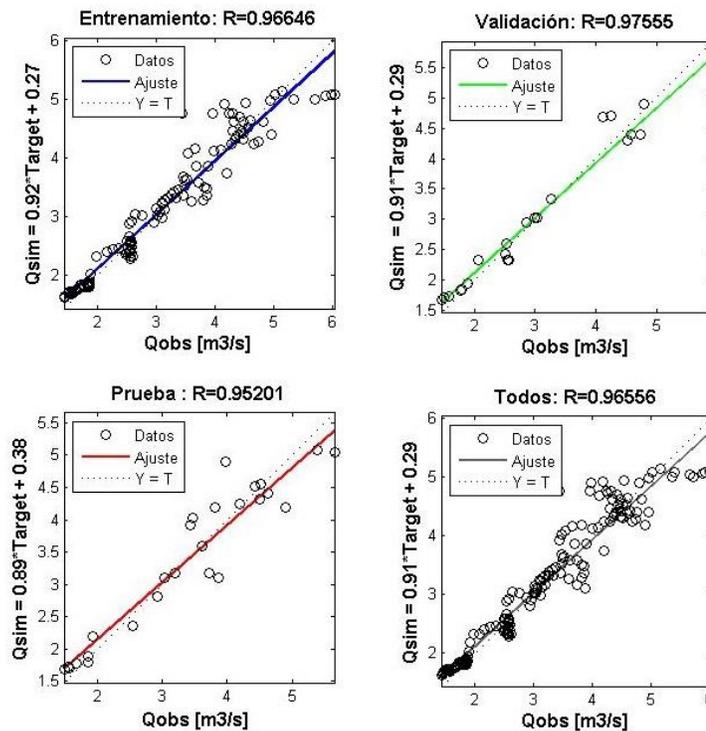


Figura 4.23 Coeficientes de correlación de Pearson, Mapocho en Los Almendros, Semanal

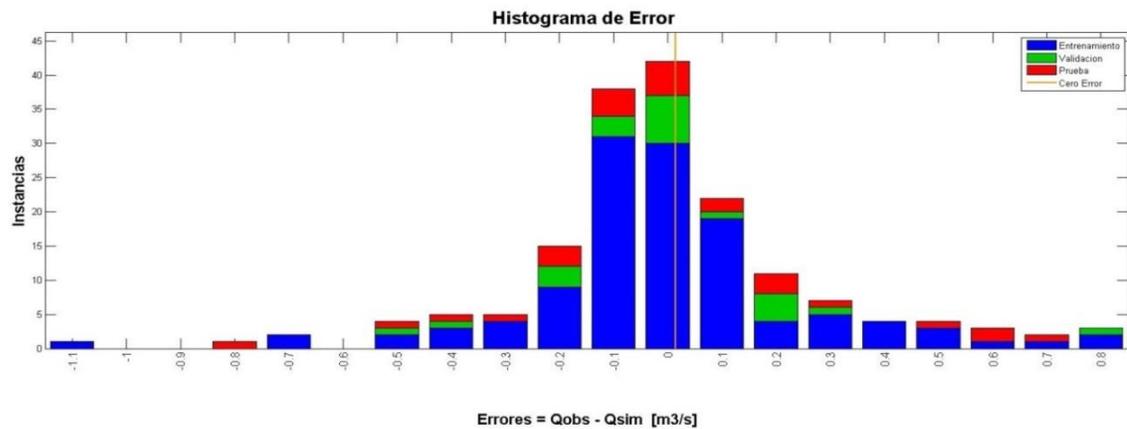


Figura 4.24 Histograma de Erroses, Mapocho en Los Almendros, Semanal

Tabla 4.40 Pesos y Bias, Mapocho en Los Almendros, Semanal

Pesos y Bias	Suma				W 2	Bias 1	Bias 2
	Q día-1	Qant	Tmax t-1	Pp t-1			
Neurona 1	-0,037	-1,105	-0,105	-0,674	0,986	-1,399	-0,620
Neurona 2	1,670	0,230	0,404	0,099	1,120	1,424	

4.2.3 RNA a escala Quincenal

Para la escala quincenal, se realiza un análisis de parámetros de entrada, determinando las variables significativas entre los promedios quincenales versus los diarios, por ejemplo, el caudal promedio de la quincena anterior “Q t-1” versus el caudal promedio del día anterior “Q día-1”. Se observa que no se realiza el análisis para las variables “Tmin”, “Tmedia”, “V viento”, “Qinv”, “Pp inv.”, “Hnieve”, “Tmax. inv.” y “Tmin inv.”, dado que fueron eliminadas en el análisis realizado para la escala diaria y su eliminación es válida para la escala temporal quincenal. Las variables seleccionadas se muestran destacadas en gris. (Tabla 4.41)

Tabla 4.41 Análisis de variables significativas, escala temporal quincenal

Variable	Promedio R ²	Desv. Est. R ²
Q t-1	0,983	0,000
Q día -1	0,868	0,005
Q t-1 Tmax t-1	0,943	0,011
Qt-1 Tmax día-1	0,887	0,001
Qt-1 Tmax día	0,881	0,000
Q t-1 Qant	0,986	0,000
Q t-1 Pp t-1	0,899	0,001
Q t-1 Pp día-1	0,826	0,003
Q t-1 H.R. t-1	0,821	0,002
Q t-1 H.R. día-1	0,816	0,002

4.2.3.1 RNA a escala Quincenal Valle Nevado

En el caso de las redes neuronales quincenales, el parámetro de entrada “Caudal de la quincena anterior” tiene mejor rendimiento que el parámetro “Caudal del día anterior”, luego, al igual que para las otras escalas temporales, se calibran tres tipos de redes neuronales, todas con dos neuronas en la capa oculta (*Tabla 4.42*).

Tabla 4.42 *Parámetros de Entrada, RNA calibradas para la escala temporal quincenal.*

	Parámetros de Entrada				Entrenamiento
Valle Nevado 1	Q t-1	H.R. t-1	Tmax t-1	Pp t-1	LM
Valle Nevado 2	Q t-1	H.R. t-1	Tmax t-1	Suma Qant	LM
Valle Nevado 3	Q t-1	Suma Qant	Tmax t-1	Pp t-1	LM

Los rendimientos para cada una de las tres redes calibradas se muestran en la *Tabla 4.43*, donde claramente se observa que la red con mejor rendimiento es “Valle Nevado 2”. Los valores de R^2 para la red seleccionada (en gris) se muestran en la *Figura 4.25*, el histograma de errores se muestra en la *Figura 4.26*, mientras que, los pesos y bias se muestran en la *Tabla 4.44*.

Tabla 4.43 *Promedios, Desviación Estándar y Mejores Coeficientes de Correlación de Pearson, para las tres redes calibradas*

	Promedio R^2	Desv. Est. R^2	Mejor R^2
Valle Nevado 1	0,979	0,006	0,9852
Valle Nevado 2	0,994	0,001	0,9944
Valle Nevado 3	0,992	0,001	0,9928

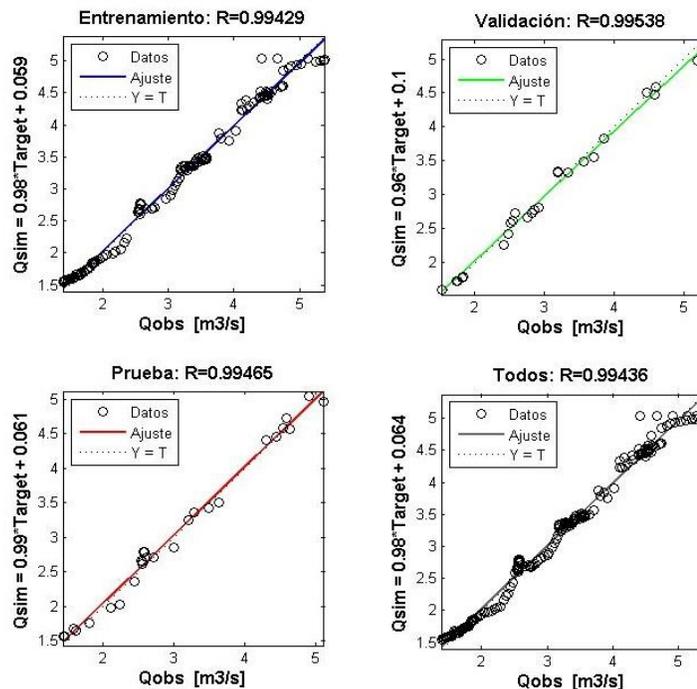


Figura 4.25 *Coefficientes de correlación de Pearson, Valle Nevado 2*

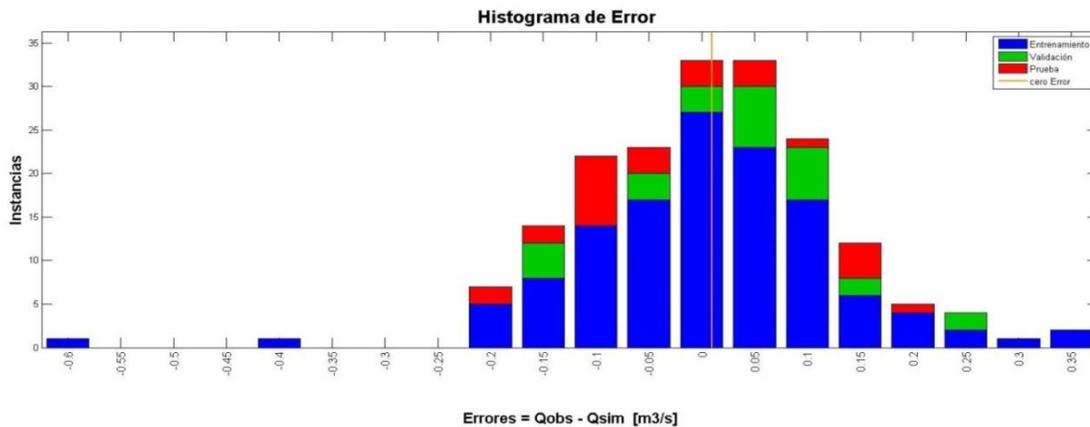


Figura 4.26 Histograma de Errores, Valle Nevado 2

Tabla 4.44 Pesos y Bias, Valle Nevado 2

Pesos y Bias	Q t-1	H.R. t-1	Tmax t-1	Suma Qant	W 2	Bias 1	Bias 2
Neurona 1	0,331	-3,048	6,522	0,232	-0,200	0,186	-19,222
Neurona 2	0,157	-0,033	-0,189	0,607	-20,762	-1,693	

4.2.3.2 RNA a escala Quincenal Mapocho en los Almendros

Las variables de entrada de la red neuronal quincenal para Mapocho en los Almendros se muestran en la *Tabla 4.45*.

Tabla 4.45 Parámetros de entrada, Red Mapocho en Los Almendros escala quincenal.

Parámetro	Descripción	Unidades
Suma Qant.	Suma de caudales diarios de deshielo anteriores	[m3/s]
Qt-1	Caudal promedio de los 15 días anteriores	[m3/s]
Tmax t-1	Temperatura máxima de la quincena anterior	[°C]
Pp t-1	Precipitación acumulada durante la quincena anterior	[mm]

Los valores de R^2 para la red calibrada se muestran en la *Figura 4.27*, el histograma de errores se muestra en la *Figura 4.28*, mientras que, los pesos y bias se muestran en la *Tabla 4.46*.

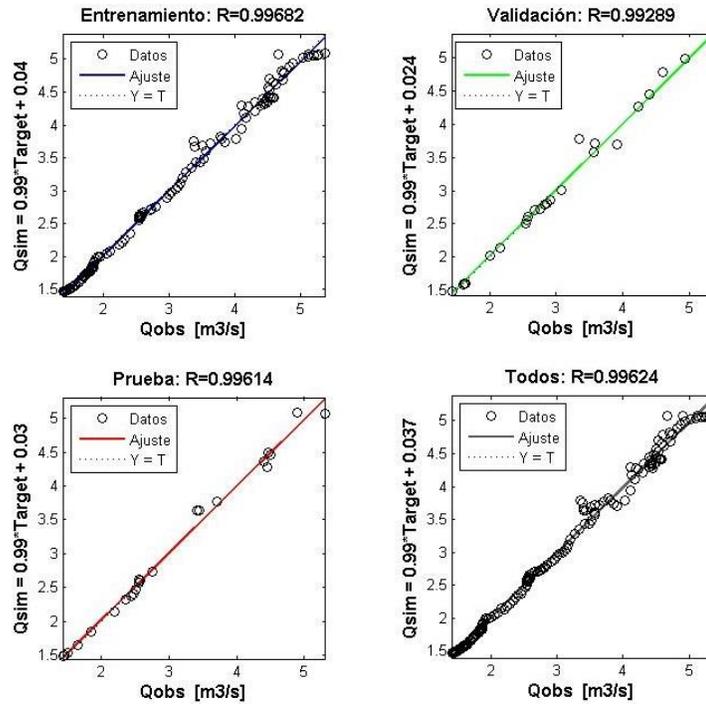


Figura 4.27 Coeficientes de correlación de Pearson, Mapocho en Los Almendros, Quincena

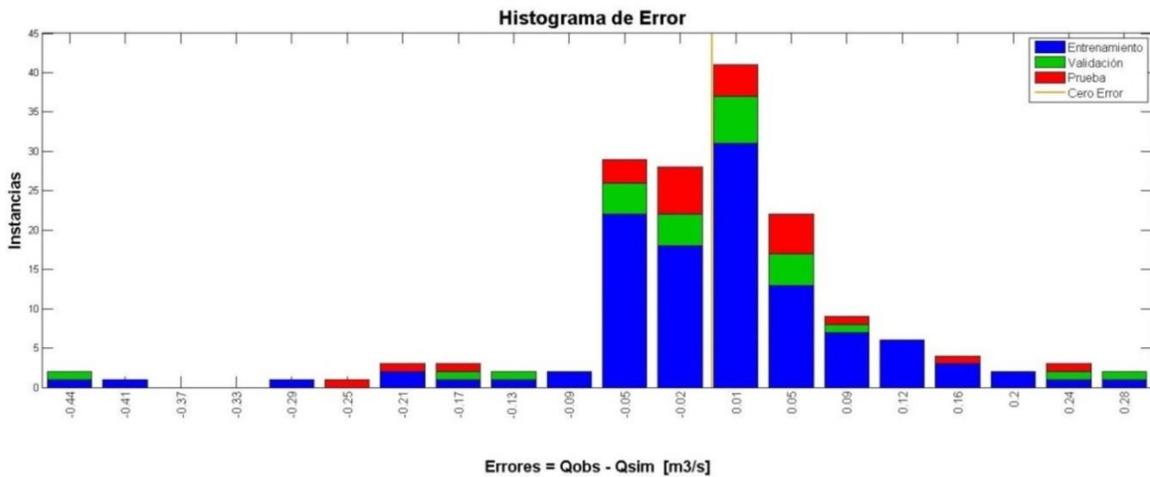


Figura 4.28 Histograma de Errores, Mapocho en Los Almendros, Quincena

Tabla 4.46 Pesos y Bias, Mapocho en Los Almendros, Quincena

Pesos y Bias	Q t-1	Suma Qant	Tmax t-1	Pp t-1	W 2	Bias 1	Bias 2
Neurona 1	0,037	-1,862	-0,024	-1,616	7,188	1,169	-6,672
Neurona 2	-0,830	-1,098	-0,494	3,081	0,835	3,032	

Capítulo 5 .- Análisis de Resultados

El análisis de resultados consiste en simular las redes neuronales artificiales óptimas seleccionadas para cada escala temporal, con nuevos datos que no han sido “vistos” por las redes. Para lo anterior, se utiliza la temporada de deshielo 2013-2014, la cual comienza en Octubre del 2013 y termina en Marzo del 2014. Se observa que los días 1 al 6 de Diciembre del 2013, faltan datos de temperatura máxima y mínima, lo que se convierte a datos faltantes en la simulación, del 2 al 7 de Diciembre para la escala temporal diaria, del 1 al 13 de Diciembre para la escala temporal semanal y del 1 al 21 de Diciembre para la escala temporal quincenal.

La simulación se realiza solo para las RNA calibradas utilizando datos de la estación Mapocho en los Almendros, dado que las redes calibradas utilizando datos de la estación Valle Nevado no cuentan con datos que no hayan sido utilizados para la calibración.

5.1 Simulación con RNA óptima a escala Diaria

La RNA óptima para la escala temporal diaria simulada para la temporada de deshielo 2013-2014, tiene un error promedio del 5.6 % ($0.18 \text{ m}^3/\text{s}$). Las Figuras 5.1 a 5.4, muestran gráficamente los resultados obtenidos.

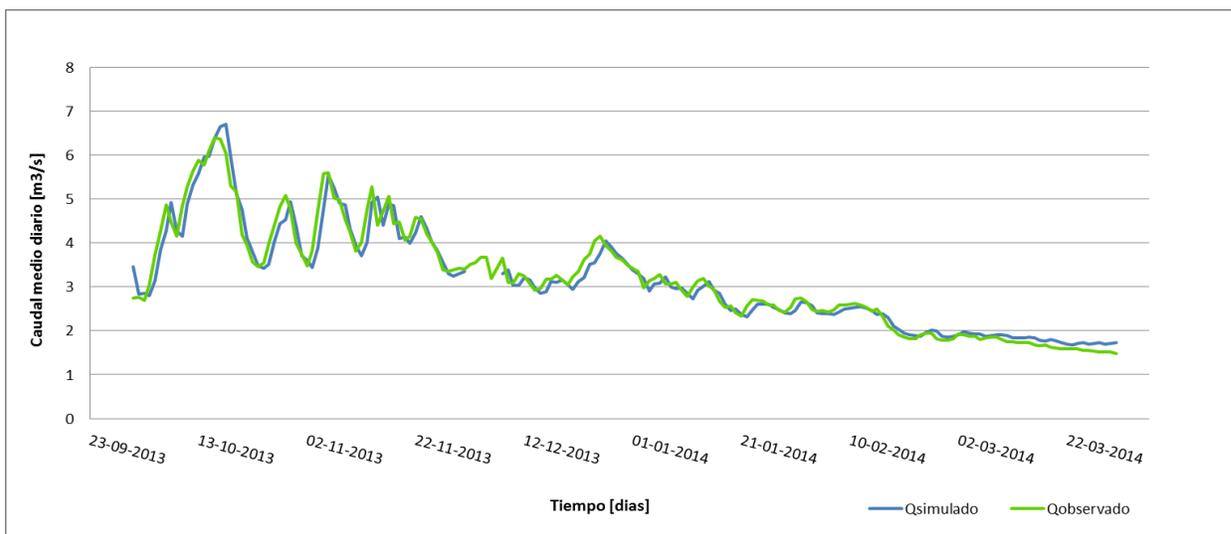


Figura 5.1 Caudales Medios Diarios Observados y Simulados, Temporada de deshielo 2013 - 2014

Se destaca que las series de caudales observados y simulados son prácticamente iguales, los máximos y mínimos son simulados con bastante precisión, salvo el máximo del día 18 de Octubre, el cual es sobreestimado. Por otro lado, se observa que los períodos de aumento de caudal son simulados levemente retardados, mientras que los períodos de disminución de caudal son simulados correctamente. Por último se observa que el final del período de deshielo es sobreestimado por la simulación.

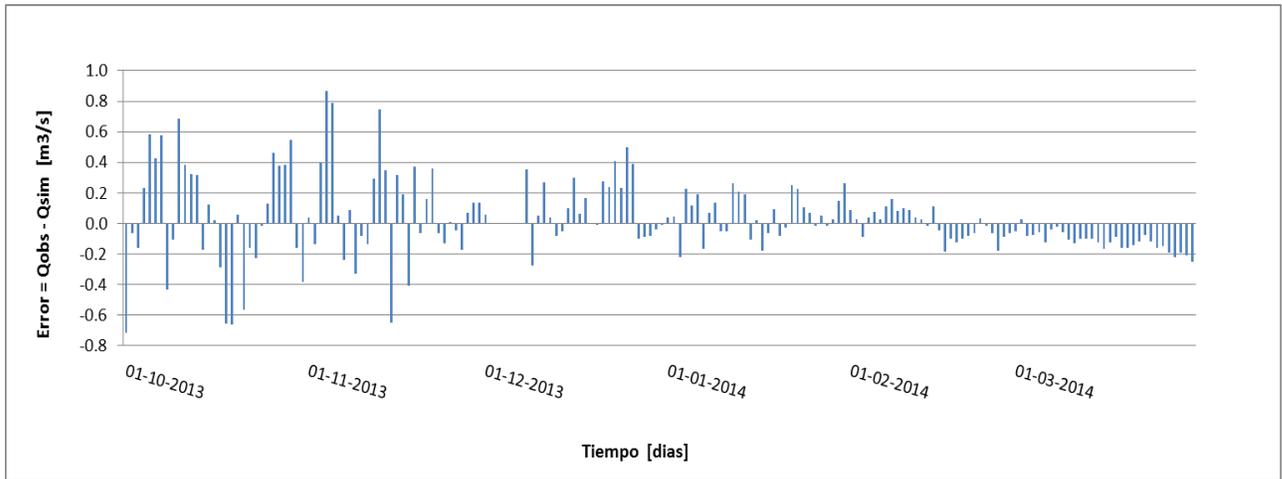


Figura 5.2 Serie temporal de errores diarios en $[m^3/s]$

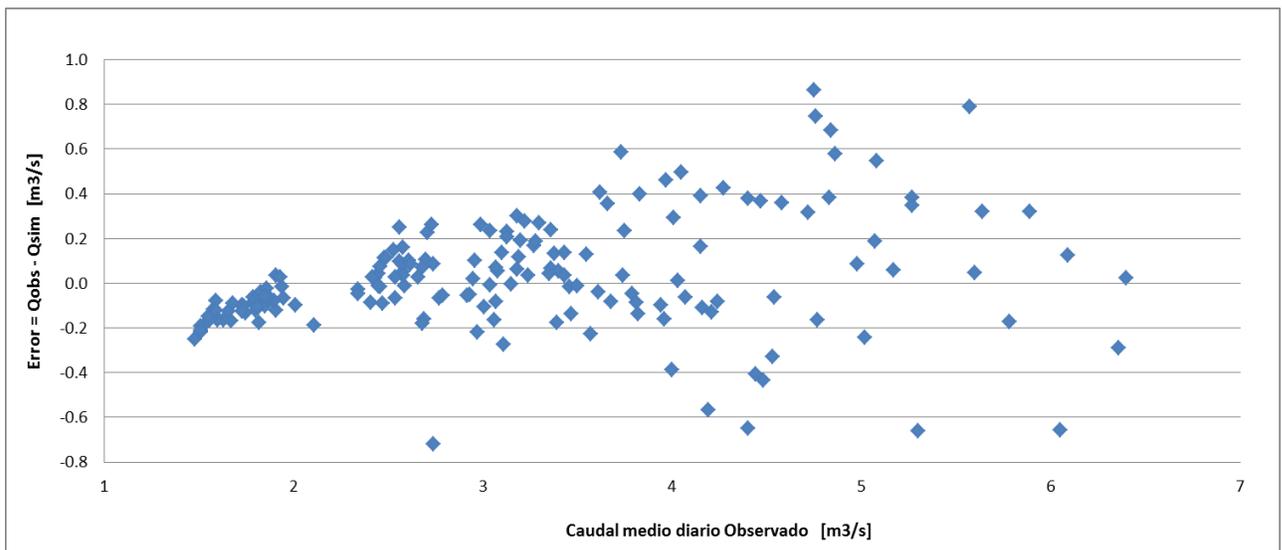


Figura 5.3 Caudal medio diario observado versus error

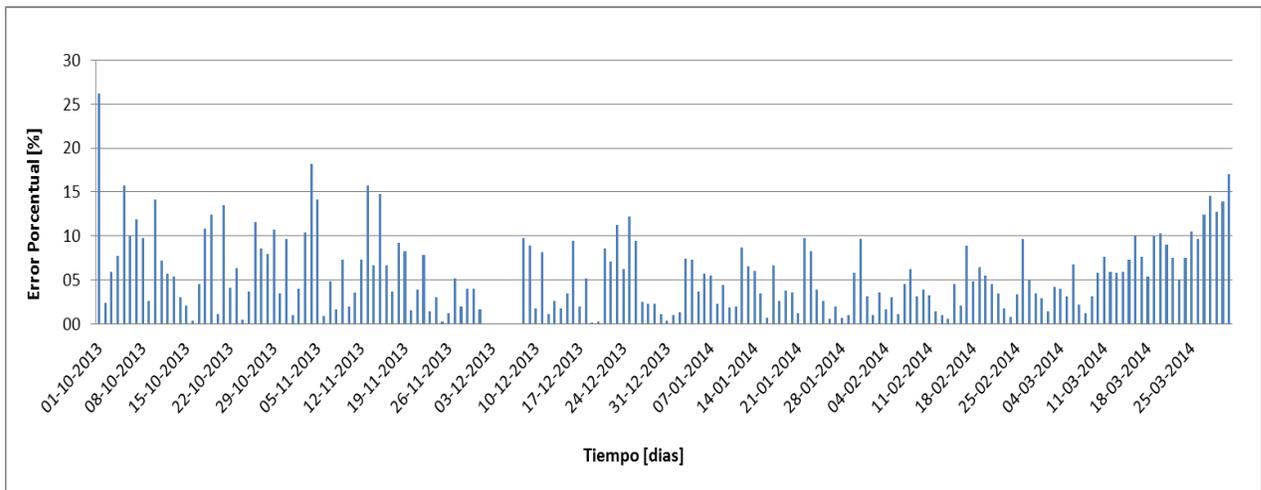


Figura 5.4 Serie temporal de error porcentual absoluto diario.

