



USO DE ALGORITMO GENÉTICO PARA CALIBRAR UN MODELO DE LÓGICA DIFUSA DE PRONÓSTICO DE CAUDALES EN TIEMPO REAL

ARNALDO SANTANDER Y XIMENA VARGAS

Depto. Ingeniería Civil, Universidad de Chile.

Av. Blanco Encalada 2120 4^{to} Piso. Casilla228-3, Santiago, Chile.

Teléfono: 6968448; Fax: 6718788

e-mail: asantand@ing.uchile.cl

RESUMEN

En la actualidad, dadas las tecnologías disponibles para la recepción y transmisión de datos meteorológicos y fluviométricos en tiempo real, existe la necesidad de evaluar los modelos que permiten pronosticar caudales en tiempo real; con las consiguientes metodologías de calibración asociadas. Las incertidumbres presentes en el pronóstico de caudales en tiempo real, en particular las que se asocian a las variables que condicionan el fenómeno, como son la magnitud de la precipitación, distribución espacio - temporal de ésta y la condición inicial de humedad del suelo, provocan que los modelos hidrológicos concentrados tradicionales no entreguen resultados precisos para pronósticos con una antelación adecuada a los requerimientos.

En este trabajo, se presentan los resultados y se hace una breve descripción de la metodología aplicada para la confección de modelos de lógica difusa para el pronóstico de caudales, empleando en su calibración un método basado en algoritmos genéticos. Además, se realiza una comparación de este tipo de modelos con modelos de pronóstico lineales recursivos, para estos efectos se usan los antecedentes disponibles en una zona de la Séptima Región de Chile, donde frecuentemente ocurren tormentas que generan críticos escenarios de inundación.

ABSTRACT

Nowadays, in order to use the available technologies of meteorological data transmission and reception in real time, it is necessary to evaluate forecast runoff models, in junction with the calibration methodologies. Uncertainties related to phenomenon data (spatial and temporal rainfall distribution and the initial soil moisture), cause that traditional concentrated models do not give accurate forecasts for sufficient lead times.

In this paper a methodology for calibration fuzzy logic models using genetic algorithms is presented. The method is applied for forecasting runoff in real time and results are compared with those obtained through concentrated recursive linear models using data from a river located at Seventh Region of Chile, frequently affected by flooding.



USO DE ALGORITMOS GENÉTICOS PARA CALIBRAR UN MODELO DE LÓGICA DIFUSA DE PRONÓSTICO DE CAUDALES EN TIEMPO REAL

1 Introducción

Desde la década del 80 en el siglo pasado, el grupo de hidrología de la División Recursos Hídricos y Medio Ambiente del Departamento de Ingeniería Civil de la Universidad de Chile realiza estudios destinados a obtener modelos de pronóstico de caudales en tiempo real.

En particular, los modelos establecidos en cuencas pluviales (Vargas et al., 1986 [1], [2], Brown y Vargas, 1988 [3]) corresponden a modelos de función de transferencia (Precipitación, Caudal) que entregan resultados aceptables para tiempos de adelanto pequeños, inferiores a seis horas, debido al escaso tiempo de desfase entre la precipitación y el caudal. En las cuencas donde la componente nival es importante, el desarrollo de modelos de pronóstico en tiempo real sigue siendo tema de investigación (Vargas et al., 2002 [4]), pues los modelos de función de transferencia no han dado resultados enteramente satisfactorios para tiempos de adelanto del pronóstico suficientes para adoptar medidas que permitan mitigar los efectos negativos asociados a eventos extremos.

En cuanto al empleo de la lógica difusa para el pronóstico de caudales en tiempo real, se han estudiado aplicaciones, en cuencas pequeñas de régimen nivo pluvial pertenecientes a la Séptima Región de Chile, que utilizan como variables de entrada precipitación y caudal. Los resultados obtenidos (Vargas y Santander, 2002 [5]), concluyen que modelos de este tipo entregan pronósticos adecuados para tiempos de adelanto menores o iguales a seis horas. Sin embargo, para pronósticos con una antelación mayor los resultados no son satisfactorios.

