

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXII CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

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

MONTSERRAT ARTIGAS M.¹
XIMENA VARGAS M.²

RESUMEN

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, resulta de gran interés e importancia para la gestión y aprovechamiento del recurso hídrico.

Este trabajo expone la construcción de redes neuronales artificiales (RNA) para el pronóstico de caudales de deshielo, a escalas temporales diaria, semanal y quincenal. Para lo cual se utilizaron datos de caudal, temperaturas extremas y precipitación, provenientes de la estación Mapocho en Los Almendros; y datos de humedad relativa, velocidad del viento, temperatura y precipitación, provenientes de la estación Valle Nevado.

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 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. Respecto a los datos de entrada para las RNA, se concluye que aquellos más significativos, son los relacionados al caudal y la temperatura máxima y que la humedad relativa es un dato significativo para el pronóstico de caudales de deshielo.

¹Ingeniera Civil, Universidad de Chile – montse.artigas31@gmail.com

²Profesor Asociado, Departamento de Ingeniería Civil, Universidad de Chile. – xvargas@ing.uchile.cl

1. INTRODUCCIÓN

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.

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. 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 pueden 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).

El objetivo principal de la presente investigación 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 Valle Nevado, en los pronósticos.

2. ZONA EN ESTUDIO Y DATOS UTILIZADOS

La zona en estudio corresponde a la cuenca “Mapocho en los Almendros” ubicada en la Región Metropolitana, Chile. Un esquema general de la cuenca se muestra en la **¡Error! No se encuentra el origen de la referencia.** La cuenca Mapocho en Los Almendros 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 Molina y San Francisco.

Cuenca Mapocho en Los Almendros, Región Metropolitana, Chile.

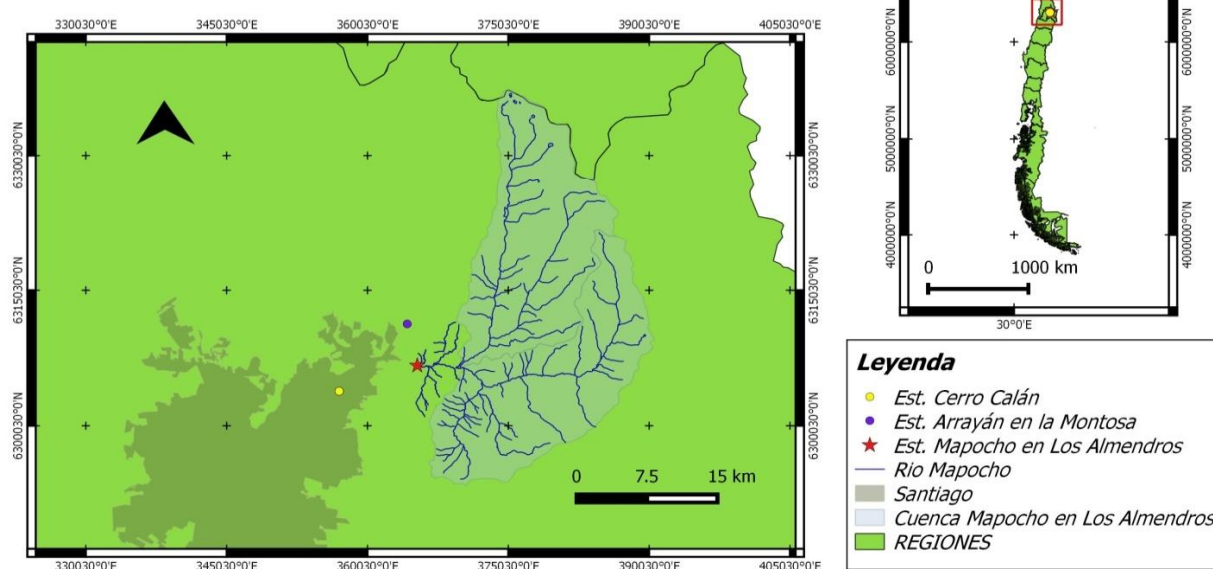


Figura 1 Cuenca Mapocho en Los Almendros, estaciones fluviométricas “Mapocho en Los Almendros”, “Estero Arrayán en la Montosa” y estaciones meteorológicas “Mapocho en Los Almendros”, “Cerro Calán”.