A partir de las Figuras 5.2 y 5.3, es posible determinar que la magnitud de error, es directamente proporcional a la magnitud del caudal, es decir, a mayor caudal, mayor es el error; además los errores máximos registrados son del orden de los $0.8 \text{ m}^3/\text{s}$. Por otro lado, el porcentaje de error es prácticamente constante, es decir, mayores caudales no producen errores porcentuales mayores o viceversa, lo cual se concluye al observar la Figura 5.4, donde al comienzo de la temporada de deshielo, cuando los caudales son mayores, se tienen errores porcentuales máximos de un 15% aproximadamente y al final de la temporada de deshielo, cuando los caudales son menores, también se tienen errores porcentuales máximos del 15%.

5.2 Simulación con RNA óptima a escala Semanal

Para la escala temporal semanal, se simularon dos RNA óptimas, Red 2 y Red 4. La primera tiene un error porcentual promedio del 11.3% ($0.41 \text{ m}^3/\text{s}$), mientras que la segunda tiene un error porcentual promedio del 11.6 % ($0.39 \text{ m}^3/\text{s}$). Las Figuras 5.5 a 5.8, muestran gráficamente los resultados obtenidos.

A partir de la Figura 5.5, se observa que para la primera mitad de la temporada de deshielo, la serie de caudales simulados por la Red 4, sigue, en forma general, mejor la forma de la serie de caudales observados en comparación con la serie de caudales simulados por la Red 2, sin embargo, la serie simulada por la Red 4 tiende a oscilar en torno a la serie de caudales observados. Por otro lado, para la segunda mitad de la temporada de deshielo, cuando los caudales son menores, ambas series de caudales simulados siguen la forma de la serie de caudales observados.

Finalmente, se observa que al comienzo de la temporada de deshielo, la serie simulada con la Red 4 presenta un peak, el cual está muy por sobre los caudales observados, generando errores de $2.5 \text{ m}^3/\text{s}$ aprox., sin embargo la serie se ajusta posteriormente y después del 20 de Octubre no se tienen errores mayores a $1 \text{ m}^3/\text{s}$. En cuanto a serie simulada por la Red 2, se observa que los errores máximos son casi de $2 \text{ m}^3/\text{s}$, los cuales ocurren al comienzo de la temporada de deshielo.

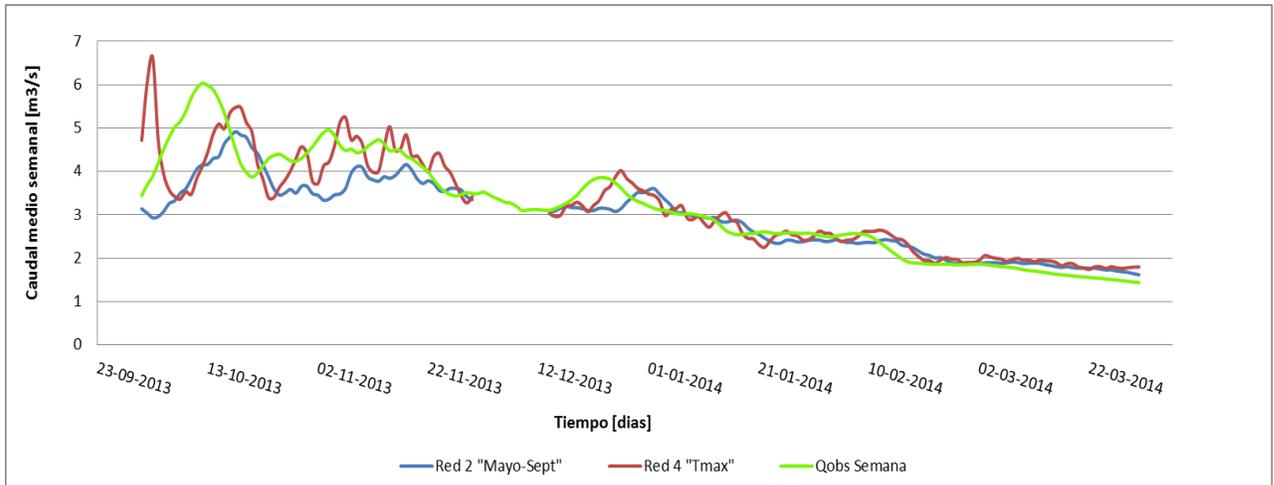


Figura 5.5 Caudales medios semanales observados y simulados, Temporada de deshielo 2013 - 2014

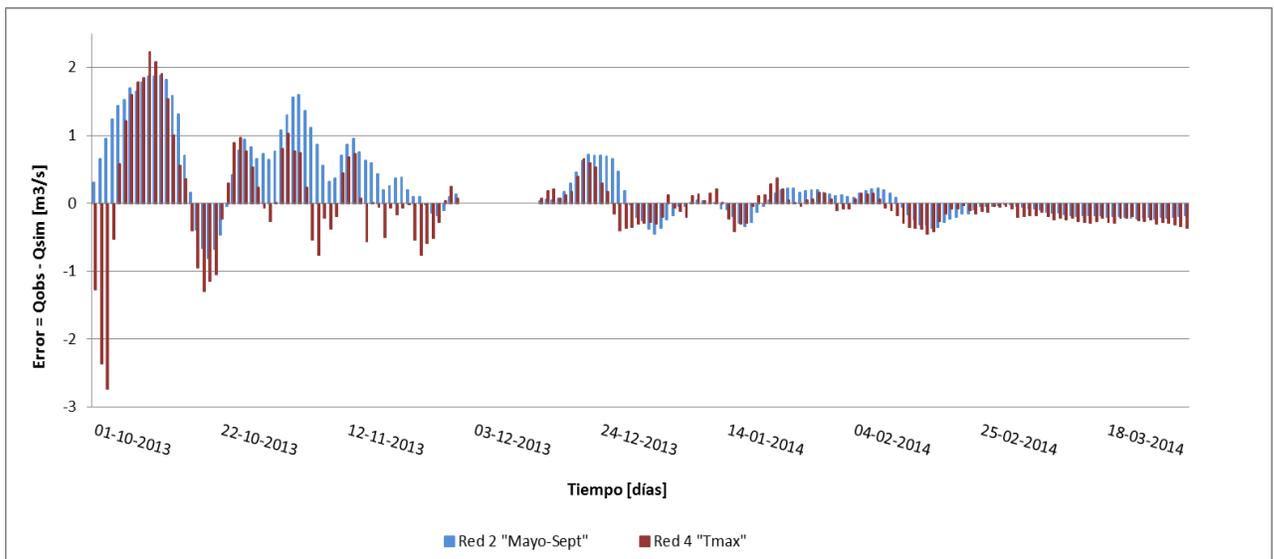


Figura 5.6 Serie temporal de errores semanales en m^3/s

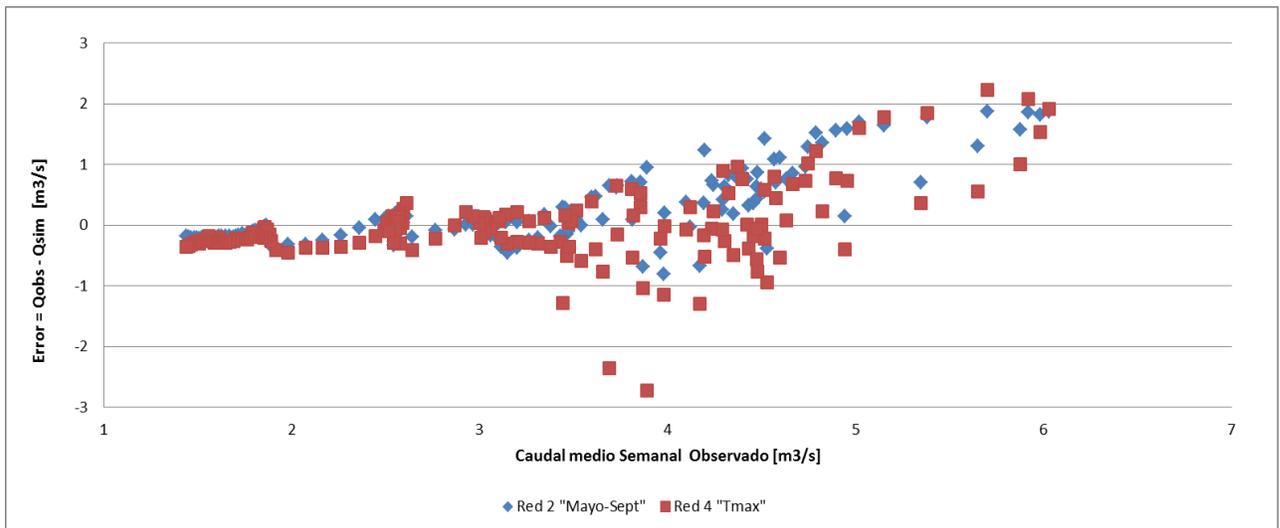


Figura 5.7 Caudal medio semanal observado versus error

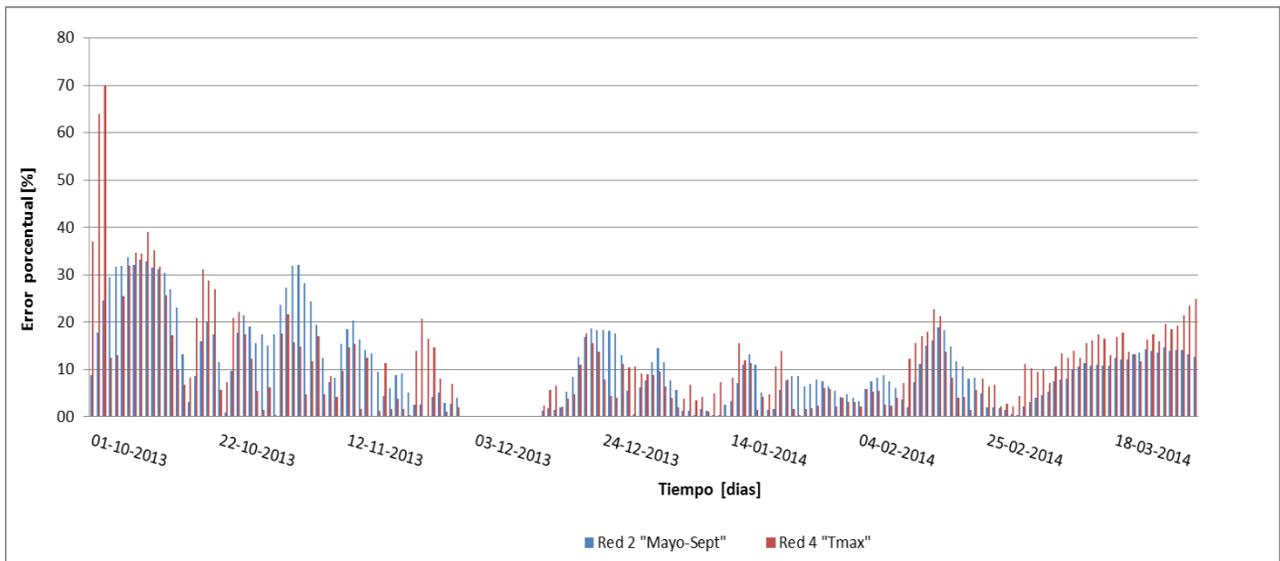


Figura 5.8 Serie temporal de error porcentual absoluto semanal

Al igual que para la escala temporal diaria, el error es directamente proporcional al caudal (Figura 5.7). Además, en un comienzo la serie simulada por la Red 4 tiene mayores errores negativos que la serie simulada por la Red 2, lo cual implica que la Red 4 sobreestima el caudal una mayor cantidad de veces, mientras que la Red 2 subestima el caudal una mayor cantidad de veces, sin embargo, después del 14 de Diciembre, los errores producidos por ambas series tienen igual signo, salvo en 4 ocasiones. Por último, al final de la temporada, ambas series tienden a sobreestimar el caudal, dado que los errores son negativos.

En cuanto a los errores porcentuales máximos (*Figura 5.8*), se observa que para el caso de la serie simulada por la Red 2, éstos tienden a disminuir, siendo alrededor del 30% los máximos errores en un comienzo, y un 15% al final. Para el caso de la serie simulada por la Red 4, éstos también disminuyen, pero en menor medida, siendo un 30% aprox. en un comienzo, y un 20% aprox. al final.

Finalmente, se selecciona la Red 4, como la red neuronal óptima para la escala diaria, ya que a pesar de que ambas redes tiene prácticamente el mismo rendimiento (11.3% v/s 11.6%), gráficamente la serie simulada por la Red 4 (*Figura 5.5*) representa en mejor medida la serie observada. Además, si se obvian los primeros tres días, se obtienen valores de error porcentual promedio de 11.2% ($0.407 \text{ m}^3/\text{s}$) para la Red 2, mientras que para la Red 4 se obtiene un error porcentual promedio de 10.8% ($0.362 \text{ m}^3/\text{s}$).

De acuerdo a la anterior, la *Figura 5.9* muestra los caudales medios semanales simulados por la Red 4, donde se seleccionaron los caudales medios semanales para 3 días y 1 día antes de un caudal medio semanal máximo o mínimo, con lo cual se observa la eficiencia de la Red 4 para prevenir los caudales extremos.

Se observa que en un comienzo, tanto el caudal máximo (primera semana), como el caudal mínimo (segunda semana) no son previstos correctamente, sin embargo en las semanas venideras la Red 4 sí es capaz de predecir los máximos y mínimos relativamente bien, con un margen de error de $0.3 \text{ m}^3/\text{s}$ en promedio.

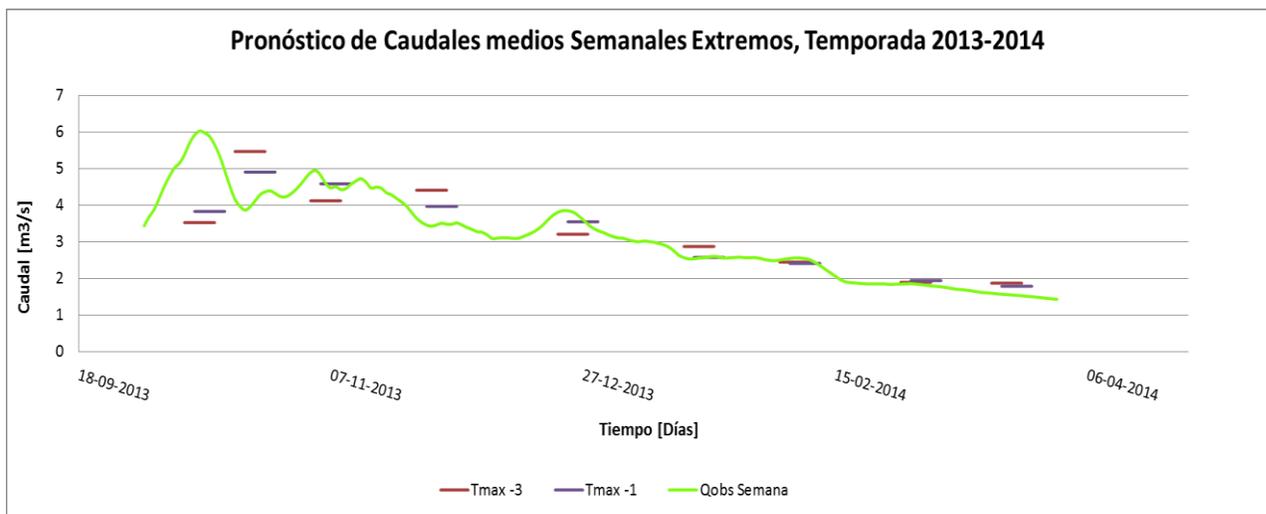


Figura 5.9 Pronóstico de caudales medios semanales extremos, con 3 y 1 día de anticipación, para la temporada de deshielo 2013 – 2014, Red 4.

5.1 Simulación con RNA óptima a escala Quincenal

Para la escala temporal quincenal, al igual que para la escala temporal semanal, se simularon dos RNA óptimas, Red 2 y Red 4. La primera tiene un error promedio porcentual del 22.3% ($0.88 \text{ m}^3/\text{s}$), mientras que la segunda tiene un error promedio porcentual del 11.5 % ($0.38 \text{ m}^3/\text{s}$). Las Figuras 5.10 a 5.14, muestran gráficamente los resultados obtenidos.

A partir de la Figura 5.10, se observa que para la primera mitad de la temporada de deshielo, la serie de caudales simulados por la Red 4, sigue, en forma general, mejor la forma de la serie de caudales observados en comparación con la serie de caudales simulados por la Red 2, sin embargo, la serie simulada por la Red 4 tiende a oscilar en torno a la serie de caudales observados, subestimando los caudales medios quincenales la mayor parte del tiempo. Por otro lado, para la segunda mitad de la temporada de deshielo, cuando los caudales son menores, ambas series de caudales simulados siguen la forma de la serie de caudales observados.

En cuanto a la serie simulada por la Red 2, se observa que ésta siempre subestima el caudal medio quincenal observado, salvo del 10 al 23 de Enero, donde se observan errores negativos (Figuras 5.10 y 5.11).

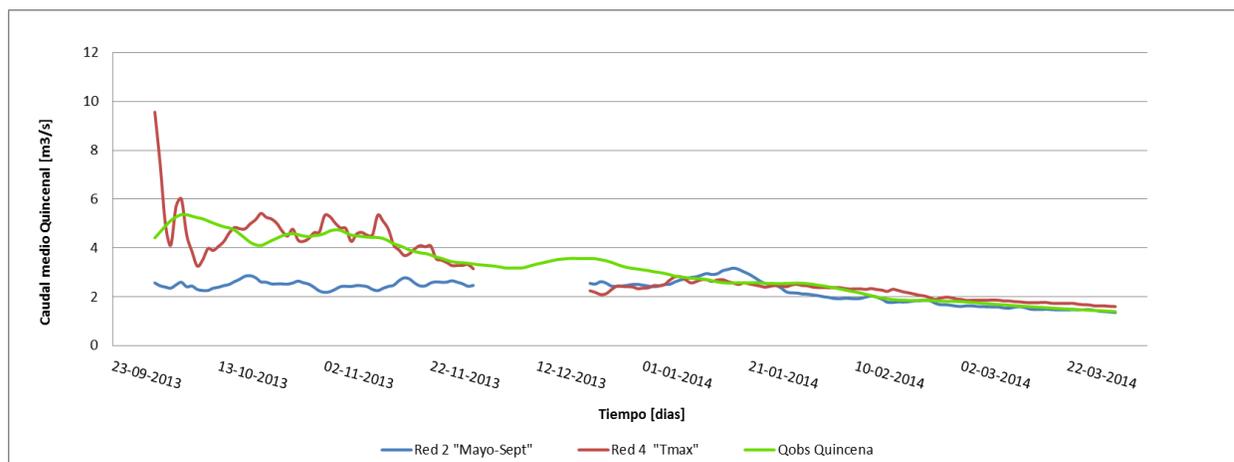


Figura 5.10 Caudales Medios Quincenales Observados y Simulados, Temporada de deshielo 2013 – 2014.

A partir de la Figura 5.11, se observa que al comienzo de la temporada de deshielo, la serie simulada con la Red 4 presenta un peak, el cual está muy por sobre los caudales observados, generando un error de $5 \text{ m}^3/\text{s}$ aprox., sin embargo posteriormente la serie se ajusta, oscilando en torno a la serie de caudales observados y con errores máximos de $2 \text{ m}^3/\text{s}$ en un principio y cerca de $1 \text{ m}^3/\text{s}$ posteriormente. Sin embargo, al final de la temporada, los errores no superan los $0.3 \text{ m}^3/\text{s}$.

Por otro lado, al comienzo de la temporada, la serie simulada con la Red 2 subestima en gran magnitud los caudales, generando errores máximos de $3 \text{ m}^3/\text{s}$ en un comienzo y $2 \text{ m}^3/\text{s}$ en promedio posteriormente, mientras que después del 1 de Enero los caudales simulados son más cercanos a los observados, generando errores menores a $0.6 \text{ m}^3/\text{s}$. (Figura 5.21)

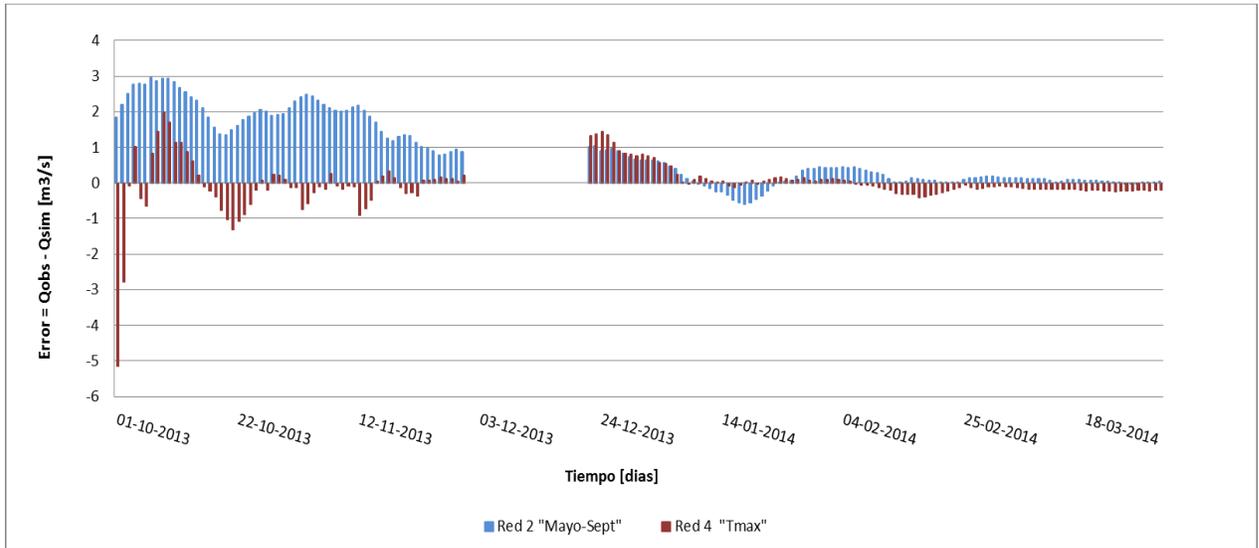


Figura 5.11 Serie temporal de errores quincenales en $[\text{m}^3/\text{s}]$.

