

## 7. BIBLIOGRAFIA

- BENSON, M.A.; 1962. *Plotting Positions and Economics of Engineering Planning*. Journal of Hydraulics Division. Amer.Society of Civil Engineering. Noviembre.Nº 88,pág 57-71. USA.
- CAAMAÑO NELLI, G.; H. DI BENEDETTO; E. ZAMANILLO; 1994. *Hietogramas Típicos de Tormentas Intensas en la Estación La Suela, Córdoba*. XV Congreso Nacional del Agua. La Plata, Argentina.
- CAAMAÑO NELLI, G.y GARCIA, C. 1998. *Estimación de la Función i-d-T a Escala Regional mediante el Factor de Frecuencia Normal*. II Simposio de Recursos Hídricos del Cono Sur y XVII Cong. Nac. del Agua. Santa Fe. Argentina. Tomo 2, pp157-167.
- CHOW, V., D.MAIDMENT y L.MAYS; 1994. *Hidrología Aplicada*. McGraw-Hill. Bogotá, Colombia.
- HALL, A. J.; 1977. *Temporal Patterns of Rainfall Bursts*. Australian Rainfall and Runoff. The Institution of Engineers, Australia. Sydney.
- HUFF, F. A.; 1967. *Time Distribution of Rainfall en Heavy Storms*. Water Resources Research, vol. 3, Nº 4, pág. 1007-1019. USA.
- KEIFER, C.J. Y CHU, H.H.; 1957. *Synthetic storm pattern for drainage design*. Journal of Hydraulics Division. Amer.Society of Civil Engineering. Agosto. Vol 83,Nº 4,pp. 1-25. USA
- PILGRIM, D.H.; I. CORDERY y R. FRENCH; 1969. *Temporal Patterns of Design Rainfall for Sydney*. Civil Engineers Transactions, vol. CE 11, Nº 1. The Institution of Engineers, Australia. Sydney.
- PILGRIM, D.H. y I. CORDERY; 1975. *Rainfall temporal patterns for desing flood*. Journal of Hydraulics Division. Amer.Society of Civil Engineering, vol 101, Nº Hy1, pág 81-95. USA.
- U.S.Department of Agriculture Soil Conservation Service. 1986. *Urban Hydrolgy for small watersheds*. Technical release N°55. USA.

## SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA XIV CONGRESO NACIONAL DE HIDRÁULICA

### USO DE REDES NEURONALES PARA LA SIMULACION DE CAUDALES EN CUENCAS PLUVIALES

XIMENA VARGAS M.<sup>1</sup>  
PABLO ANGUITA M.<sup>2</sup>

#### RESUMEN

Con la finalidad de mejorar los sistemas de predicción existentes en el país, se estudia la aplicabilidad de la metodología denominada redes neuronales al pronóstico de caudales medios diarios en cuencas de régimen pluvial de la zona central de Chile. Esta metodología que consiste en un sistema experto que modifica su comportamiento para adaptarse a las condiciones que se van produciendo, utiliza relaciones y combinaciones entre las neuronas de las distintas capas que conforman la red, lo que permite modelar el fenómeno precipitación escorrentía.

<sup>1</sup> Ingeniero Civil. Profesor Asociado Departamento de Ingeniería Civil. Universidad de Chile  
<sup>2</sup> Ingeniero Civil. Universidad de Chile

## 1. INTRODUCCIÓN

En la actualidad, el avance que ha alcanzado el procesamiento computacional de la información, permite la existencia de una gama importante de recursos tecnológicos que pueden ser aplicados para resolver problemas de la más diversa índole. Junto a lo anterior, se ha logrado introducir modelos de mayor complejidad, con los que se han obtenido mejores representaciones del fenómeno que se está modelando con los consiguientes mejores resultados. Como ejemplo específico de métodos o modelos de procesamiento de la información, puede citarse a las Redes Neuronales que permiten modelar en forma diferente la información que se entrega, mediante relaciones o conexiones neurales.

En el ámbito de la hidrología, se hace imprescindible conocer en forma anticipada hidrogramas de crecidas, para con ello poder operar y controlar obras hidráulicas de manera más segura. También, en muchos casos existen datos que no han sido registrados, por lo que se buscan métodos de cálculo que permitan obtener valores que se ajusten a la realidad. En este esquema, se analiza el uso de Redes Neuronales el que, según los antecedentes disponibles en la literatura (Aracena, 1997; Camargo, 1990; Haykin, 1994; Jiménez, 1996; Minns, 1996 y Toledo, 1996), ofrece una mejor adaptabilidad a las distintas situaciones. Las Redes Neuronales representan un intento por simular el comportamiento de las neuronas del cerebro humano, las cuales, después de realizar un proceso de aprendizaje que les enseña a reconocer ciertos patrones determinados, son capaces de crear sus propios patrones de respuesta a partir de nuevas entradas de información, aunque ellas contengan ruido o sean sólo parciales. De acuerdo a lo anterior, ellas consisten en un sistema experto que modifica su comportamiento para adaptarse a las nuevas condiciones.