La 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.

Tabla 1.- Estaciones Utilizadas y sus características.

	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

Finalmente, la estación Valle Nevado pertenece al Departamento de Ingeniería Civil, División Recursos Hídricos y Medio Ambiente, Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile. 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.

3. REDES NEURONALES ARTIFICIALES

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. La capa de entrada recibe la información desde el exterior, las capas ocultas procesan y transmiten la información y finalmente la capa de salida genera las salidas del modelo. (Figura 2).

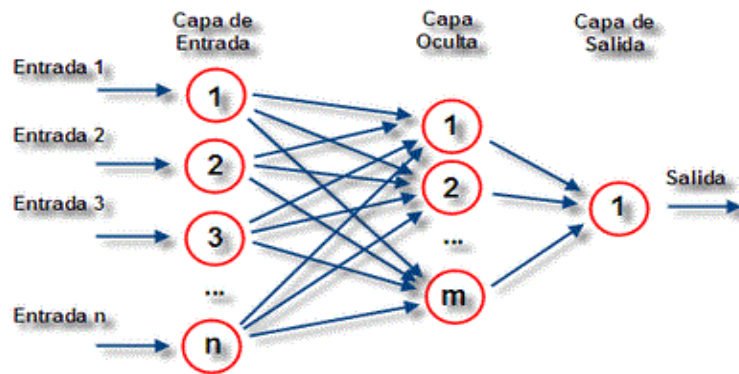


Figura 2 Red multicapa con "n" neuronas de entrada y "m" neuronas en su capa oculta.
Fuente: <https://rneuronales.wordpress.com>

Las capas ocultas y la capa de salida se componen de neuronas, las cuales son la unidad básica de una RNA, y donde se llevan a cabo las funciones de red y de activación. En la Figura 3 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.

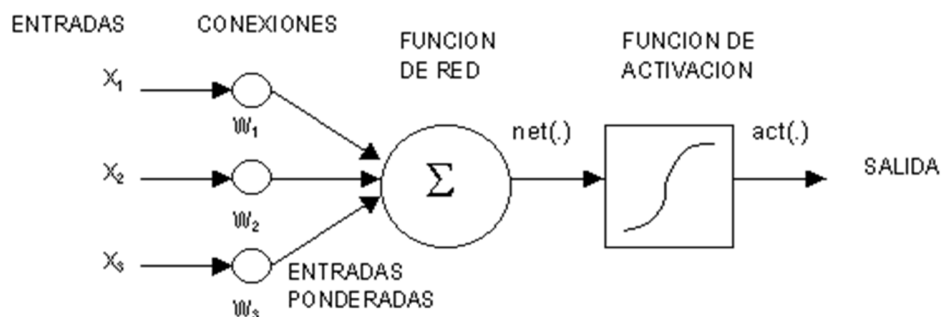


Figura 3 Estructura de una neurona.
Fuente: http://magomar.webs.upv.es/rna/tutorial/RNA_marcos.html.

La función de red, 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

W_{ij} = peso entre la neurona i de la capa de entrada y la neurona 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

Los principales tipos de funciones de activación o funciones de transferencia, son las funciones de transferencia Lineal, Escalón y Sigmoide; 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)

El error cometido por la red, corresponde a la diferencia entre las salidas observadas y simuladas, luego, el entrenamiento de una RNA consiste en modificar los pesos de ésta iterativamente, de manera tal de minimizar el error generado por la red. De éste modo, el entrenamiento corresponde a un problema de optimización, donde se minimiza una función objetivo, la cual corresponde al error cuadrático medio usualmente (ECM). En la ecuación (2) se observa el error generado por la red o ECM.

$$E_p = \frac{1}{n} \sum_{a=1}^n (S_{obs} - S_{sim})^2 \quad (2)$$

donde:

E_p = error generado por la red, calculado como el ECM.