Se ha observado, y en particular en este trabajo, que a mayor adelanto del pronóstico los modelos "Q-Q" tienden a subestimar el caudal en la zona del máximo, por lo que se pretende analizar la conveniencia de hacer interactuar los pronósticos realizados con el modelo "Q-Q" al tiempo " $t+\Delta$ " con aquellos de mayores tiempos de adelanto ($t + r\Delta$, $r > 1$). Esto se lograría mediante el uso de lógica difusa.

El uso de algoritmos genéticos (G.A.) para la calibración de los modelos de lógica difusa se debe, como se verá en este estudio, a que estos modelos son altamente no-lineales y con una topología dependiente de un alto número de parámetros. Por lo tanto, para la calibración de estos modelos no es práctico el uso de técnicas de optimización "clásicas" tales como mínimos cuadrados o "backpropagation". En la bibliografía relacionada al tema de los algoritmos evolutivos y sistemas expertos, existe documentación sobre la calibración de Redes Neuronales y Controladores Difusos mediante el empleo del G.A. (Túpac et al., 1999 [6]).



2 Metodología General

2.1 Modelo Lineal Q-Q

Estos modelos se basan en representar la variable de estado en el instante actual “Q(t)” (caudal en el lugar donde se realiza el pronóstico) en función del valor de la misma variable en tiempos pasados, además de las variables exógenas “x(t)”, las cuales en este caso corresponden a los caudales registrados aguas arriba de la zona donde se pronostica. Además, los modelos “Q-Q” poseen un término de “ruido” o residuo que se adiciona a las variables de entrada mencionadas anteriormente. La estructura general de este tipo de modelos puede resumirse en las ecuaciones 1 y 2.

$$Q(t) = D(t) + \xi(t) \quad (1)$$

$$D(t) = f \{ \delta[Q(t) \dots y(Q(t-n))] ; \lambda[x_1(t-1), \dots, x_1(t-r_1), \dots, x_k(t-1), \dots, x_k(t-r_k), \dots, x_p(t-r_p)] \} \quad (2)$$

Donde:

Q(t): Variable de estado en el tiempo t, igual al caudal en la zona donde se realiza el pronóstico.

x_k(t): Variable exógena k – ésima en el tiempo t, caudal registrado en el k-ésimo afluente del lugar donde se realiza el pronóstico.

D(t): Combinación lineal que relaciona las variables del modelo, las cuales son entregadas por las funciones δ y λ .

$\xi(t)$: Parte aleatoria o ruido del modelo.

$\delta(t)$: Función que relaciona la variable de estado en tiempos igual y/o anteriores al actual.

$\lambda(t)$: Función que relaciona las variables exógenas en tiempos igual y/o anteriores al actual.

Además, los modelos “Q-Q” estudiados en este trabajo son absolutamente determinísticos, asumiendo que el valor de la variable aleatoria o ruido $\xi(t)$ es nula. Los modelos asumen que el sistema es estacionario de primer orden, lo que equivale a decir que la media y varianza de las variables empleadas (y de los residuos $\xi(t)$) son también constantes en el tiempo.

Es importante señalar que los modelos lineales de pronóstico, del tipo “Q-Q”, presentan ventajas en cuencas nivo pluviales con respecto a los modelos función de transferencia “P-Q”, dado que la distribución espacial de la precipitación puede verse considerablemente afectada por efectos orográficos y de ubicación de la isoterma cero, lo cual puede cambiar el área pluvial aportante neta, en vista de la fuerte pendiente media que se presenta en estos sectores, y por lo tanto la respuesta de la cuenca para distintas crecidas.

2.2 Lógica difusa

La lógica difusa es una herramienta práctica que pretende describir, con el posterior objetivo de simular, el comportamiento de ciertos fenómenos sin la necesidad de un modelamiento físico-matemático extensivo del mismo. Se ha considerado de



manera general que el concepto de lógica difusa apareció en 1965 introducido por Lotfi A. Zadeh [7]. Las lógicas difusas, pues de hecho hay que hablar de ellas en plural, dado que existen diversas variantes en la aplicación del concepto, son multivaluadas, puesto que no imponen en las proposiciones o hipótesis valores discretos de las variables de decisión y consecuencia (*falso* o *verdadero*), como lo hace la lógica binaria.