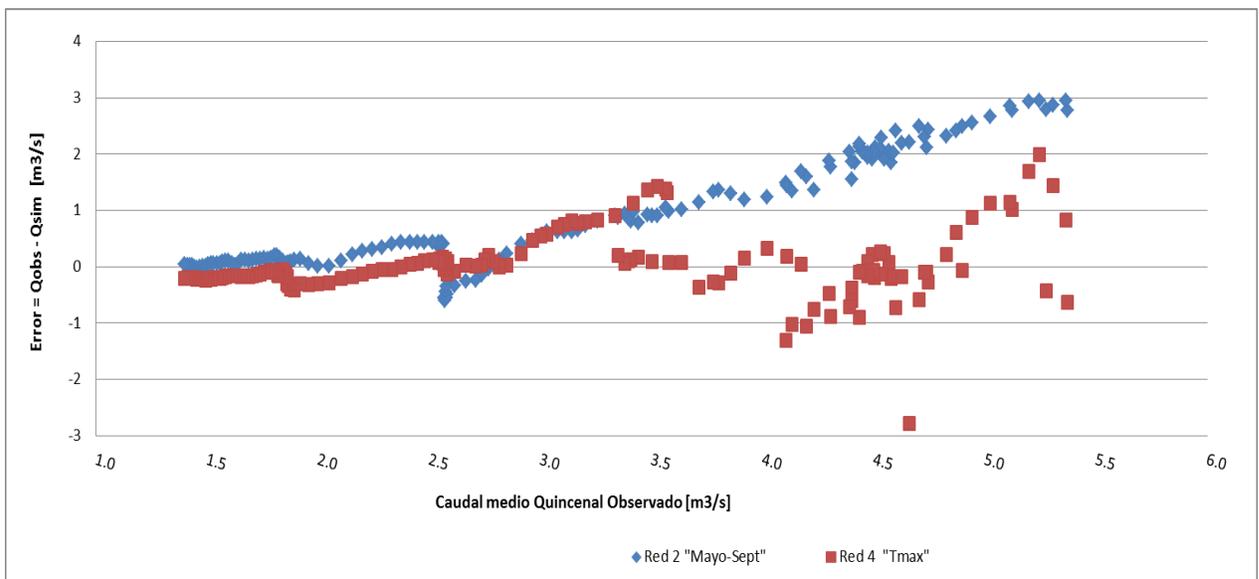


Figura 5.12 Caudal medio quincenal observado versus error.

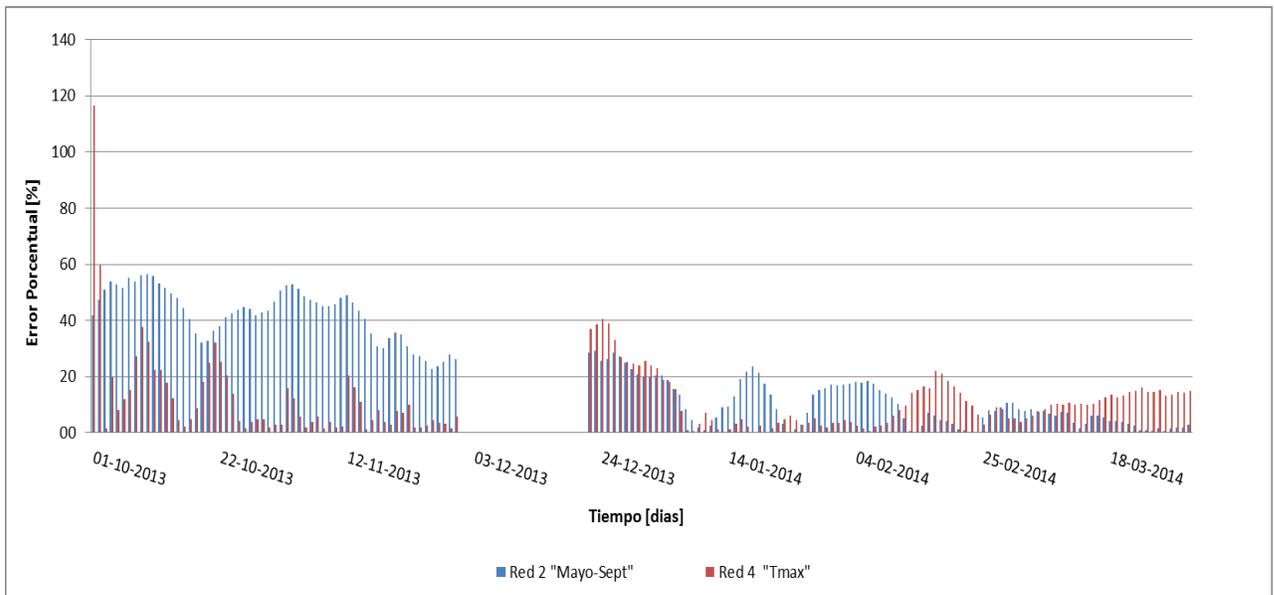


Figura 5.13 Serie temporal de error porcentual absoluto quincenal

Al igual que las series a escalas temporales diaria y semanal, el error es directamente proporcional al caudal (*Figura 5.12*), además se observa que la Red 2 produce errores mayoritariamente positivos, es decir, tiende a subestimar el caudal, y de mayor magnitud en comparación con los errores producidos por la Red 4, salvo al final de la temporada de deshielo, donde los errores de la serie simulada por la Red 4 son mayores a los de la Red 2 (*Figuras 5.11 y 5.13*).

En cuanto a los errores porcentuales máximos se observa que para el caso de la serie simulada por la Red 2, éstos tienden a disminuir, siendo alrededor del 50% los máximos errores en un comienzo, y un 10% al final. Para el caso de la serie simulada por la Red 4, éstos también disminuyen, pero en menor medida, siendo un 30% aprox. en un comienzo, y un 15% aprox. al final. (*Figura 5.13*),

Finalmente, se determina que la red óptima para la escala temporal quincenal es la Red 4, dado que tiene mejor rendimiento (22.3% versus 11.5% de error promedio porcentual equivalentes a $0.88 \text{ m}^3/\text{s}$ y $0.38 \text{ m}^3/\text{s}$ de error promedio respectivamente), por lo que se usa la Red 4 para realizar el pronóstico de caudales medios quincenales extremos que se muestra en la *Figura 5.14*.

A partir de la *Figura 5.14* se observan dos quincenas graficadas cuyo pronóstico es mayormente errado; la primera, donde el caudal simulado siete días antes del caudal medio quincenal máximo, está muy por sobre el caudal máximo observado, por lo que la red tiende a sobreestimar el caudal; y la tercera, donde se subestima el caudal. Además, se observa que, salvo para la primera quincena graficada, no existen diferencias importantes entre el pronóstico realizado 7 días antes y el pronóstico realizado 3 días antes.

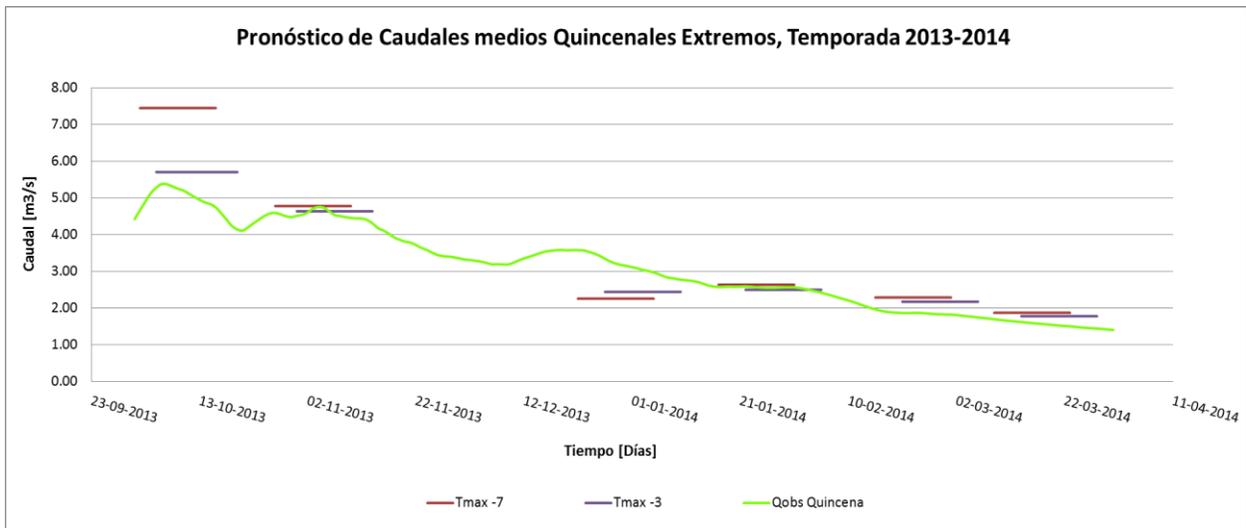


Figura 5.14 Pronóstico de caudales medios quincenales extremos, con 7 y 3 días de anticipación, para la temporada de deshielo 2013 – 2014.

Finalmente, la *Figura 5.15* muestra los pronósticos conjuntos de las escalas diaria, semanal y quincenal, para distintos períodos de la temporada de deshielo 2013-2014, donde se observa que los pronósticos diario y quincenal son bastante precisos durante toda la temporada; mientras que los pronósticos semanales, las primeras tres series graficadas, tienen un mayor error, sin embargo los siguientes tres pronósticos son buenos.

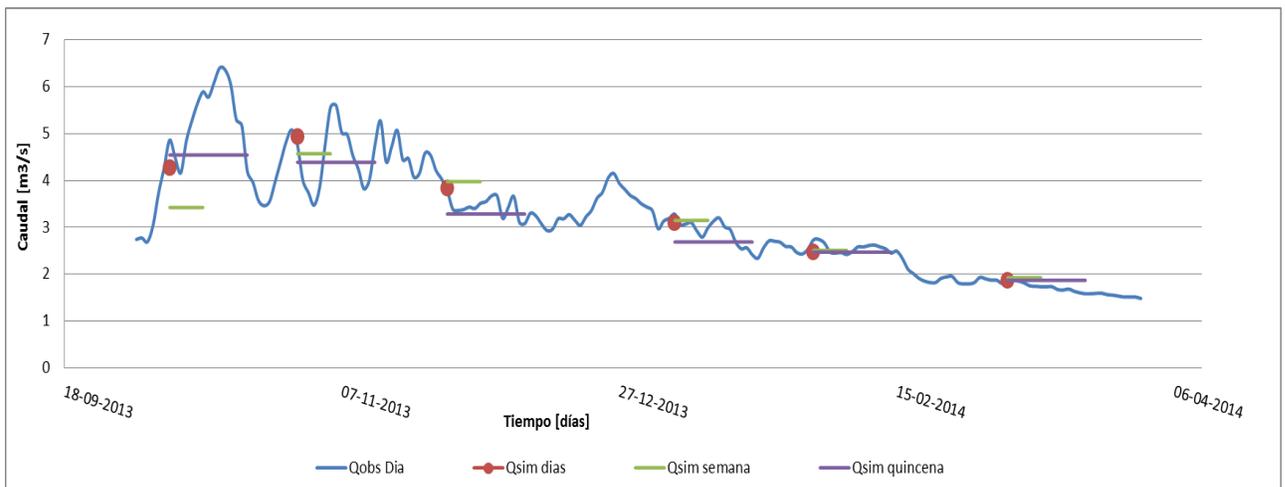


Figura 5.15 Pronóstico de caudales medios diarios, semanales y quincenales, Temporada 2013 - 2014

Capítulo 6 .- Conclusiones

6.1 Conclusiones RNA usando datos estación Mapocho en Los Almendros

Considerar la temporada de invierno desde Mayo a Septiembre para determinar los parámetros de caudal promedio de invierno, temperaturas extremas promedio de invierno y precipitación líquida acumulada durante el invierno, es siempre mejor que considerar la temporada de invierno desde Junio a Agosto, dado que las RNA óptimas para las tres escalas temporales corresponden a aquellas que consideran el período invernal de Mayo a Septiembre.

Del mismo modo, considerar como parámetro de entrada la temperatura máxima del mismo día pronosticado, Red 4, entrega mejores resultados en comparación con utilizar como parámetro de entrada la temperatura máxima del día anterior, Red 3. Lo anterior ocurre tanto para las RNA de escala semanal como quincenal.

La función de entrenamiento basada en el método de Levenberg-Marquardt “LM”, siempre entrega mejores resultados que la función de entrenamiento basado en el algoritmo del gradiente conjugado escalado “SCG”, por lo que se concluye que para el caso en estudio, el método de Levenberg-Marquardt es el óptimo.

La función de transferencia en la capa oculta, logaritmo sigmoidal, entrega RNA calibradas con coeficientes de correlación de Pearson de 0.55 en promedio, lo cual al comparar con las demás RNA, con función de transferencia tangente sigmoidal, con R^2 sobre 0.97, implica que la función de transferencia “logaritmo sigmoidal” no es eficiente para el tipo de problema a resolver en esta investigación.

Con respecto a la función de transferencia en la capa de salida, lineal ó “purelin” versus tangente sigmoidal ó “tangente sigmoidal”, se concluye que tangente sigmoidal entrega mejores resultados la mayoría de las veces, y las RNA seleccionadas como óptimas para las tres escalas temporales corresponden a aquellas con función de transferencia en la capa de salida tangente sigmoidal, sin embargo “purelin” entregó mejores resultados en dos ocasiones, en la Red 3 para la escala temporal semanal y en la Red 1 para la escala temporal quincenal, además, los coeficientes de correlación de Pearson entregados por “tangente sigmoidal” superan por muy poco a los R^2 entregados por “purelin”, con variaciones en la milésima.

Por otro lado, se concluye que las RNA de las escalas temporales semanales y quincenales mejoran al incluir en los parámetros de entrada, valores de caudal y temperatura máxima recientes, es decir del día anterior o del mismo día, y no sólo parámetros de entrada con valores promedios de los 7 o 15 días antes, para la escala temporal semanal y quincenal respectivamente. Lo anterior se observa al comparar los resultados obtenidos al simular los caudales de deshielo de la temporada 2013-2014, donde se concluye que la Red 4 entrega mejores resultados que la Red 2, tanto para las RNA semanales como quincenales, pero en mayor medida para el caso de las RNA quincenales.

En cuanto al número óptimo de neuronas en la capa oculta, se concluye que éste corresponde al máximo número posible, es decir 20, dado que tanto para las RNA entrenadas para la escala temporal semanal como quincenal, las redes óptimas son aquellas compuestas por 20 neuronas en la capa oculta; para el caso de las RNA entrenadas para la escala diaria, se observa que la red “Junio-Agosto” óptima tiene 20 neuronas en la capa oculta, pero la red “Mayo-Septiembre” óptima tiene 10 neuronas en la capa oculta, siendo la excepción.

Finalmente, se observa que las series simuladas para la temporada de deshielo 2013-2014 usando las redes óptimas, tanto en la escala temporal diaria, Red 2, semanal, Red 4, como quincenal, Red 4, comienzan con uno o dos caudales simulados muy por sobre el caudal observado, generando errores del 26% en el caso de la serie diaria, del 70% en el caso de la serie semanal y del 116% en el caso de la serie quincenal. Sin embargo las series se ajustan al cabo de unos días, siendo el tiempo de ajuste de un día para la escala diaria, de tres días para la escala semanal y de cuatro días para la escala quincenal.

6.2 Conclusiones RNA usando datos estación Valle Nevado

Al observar las variables o parámetros de entrada significativos, se concluye que las variables correspondientes a los promedios semanales o quincenales, dependiendo del caso, son más significativas que las variables correspondientes al valor del día anterior, de éste modo, las variables seleccionadas son la temperatura máxima promedio de la semana o quincena anterior, la precipitación acumulada la semana o quincena anterior y la humedad relativa promedio de la semana o quincena anterior. El caso del caudal es una excepción, dado que para el caso de la escala temporal semanal, es más significativo el caudal del día anterior, mientras que para la escala temporal quincenal, es más significativo el caudal de la quincena anterior.

En cuanto a la inclusión de datos hidrometeorológicos de la estación “Valle Nevado” se observa que éstos generan una leve mejora en los pronósticos a escalas temporales diaria y semanal, donde la redes neuronales artificiales óptimas entrenadas utilizando los datos provenientes de la estación Valle Nevado tienen mejores coeficientes de correlación de Pearson en comparación con las RNA óptimas entrenadas utilizando los datos provenientes de la estación Mapocho en Los Almendros. En el caso de la escala temporal quincenal, la RNA óptima para Mapocho en Los Almendros entrega un R^2 de 0.9962, mientras que la RNA óptima para Valle Nevado entrega un R^2 de 0.9944, por lo que no se observan mejoras en el pronóstico.

El parámetro de entrada, Humedad Relativa, es significativo para las escalas temporales mayores a la diaria, dado que en el caso de la escala temporal diaria, la red óptima es la red “Valle Nevado 3”, cuyos parámetros de entrada no incluyen la humedad relativa, sin embargo para el caso de las escalas temporales semanal y quincenal, la RNA óptima es la red “Valle Nevado 2”, cuyos parámetros de entrada sí incluyen la humedad relativa de la semana o quincena anterior según sea el caso.

6.3 Conclusiones generales y Comentarios

En primer lugar se observa que se obtuvieron RNA con coeficientes de correlación de Pearson “ R^2 ” mayores a 0.99 en el caso de las escalas temporales diaria y quincenal y R^2 mayores a 0.98 en el caso de la escala temporal semanal. Al simular las RNA óptimas para la temporada de deshielo 2013-2014, se obtuvieron errores del 5.6 % (0.18 m³/s) para la escala temporal diaria, 11.6% (0.39 m³/s) para la escala temporal semanal y 11.5% (0.38 m³/s) para la escala temporal quincenal. Lo anterior implica que las RNA óptimas sí logran pronosticar con bastante certeza los caudales de deshielo, con mayor precisión para la escala temporal diaria, y con menor precisión para las otras dos escalas temporales.

La RNA óptima para las escala temporales semanal entrega un buen pronóstico a nivel general, sin embargo muestra deficiencias al pronosticar los caudales extremos, es decir, caudales medios semanales máximos y mínimos, los cuales ocurren en los primeros dos meses de la temporada de deshielo.

El determinar la eficiencia de una RNA sólo en base al valor del coeficiente de correlación de Pearson obtenido no es suficiente, dado que la mayoría de las veces éstos varían en la centésima e incluso milésima, por lo que se recomienda realizar las simulaciones y graficar las series temporales de caudales de deshielo con dos o más RNA óptimas para cada caso. Lo anterior se justifica al observar el caso de las RNA quincenales, donde la “Red 4” tienen peor R^2 en comparación con las “Red 2”, 0.9905 v/s 0.9963, pero al simular las RNA óptimas para la temporada 2013-2014, la “Red 4” entrega resultados notoriamente superiores, errores del 22.3% (0.88 m³/s) para la Red 2 versus errores del 11.5 % (0.38 m³/s) para la Red 4. Lo anterior, también ocurre para el caso de las Red 2 y Red 4 de la escala temporal semanal, pero en menor medida.

Los parámetros de entrada más significativos son aquellos relacionados al caudal y la temperatura máxima, lo cual queda en evidencia al observar las mejoras en los resultados al incluir éstos en los parámetros de entrada en las RNA con datos de Mapocho en los Almendros, a escalas temporales semanal y quincenal. Otra evidencia es el análisis de variables significativas realizado para las RNA con datos de la estación Valle Nevado, donde para la escala temporal semanal, se obtienen coeficientes de correlación de Pearson para la temperatura máxima “ $T_{max\ t-1}$ ”, la suma de caudales anteriores “ Q_{ant} ”, la precipitación “ $P_p\ t-1$ ” y la humedad relativa “ $H.R.\ t-1$ ” de 0.949, 0.959, 0.924 y 0.923 respectivamente; y para la escala temporal quincenal se obtienen coeficientes de correlación de Pearson para la temperatura máxima “ $T_{max\ t-1}$ ”, la suma de caudales anteriores “ Q_{ant} ”, la precipitación “ $P_p\ t-1$ ” y la humedad relativa “ $H.R.\ t-1$ ” de 0.943, 0.986, 0.899 y 0.821 respectivamente.

En cuanto a la inclusión de datos hidrometeorológicos provenientes de la estación Valle Nevado, se observaron mejores, iguales y peores coeficientes de correlación de Pearson, en comparación con los R^2 obtenidos al calibrar las RNA utilizando datos de la estación Mapocho en Los Almendros. Además, no fue posible utilizar la información de radiación neta ni de altura de nieve, por existir fallas en la medición., la cual de ser usada sí podría generar mejoras en los pronósticos. En resumen, debido a la escasa disponibilidad de datos y a la baja calidad de los mismos, los resultados obtenidos no son concluyentes, por lo que no es posible determinar con certeza si el contar con datos meteorológicos provenientes de una estación ubicada a los 3.000 m.s.n.m. aprox., implica siempre una mejora significativa en los pronósticos de caudales de deshielo.

Finalmente, al trabajar con RNA se debe tener claro el tipo de problema que se desea resolver, dado que eso permite acotar la multitud de RNA a probar, acotando la arquitectura de la red, la función de entrenamiento y las funciones de transferencia, dado que en el *Toolbox* de Matlab existen más de 15 arquitecturas de red y más de 10 funciones de entrenamiento. Además se debe saber la cantidad exacta de datos para entrenamiento, validación y prueba con los que se cuenta, dado que eso determinará el máximo número de pesos y bias que se pueden tener para ser calibrados. Lo anterior permite reducir la cantidad de RNA posibles para la resolución del problema y optimizar la investigación.

Capítulo 7 .- Bibliografía

BARRÍA P. (2010) Pronóstico de caudales medios mensuales en las cuencas de los ríos Baker y Pascua. Memoria para optar al Título de Ingeniero Civil. Departamento de Ingeniería Civil, Universidad de Chile.

CARTES, M. (2009) Pronóstico de volúmenes de deshielo mediante redes neuronales recurrentes e imágenes satelitales MODIS. Tesis para optar al grado de Magister en Ciencias de la Ingeniería Mención Recursos y Medio Ambiente Hídrico. Departamento de Ingeniería Civil, Universidad de Chile.

GONZÁLEZ, R. (2003) Pronóstico de crecidas en tiempo real. Uso de Redes Neuronales. Tesis para optar al grado de Magister en Ciencias de la Ingeniería Mención Recursos Hídricos y Medio Ambiente. Universidad de Chile.

ESPINOZA, A. (1973) Caracterización estadística del régimen de escorrentía de deshielo de la hoya del río Aconcagua y método para su predicción. Memoria para optar al Título de Ingeniero Civil. Departamento de Ingeniería Civil, Universidad de Chile.

MÁRQUEZ, F. (1991). Pronóstico de Crecidas en Tiempo Real, Aplicado a la cuenca del Río Mapocho. Memoria para optar al Título de Ingeniero Civil. Departamento de Ingeniería Civil, Universidad de Chile.

MUÑOZ, M. (2008) Pronóstico de Crecidas en Tiempo Real, usando Redes Neuronales Recurrentes. Memoria para optar al Título de Ingeniero Civil. Departamento de Ingeniería Civil, Universidad de Chile.

NAZARALA B., Miñano J. y Larenas M. (2010) Pronóstico de Disponibilidad de Agua, Temporada de Riego 2010-2011, Dirección General de Aguas, Ministerio de Obras Públicas, República de Chile.

CORNWELL E. (2012) Reconstrucción del Equivalente en Agua de Nieve Mediante Imágenes MODIS incorporadas a un Balance de Masa-Energía. Tesis para optar al grado de Magister en Ciencias de la Ingeniería Mención Recursos y Medio Ambiente Hídrico. Departamento de Ingeniería Civil, Universidad de Chile.

RAJURKAR M. Kothiyari U. Chaube U. (2002) Artificial neural networks for daily rainfall-runoff modelling. *Hydrological Sciences-Journal-des Sciences Hydrologiques*, 47(6).

DÖLLIN, O. y Varas, E. (2000) Pronóstico de Caudales en Cuencas Nivales usando Redes Neuronales Artificiales. XIX Congreso Latino Americano de Hidráulica, Córdoba.

DAWSON, C. and Wilby, R. (1998) An artificial neuronal network approach to rainfall-runoff modelling. *Hydrological Sciences Journal*, 43(1), 47-66.

HUDSON M. Hagan M. and Demuth H. (2014) *Neural Network Toolbox, User`s Guide*, R2014b, Matlab.

GARCÍA J. López A. Romero J. García A. Camacho C. Cantero J. Atienza M. y Salas R. (2002) Hojas de cálculo para la simulación de redes de neuronas artificiales (RNA), *QUESTIIO*, vol. 26, 1-2, p. 289-305, 2002

SOCHA D. y Ortiz G. (2005) Aplicación de Redes Neuronales MLP a la predicción de un Paso en Series de Tiempo. Facultad de Ingenieria de Sistemas, Fundación Universitaria Konrad Lorenz, Bogota.