S_{obs} = salida Observada

S_{sim} = salida Simulada

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

Específicamente en el algoritmo de retropropagación, la modificación de los pesos se realiza según las ecuaciones (3) y (4).

$$w(k+1) = w(k) + \alpha_k * D_k \quad (3)$$

donde:

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

α_k = tasa de aprendizaje

D_k = dirección de descenso en la iteración k

La dirección de descenso corresponde al gradiente negativo del error cometido por la red o “ E_p ” con respecto a los pesos.

$$-\nabla E_p = \frac{\partial E_p}{\partial w_{ij}} \quad (4)$$

Existen numerosas variaciones al algoritmo de retropropagación, en las cuales se modifica la búsqueda de la dirección de descenso. Entre éstas destacan, debido a su eficiencia, el método del gradiente conjugado y el método de Levenberg Marquardt. El método del gradiente conjugado determina la dirección de descenso en la iteración “k” utilizando la dirección de descenso en la iteración anterior; Mientras que el método de Levenberg Marquardt utiliza la segunda derivada, aproximando la matriz Hessiana según la ecuación (5). De éste modo se obtiene una convergencia más rápida sin gran requerimiento computacional.

$$H = J^T * J \quad (5)$$

donde:

J^T = matriz Jacobiana traspuesta

H = aproximación de la matriz Hessiana

4. RESULTADOS RNA MAPOCHO EN LOS ALMENDROS

Metodología

Se entrenan diferentes redes en las cuales se varían los parámetros de entrada y la estructura de la red, de manera tal de determinar la red óptima, formada tanto por los datos de entrada como la estructura óptimos. Los datos de entrada utilizados en las distintas redes se muestran en la *Tabla 2*, se observa que los primeros cuatro parámetros, “Qinv”, “Tmax inv.”, “Tmin inv.” y “Pp inv.” tienen dos variantes, en la primera se considera el período invernal de Junio a Agosto y en la segunda de Mayo a Septiembre.

Tabla 2. Datos de entrada.

<i>Parámetro</i>	<i>Descripción</i>	<i>Unidades</i>
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, semana o quincena anterior	[m3/s]
Tmax t-1	Temperatura máxima del día semana o quincena anterior	[°C]
Tmin t-1	Temperatura mínima del día, semana o quincena anterior	[°C]
Pp t-1	Precipitación acumulada en el día, semana o quincena 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]

Se entrenan 4 redes en las cuales se varían los parámetros de entrada (Tabla 3), a su vez, cada una de estas 4 redes se entrena seis veces, en las cuales se varía la estructura de la red. Las figuras 4 a 6 muestran esquemáticamente la metodología implementada.




Figura 4. Metodología general, donde cada una de las 4 redes, Red 1 a Red 4, es entrenada 6 veces.

Las redes 1 y 2 permiten determinar si es óptimo considerar el período pluvial de Junio a Agosto ó de Mayo a Septiembre, mientras que las redes 3 y 4 permiten determinar si es mejor utilizar la temperatura máxima del día anterior “Tmax día-1”, o la temperatura máxima del mismo día “Tmax t” (Figura 5).

Tabla 3. Parámetros de Entrada de las Redes 1 a 4.

	Parámetros de Entrada									
Red 1	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1	Qinv 1	Pp inv. 1	Tmax inv. 1	Tmin inv. 1	
Red 2	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1	Qinv 2	Pp inv. 2	Tmax inv. 2	Tmin inv. 2	
Red 3	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1	Qdía-1	Pp inv.	Tmax día-1		
Red 4	Suma Qant	Q t-1	Tmax t-1	Tmin t-1	Pp t-1	Qdía-1	Pp inv.	Tmax t		




Figura 5. Selección de los parámetros de entrada óptimos.