El adjetivo “difuso” con que se denomina a este tipo de esquemas, se debe a que los valores de verdad no-deterministas utilizados tienen, por lo general, una connotación de incertidumbre. En consecuencia, lo difuso puede entenderse como la posibilidad de asignar valores de verdad intermedios entre “falso” o “verdadero”.

Un conjunto difuso es una función que a cada elemento del universo le asocia su grado de pertenencia, cuyo dominio es el universo y cuyo recorrido es el intervalo $[0,1]$. En tanto el grado de pertenencia sea más cercano a 1, tanto más pertenecerá el elemento al conjunto y en tanto el grado de pertenencia sea más cercano a 0 menos lo estará. Además, estos conjuntos tienen la propiedad que suelen ser no disjuntos. Mediante notación matemática, en la ecuación 3, se define un Conjunto Difuso MF, para la variable de entrada x que pertenece al universo X .

La función de pertenencia μ_A , se establece de una manera arbitraria, lo cual es uno de los aspectos más flexibles de los Conjuntos Difusos. Para operar en la práctica con los Conjuntos Difusos, se suelen emplear funciones de pertenencia del tipo representado en la figura 1.

$$\mathbf{MF(x) = \{(x, \mu_A(x)) / x \in X\}} \quad (3)$$
$$\mu_A: X \rightarrow [0,1]$$

Figura 1 Ejemplos de funciones de pertenencia “MF”



En la figura 1, se pueden observar dos tipos de funciones de pertenencia, de todos los posibles; el tipo triangular, que puede ser un caso concreto del trapezoidal en el que los dos valores centrales son iguales, y el de forma de campana Gaussiana. Las funciones de pertenencia de los Conjuntos Difusos se pueden operar entre sí del mismo modo que los conjuntos clásicos. Puesto que los primeros son un caso particular de los segundos, siendo posible definir las operaciones de intersección, unión y complemento haciendo uso de las mismas funciones de pertenencia, por ejemplo estas operaciones se pueden definir como se señala en las ecuaciones 4 y 5.



$$\mu_{A \cap B}(x) = \mu_A(x) * \mu_B(x) \quad (\text{conector lógico "Y"}) \quad (4)$$

$$\mu_{A \cup B}(x) = \text{Max} \{ \mu_A(x), \mu_B(x) \} \quad (\text{conector lógico "O"}) \quad (5)$$

La estructura de las proposiciones lógicas del sistema se pueden expresar de la forma que se describe a continuación, considerando que para todas las variables de entrada " V_k " se dispone de un número de funciones de membresía " m ", donde las " n " reglas del modelo " R_i " vienen dadas de la siguiente forma:

R_i: "Si V_1 es $MF_{(1,i)}$ Y/O....Y/O V_k es $MF_{(k,i)}$ Y/OY/O V_p es $MF_{(p,i)}$ "

Entonces: Implicancia i -ésima = $A_i(V_1, \dots, V_k, \dots, V_p)$ "

Donde: $i = \{1, \dots, n\}$ $k = \{1, \dots, p\}$ " V_k es $MF_{(k,i)}$ " = $MF_{(k,i)}(V_k)$

En este trabajo se emplean las funciones de implicancias o consecuencias de tipo Sugeno (1985, [8]), donde la implicancia la regla i -ésima " A_i " se obtiene simplemente de una combinación lineal de las variables de entrada, tal como se presenta en la ecuación 6.

Para obtener el valor de las variables "desfuzzyficadas" o salida del FIS, se emplea la suma ponderada de las implicancias por la "membresía conjunta" de la regla respectiva, la cual se obtiene mediante la operación unión (si el conector lógico es "O") o intersección (si el conector lógico es "Y"), utilizando la expresión señalada en la ecuación 7 (para el caso que de la "membresía conjunta" definida por la unión).

$$A_i = a_0^i + \sum_{k=1}^p a_k^i V_k \quad (6) \quad FIS(V_1, \dots, V_k, \dots, V_p) = \frac{\sum_{i=1}^n A_i * \text{Max}_{k \in \{1, \dots, p\}} \{MF_k^i(V_k)\}}{\sum_{i=1}^n \text{Max}_{k \in \{1, \dots, p\}} \{MF_k^i(V_k)\}} \quad (7)$$

2.3 Calibración de los FIS mediante el uso de Algoritmo Genético

Los algoritmos genéticos (G.A.) (Estévez, 1999 [9]) son métodos exhaustivos para la resolución de problemas de búsqueda y optimización, que aplican a estos los métodos de la evolución biológica; mediante los mecanismos de reproducción sexual y mutación.