Capítulo 8 .- Anexos

Anexo 1. “*Toolbox de RNA de Matlab*”

Un *toolbox* de Matlab es una “caja de herramientas” o un grupo de funciones que han sido creadas y agrupadas con una finalidad común; en éste caso, el *toolbox* de redes neuronales de Matlab es un conjunto de funciones y/o instrucciones especializadas para crear, entrenar, validar y utilizar una red neuronal. Este *toolbox* viene incluido gratuitamente en los programas de Matlab más recientes como “Matlab R2014b”. Dentro de la gran cantidad de funciones disponibles en el *toolbox* de RNA, destacan las siguientes:

Para ingresar el set de datos de entrada y valores de salida observados, se deben ordenar en columnas cada par de datos de “inputs – Salida Observada”, siendo la primera fila el vector de salidas observadas y las filas siguientes los vectores de entrada.

Crear una red prealimentada o feedforward, con una capa oculta:

$$net = feedforwardnet(hiddenSizes, trainFcn)$$

donde:

trainFcn = 'LM' (Método de Levenberg-Marquardt o alguna otra función de entrenamiento)

hiddenSizes = número de neuronas en la capa oculta

Determinar la función de transferencia para todas las capas:

$$net.layers\{ \}.transferFcn = 'tansig'$$

Por defecto, el *toolbox* de RNA divide el set de datos ingresados al azar en 3 grupos, con el 70% de los datos para entrenamiento, 15% para validación y 15% para prueba. De este modo, si se desea cambiar el porcentaje asignado a cada grupo, se escribe el porcentaje en fracción, donde el denominador es el número total de datos disponibles, 1000 por ejemplo, por lo tanto si deseo que el 50% de los datos sean de entrenamiento, el numerador debe ser 500. Además, es posible modificar la manera de dividir el set de datos, la cual es por defecto aleatoria, sin embargo se puede cambiar a división por bloques continuos, por intervalos o por un índice.

$$\begin{aligned} net.divideParam.trainRatio &= 500/1000 \\ net.divideParam.valRatio &= 250/1000 \\ net.divideParam.testRatio &= 250/1000 \end{aligned}$$

Al crear una red neuronal, el *toolbox* de RNA automáticamente asigna una función de preprocesamiento a las entradas y salidas observadas, la cual es por defecto “mapminmax” y normaliza las entradas y salidas observadas en el rango [-1,1]. Las funciones de preprocesamiento transforman los valores de las entradas y salidas observadas en valores que son mejores para el entrenamiento de la red, por ejemplo “si las entradas son muy grandes, los pesos deberán ser muy pequeños para prevenir que la función de transferencia se sature, por lo que usualmente se normalizan las entradas.” (Hudson et al. 2014). Existen otras funciones de preprocesamiento, como “mapstd” la cual normaliza las entradas y salidas observadas para que tengan media cero y varianza igual a 1.

Existen seis parámetros de entrenamiento generales, que utilizan las distintas funciones de entrenamiento, los cuales son:

- Epochs = número de iteraciones máxima, el entrenamiento se detiene si se excede este número de iteraciones.
- Minigrad = magnitud mínima del gradiente, el entrenamiento se detienen si la magnitud del gradiente está por debajo de este valor.
- Goal = decrementos de la función de desempeño, el entrenamiento se detiene si los decrementos de la función de desempeño están por debajo de este valor.
- Time = tiempo máximo de entrenamiento, el entrenamiento se detiene si el tiempo de entrenamiento excede este valor.
- Max_fail = asociado con la técnica de detención temprana.
- Validation checks = representa el número de iteraciones sucesivas que la función de desempeño no decae. El entrenamiento se detiene si se excede el número de *validation checks*, el cual es por defecto igual a seis.

Para entrenar la red, se escribe:

$$[net, tr] = trainlm(net, input, target)$$

donde:

net = red creada

input = set de datos de entrada

target = set de datos de salida observados o deseados

Para simular la red con nuevos datos de entrada, una vez que ya ha sido entrenada, se escribe:

$$TargetSimulados = sim(net, inputS)$$

donde:

net = red ya entrenada

inputs = nuevos datos de entrada

El *toolbox* de RNA está programado según la configuración que produce el mejor rendimiento en la mayoría de los casos, esta configuración implica que por defecto el número de capas ocultas sea uno, el número de neuronas en la capa oculta sea 10, la función de entrenamiento sea “LM” (Método de Levenberg-Marquardt), la función de transferencia en la capa oculta sea “tangente sigmoideal” y por último la función de transferencia en la capa de salida sea “purelin”.

Anexo 2. “Estadísticas Fluviométricas y Meteorológicas”