En cuanto a la estructura de la red, las redes 1, 2 y 3 permiten determinar el número óptimo de neuronas en la capa oculta, entre 5, 10 o 20. Las redes 4 y 6 determinan la función de transferencia óptima, entre tangente sigmoideal, logaritmo sigmoideal, y lineal. Por último, la red 5 determina la función de entrenamiento óptima, entre el método de Levenberg Marquardt y el método del Gradiente Conjugado. (Figura 6)

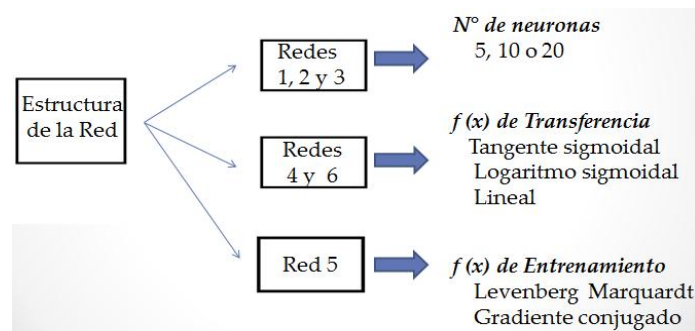


Figura 6. Selección de la estructura óptima de la red.

Redes Neuronales Artificiales Óptimas

Para la escala temporal diaria se obtuvo que la red óptima es la Red 2, con un coeficiente de correlación de Pearson de 0,994. La *Tabla 4* muestra la estructura de la red.

Tabla 4. RNA óptima, escala diaria

Red 2 "Mayo – Septiembre"	
nº neuronas	10
f(x) transferencia	Tangente sigmooidal
f(x) entrenamiento	LM
R^2	0,99409

Para la escala temporal semanal se obtuvo que las redes óptimas son la Red 2 y Red 4, con coeficientes de correlación de Pearson de 0,9898 y 0,9882 respectivamente. Las *Tablas 5 y 6* muestran las características de las redes respectivamente.

Tabla 5. RNA óptima, escala semanal, Red 2

Red 2 "Mayo - Septiembre"	
nº neuronas	20
f(x) transferencia	Tangente sigmooidal
f(x) entrenamiento	LM
R^2	0,9898

Tabla 6. RNA óptima, escala semanal, Red 4.

Red 4 "Tmax día"	
nº neuronas	20
f(x) transferencia	Tangente sigmooidal
f(x) entrenamiento	LM
R^2	0,9882

Para la escala temporal quincenal se obtuvo que las redes óptimas son la Red 2 y Red 4, con coeficientes de correlación de Pearson de 0,9963 y 0,9905 respectivamente. Las *Tablas 7 y 8* muestran las características de las redes respectivamente.

Tabla 7. RNA óptima, escala quincenal, Red 2.

Red 2 "Mayo - Septiembre"	
nº neuronas	20
f(x) transferencia	Tangente sigmooidal
f(x) entrenamiento	LM
R2	0,9963

Tabla 8. RNA óptima, escala quincenal, Red 4.

Red 4 "Tmax día"	
nº neuronas	20
f(x) transferencia	Tangente sigmooidal
f(x) entrenamiento	LM
R2	0,9905

5. RESULTADOS RNA VALLE NEVADO V/S MAPOCHO EN LOS ALMENDROS

Metodología

En esta parte del trabajo se busca comparar la calidad de la información, entre realizar un pronóstico utilizando datos provenientes de una estación ubicada sobre los 3.000 m.s.n.m (Valle Nevado) y realizar un pronóstico utilizando datos provenientes de una estación ubicada a 1.000 m.s.n.m. aprox. (Mapocho en Los Almendros). Debido a que se desea comparar sólo la calidad de la información, la estructura de las redes y la cantidad de la información debe ser la misma, variando sólo los parámetros de entrada.

Se cuenta con datos de la estación Valle Nevado sólo para la temporada de deshielo 2013-2014, por consiguiente se tiene un número reducido de datos para el entrenamiento, validación y prueba de las redes neuronales. Dado que se cuenta con muy pocos datos, se debe reducir el número de pesos y bias a determinar, por lo tanto se reduce el número de neuronas en la capa oculta a 2, y el número de datos de entrada a 4. De éste modo, se realiza un análisis de significancia de los parámetros de entrada para determinar aquellos de mayor importancia.