En el presente trabajo, se emplearán los G.A. para la calibración de los FIS tipo Sugeno, con funciones de pertenencia o membresía "MF" Gaussianas, representadas en la ecuación 8. Por otro lado, la "membresía conjunta" de cada regla se define por la operación Unión. Además, como se verá más adelante en este trabajo, los parámetros " a_k^i " se definen como se presenta en la ecuación 9 y $n = p$. Por lo tanto, de las ecuaciones 6, 7, 8 y 9 se obtiene el FIS presentado en la ecuación 10.



$$MF_k^i(V_k) = e^{-\frac{(V_k - \mu_k^i)^2}{2\sigma_k^2}} \quad (8)$$

$$a_k^i = \begin{cases} 1 & \dots i = k \\ 0 & \dots i \neq k \end{cases} \quad (9)$$

Se deduce de la ecuación 10 que los parámetros a ser calibrados son “ μ_k^i ” y “ σ_k^i ”, los cuales, en la nomenclatura de los G.A, se denominan “cromosomas”. El Algoritmo Genético utiliza las operaciones que se describen brevemente a continuación:

1) Generación de la población inicial y codificación de los genes: Se genera una población aleatoria inicial de “individuos” (conjuntos de cromosomas). Luego se procede a codificar en “genes” los cromosomas, convirtiéndolos en una serie binaria de largo dado por la base que se utilice, a este valor se denomina “Ngen”.

2) Evaluación en el FIS de la población: Se evalúa el FIS para cada individuo, obteniendo el valor de la función objetivo “FO” de calibración (o heurística) para cada uno, la cual debe ser minimizada. (En este caso “FO” es la suma de las diferencias al cuadrado entre valores observados y pronosticados)

3) Ranking del ajuste de los individuos y elección de los progenitores: Calificación relativa de los individuos con respecto a la población, a menor “FO” mejor Ranking, y elección del par progenitor, estos engendrarán los individuos que constituirán la generación siguiente, se realiza por el método llamado “método de Ruleta” (Estévez, 1999 [9]).

4) Cruza (Crossover) de los individuos “Progenitores”: reproducción sexual de los progenitores por intercambio, de manera correlativa y aleatoria, de los genes entre los cromosomas de estos individuos. Se obtiene así la descendencia de este par progenitor, la cual tiene igual tamaño que la población inicial.

5) Mutación de la descendencia: Fenómeno espontáneo, de origen aleatorio, de cambio en los genes de los cromosomas que describen al individuo. Se define mediante una probabilidad de mutación “Pmut”, de manera como se expresa en la ecuación 11, donde Gen_k^0 el valor del gen (0 ó 1) previo a la aplicación del operador mutación.

El término del algoritmo está dado por el cumplimiento de alguna condición de convergencia, o bien por un número máximo de iteraciones, rescatando los “cromosomas” (parámetros calibrados) constituyentes del individuo “mejor adaptado” en todas la generaciones.

$$FIS(V_1, \dots, V_k, \dots, V_p) = \frac{\sum_{i=1}^{n=p} V_i \cdot \text{Max}_{k \in \{1, \dots, p\}} \left\{ e^{-\frac{(V_k - \mu_k^i)^2}{\sigma_k^i}} \right\}}{\sum_{i=1}^{n=p} \text{Max}_{k \in \{1, \dots, p\}} \left\{ e^{-\frac{(V_k - \mu_k^i)^2}{\sigma_k^i}} \right\}} \quad (10)$$

$$\begin{aligned} x &\rightarrow U[0,1] \\ P_x \leq Pmut &\Rightarrow Gen_k = 1 - Gen_k^0 \\ P_x > Pmut &\Rightarrow Gen_k = Gen_k^0 \end{aligned} \quad (11)$$