2.1 Regresiones Mensuales de Temperaturas Mínimas

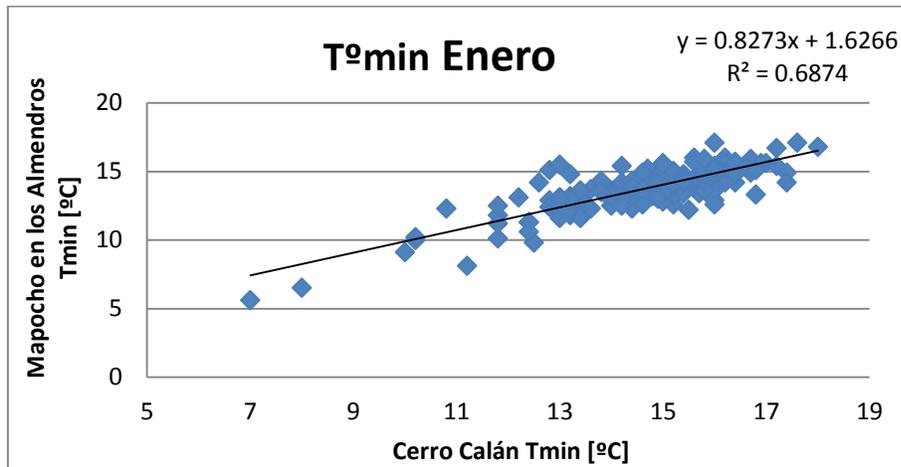


Figura 8.1 Regresión Temperatura mínima Enero

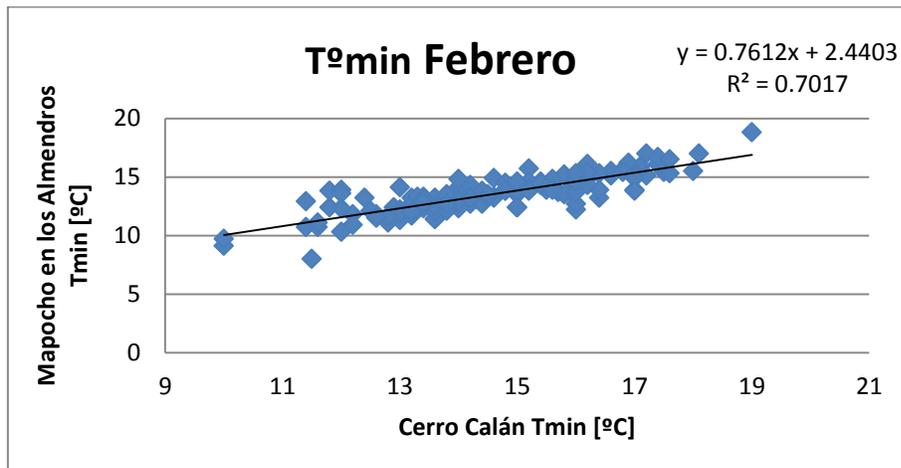


Figura 8.2 Regresión Temperatura mínima Febrero

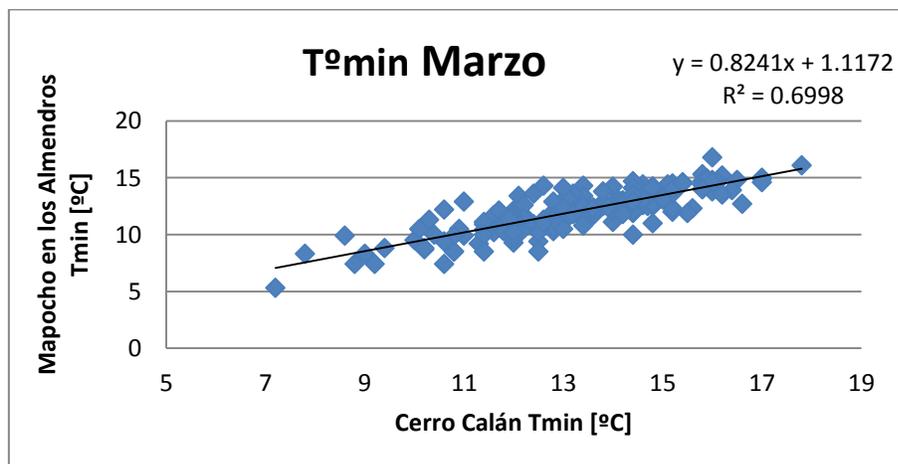


Figura 8.3 Regresión Temperatura mínima Marzo

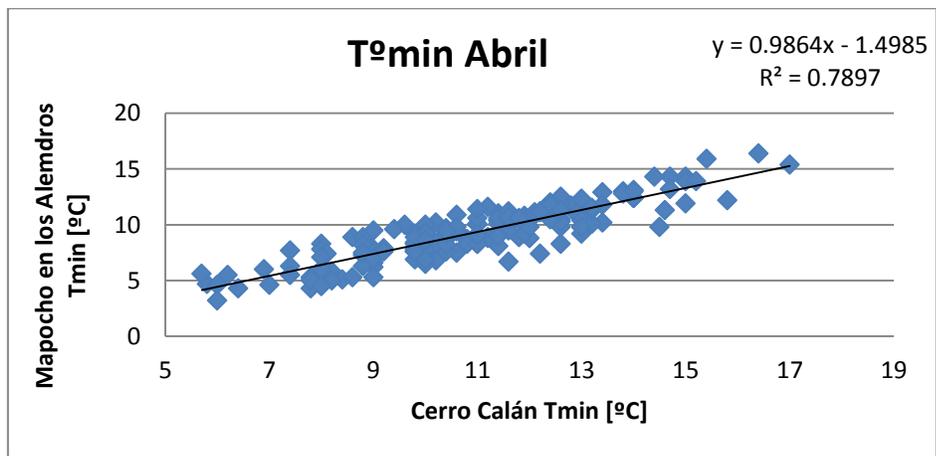


Figura 8.4 Regresión Temperatura mínima Abril

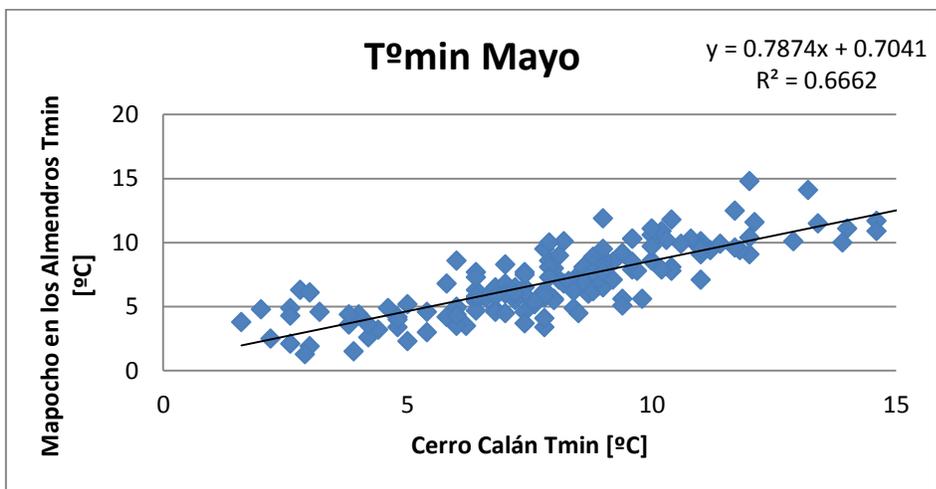


Figura 8.5 Regresión Temperatura mínima Mayo

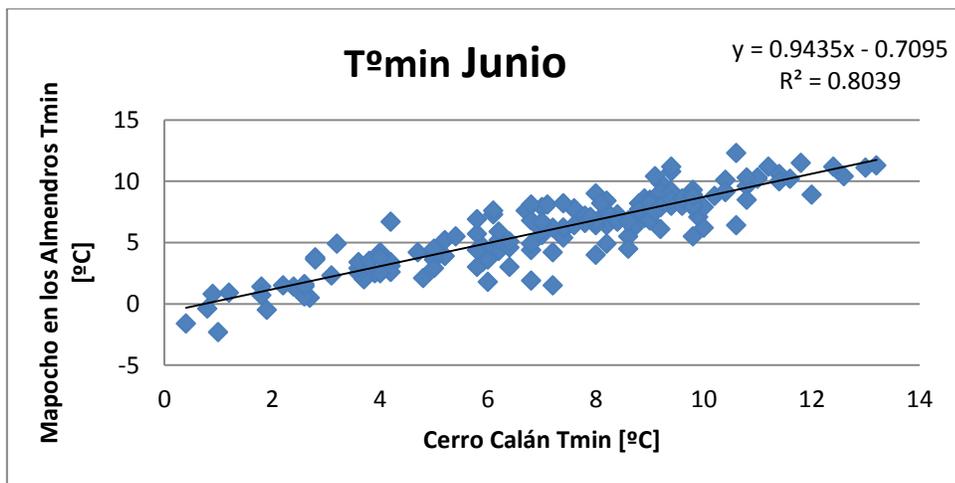


Figura 8.6 Regresión Temperatura mínima Junio

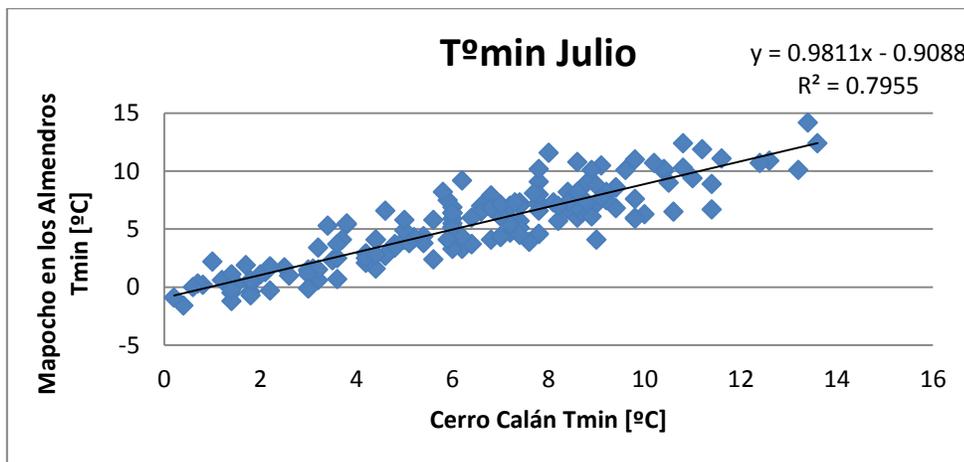


Figura 8.7 Regresión Temperatura mínima Julio

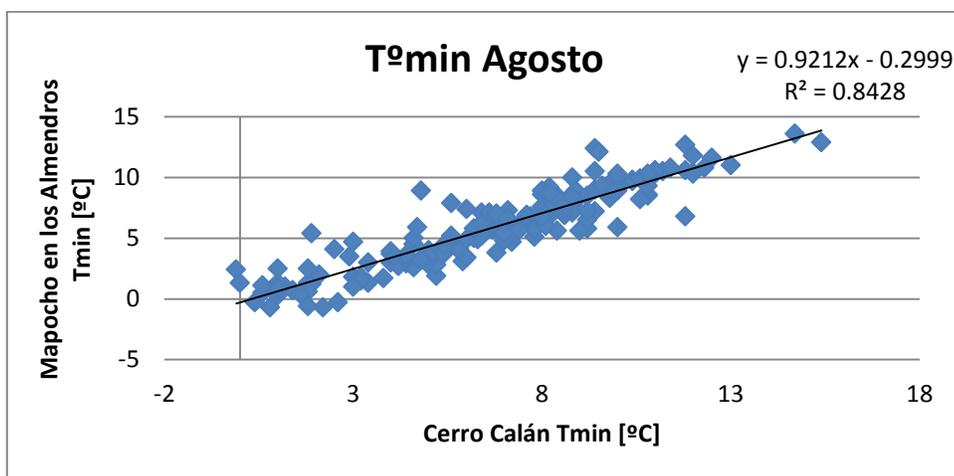


Figura 8.8 Regresión Temperatura mínima Agosto

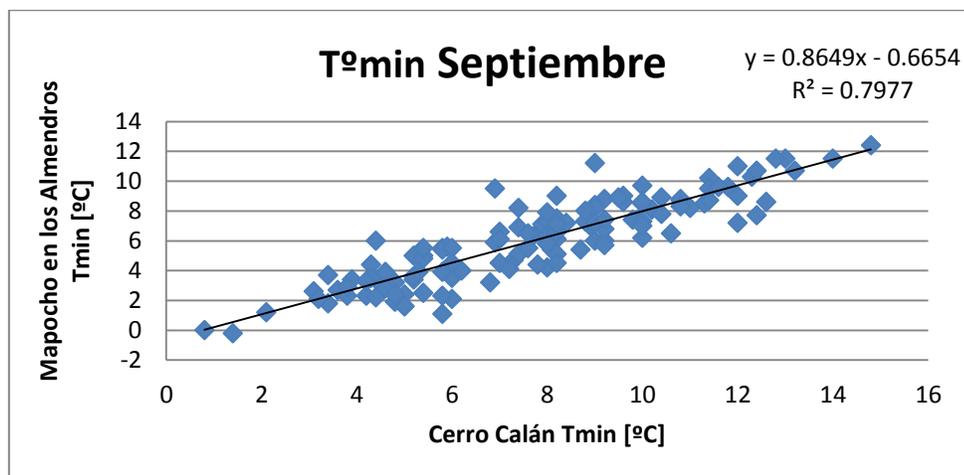


Figura 8.9 Regresión Temperatura mínima Septiembre

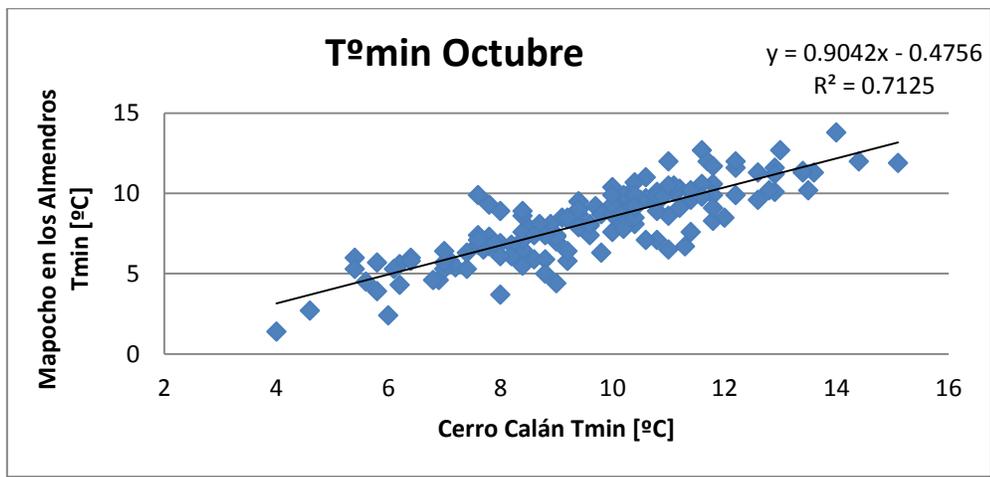


Figura 8.10 Regresión Temperatura mínima Octubre

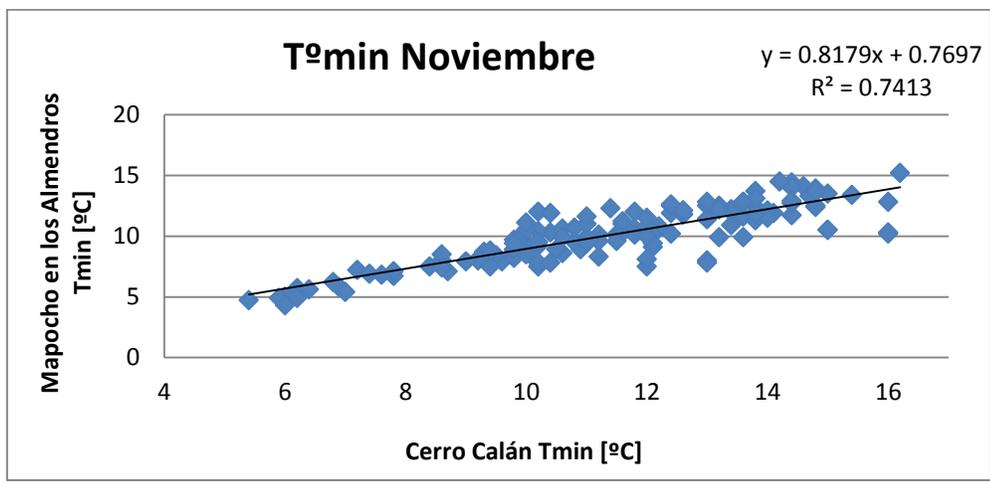


Figura 8.11 Regresión Temperatura mínima Noviembre

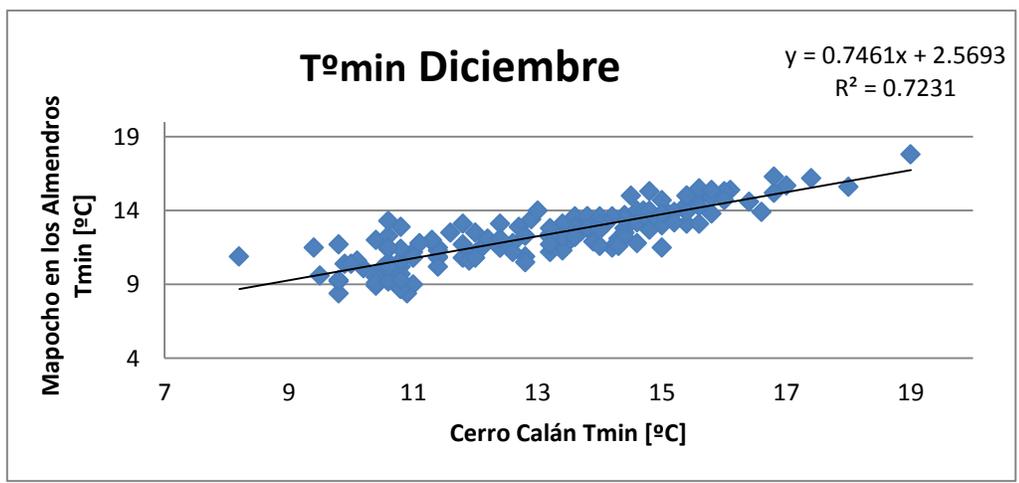


Figura 8.12 Regresión Temperatura mínima Diciembre

2.2 Regresiones Mensuales de Temperaturas Máximas

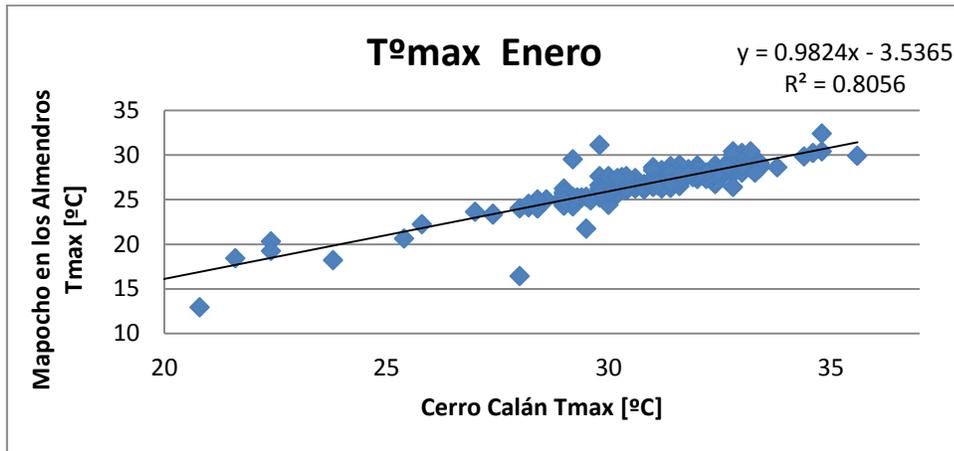


Figura 8.13 Regresión Temperatura máxima Enero

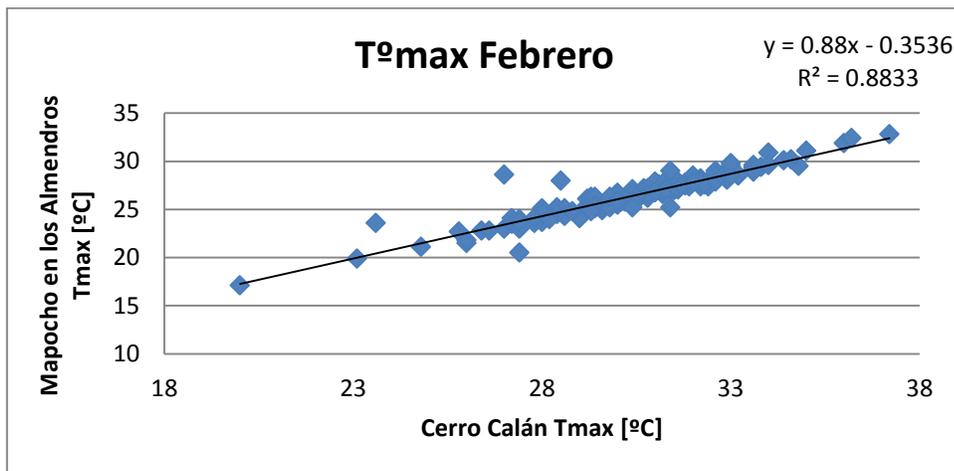


Figura 8.14 Regresión Temperatura máxima Febrero

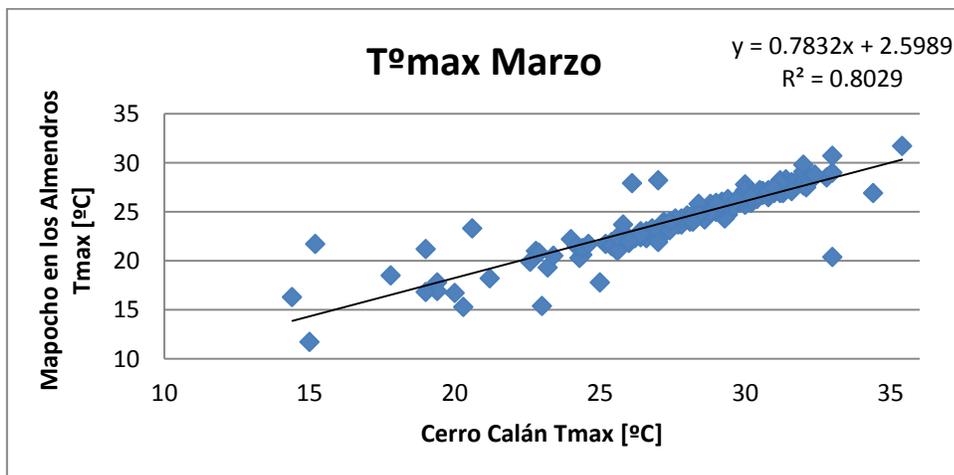


Figura 8.15 Regresión Temperatura máxima Marzo

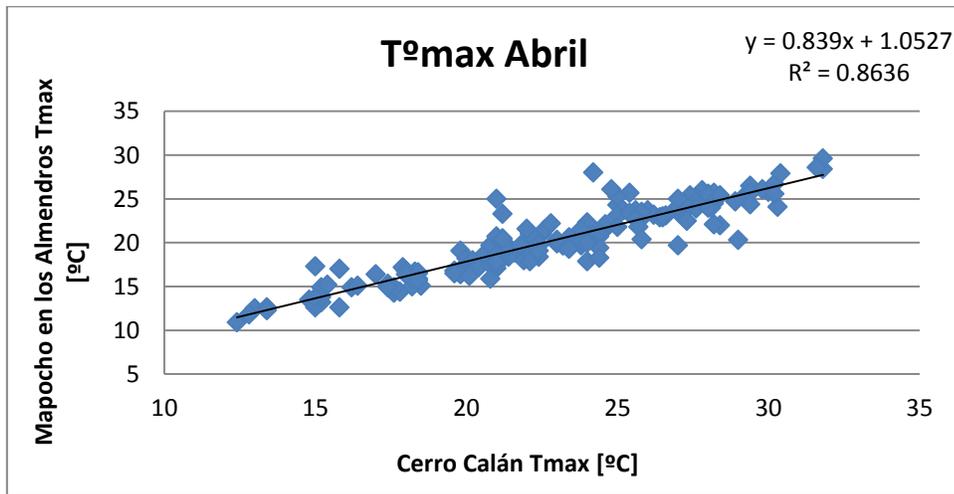


Figura 8.16 Regresión Temperatura máxima Abril

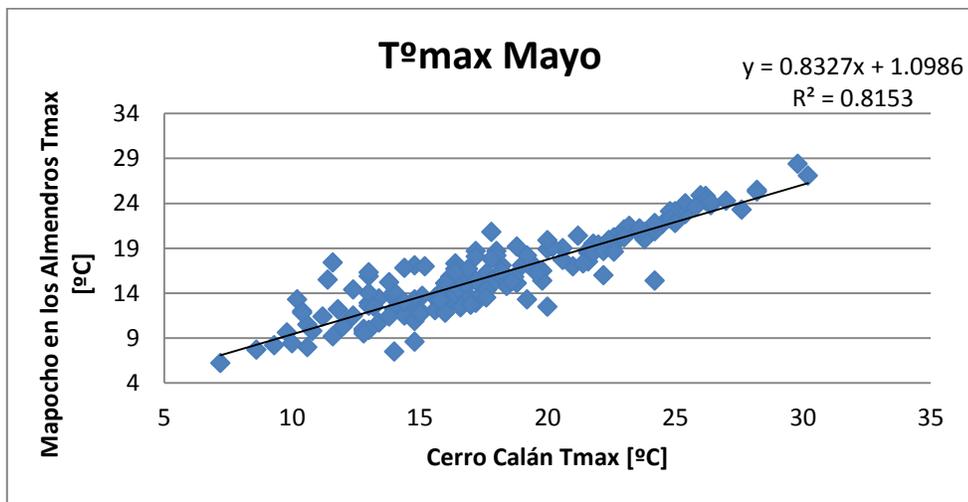


Figura 8.17 Regresión Temperatura máxima Mayo

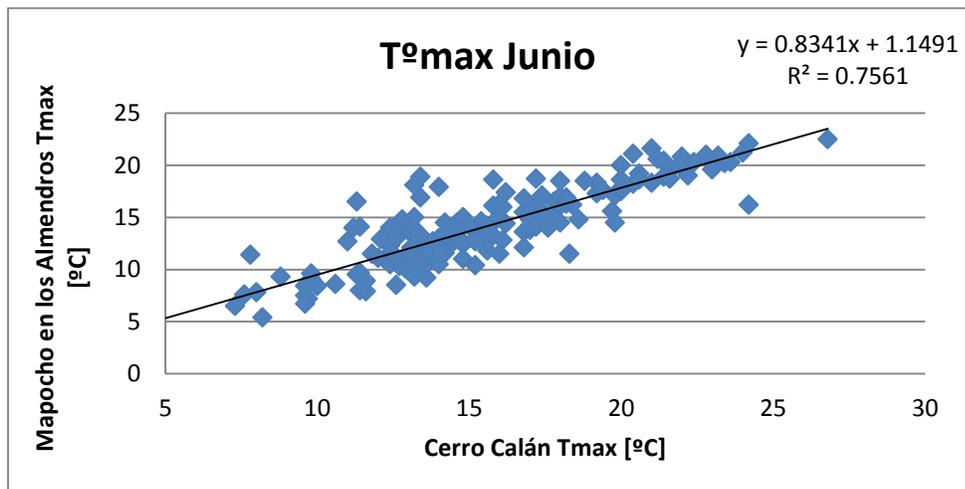


Figura 8.18 Regresión Temperatura máxima Junio

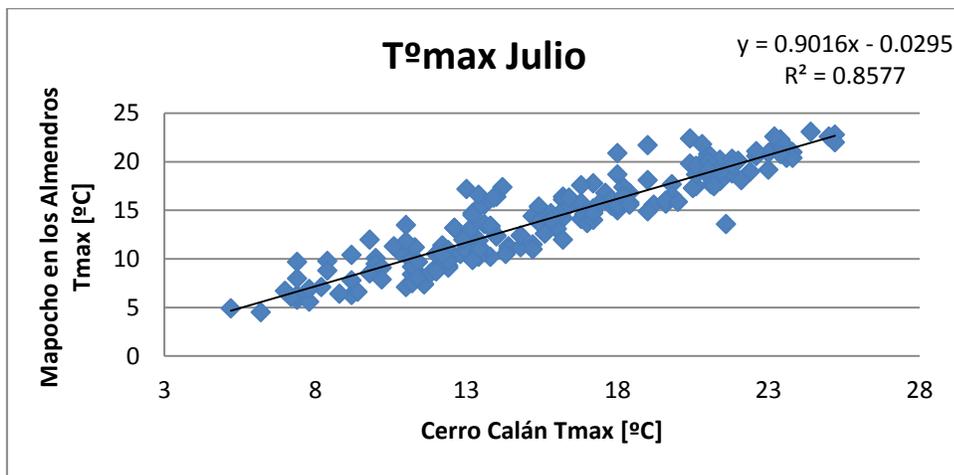


Figura 8.19 Regresión Temperatura máxima Julio

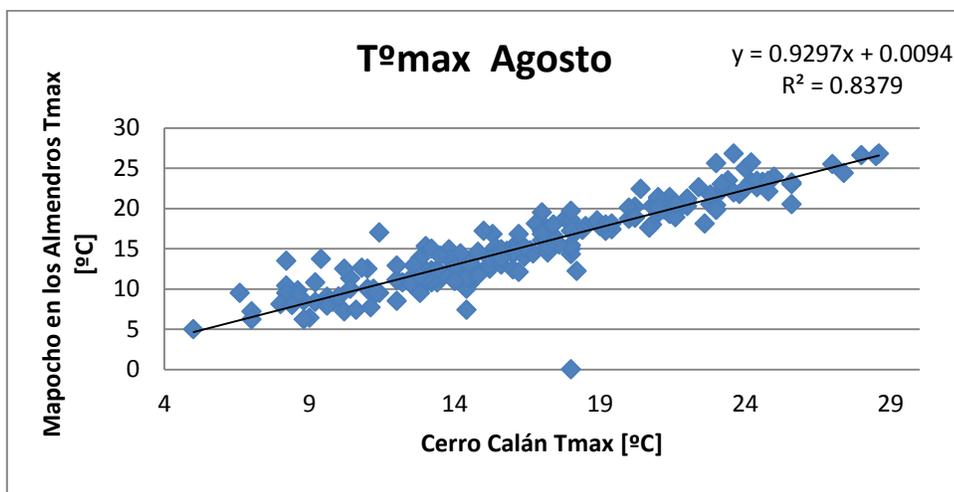


Figura 8.20 Regresión Temperatura máxima Agosto

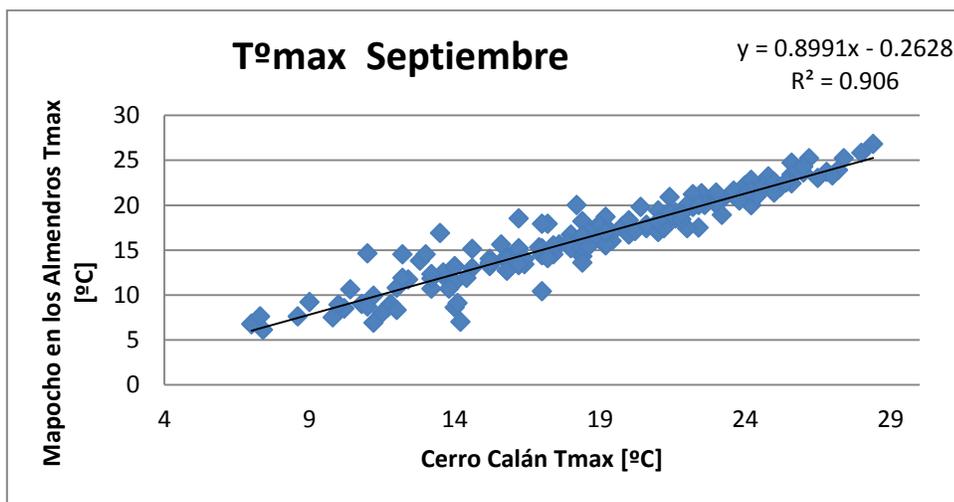


Figura 8.21 Regresión Temperatura máxima Septiembre

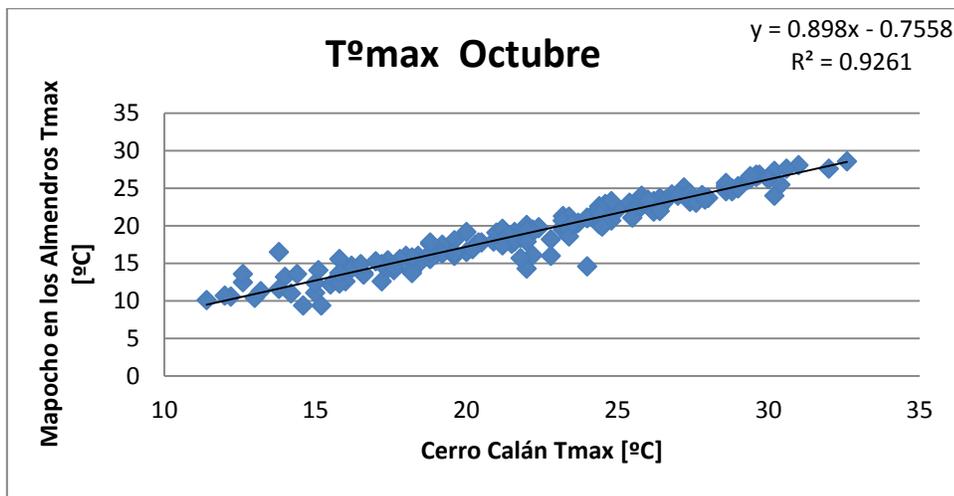


Figura 8.22 Regresión Temperatura máxima Octubre

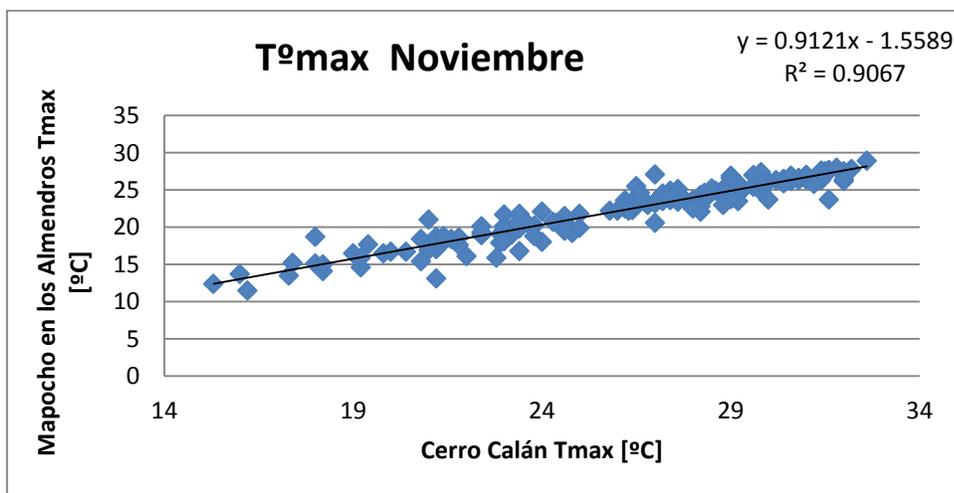


Figura 8.23 Regresión Temperatura máxima Noviembre

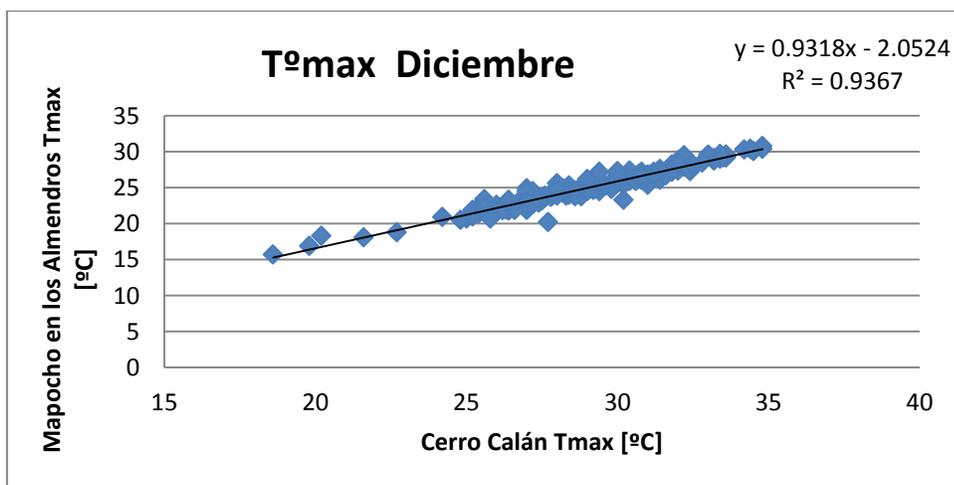


Figura 8.24 Regresión Temperatura máxima Diciembre

2.3 Regresiones Mensuales de Precipitaciones

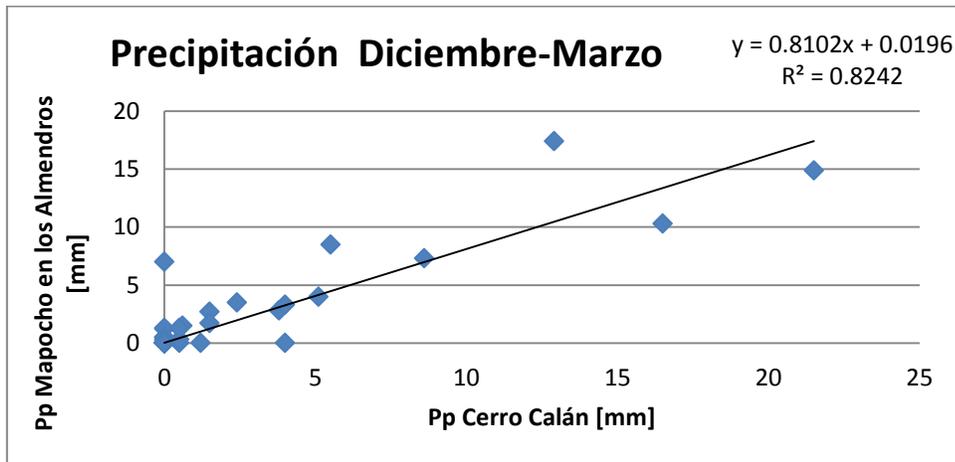


Figura 8.25 Regresión de Precipitaciones Diciembre - Marzo

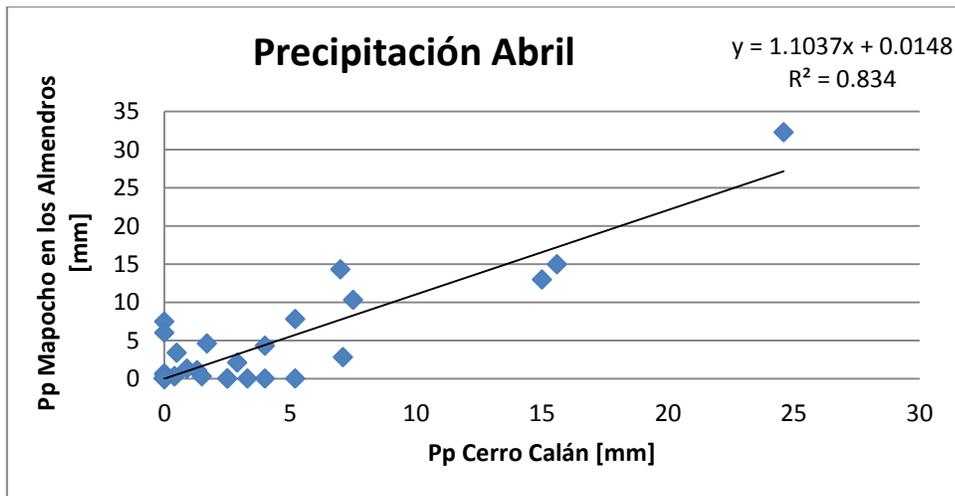


Figura 8.26 Regresión de Precipitaciones Abril

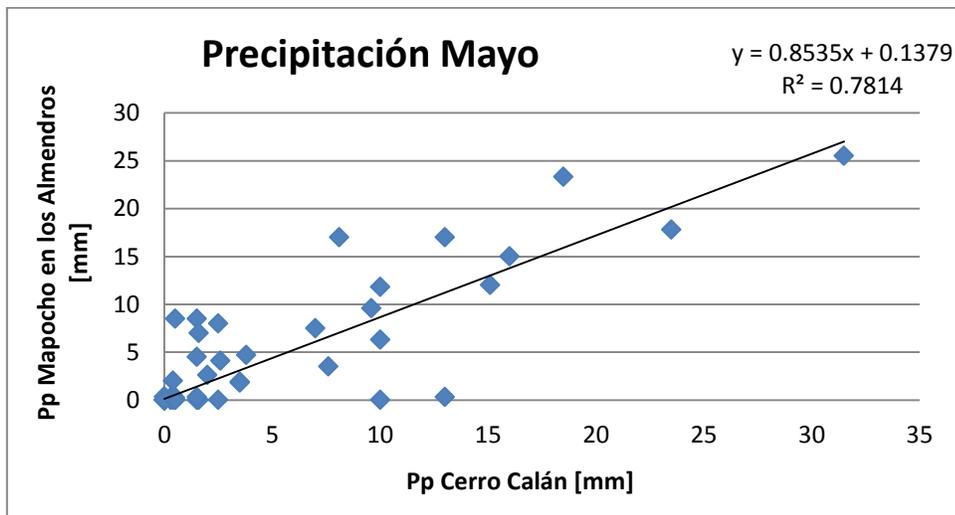


Figura 8.27 Regresión de Precipitaciones Mayo

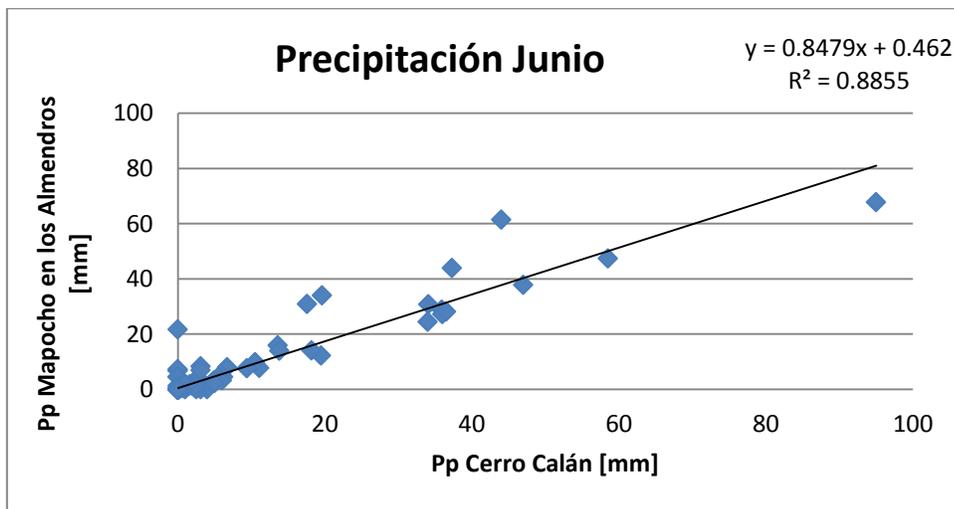


Figura 8.28 Regresión de Precipitaciones Junio

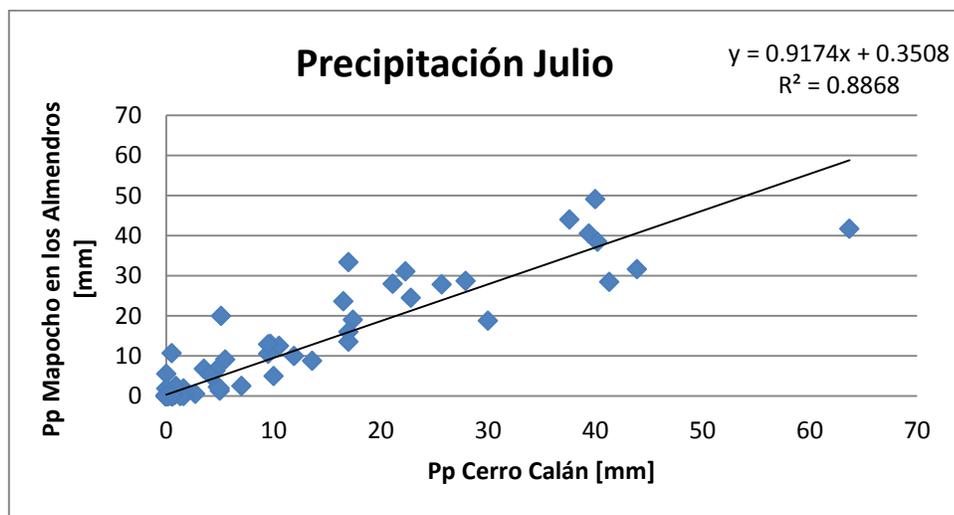


Figura 8.29 Regresión de Precipitaciones Julio

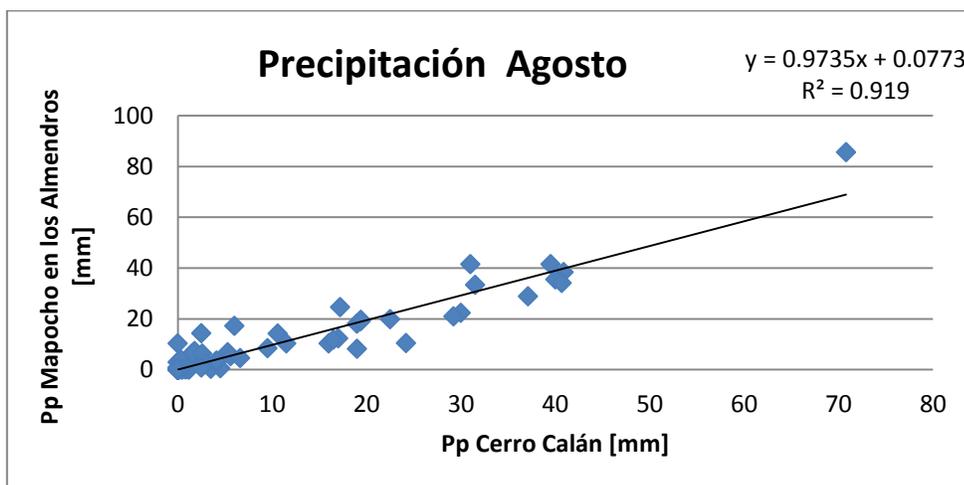


Figura 8.30 Regresión de Precipitaciones Agosto

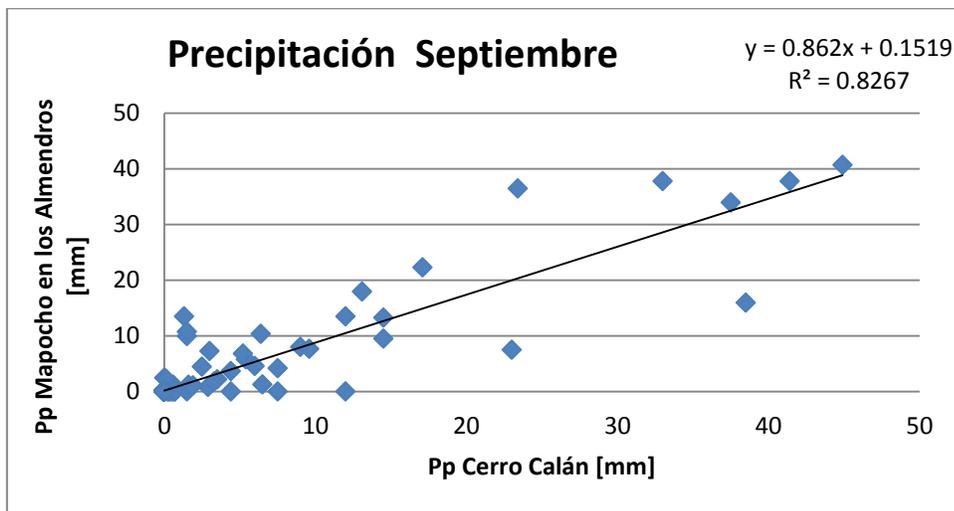


Figura 8.31 Regresión de Precipitaciones Septiembre

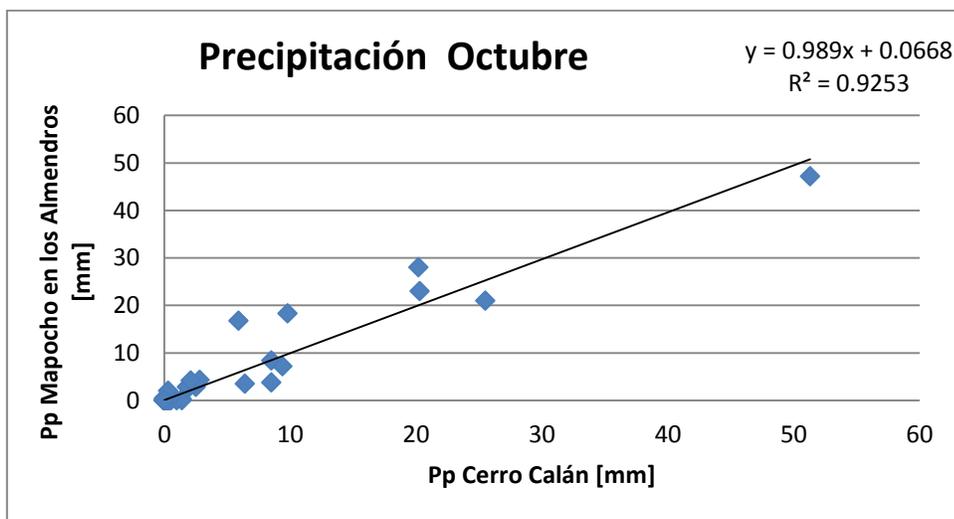


Figura 8.32 Regresión de Precipitaciones Octubre

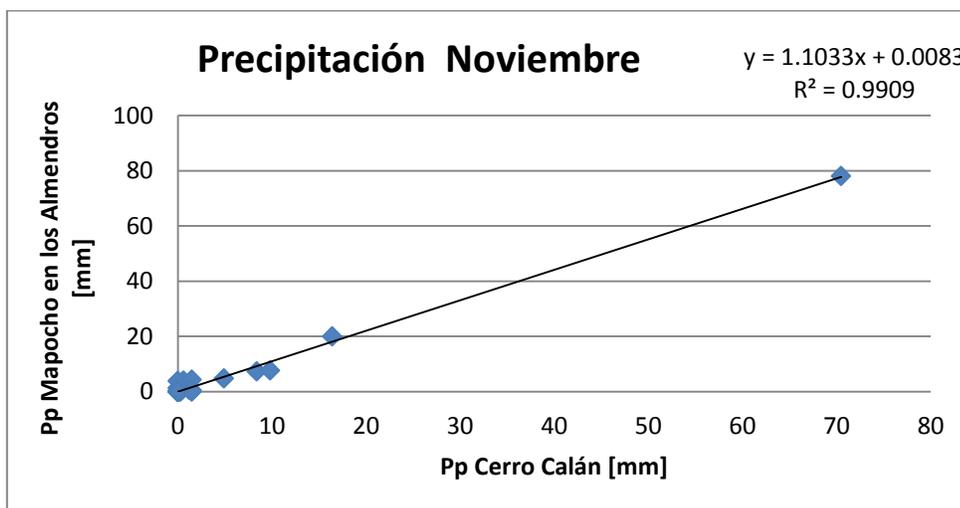


Figura 8.33 Regresión de Precipitaciones Noviembre

2.4 Regresiones Mensuales de Caudales

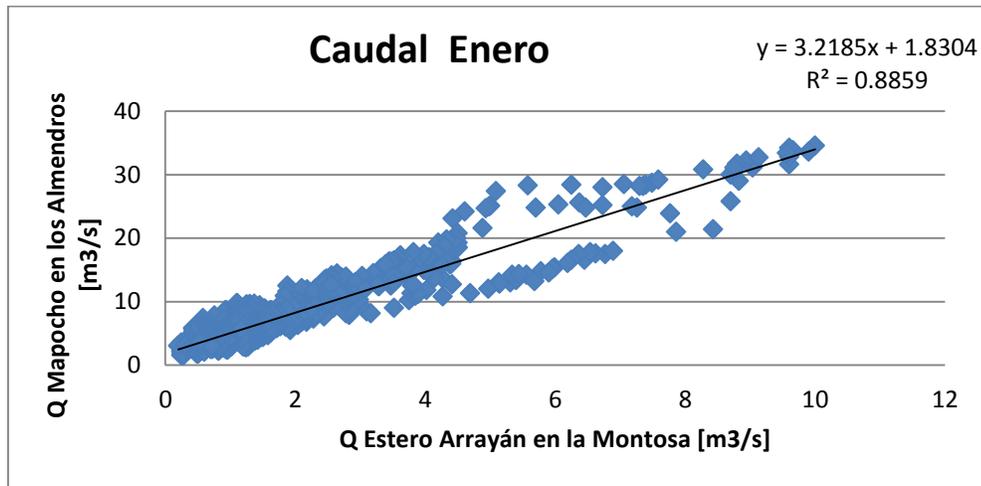


Figura 8.34 Regresión de Caudales Enero

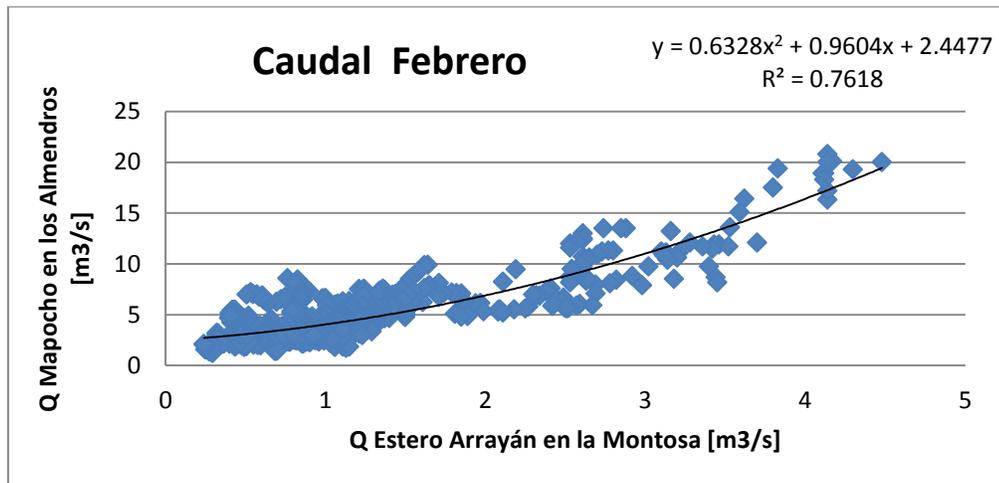


Figura 8.35 Regresión de Caudales Febrero

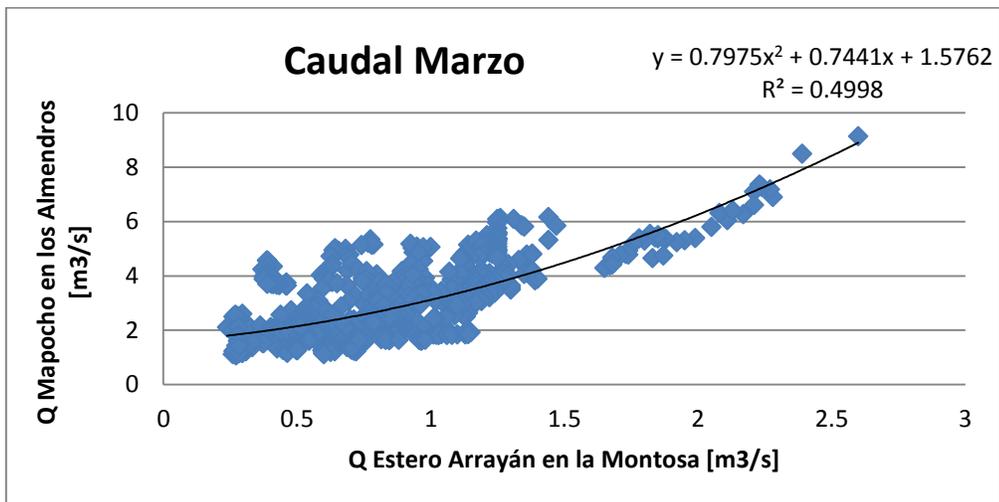


Figura 8.36 Regresión de Caudales Marzo

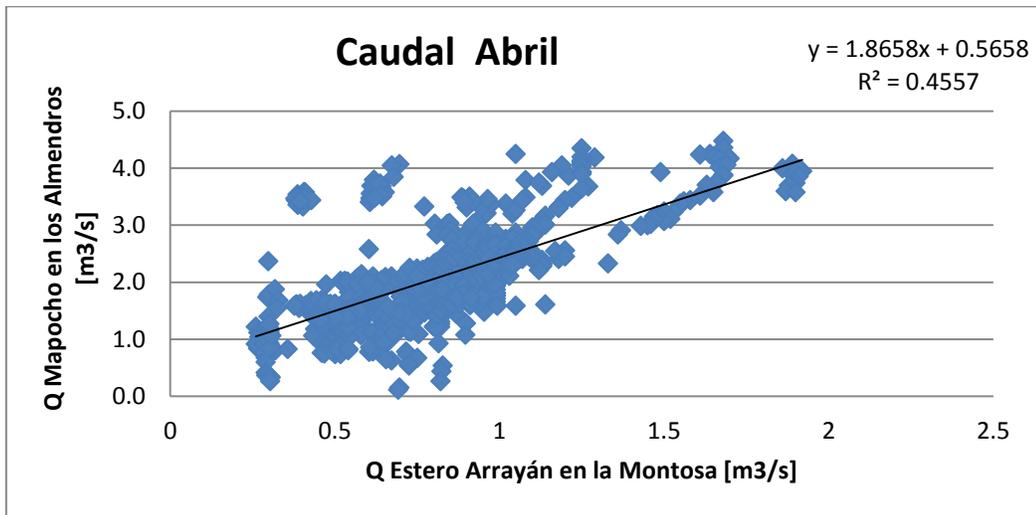


Figura 8.37 Regresión de Caudales Abril

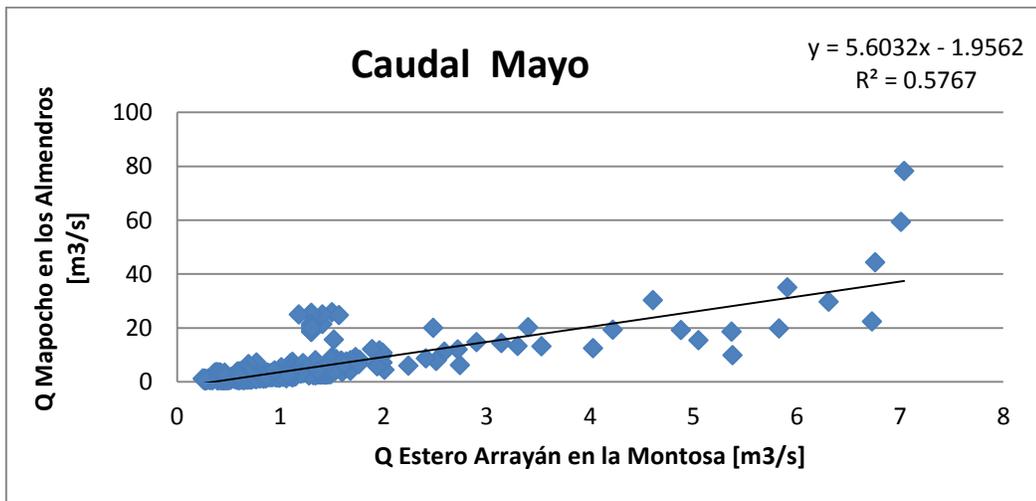


Figura 8.38 Regresión de Caudales Mayo

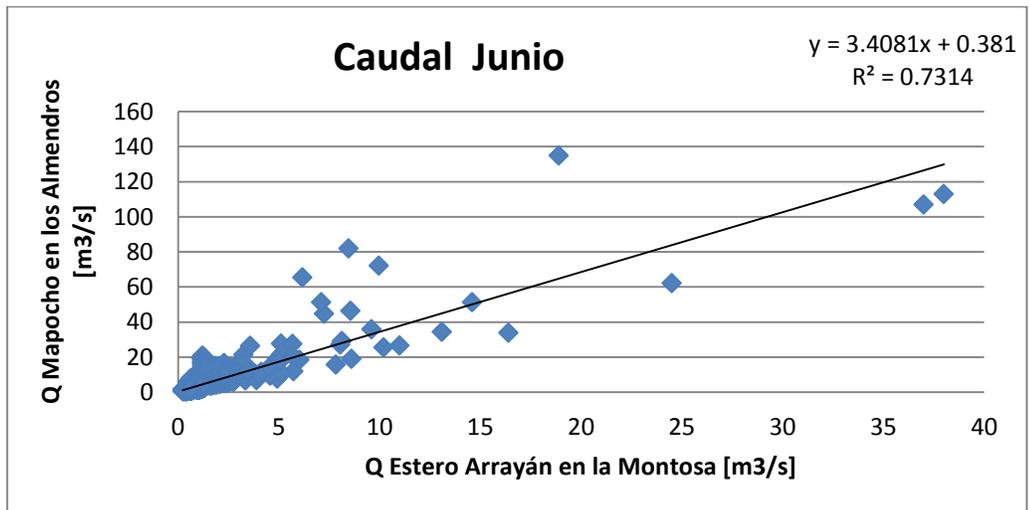


Figura 8.39 Regresión de Caudales Junio

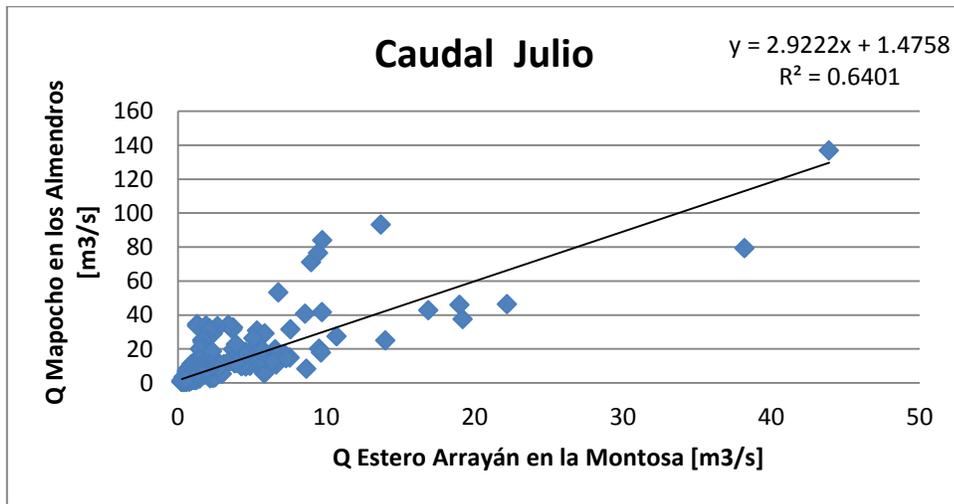


Figura 8.40 Regresión de Caudales Julio

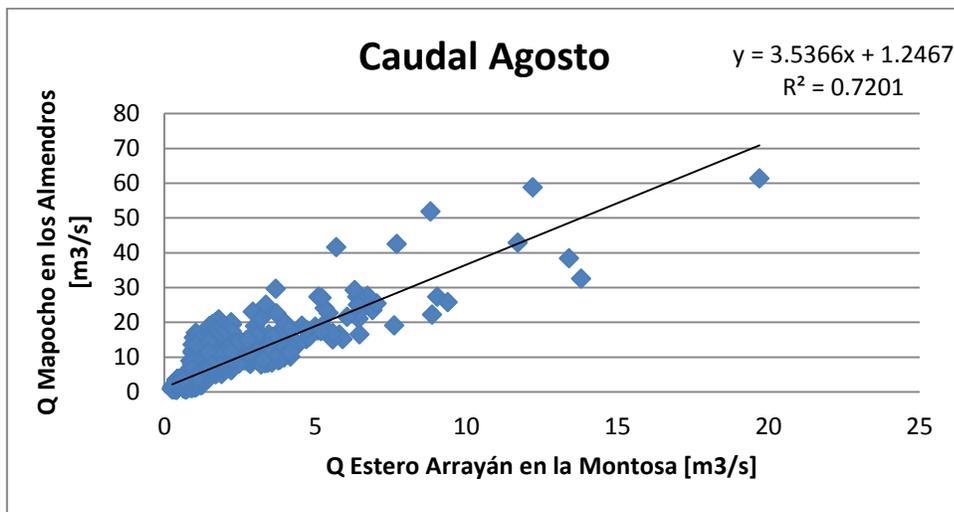


Figura 8.41 Regresión de Caudales Agosto

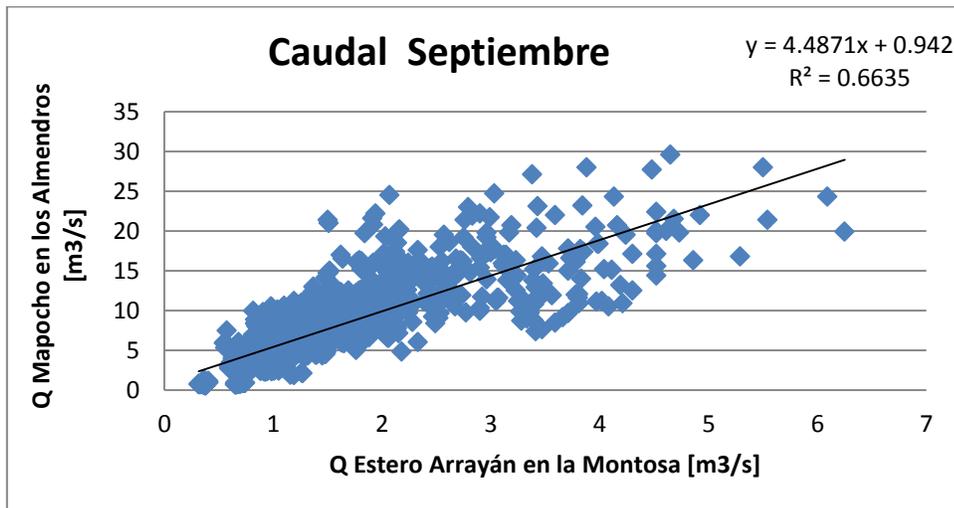


Figura 8.42 Regresión de Caudales Septiembre

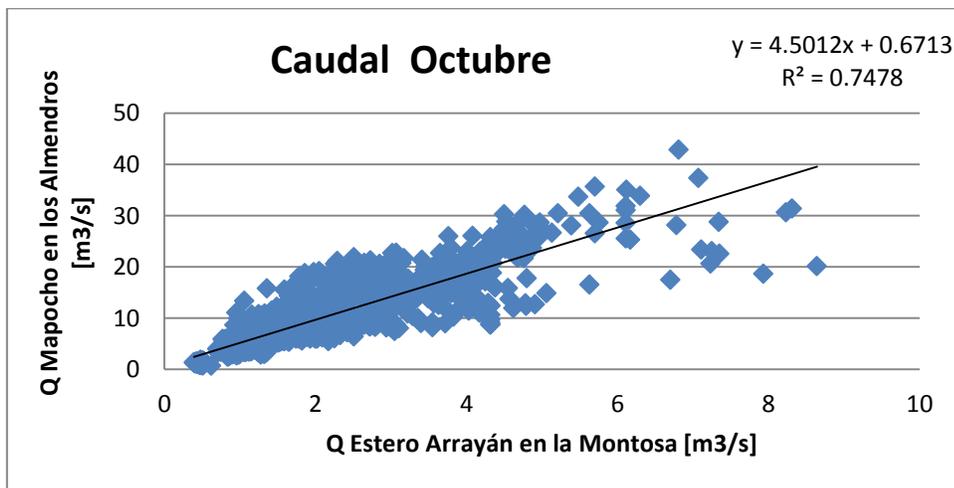


Figura 8.43 Regresión de Caudales Octubre

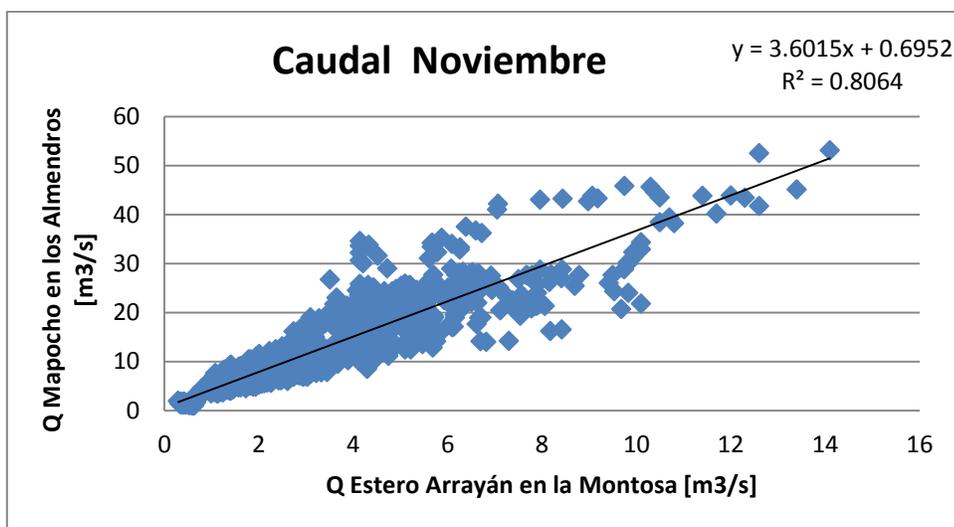


Figura 8.44 Regresión de Caudales Noviembre

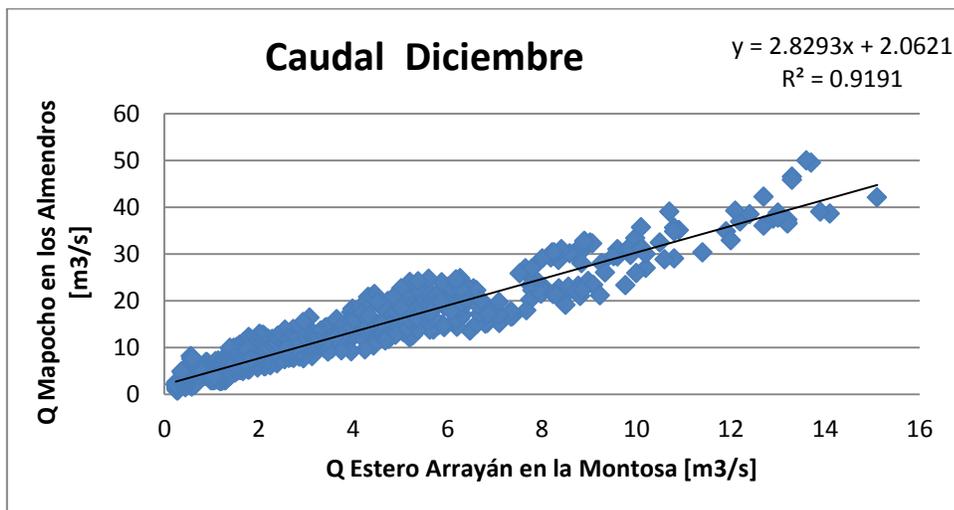


Figura 8.45 Regresión de Caudales Diciembre

Anexo 3. “Coeficientes de Correlación de Pearson, RNA para Mapocho en los Almendros”

3.1 Coeficientes de Correlación de Pearson, RNA Diarias.

Junio-Agosto		
Día 1	n° neuronas	5
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
Día 2	n° neuronas	10
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
Día 3	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	LM
Día 4	n° neuronas	20
	f(x) transferencia	logaritmo sigmoidal
	f(x) entrenamiento	LM
Día 5	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
	f(x) entrenamiento	SCG
Día 6	n° neuronas	20
	f(x) transferencia	purelin
	f(x) entrenamiento	LM

Tabla 8.1 Características de RNA calibradas para "Junio-Agosto"

Junio-Agosto			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Día 1	Entrenamiento	50%	0.9933	0.99365	0.99136	0.99144	0.99115	0.9919	0.0010
	Validación	25%	0.9916	0.99267	0.98766	0.9928	0.99434		
	Test	25%	0.9938	0.9852	0.99144	0.9938	0.99246		
	Todos	100%	0.9930	0.9914	0.99043	0.99233	0.99229		
Día 2	Entrenamiento	50%	0.99477	0.99358	0.99611	0.99381	0.99245	0.9926	0.0009
	Validación	25%	0.99337	0.99406	0.99006	0.98812	0.98889		
	Test	25%	0.98733	0.99092	0.99213	0.9938	0.99133		
	Todos	100%	0.9925	0.99305	0.99366	0.99238	0.99132		
Día 3	Entrenamiento	50%	0.99638	0.99626	0.99487	0.99321	0.99665	0.9932	0.0007
	Validación	25%	0.98866	0.98969	0.9904	0.99248	0.99458		
	Test	25%	0.99395	0.99418	0.98926	0.99304	0.98322		
	Todos	100%	0.99389	0.99406	0.99236	0.99298	0.99283		
Día 4	Entrenamiento	50%	0.506	0.402	0.518	0.4363	0.502	0.4846	0.0572
	Validación	25%	0.53	0.464	0.57	0.363	0.518		
	Test	25%	0.523	0.435	0.55	0.45	0.559		
	Todos	100%	0.514	0.426	0.542	0.42	0.521		
Día 5	Entrenamiento	50%	0.99465	0.99467	0.99251	0.99166	0.99222	0.9922	0.0009
	Validación	25%	0.98488	0.9868	0.99387	0.99208	0.99417		
	Test	25%	0.99218	0.99344	0.99378	0.98814	0.99222		
	Todos	100%	0.99164	0.99247	0.99317	0.99093	0.99274		
Día 6	Entrenamiento	50%	0.99614	0.99519	0.99319	0.9943	0.99365	0.9930	0.0007
	Validación	25%	0.98953	0.98459	0.99383	0.99262	0.99337		
	Test	25%	0.9905	0.99299	0.9933	0.99328	0.99155		
	Todos	100%	0.9931	0.99172	0.99336	0.9936	0.99304		

Tabla 8.2 Coeficientes de Correlación de Pearson, RNA diaria "Junio-Agosto"

Mayo-Septiembre		