Para la escala diaria, se obtiene que los datos más significativos son el caudal, la temperatura máxima, precipitación y humedad relativa, todos del día anterior; y la suma de caudales anteriores de deshielo. Para la escala semanal, se concluye que los datos significativos son el caudal del día anterior, la suma de caudales de deshielo anteriores y la temperatura máxima, precipitación y humedad relativa, promedio de la semana anterior.

Por último, para la escala quincenal, se concluye que los datos significativos son el caudal medio, la temperatura máxima, precipitación y humedad relativa, todos promedios de la quincena anterior, y la suma de caudales de deshielo anteriores.

Para las tres escalas temporales, se entrenan 3 redes utilizando parámetros de entrada provenientes de Valle Nevado, donde se varían los datos de entrada; y una red para Mapocho en Los Almendros, dado que ésta estación no cuenta con información de humedad relativa, por lo que se tienen sólo 4 posibles datos de entrada. En la *Tabla 9* se muestran los parámetros de entrada de las 4 redes entrenadas, se destaca que “t-1” depende de la escala temporal en la que se esté trabajando, pudiendo ser el día anterior, semana anterior o quincena anterior.

Tabla 9. Parámetros de Entrada, Redes Valle Nevado v/s Mapocho en Los Almendros

	Datos de Entrada			
Valle Nevado 1	Q t-1	H.R. t-1	Tmax t-1	Pp t-1
Valle Nevado 2	Q t-1	H.R. t-1	Tmax t-1	Suma Qant
Valle Nevado 3	Q t-1	Suma Qant	Tmax t-1	Pp t-1
Mapocho en Los Almendros	Q t-1	Suma Qant	Tmax t-1	Pp t-1

Se destaca que los datos de caudal provienen siempre de la estación Mapocho en Los Almendros, los datos de humedad relativa provienen de la estación Valle Nevado y los datos de temperatura máxima y precipitación provienen de la estación Valle Nevado o Mapocho en Los Almendros dependiendo del caso.

Redes Neuronales Artificiales Óptimas

Para la escala temporal diaria se obtiene que la red óptima es la red “Valle Nevado 3”, con coeficiente de correlación de Pearson de 0,9846. Los datos de entrada son el caudal medio del día anterior, suma de caudales de deshielo anteriores, T° máxima y precipitación del día anterior.

Para la escala temporal semanal se obtiene que la red óptima es la red “Valle Nevado 2”, con coeficiente de correlación de Pearson de 0,976. Los datos de entrada son el caudal medio del día anterior, humedad relativa, T° máxima y precipitación promedio de la semana anterior.

Para la escala temporal quincenal se obtiene que la red óptima es la red “Mapocho en Los Almendros”, con coeficiente de correlación de Pearson de 0,9962. Los datos de entrada son el caudal medio de la quincena anterior, suma de caudales de deshielo anteriores, T° máxima y precipitación de la quincena anterior.

6. ANÁLISIS DE RESULTADOS, SIMULACIÓN TEMPORADA 2013-2014

El análisis de resultados consiste en simular la temporada de deshielo 2013-2014, utilizando las RNA óptimas seleccionadas para Mapocho en Los Almendros.

Escala Temporal Diaria

Se obtuvo un pronóstico con un 5.6% de error ($0.18 \text{ m}^3/\text{s}$). Se observa que tanto los caudales máximos como mínimos son pronosticados con precisión; sin embargo las zonas de aumento de caudal presentan un leve retardo en el pronóstico (*Figura 7*).