$k \in \{1, \dots, Ngen\}$

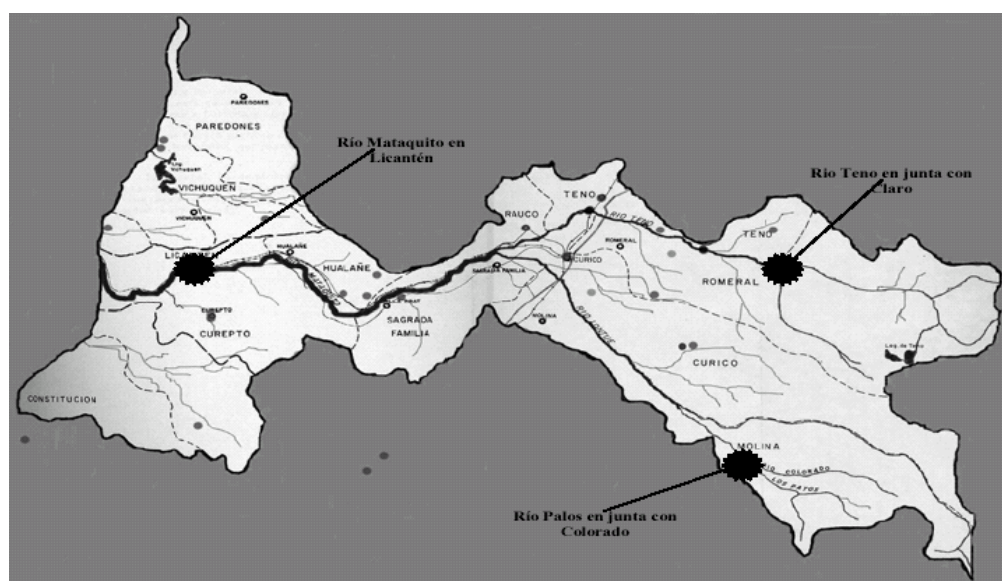
3 Descripción zona de estudio

El trabajo se desarrolla en la Hoya del río Mataquito en Licantén, en la cual se encuentran las estaciones fluviográficas de la D.G.A. Mataquito en Licantén ($A = 5.923 \text{ Km}^2$), Palos en junta con Colorado ($A = 514 \text{ Km}^2$) y Teno en junta con Claro ($A = 1.198 \text{ Km}^2$), las cuales se presentan en las figura 2. En particular, los modelos de pronósticos



de caudales son desarrollados la estación Mataquito en Licantén, los cuales consideran como variables de entrada los registros en las estaciones ubicadas en los afluentes al río Mataquito que se señalan anteriormente. Ambas cuencas presentan pendientes importantes, lo cual determina que los tiempos de concentración de ambas estaciones sean bastante bajos (3 a 4 horas). El régimen del río Mataquito es de tipo nivo pluvial, con importantes caudales de deshielo al comienzo del período de estiaje, particularmente en el mes de Diciembre, aunque las crecidas de mayor envergadura, e históricamente más destructivas, se producen en el período pluvial. Además, generalmente se observa un desfase al peak durante crecidas, entre las estaciones ubicadas en los afluentes al río Mataquito y la estación Mataquito en Licantén del orden de 18 hrs.

Figura 2 Zona de estudio



4 Resultados de los modelos de pronóstico

4.1 Resultados modelo Q-Q

La estructura de los modelos Q-Q utilizados contempla el uso de los siguientes datos de entrada a nivel horario:

- **QPC(t)**: Caudal registrado en la estación fluviográfica Palos en junta con Colorado en el instante "t".
- **QTC(t)**: Caudal registrado en la estación fluviográfica Teno en junta con Claro en el instante "t".
- **QML(t)**: Caudal registrado en la estación fluviográfica Mataquito en Licantén en el instante "t".

Empleando la información medida en las estaciones antes señaladas, se definen los modelos de pronóstico Q-Q que se presentan en la ecuación 12. El modelo antes planteado opera bajo la restricción que se plantea en la ecuación 13. En la ecuación 12



se aprecia que la función $\delta(t)$, para valores de $r > 1$, depende de los pronósticos realizados para tiempos anteriores. Por lo tanto, los pronósticos para estos tiempos de antelación se obtienen mediante una aplicación recursiva del esquema presentado en dicha ecuación.