Día 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoideal LM
Día 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoideal LM
Día 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal LM
Día 4	n° neuronas f(x) transferencia f(x) entrenamiento	10 logaritmo sigmoideal LM
Día 5	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoideal SCG
Día 6	n° neuronas f(x) transferencia f(x) entrenamiento	10 purelin LM

Tabla 8.3 Características de RNA calibradas para "Mayo - Septiembre"

Mayo-Septiembre			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Día 1	Entrenamiento	50%	0.9925	0.99268	0.99492	0.99343	0.99274	0.9925	0.0011
	Validación	25%	0.9885	0.99436	0.99468	0.99331	0.99215		
	Test	25%	0.9903	0.994	0.99007	0.98993	0.99027		
	Todos	100%	0.9909	0.9934	0.99364	0.99257	0.99196		
Día 2	Entrenamiento	50%	0.99483	0.99617	0.99369	0.99604	0.99372	0.9936	0.0005
	Validación	25%	0.98887	0.98969	0.99385	0.99402	0.99307		
	Test	25%	0.99274	0.99194	0.99523	0.98902	0.99379		
	Todos	100%	0.99282	0.99361	0.99409	0.99373	0.99357		
Día 3	Entrenamiento	50%	0.99242	0.99602	0.99459	0.99471	0.98412	0.9910	0.0048
	Validación	25%	0.99479	0.99018	0.99324	0.9907	0.99186		
	Test	25%	0.98987	0.99307	0.99329	0.99071	0.97003		
	Todos	100%	0.99237	0.99364	0.99393	0.99267	0.98241		
Día 4	Entrenamiento	50%	0.384	0.5411	0.534	0.0199	0.5482	0.3986	0.2234
	Validación	25%	0.41	0.5668	0.5129	0.017	0.515		
	Test	25%	0.31	0.5063	0.5676	0.022	0.493		
	Todos	100%	0.376	0.537	0.538	0.018	0.524		
Día 5	Entrenamiento	50%	0.99007	0.99471	0.99065	0.99318	0.99357	0.9912	0.0013
	Validación	25%	0.98514	0.98831	0.99088	0.98636	0.98779		
	Test	25%	0.99139	0.99062	0.99218	0.99328	0.99441		
	Todos	100%	0.98903	0.99207	0.9911	0.99166	0.99237		
Día 6	Entrenamiento	50%	0.9925	0.99361	0.99546	0.99228	0.99324	0.9932	0.0006
	Validación	25%	0.99374	0.99225	0.99169	0.99397	0.99482		
	Test	25%	0.99306	0.99501	0.99108	0.99109	0.99415		
	Todos	100%	0.99294	0.9936	0.99339	0.99238	0.99389		

Tabla 8.4 Coeficientes de Correlación de Pearson, RNA diaria "Mayo - Septiembre"

3.2 Coeficientes de Correlación de Pearson, RNA Semanales.

Red 1 "Junio-Agosto"		
Semana 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoideal LM
Semana 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoideal LM
Semana 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal LM
Semana 4	n° neuronas f(x) transferencia f(x) entrenamiento	20 logaritmo sigmoideal LM
Semana 5	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal SCG
Semana 6	n° neuronas f(x) transferencia f(x) entrenamiento	20 purelin LM

Tabla 8.5 Características de RNA calibradas para Red 1 "Junio - Agosto"

Red 1 "Junio-Agosto"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Semana 1	Entrenamiento	50%	0.9697	0.97601	0.9759	0.97546	0.97585	0.9721	0.0029
	Validación	25%	0.9678	0.975	0.97498	0.97284	0.96385		
	Test	25%	0.9640	0.97363	0.96046	0.97374	0.97069		
	Todos	100%	0.9678	0.97514	0.97174	0.97431	0.97155		
Semana 2	Entrenamiento	50%	0.98161	0.98423	0.98577	0.98383	0.98367	0.9808	0.0024
	Validación	25%	0.97512	0.97679	0.98102	0.98081	0.97583		
	Test	25%	0.97125	0.97851	0.98236	0.97875	0.97854		
	Todos	100%	0.97715	0.98104	0.98375	0.98172	0.98053		
Semana 3	Entrenamiento	50%	0.99004	0.99239	0.99171	0.98803	0.99019	0.9865	0.0021
	Validación	25%	0.98261	0.98183	0.98725	0.97735	0.98511		
	Test	25%	0.98296	0.97622	0.98727	0.98166	0.98431		
	Todos	100%	0.98644	0.98584	0.98945	0.98366	0.98731		
Semana 4	Entrenamiento	50%	0.5228	0.5425	0.534	0.5718	0.558	0.5493	0.0092
	Validación	25%	0.537	0.536	0.5129	0.5617	0.5611		
	Test	25%	0.613	0.548	0.5676	0.53838	0.5438		
	Todos	100%	0.551	0.542	0.538	0.56033	0.555		
Semana 5	Entrenamiento	50%	No Converge						
	Validación	25%	No Converge						
	Test	25%	No Converge						
	Todos	100%	No Converge						
Semana 6	Entrenamiento	50%	0.99188	0.98756	0.98989	0.99061	0.97725	0.9840	0.0051
	Validación	25%	0.98592	0.982	0.9818	0.98285	0.97865		
	Test	25%	0.98373	0.98019	0.9803	0.98396	0.9682		
	Todos	100%	0.98833	0.98412	0.9853	0.98696	0.97541		

Tabla 8.6 Coeficientes de Correlación de Pearson, RNA semanal Red 1 "Junio - Agosto"

Red 2 "Mayo - Septiembre"		
Semana 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoidal LM
Semana 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoidal LM
Semana 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoidal LM
Semana 4	n° neuronas f(x) transferencia f(x) entrenamiento	20 logaritmo sigmoidal LM
Semana 5	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoidal SCG
Semana 6	n° neuronas f(x) transferencia f(x) entrenamiento	20 purelin LM

Tabla 8.7 Características de RNA calibradas para Red 2 "Mayo - Septiembre"

Red 2 "Mayo - Septiembre"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Semana 1	Entrenamiento	50%	0.9767	0.9686	0.97463	0.97907	0.97045	0.9721	0.0039
	Validación	25%	0.9761	0.95994	0.97208	0.96734	0.9657		
	Test	25%	0.9754	0.96755	0.9735	0.97097	0.97096		
	Todos	100%	0.9762	0.96625	0.97369	0.97384	0.97034		
Semana 2	Entrenamiento	50%	0.98487	0.98152	0.98587	0.98296	0.98435	0.9817	0.0018
	Validación	25%	0.98068	0.9759	0.98166	0.98078	0.97671		
	Test	25%	0.97693	0.97723	0.98238	0.98168	0.98129		
	Todos	100%	0.98196	0.97894	0.98391	0.98204	0.98174		
Semana 3	Entrenamiento	50%	0.99277	0.99261	0.99133	0.99175	0.99247	0.9888	0.0008
	Validación	25%	0.98735	0.9878	0.98796	0.98666	0.98492		
	Test	25%	0.98671	0.9779	0.98596	0.98368	0.98296		
	Todos	100%	0.98982	0.98779	0.98922	0.98857	0.98845		
Semana 4	Entrenamiento	50%	0.5169	0.5463	0.5425	0.5825	0.5926	0.5516	0.0118
	Validación	25%	0.547	0.555	0.536	0.5177	0.5013		
	Test	25%	0.5689	0.5666	0.548	0.56	0.5614		
	Todos	100%	0.537	0.5537	0.542	0.5628	0.56255		
Semana 5	Entrenamiento	50%	0.9706	0.9811	0.98467	0.9852	0.98522	0.9790	0.0045
	Validación	25%	0.97115	0.9786	0.97908	0.9822	0.97775		
	Test	25%	0.9735	0.9765	0.97887	0.97936	0.97077		
	Todos	100%	0.97148	0.979	0.9818	0.98304	0.9797		
Semana 6	Entrenamiento	50%	0.9872	0.9892	0.99202	0.99198	0.98955	0.9863	0.0023
	Validación	25%	0.9829	0.98081	0.98759	0.98735	0.98394		
	Test	25%	0.97645	0.98284	0.98388	0.98528	0.97978		
	Todos	100%	0.98343	0.98542	0.9881	0.98925	0.98541		

Tabla 8.8 Coeficientes de Correlación de Pearson, RNA semanal Red 2 "Mayo - Septiembre"

Red 3 "Tmax día-1"		
Semana 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoidal LM
Semana 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoidal LM
Semana 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoidal LM