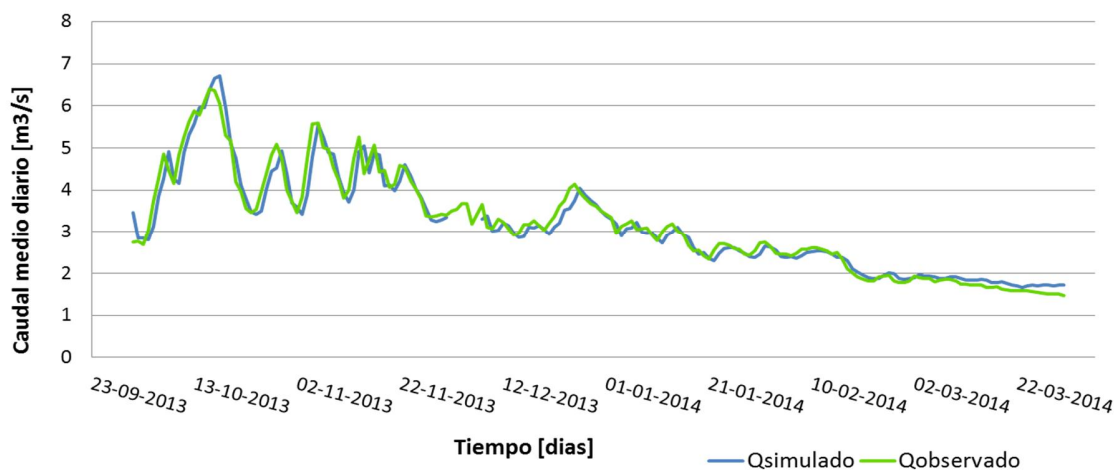


Figura 7. Serie de caudales medios diarios.

En relación a los errores, se observa que éstos son directamente proporcionales al caudal, es decir, a mayor caudal, mayor es el error en magnitud. Por otro lado se destaca que los mayores errores no superan $1 \text{ m}^3/\text{s}$, tanto positivos como negativos (*Figura 8*).

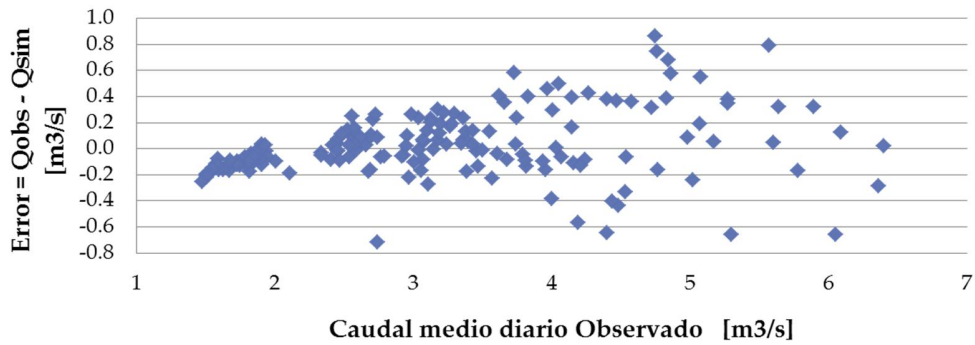


Figura 8. Caudal versus Error, Serie diaria.

Escala Temporal Semanal

Se obtuvieron series simuladas con un 11.3% de error ($0.41 \text{ m}^3/\text{s}$) para la Red 2 y un 11.6% ($0.39 \text{ m}^3/\text{s}$) para la Red 4. Se observa que si bien los errores porcentuales son prácticamente iguales, al comparar las visualmente, se observa que al comienzo de la temporada la Red 4 es más precisa que la Red 2. (Figura 9)




Figura 9. Serie de caudales medios semanales.

En relación a los errores, se observa, al igual que para la escala diaria, que éstos son directamente proporcionales al caudal, existiendo una leve tendencia a errores positivos en caudales mayores, es decir, ambas series tienen a subestimar los caudales de mayor magnitud. (Figura 10).




Figura 10. Caudal versus Error, Series semanales.

Escala Temporal Quincenal

Se obtuvieron series simuladas con un 22.3% de error (0.88 m³/s) para la Red 2 y un 11.5% (0.38 m³/s) para la Red 4. Se observa que el pronóstico realizado por la Red 4 es superior al realizado por la Red 2, donde ésta última tiene a subestimar en demasía los caudales al comienzo de la temporada. Sin embargo el pronóstico de la Red 4 tiende a oscilar en torno a la serie de caudales observados (Figura 11).