$$\delta(t) = \begin{bmatrix} \delta_1 = QML(t) \\ \delta_2 = \sum_{j=1}^2 \frac{QML(t-j)}{2} \end{bmatrix} \quad (12)$$

$$\lambda(t) = \begin{bmatrix} \lambda_1 = \frac{QPC(t - \Delta_1^{\max}) - QPC(t - \Delta_1^{\max} - 3)}{QPC(t - \Delta_1^{\max})} \\ \lambda_2 = \frac{QTC(t - \Delta_2^{\max}) - QTC(t - \Delta_2^{\max} - 3)}{QTC(t - \Delta_2^{\max})} \end{bmatrix}$$

$$QML(t + r\Delta) = [a_1^r \quad a_2^r] \begin{bmatrix} \delta_1(t + r\Delta - \Delta) \\ \delta_2(t + r\Delta) \end{bmatrix} + [a_3^r \quad a_4^r] \begin{bmatrix} \lambda_1(t + r\Delta) \\ \lambda_2(t + r\Delta) \end{bmatrix}$$

$$r\Delta \leq \text{Min}\{\Delta_1^{\max}, \Delta_2^{\max}\} \dots \forall r \in \{1, \dots, n\} \quad (13)$$

Los parámetros “ Δ_1^{\max} ” y “ Δ_2^{\max} ” corresponden a los desfases (en horas) con respecto a la estación Mataquito en Licantén observados en las estaciones Palos en Junta con Colorado y Teno en Junta con Claro, respectivamente (ambos iguales a 18 hrs.). El valor de “ Δ ” representa el intervalo elemental de pronóstico (3 horas). Los parámetros del modelo lineal a_i^r ($i = \{1, 2, 3, 4\}$ y $r = \{1, \dots, 6\}$) son calibrados y validados de forma independiente para cada valor de r , empleando en la calibración las crecidas ocurridas durante Mayo de 1991, Julio de 1994 y Mayo-Junio del 2002, mientras que en la validación se utilizan las crecidas registradas en Mayo de 1992 y Junio de 1997. Se obtienen los parámetros presentados en la tabla 1. Los valores de los coeficientes R^2 obtenidos en la calibración y validación de los modelos se presentan en la tabla 2.

Tabla 1 Parámetros estimados modelo Q-Q

Parámetros estimados de los modelos de pronóstico Q-Q						
Parámetro	r = 1	r = 2	r = 3	r = 4	r = 5	r = 6
a_1^r	1,96	1,65	1,08	1,05	1,03	0,92
a_2^r	-0,96	-0,66	-0,09	-0,06	-0,03	0,07
a_3^r	35,8	239,22	277,3	285,09	289,05	299,46
a_4^r	18,47	49,13	23,64	4,82	-8,27	-11,94
Δ (hrs.)	3					
Δ_1^{\max} (hrs.)	18					
Δ_2^{\max} (hrs.)	18					

Tabla 2 Coeficientes R^2 , modelo Q-Q

Coeficiente R^2 para datos de calibración modelo Q-Q						
r=1	r=2	r=3	r=4	r=5	r=6	
0,992	0,973	0,950	0,923	0,891	0,857	
Coeficiente R^2 para datos de validación modelo Q-Q						
r=1	r=2	r=3	r=4	r=5	r=6	
0,992	0,962	0,909	0,844	0,773	0,699	

4.2 Resultados modelos FIS de pronóstico

Los modelos FIS de pronóstico empleados buscan hacer interactuar los modelos Q-Q obtenidos en el punto anterior, de manera de combinar la información brindada por un modelo Q-Q, para un tiempo de adelanto “ $r\Delta$ ”, $QML(t+r\Delta)$, con los caudales pronosticados por los modelos Q-Q para tiempos de adelanto mayores, $QML(t+k\Delta)$ con $k > r$. Para estos efectos se plantean los FIS en función de los pronósticos realizados con adelantos iguales o mayores a “ $r\Delta$ ”. En consecuencia, se definen las variables de



entrada de los FIS como se presenta en la ecuación 14, para utilizar el esquema planteado en la ecuación 10, obteniéndose de ambas expresiones la ecuación 15.