Semana 4	n° neuronas f(x) transferencia f(x) entrenamiento	20 logaritmo sigmoidal LM
Semana 5	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoidal SCG
Semana 6	n° neuronas f(x) transferencia f(x) entrenamiento	20 purelin LM

Tabla 8.9 Características de RNA calibradas para Red 3 "Tmax día - 1"

Red 3 "Tmax día-1"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Semana 1	Entrenamiento	50%	0.9815	0.9824	0.98313	0.98149	0.97787	0.9804	0.0006
	Validación	25%	0.9801	0.9797	0.98029	0.98166	0.98078		
	Test	25%	0.9787	0.98047	0.9765	0.97628	0.98228		
	Todos	100%	0.9803	0.98118	0.98074	0.98022	0.97966		
Semana 2	Entrenamiento	50%	0.9857	0.98411	0.98485	0.98549	0.98235	0.9822	0.0011
	Validación	25%	0.97912	0.98363	0.97816	0.98043	0.97857		
	Test	25%	0.98363	0.97874	0.9778	0.98026	0.98014		
	Todos	100%	0.98362	0.9825	0.98142	0.98282	0.98081		
Semana 3	Entrenamiento	50%	0.98544	0.98575	0.98891	0.98534	0.98925	0.9838	0.0007
	Validación	25%	0.98301	0.97944	0.98045	0.98258	0.98335		
	Test	25%	0.97932	0.98556	0.9764	0.98092	0.97813		
	Todos	100%	0.98324	0.98413	0.9836	0.98341	0.98486		
Semana 4	Entrenamiento	50%	0.57692	0.518	0.534	0.532	0.53668	0.5460	0.0106
	Validación	25%	0.59475	0.57	0.5129	0.5564	0.56755		
	Test	25%	0.47189	0.55	0.5676	0.5221	0.57749		
	Todos	100%	0.55933	0.542	0.538	0.5356	0.5552		
Semana 5	Entrenamiento	50%	No Converge						
	Validación	25%	No Converge						
	Test	25%	No Converge						
	Todos	100%	No Converge						
Semana 6	Entrenamiento	50%	0.98717	0.99103	0.98879	0.98903	0.98684	0.9849	0.0013
	Validación	25%	0.98344	0.98013	0.98621	0.98247	0.97825		
	Test	25%	0.97745	0.98571	0.97763	0.97875	0.98231		
	Todos	100%	0.98392	0.987	0.98522	0.98489	0.98363		

Tabla 8.10 Coeficientes de Correlación de Pearson, RNA semanal Red 3 "Tmax día - 1"

Red 4 "Tmax día"		
Semana 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoideal LM
Semana 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoideal LM
Semana 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal LM
Semana 4	n° neuronas f(x) transferencia f(x) entrenamiento	20 logaritmo sigmoideal LM
Semana 5	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal SCG
Semana 6	n° neuronas f(x) transferencia f(x) entrenamiento	20 purelin LM

Tabla 8.11 Características de RNA calibradas para Red 4 "Tmax día"

Red 4 "Tmax día"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Semana 1	Entrenamiento	50%	0.9824	0.98163	0.98296	0.98436	0.97477	0.9799	0.0034
	Validación	25%	0.9802	0.97685	0.983	0.97964	0.97146		
	Test	25%	0.9808	0.98032	0.98006	0.9787	0.97493		
	Todos	100%	0.9814	0.97999	0.98224	0.98175	0.97399		
Semana 2	Entrenamiento	50%	0.98573	0.98294	0.98632	0.98633	0.9803	0.9829	0.0015
	Validación	25%	0.98113	0.9838	0.97721	0.98351	0.98016		
	Test	25%	0.98047	0.9856	0.98185	0.98063	0.98069		
	Todos	100%	0.98328	0.9838	0.98295	0.98421	0.98032		
Semana 3	Entrenamiento	50%	0.98726	0.98695	0.98781	0.99129	0.98803	0.9859	0.0013
	Validación	25%	0.98469	0.98442	0.98567	0.9845	0.98053		
	Test	25%	0.98509	0.98036	0.98119	0.9853	0.98498		
	Todos	100%	0.98602	0.98469	0.98549	0.98815	0.98529		
Semana 4	Entrenamiento	50%	0.56973	0.54034	0.5425	0.57692	0.53668	0.5573	0.0117
	Validación	25%	0.5734	0.59445	0.536	0.59475	0.56755		
	Test	25%	0.58684	0.54129	0.548	0.47189	0.57749		
	Todos	100%	0.57473	0.55512	0.542	0.55933	0.5552		
Semana 5	Entrenamiento	50%	No Converge						
	Validación	25%	No Converge						
	Test	25%	No Converge						
	Todos	100%	No Converge						
Semana 6	Entrenamiento	50%	0.98893	0.98541	0.98905	0.98595	0.98843	0.9845	0.0012
	Validación	25%	0.98393	0.97843	0.98248	0.98594	0.97915		
	Test	25%	0.98164	0.98152	0.97963	0.97838	0.9862		
	Todos	100%	0.9858	0.98262	0.98484	0.98406	0.98528		

Tabla 8.12 Coeficientes de Correlación de Pearson, RNA semanal Red 4 "Tmax día"

3.3 Coeficientes de Correlación de Pearson, RNA Quincenales.

Red 1 "Junio-Agosto"		
Quincena 1	n° neuronas	5
	f(x) transferencia	tangente sigmoidal
Quincena 2	n° neuronas	10
	f(x) transferencia	tangente sigmoidal
Quincena 3	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
Quincena 4	n° neuronas	20
	f(x) transferencia	logaritmo sigmoidal
Quincena 5	n° neuronas	20
	f(x) transferencia	tangente sigmoidal
Quincena 6	n° neuronas	20
	f(x) transferencia	purelin
	f(x) entrenamiento	LM

Tabla 8.13 Características de RNA calibradas para Red 1 "Junio - Agosto"

Red 1 "Junio-Agosto"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Quincena 1	Entrenamiento	50%	0.9830	0.98085	0.98369	0.98048	0.98043	0.9811	0.0016
	Validación	25%	0.9803	0.97829	0.9821	0.98117	0.97896		
	Test	25%	0.9816	0.97995	0.98449	0.97868	0.97897		
	Todos	100%	0.9820	0.98004	0.98352	0.98024	0.97967		
Quincena 2	Entrenamiento	50%	0.9863	0.98908	0.99031	0.98894	0.99114	0.9875	0.0022
	Validación	25%	0.9835	0.98637	0.98846	0.98701	0.98883		
	Test	25%	0.9800	0.98262	0.98615	0.98595	0.98862		
	Todos	100%	0.9840	0.98695	0.98874	0.98766	0.98992		
Quincena 3	Entrenamiento	50%	0.99635	0.99725	0.99612	0.99613	0.99611	0.9952	0.0007
	Validación	25%	0.99594	0.99576	0.99245	0.99477	0.99396		
	Test	25%	0.99382	0.99359	0.9918	0.99469	0.99296		
	Todos	100%	0.995615	0.99598	0.99412	0.99542	0.99485		
Quincena 4	Entrenamiento	50%	0.58466	0.56398	0.607	0.59417	0.532	0.5737	0.0269
	Validación	25%	0.58859	0.5858	0.598	0.53417	0.5564		
	Test	25%	0.59346	0.51164	0.596	0.6123	0.5221		
	Todos	100%	0.58738	0.55701	0.602	0.5866	0.5356		
Quincena 5	Entrenamiento	50%	0.98717	0.98875	0.99044	0.9908	0.99021	0.9887	0.0017
	Validación	25%	0.98496	0.98779	0.98863	0.98969	0.98894		
	Test	25%	0.98613	0.98631	0.98719	0.99104	0.98947		
	Todos	100%	0.98636	0.98787	0.98919	0.99057	0.98972		
Quincena 6	Entrenamiento	88%	0.99632	0.99654	0.99677	0.99603	0.99694	0.9953	0.0005
	Validación	103%	0.99407	0.99431	0.99464	0.99306	0.99562		
	Test	118%	0.99237	0.99343	0.9941	0.99395	0.99448		
	Todos	133%	0.99475	0.9952	0.99557	0.99477	0.99604		

Tabla 8.14 Coeficientes de Correlación de Pearson, RNA quincenal Red 1 "junio - Agosto"

Red 2 "Mayo - Septiembre"		
Quincena 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoideal LM
Quincena 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoideal LM
Quincena 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal LM
Quincena 4	n° neuronas f(x) transferencia f(x) entrenamiento	20 logaritmo sigmoideal LM
Quincena 5	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal SCG
Quincena 6	n° neuronas f(x) transferencia f(x) entrenamiento	20 purelin LM

Tabla 8.15 Características de RNA calibradas para Red 2 "Mayo - Septiembre"