Figura 11. Serie de caudales medios quincenales.

En cuanto a los errores, se observa, al igual que para la escala diaria y semanal, que éstos son directamente proporcionales al caudal, existiendo una leve tendencia a errores positivos en caudales mayores para el caso de la Red 2, lo cual no sucede para la Red 4, la cual presenta errores tanto positivos como negativos. (Figura 12).




Figura 12. Caudal versus Error, Serie Quincenal

Por último, se muestran los pronósticos para las tres escalas temporales en conjunto, para la temporada de deshielo 2013-2014. (Figura 13)

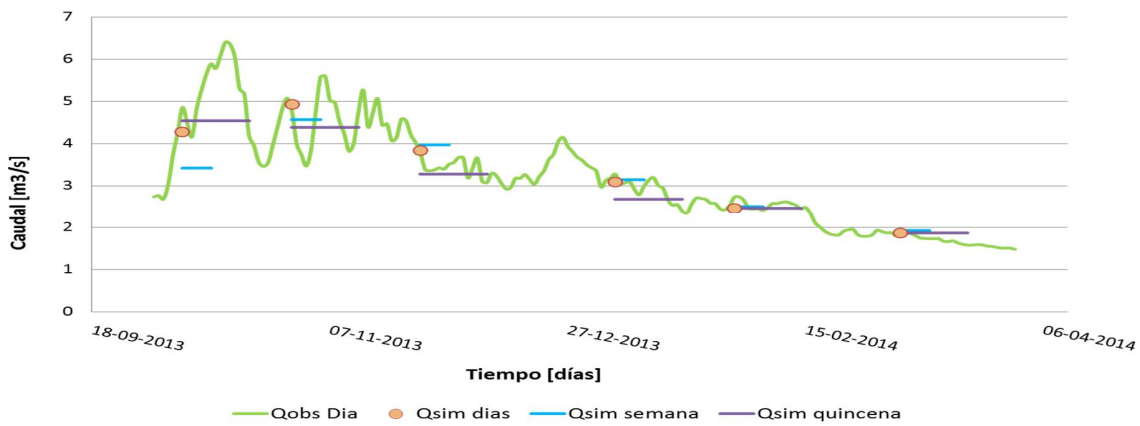


Figura 13. Serie de caudales diarios, semanales y quincenales.

7. CONCLUSIONES

En cuanto a la estructura de la red se concluye que el número óptimo de neuronas en la capa oculta es 20, la función de entrenamiento es Levenberg Marquardt y la función de transferencia tanto en la capa oculta como en la capa de salida es tangente sigmoideal.

En relación a los datos de entrada para las RNA de Mapocho en Los Almendros, se concluye que 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. 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.

Por otro lado, se concluye para las RNA de Valle Nevado, la humedad relativa es un parámetro de gran importancia para el pronóstico de caudales de deshielo. Además, es mejor utilizar los datos de entrada como promedios semanales o quincenales para pronosticar a escalas semanal y quincenal respectivamente, y no los datos diarios.

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. Por otro lado, las RNA óptimas para escalas temporales diaria y quincenal generaron pronósticos de caudales extremos con mayor precisión que la escala semanal.

En cuanto a la inclusión de datos hidrometeorológicos de la estación “Valle Nevado” se observa que éstos generan mejoras en los pronósticos a escalas temporales diaria y semanal, pero no se observaron mejoras a nivel quincenal, por lo que no es posible concluir que la inclusión de datos provenientes de una estación a 3000 m.s.n.m. genere siempre mejoras significativas en los pronósticos de caudales de deshielo. Sin embargo se destaca, que el estudio fue realizado con escasa disponibilidad de datos.

AGRADECIMIENTOS

Se agradece el financiamiento entregado por el Proyecto Fondef N°CA13I10277 “Pronóstico de Caudales de deshielo utilizando técnicas de percepción remota y asimilación de datos hidrometeorológicos”, así como la colaboración de Miguel Lagos en la preparación de este artículo.

REFERENCIAS

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.

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.

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

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

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.

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

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.

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

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.

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

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