El FIS se calibra para las crecidas con las que se ajustó el modelo Q-Q, mediante el uso de G.A., empleando una población de 25 individuos, una probabilidad de mutación "Pmut" = 0,1 y un total de 250 generaciones, obteniéndose los parámetros que se muestran en la tabla 3, con los coeficientes R² asociados se presentan en la tabla 4. En la figura 3 se presentan los valores de "FO" para el "mejor individuo" por generación, para un valor de r = 3, Pmut = 0,1 y Pmut = 0. Se observa que el comportamiento del G.A, para Pmut =0,1, es bastante errático, aunque presente algunas regiones donde converge, mientras que para Pmut = 0 es rápidamente convergente, pero a una solución de menor ajuste que la encontrada en el otro caso. Además, en la figura 4, donde se comparan los R² de calibración y validación de los modelos Q-Q y FIS, se observa en general que estos últimos presentan un mejor ajuste, en particular para r = 3, aún cuando se observe un sobre ajuste de los modelos para valores r mayores (disminución de R² de los datos de validación).

Tabla 4 Parámetros calibrados de los FIS

Parámetros calibrados QML(t+rΔ) = FIS(t+rΔ)										
Modelo de pronóstico de 6 hrs.										
r = 2	μ _k ¹	μ _k ²	μ _k ³	μ _k ⁴	μ _k ⁵	σ _k ¹	σ _k ²	σ _k ³	σ _k ⁴	σ _k ⁵
1	208,0	739,8	1770,1	678,3	804,6	176,9	116,1	116,7	35,6	64,1
2	394,1	680,0	1589,0	1735,2	1650,4	27,2	50,6	162,7	159,5	120,8
3	262,9	1454,3	1251,6	1662,1	801,3	64,9	163,2	5,3	2,7	76,1
4	1082,1	1288,2	1446,0	1226,7	1457,7	175,4	11,5	150,7	166,8	189,1
5	1243,3	1730,2	503,8	1569,0	1642,1	136,9	140,2	18,2	173,6	40,7
Modelo de pronóstico de 9 hrs.										
r = 3	μ _k ¹	μ _k ²	μ _k ³	μ _k ⁴	σ _k ¹	σ _k ²	σ _k ³	σ _k ⁴		
1	267,8	1193,5	505,5	1785,0	157,4	183,4	50,6	147,6		
2	1156,9	716,5	1376,2	791,3	36,4	12,1	2,7	95,6		
3	382,5	1205,1	1688,7	1328,1	193,0	172,4	102,4	117,1		
4	189,7	1250,0	1233,3	1318,1	147,0	3,7	63,5	36,6		
Modelo de pronóstico de 12 hrs.										
r = 4	μ _k ¹	μ _k ²	μ _k ³	σ _k ¹	σ _k ²	σ _k ³				
1	307,7	555,3	615,2	53,4	4,9	60,6				
2	716,5	995,7	1662,1	23,3	27,8	176,5				
3	497,2	1253,3	1309,8	144,1	38,9	181,6				
Modelo de pronóstico de 15 hrs.										
r = 5	μ _k ¹	μ _k ²	σ _k ¹	σ _k ²						
1	164,8	1535,8	103,6	176,9						
2	179,8	498,8	42,2	52,0						