Red 2 "Mayo - Septiembre"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Des. Est.
Quincena 1	Entrenamiento	50%	0.9724	0.98229	0.9791	0.97875	0.98022	0.9771	0.0034
	Validación	25%	0.9694	0.9797	0.9758	0.98099	0.97534		
	Test	25%	0.9724	0.97912	0.97355	0.97654	0.97386		
	Todos	100%	0.9716	0.9808	0.97684	0.97877	0.9773		
Quincena 2	Entrenamiento	50%	0.9915	0.99169	0.98356	0.9909	0.98972	0.9879	0.0033
	Validación	25%	0.9884	0.98794	0.98079	0.98896	0.98743		
	Test	25%	0.9888	0.98631	0.98053	0.98615	0.98869		
	Todos	100%	0.9901	0.98936	0.9821	0.98921	0.98883		
Quincena 3	Entrenamiento	50%	0.99615	0.99702	0.99686	0.99701	0.99685	0.9956	0.0008
	Validación	25%	0.99244	0.99509	0.99533	0.99471	0.99493		
	Test	25%	0.992	0.99606	0.99457	0.99519	0.99299		
	Todos	100%	0.9942	0.99633	0.99596	0.99598	0.99542		
Quincena 4	Entrenamiento	50%	0.5867	0.532	0.5347	0.5916	0.5718	0.5564	0.0118
	Validación	25%	0.5719	0.5564	0.5897	0.5537	0.5617		
	Test	25%	0.5	0.5221	0.5703	0.5137	0.53838		
	Todos	100%	0.5632	0.5356	0.559	0.564	0.56033		
Quincena 5	Entrenamiento	50%	0.9863	0.98354	0.9873	0.9823	0.9887	0.9848	0.0026
	Validación	25%	0.986	0.9826	0.9857	0.981	0.988		
	Test	25%	0.98423	0.9832	0.9863	0.789	0.9836		
	Todos	100%	0.9857	0.9832	0.98667	0.9811	0.9873		
Quincena 6	Entrenamiento	88%	0.99484	0.99704	0.9961	0.99495	0.99692	0.9948	0.0013
	Validación	103%	0.99293	0.99513	0.99273	0.99157	0.99558		
	Test	118%	0.99346	0.99441	0.99336	0.99108	0.99533		
	Todos	133%	0.99403	0.99588	0.99464	0.99306	0.99618		

Tabla 8.16 Coeficientes de Correlación de Pearson, RNA quincenal Red 2 "Mayo - Septiembre"

Red 3 "Tmax día-1"		
Quincena 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoideal LM
Quincena 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoideal LM
Quincena 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal LM
Quincena 4	n° neuronas f(x) transferencia f(x) entrenamiento	20 logaritmo sigmoideal LM
Quincena 5	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoideal SCG
Quincena 6	n° neuronas f(x) transferencia f(x) entrenamiento	20 purelin LM

Tabla 8.17 Características de RNA calibradas para Red 3 "Tmax día -1"

Red 3 "Tmax día-1"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Quincena 1	Entrenamiento	50%	0.9774	0.97679	0.98154	0.97968	0.98268	0.9780	0.0024
	Validación	25%	0.9829	0.96961	0.97944	0.98091	0.97567		
	Test	25%	0.9761	0.97232	0.97181	0.97478	0.97891		
	Todos	100%	0.9785	0.97381	0.97872	0.97866	0.98009		
Quincena 2	Entrenamiento	50%	0.98717	0.98614	0.98601	0.98814	0.98388	0.9852	0.0012
	Validación	25%	0.9857	0.98567	0.98438	0.98636	0.98371		
	Test	25%	0.98213	0.98481	0.98383	0.98338	0.98202		
	Todos	100%	0.98557	0.98569	0.98505	0.98652	0.98339		
Quincena 3	Entrenamiento	50%	0.9927	0.99147	0.98991	0.99194	0.99163	0.9893	0.0006
	Validación	25%	0.98838	0.98727	0.98548	0.98712	0.98665		
	Test	25%	0.98502	0.98737	0.9873	0.98735	0.9889		
	Todos	100%	0.98974	0.98931	0.9882	0.98965	0.98963		
Quincena 4	Entrenamiento	50%	0.515	0.5716	0.5484	0.534	0.5428	0.5456	0.0137
	Validación	25%	0.578	0.562	0.5154	0.5894	0.5365		
	Test	25%	0.552	0.5388	0.496	0.5724	0.5489		
	Todos	100%	0.54	0.561	0.527	0.557	0.543		
Quincena 5	Entrenamiento	50%	No Converge						
	Validación	25%							
	Test	25%							
	Todos	100%							
Quincena 6	Entrenamiento	88%	0.98966	0.99099	0.99072	0.98954	0.99023	0.9878	0.0005
	Validación	103%	0.98724	0.98472	0.98369	0.98662	0.98546		
	Test	118%	0.9842	0.98668	0.98245	0.98632	0.98629		
	Todos	133%	0.98768	0.98834	0.98702	0.98802	0.98795		

Tabla 8.18 Coeficientes de Correlación de Pearson, RNA quincenal Red 3 "Tmax día -1"

Red 4 "Tmax día"		
Quincena 1	n° neuronas f(x) transferencia f(x) entrenamiento	5 tangente sigmoidal LM
Quincena 2	n° neuronas f(x) transferencia f(x) entrenamiento	10 tangente sigmoidal LM
Quincena 3	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoidal LM
Quincena 4	n° neuronas f(x) transferencia f(x) entrenamiento	20 logaritmo sigmoidal LM
Quincena 5	n° neuronas f(x) transferencia f(x) entrenamiento	20 tangente sigmoidal SCG
Quincena 6	n° neuronas f(x) transferencia f(x) entrenamiento	20 purelin LM

Tabla 8.19 Características de RNA calibradas para Red 4 "Tmax día"

Red 4 "Tmax día"			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Quincena 1	Entrenamiento	50%	0.9791	0.9812	0.98237	0.98405	0.98038	0.9797	0.0010
	Validación	25%	0.9778	0.98203	0.97619	0.97832	0.97803		
	Test	25%	0.9771	0.9739	0.97942	0.97631	0.97949		
	Todos	100%	0.9783	0.97966	0.98027	0.98084	0.97953		
Quincena 2	Entrenamiento	50%	0.98506	0.9856	0.9842	0.98684	0.98726	0.9839	0.0007
	Validación	25%	0.98235	0.98181	0.984	0.98281	0.98047		
	Test	25%	0.97968	0.98214	0.98173	0.98035	0.98479		
	Todos	100%	0.983	0.98364	0.98355	0.9842	0.98496		
Quincena 3	Entrenamiento	50%	0.99204	0.99188	0.99102	0.99132	0.99272	0.9895	0.0010
	Validación	25%	0.98573	0.98863	0.98661	0.98467	0.9876		
	Test	25%	0.98833	0.98939	0.98656	0.98545	0.9894		
	Todos	100%	0.98955	0.99048	0.98891	0.9882	0.99046		
Quincena 4	Entrenamiento	50%	0.595	0.532	0.5228	0.502	0.62112	0.5569	0.0311
	Validación	25%	0.587	0.5564	0.537	0.518	0.5759		
	Test	25%	0.547	0.5221	0.613	0.559	0.559		
	Todos	100%	0.581	0.5356	0.551	0.521	0.59588		
Quincena 5	Entrenamiento	50%	No Converge						
	Validación	25%							
	Test	25%							
	Todos	100%							
Quincena 6	Entrenamiento	88%	0.99031	0.99171	0.99032	0.99112	0.99094	0.9886	0.0007
	Validación	103%	0.98589	0.9876	0.98645	0.9822	0.98713		
	Test	118%	0.9885	0.98628	0.984	0.98693	0.98763		
	Todos	133%	0.98868	0.98948	0.98771	0.98799	0.98914		

Tabla 8.20 Coeficientes de Correlación de Pearson, RNA quincenal Red 4 "Tmax día"

Anexo 4. “Coeficientes de Correlación de Pearson, RNA para Valle Nevado”

4.1 Coeficientes de Correlación de Pearson, RNA Diarias.

Variables Significativas Días			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Q t-1 Tmax	Entrenamiento	70%	0,9670	0,96985	0,96808	0,96685	0,96887	0,9694	0,0003
	Validación	15%	0,9770	0,9555	0,9809	0,96425	0,97218		
	Test	15%	0,9767	0,97539	0,97305	0,984	0,97165		
	Todos	100%	0,9695	0,96918	0,96907	0,96926	0,96994		
Q t-1 Tmin	Entrenamiento	70%	0,9665	0,96792	0,96873	0,96385	0,96596	0,9685	0,0008
	Validación	15%	0,9576	0,96467	0,96318	0,97957	0,98499		
	Test	15%	0,9874	0,97829	0,98042	0,9872	0,96266		
	Todos	100%	0,9687	0,96848	0,96712	0,96925	0,96874		
Q t-1 Tmed	Entrenamiento	70%	0,96978	0,96655	0,97142	0,97232	0,96873	0,9691	0,0003
	Validación	15%	0,97108	0,9825	0,9445	0,94018	0,97457		
	Test	15%	0,9642	0,97774	0,98155	0,97988	0,97284		
	Todos	100%	0,9693	0,96928	0,96909	0,96942	0,96865		
Q t-1 Pp	Entrenamiento	70%	0,97109	0,96904	0,96524	0,96999	0,97061	0,9685	0,0007
	Validación	15%	0,95567	0,98176	0,96023	0,95817	0,98137		
	Test	15%	0,97425	0,95355	0,98312	0,97822	0,95837		
	Todos	100%	0,96777	0,96926	0,96770	0,96883	0,96912		
Q t-1 Qant	Entrenamiento	70%	0,9698	0,97474	0,96362	0,97086	0,97575	0,9689	0,0009
	Validación	15%	0,9755	0,96661	0,98621	0,96227	0,96181		
	Test	15%	0,9588	0,95631	0,98126	0,9716	0,93717		
	Todos	100%	0,9694	0,96903	0,96975	0,969	0,96745		
Q t-1 H.R.	Entrenamiento	70%	0,9724	0,97804	0,97939	0,96902	0,97129	0,9715	0,0002
	Validación	15%	0,9775	0,96429	0,96071	0,97592	0,97491		
	Test	15%	0,9628	0,96047	0,94402	0,9782	0,97274		
	Todos	100%	0,9715	0,97164	0,97152	0,97124	0,97175		
Q t-1 Vviento	Entrenamiento	70%	0,97489	0,96855	0,97095	0,96692	0,96941	0,9685	0,0004
	Validación	15%	0,95053	0,9675	0,97096	0,96631	0,93832		
	Test	15%	0,9594	0,96982	0,96262	0,98142	0,98121		
	Todos	100%	0,96795	0,96851	0,96891	0,96865	0,9684		
Q t-1	Entrenamiento	70%	0,97116	0,96324	0,96921	0,97102	0,96787	0,9683	0,0002
	Validación	15%	0,96234	0,98897	0,97094	0,95696	0,95875		
	Test	15%	0,9547	0,97296	0,97141	0,97696	0,98778		
	Todos	100%	0,96829	0,96826	0,96869	0,96801	0,96839		

Tabla 8.21 Coeficientes de Correlación de Pearson para Variables significativas, RNA Diarias

Valle Nevado y Mapocho Escala Diaria			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Valle Nevado 1	Entrenamiento	70%	0.9740	0.96857	0.98286	0.96939	0.97611	0.9730	0.0043
	Validación	15%	0.9496	0.97489	0.97254	0.97839	0.98833		
	Test	15%	0.9652	0.95806	0.96168	0.96962	0.97604		
	Todos	100%	0.9710	0.96791	0.97682	0.97117	0.97809		
Valle Nevado 2	Entrenamiento	70%	0.9848	0.97716	0.97992	0.98861	0.98323	0.9818	0.0032
	Validación	15%	0.9742	0.98304	0.99403	0.96701	0.97181		
	Test	15%	0.9657	0.97033	0.99064	0.97122	0.98748		
	Todos	100%	0.9816	0.97632	0.98368	0.9842	0.98293		
Valle Nevado 3	Entrenamiento	70%	0.98376	0.98348	0.98487	0.98361	0.98162	0.9832	0.0014
	Validación	15%	0.98723	0.98563	0.97796	0.99077	0.99326		
	Test	15%	0.98102	0.98895	0.97178	0.97682	0.981		
	Todos	100%	0.9836	0.98459	0.98094	0.98326	0.98359		
Mapocho Almendros	Entrenamiento	70%	0.99003	0.9856	0.98118	0.97895	0.98265	0.9820	0.0014
	Validación	15%	0.97232	0.98239	0.98528	0.99118	0.9706		
	Test	15%	0.96374	0.96499	0.9799	0.97831	0.98879		
	Todos	100%	0.98432	0.98142	0.98132	0.98068	0.98205		

Tabla 8.22 Coeficientes de Correlación de Pearson, RNA diarias

4.2 Coeficientes de Correlación de Pearson, RNA Semanales.

Variables Significativas Semana			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Q t-1	Entrenamiento	70%	0.9058	0.90908	0.88632	0.89178	0.89431	0.8964	0.0001
	Validación	15%	0.9050	0.85863	0.92399	0.95826	0.92597		
	Test	15%	0.8728	0.90207	0.91405	0.89173	0.90901		
	Todos	100%	0.8962	0.89642	0.89647	0.89649	0.89633		
Q día -1	Entrenamiento	70%	0.9126	0.92003	0.92476	0.89988	0.91509	0.9217	0.0063
	Validación	15%	0.9541	0.94773	0.88751	0.9431	0.9213		
	Test	15%	0.9452	0.92325	0.95538	0.95556	0.95114		
	Todos	100%	0.9248	0.92454	0.92392	0.91052	0.9248		
Q día -1 Tmax t-1	Entrenamiento	70%	0.96045	0.94906	0.94932	0.95247	0.94976	0.9498	0.0002
	Validación	15%	0.90736	0.95625	0.95285	0.93814	0.95911		
	Test	15%	0.95437	0.95473	0.95403	0.96041	0.94903		
	Todos	100%	0.94909	0.94959	0.95002	0.94987	0.94991		
Q día -1 Tmax día-1	Entrenamiento	70%	0.93298	0.93244	0.93021	0.9354	0.93407	0.9314	0.0008
	Validación	15%	0.95761	0.92739	0.94792	0.94521	0.94051		
	Test	15%	0.90048	0.92333	0.94311	0.9085	0.91561		
	Todos	100%	0.93153	0.93015	0.93234	0.93183	0.93117		
Q día -1 Tmax día	Entrenamiento	70%	0.92865	0.92308	0.92965	0.93751	0.93421	0.9271	0.0004
	Validación	15%	0.93542	0.93636	0.896005	0.95112	0.94447		
	Test	15%	0.9353	0.93747	0.94015	0.86482	0.86143		
	Todos	100%	0.92734	0.92723	0.92747	0.92724	0.92636		
Q día-1 Qant	Entrenamiento	70%	0.9601	0.96013	0.96452	0.96097	0.95986	0.9599	0.0007
	Validación	15%	0.9598	0.95969	0.94756	0.96115	0.97275		
	Test	15%	0.9687	0.96377	0.95827	0.95508	0.95764		
	Todos	100%	0.9601	0.96035	0.95977	0.95882	0.96053		
Q día-1 Pp t-1	Entrenamiento	70%	0.9127	0.91863	0.92316	0.9347	0.9155	0.9242	0.0019
	Validación	15%	0.9398	0.96492	0.9276	0.87742	0.94405		
	Test	15%	0.9591	0.89462	0.93337	0.91953	0.94644		
	Todos	100%	0.9242	0.92143	0.9243	0.9268	0.92409		
Q día-1 Pp día-1	Entrenamiento	70%	0.91978	0.91006	0.9255	0.92725	0.92352	0.9238	0.0008
	Validación	15%	0.97194	0.97036	0.93682	0.93374	0.94335		
	Test	15%	0.9019	0.94923	0.92223	0.90377	0.91355		
	Todos	100%	0.92366	0.92507	0.92387	0.92282	0.92366		
Q día-1 H.R. t-1	Entrenamiento	70%	0.9293	0.93307	0.91309	0.92586	0.92998	0.9236	0.0007
	Validación	15%	0.9049	0.92962	0.94141	0.94122	0.89399		
	Test	15%	0.9118	0.86487	0.95803	0.91943	0.92826		
	Todos	100%	0.9230	0.92284	0.92451	0.92392	0.92358		
Q día-1 H.R. día-1	Entrenamiento	70%	0.91619	0.91252	0.92675	0.9288	0.92254	0.9196	0.0020
	Validación	15%	0.94569	0.92284	0.83698	0.92564	0.91329		
	Test	15%	0.9418	0.931	0.94519	0.86799	0.92323		
	Todos	100%	0.92032	0.91602	0.92026	0.92087	0.92076		

Tabla 8.23 Coeficientes de Correlación de Pearson para Variables significativas, RNA Semanales

Valle Nevado y Mapocho Escala Semanal			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Valle Nevado 1	Entrenamiento	70%	0,9464	0,95772	0,95852	0,96597	0,96779	0,9589	0,0066
	Validación	15%	0,9487	0,95737	0,96235	0,97516	0,9544		
	Test	15%	0,9561	0,97631	0,97719	0,96427	0,91402		
	Todos	100%	0,9481	0,96071	0,96106	0,96617	0,95853		
Valle Nevado 2	Entrenamiento	70%	0,9607	0,97438	0,96227	0,97673	0,978	0,9669	0,0105
	Validación	15%	0,9429	0,973321	0,92844	0,97033	0,97295		
	Test	15%	0,9428	0,97581	0,95879	0,98237	0,9463		
	Todos	100%	0,9554	0,97406	0,95561	0,97632	0,9732		
Valle Nevado 3	Entrenamiento	70%	0,9636	0,97058	0,96858	0,96317	0,96313	0,9659	0,0040
	Validación	15%	0,9569	0,97403	0,97421	0,98536	0,95969		
	Test	15%	0,97232	0,95805	0,97928	0,95995	0,95026		
	Todos	100%	0,96392	0,96821	0,97094	0,96619	0,96048		
Mapocho Almendros	Entrenamiento	70%	0,96627	0,96824	0,97168	0,96646	0,96912	0,9626	0,0018
	Validación	15%	0,97807	0,9583	0,91532	0,97555	0,92678		
	Test	15%	0,9508	0,95457	0,9602	0,95201	0,96537		
	Todos	100%	0,96294	0,96249	0,96080	0,96556	0,96139		

Tabla 8.24 Coeficientes de Correlación de Pearson, RNA semanales

4.3 Coeficientes de Correlación de Pearson, RNA Quincenales.

Variables Significativas Quincena			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Q t-1	Entrenamiento	70%	0,9825	0,98155	0,98037	0,9832	0,98196	0,9829	0,0001
	Validación	15%	0,9882	0,98802	0,98679	0,98667	0,98338		
	Test	15%	0,9793	0,9804	0,99304	0,98636	0,98639		
	Todos	100%	0,9828	0,98298	0,98307	0,98287	0,98298		
Q día -1	Entrenamiento	70%	0,8459	0,87393	0,87544	0,8983	0,88499	0,8676	0,0055
	Validación	15%	0,9222	0,95328	0,84434	0,68834	0,82951		
	Test	15%	0,9278	0,74418	0,85499	0,92247	0,87076		
	Todos	100%	0,8702	0,85783	0,87006	0,86977	0,87016		
Q t-1 Tmax t-1	Entrenamiento	70%	0,9154	0,94635	0,95877	0,9501	0,95045	0,9431	0,0115
	Validación	15%	0,94494	0,96406	0,93433	0,95146	0,95597		
	Test	15%	0,93043	0,95551	0,90652	0,94089	0,93918		
	Todos	100%	0,92268	0,94893	0,94844	0,94693	0,94866		
Q t-1 Tmax día-1	Entrenamiento	70%	0,88731	0,88347	0,8884	0,88455	0,89124	0,8875	0,0009
	Validación	15%	0,92581	0,94403	0,83578	0,94606	0,88626		
	Test	15%	0,82615	0,85827	0,88398	0,8777	0,87887		
	Todos	100%	0,8878	0,88801	0,88581	0,8881	0,88767		
Q t-1 Tmax día	Entrenamiento	70%	0,8941	0,89426	0,88976	0,8873	0,86969	0,8812	0,0005
	Validación	15%	0,79981	0,85727	0,88598	0,85708	0,9059		
	Test	15%	0,91021	0,84708	0,8388	0,90389	0,93093		
	Todos	100%	0,88124	0,88126	0,88179	0,88125	0,88047		
Q t-1 Qant	Entrenamiento	70%	0,9864	0,98523	0,98735	0,98738	0,98742	0,9863	0,0002
	Validación	15%	0,9828	0,98634	0,98172	0,98307	0,98365		
	Test	15%	0,9895	0,99224	0,98363	0,98803	0,98756		
	Todos	100%	0,9863	0,98654	0,98595	0,98633	0,98619		
Q t-1 Pp t-1	Entrenamiento	70%	0,9220	0,87547	0,88368	0,8991	0,90149	0,8990	0,0006
	Validación	15%	0,7219	0,9657	0,96449	0,91335	0,88378		
	Test	15%	0,9564	0,9427	0,87889	0,86985	0,95608		
	Todos	100%	0,8980	0,89887	0,89928	0,8993	0,89942		
Q t-1 Pp día-1	Entrenamiento	70%	0,83636	0,81083	0,86788	0,82928	0,82564	0,8259	0,0031
	Validación	15%	0,78043	0,83768	0,84484	0,75681	0,74453		
	Test	15%	0,84043	0,889	0,63344	0,8959	0,9093		
	Todos	100%	0,82739	0,82854	0,82061	0,82622	0,82685		
Q t-1 H.R. t-1	Entrenamiento	70%	0,8539	0,79918	0,85761	0,84617	0,83282	0,8213	0,0017
	Validación	15%	0,7050	0,87415	0,72989	0,85876	0,87838		
	Test	15%	0,7673	0,87455	0,75227	0,67118	0,72152		
	Todos	100%	0,8223	0,81921	0,8201	0,82346	0,82145		
Q t-1 H.R. día-1	Entrenamiento	70%	0,82645	0,8242	0,87321	0,78217	0,81879	0,8159	0,0024
	Validación	15%	0,76976	0,71254	0,79021	0,86395	0,8069		
	Test	15%	0,80113	0,86889	0,60208	0,94945	0,87038		
	Todos	100%	0,81842	0,81334	0,81376	0,81816	0,81561		

Tabla 8.25 Coeficientes de Correlación de Pearson para Variables significativas, RNA Quincenales

Valle Nevado y Mapocho Escala Quincenal			Calib. 1	Calib. 2	Calib. 3	Calib. 4	Calib. 5	Promedio	Desv. Est.
Valle Nevado 1	Entrenamiento	70%	0,9737	0,98497	0,97844	0,98361	0,98708	0,9790	0,0061
	Validación	15%	0,9514	0,98282	0,97735	0,94952	0,97106		
	Test	15%	0,9624	0,98357	0,97855	0,96901	0,98414		
	Todos	100%	0,9702	0,98454	0,97819	0,97717	0,98517		
Valle Nevado 2	Entrenamiento	70%	0,9936	0,9925	0,99417	0,99429	0,99395	0,9936	0,0008
	Validación	15%	0,9950	0,99171	0,99462	0,99538	0,99108		
	Test	15%	0,9959	0,99225	0,9918	0,99465	0,99328		
	Todos	100%	0,9940	0,99223	0,99378	0,99436	0,9934		
Valle Nevado 3	Entrenamiento	70%	0,98942	0,99225	0,99307	0,99174	0,9929	0,9917	0,0011
	Validación	15%	0,98735	0,99677	0,99044	0,99776	0,98751		
	Test	15%	0,99379	0,98874	0,99466	0,99235	0,99031		
	Todos	100%	0,99003	0,99185	0,99281	0,9925	0,99113		
Mapocho Almendros	Entrenamiento	70%	0,99682	0,99641	0,99648	0,99603	0,9937	0,9954	0,0008
	Validación	15%	0,99289	0,99508	0,99586	0,99742	0,99655		
	Test	15%	0,99614	0,99281	0,99351	0,98968	0,99677		
	Todos	100%	0,99624	0,99567	0,99599	0,99467	0,99447		

Tabla 8.26 Coeficientes de Correlación de Pearson, RNA quincenales