Figura 3 FO v/s N° de generación

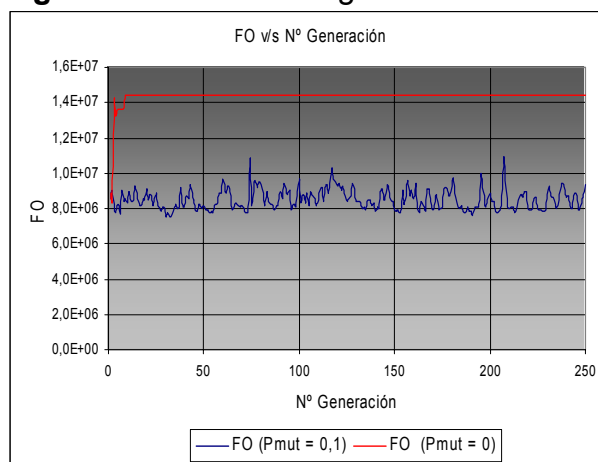


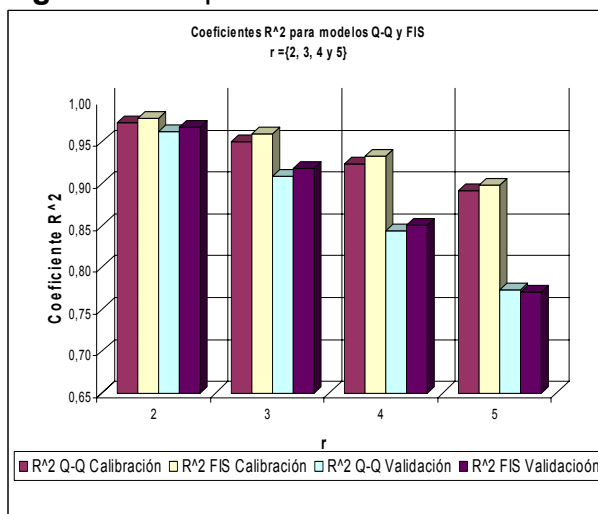
Tabla 5 Coeficientes R² de ajuste de los FIS

Coeficiente R ² para datos de calibración modelo FIS			
r=2	r=3	r=4	r=5
0,98	0,96	0,93	0,90
Coeficiente R ² para datos de validación modelo FIS			
r=2	r=3	r=4	r=5
0,967	0,918	0,850	0,771

$$V_{k-r+1} = QML(t + k\Delta) \dots r \leq k \leq n \quad (14)$$

$$QML_{FIS}(t+r\Delta) = FIS(V_1, \dots, V_{n-r+1}) \quad (15)$$

Figura 4 Comparación coeficiente R²





5 Conclusiones y Comentarios

- Los modelos de pronóstico empleados, en general, presentan una precisión aceptable para tiempos iguales o inferiores a 9 hrs.
- Los FIS permiten obtener mejoras, aunque poco significativas, con respecto a los pronósticos que entregan los modelos Q-Q para tiempos de adelanto mayores a tres horas. En consecuencia, se estima poco conveniente esta aplicación de los FIS.
- La calibración de los FIS mediante G.A. está altamente sujeta al operador de mutación.

6 Referencias

- [1] Vargas X., E. Brown y G. Sandoval. "Un Modelo de Función de Transferencia para el Pronóstico de Caudales en Tiempo Real". XII Congreso Latinoamericano de Hidráulica, Vol. 2, Sao Paulo, Brasil, 1986.
- [2] Vargas X., H. Zavala y E. Brown. "Modelos ARMAX en el Estudio de Propagación de Crecidas en Tiempo Real". XII Congreso Latinoamericano de Hidráulica, Vol. 2, Sao Paulo, Brasil, 1986.
- [3] Brown E. y X. Vargas. "Modelos de Función de Transferencia. Su Uso en el Pronóstico en Tiempo Real". XIII Congreso Latinoamericano de Hidráulica, Vol. 2, La Habana, Cuba 1988.
- [4] Vargas X., Valck P. y Santander A. "Pronóstico de caudales en tiempo real. ¿Modelación concentrada o semidistribuida?", XX Congreso Latinoamericano de Hidráulica, La Habana, Cuba 2002.
- [5] Vargas X. y Santander A. "Uso de Lógica Difusa para la estimación de Índices de Riesgo de Inundación y falla de Obras Hidráulicas en Tiempo Real", XX Congreso Latinoamericano de Hidráulica, La Habana, Cuba 2002.
- [6] Túpac Y., Pacheco M., Vellasco M. y Tanscheit R. "Controlador Difuso con Evolución del Conjunto de Reglas de Inferencia", V Congreso Internacional de Ingeniería Informática (ICIE99), Argentina, Buenos Aires 1999.
- [7] Lofti A. Zadeh, "Fuzzy Sets", Information and Control, vol. 8, pp. 338-353. (1965)
- [8] Sugeno M. "Industrial applications of Fuzzy control", Elsevier Science Pub. Co. (1985)
- [9] Estévez P. "Optimización Mediante Algoritmos Genéticos" Anales del Instituto de Ingenieros de Chile, pp. 83-92 Agosto 1997

7 Agradecimientos

Los autores del trabajo agradecen a la D.G.A. y al Fondo de Innovación del Ministerio de Obras Públicas de Chile por apoyar este estudio, a través de los datos entregados y el financiamiento otorgado al proyecto Índices de Riesgo de Inundación y Falla de Obras Hidráulicas en tiempo Real para la mitigación de efectos de temporales.