El objetivo de este trabajo es aplicar este nuevo método para simular caudales medios diarios en cuencas pluviales y efectuar pronósticos con cierta antelación, de manera de determinar si el uso de Redes Neuronales permite obtener un avance significativo con respecto a otros métodos de predicción.

## 2. ANTECEDENTES TEÓRICOS

Las Redes Neuronales son un sistema diferente de modelar la información con grandes perspectivas para manejar una gran diversidad de problemas computacionales. A medida que la computación y las técnicas de inteligencia artificial se desarrollan, expandiendo las capacidades de los computadores y disminuyendo los tiempos de procesamiento, se ha alcanzado un avance significativo en imitar el comportamiento del cerebro humano a nivel de software. En éste contexto las Redes Neuronales son un intento por simular éste comportamiento a nivel de hardware, separando el procesamiento de la información en entes independientes que calculan una salida al estímulo que se les entrega.

Una Red Neuronal consiste en un conjunto de elementos o entes de procesamiento llamados *Neuronas*, que se identifican con enteros  $1, 2, 3, \dots, N$ . Estas neuronas están conectadas a través de un conjunto de conexiones o pesos neuronales. Cada neurona recibe un estímulo de entrada de otras neuronas o del medio exterior, según lo cual calcula su nivel de excitación o estado interno, en cada instancia de procesamiento, de acuerdo a la siguiente expresión:

$$x_{ij} = \sum_{k=1}^{M_i} w_{ik} y_{j-1k} + I_i = \sum_{k=0}^{M_i} w_{ik} y_{j-1k} \quad (1)$$

donde:  $x_{ij}$  : Corresponde al nivel de excitación de la neurona  $i$   
 $M_i$  : Corresponde a la cantidad de entradas que posee la neurona  $i$ .  
 $w_{ik}$  : Corresponde al peso de la conexión entre las neuronas  $i$  y  $k$ .  
 $y_{j-1k}$  : Corresponde a la salida de la neurona  $k$  de la capa  $j-1$ .  
 $I_i$  : Corresponde al umbral de excitación de la neurona  $i$ . Este valor puede quedar incluido dentro de la suma si a  $y_0$  se le asigna un valor 1 y  $w_{i0}$  el peso asociado. Por medio de la incorporación del umbral de excitación se busca mantener el nivel de respuesta de la neurona sobre un nivel mínimo, para con ello disminuir la ponderación de las demás entradas.

Considerando vectorialmente el producto interno entre  $W_i = [w_{i0}, w_{i1}, \dots, w_{iM_i}]$ , vector de pesos e  $Y_i = [y_{i0}, y_{i1}, \dots, y_{iM_i}]^T$ , vector de entrada de la neurona  $i$ , la activación de la neurona  $i$  será simplemente:

$$x_i = W_i \cdot Y_i \quad (2)$$

### • Funciones Neuronales

Con el nivel de excitación calculado con la ecuación 1, la neurona calcula su salida  $y_{ij} = f(x_{ij})$ , en que la función  $f()$  puede tener distintas formas dependiendo del modelo que se esté utilizando. Como por ejemplo la función  $f()$  puede tener las formas que se indican en la figura 1.

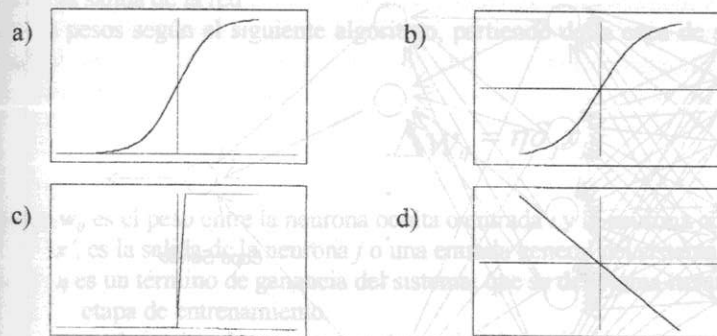


Figura 1 a)  $y = f(x) = \frac{1}{1 + e^{-kx}}$  función sigmoide b)  $y = f(x) = \tanh(kx)$

$$c) y = f(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad d) y = f(x) = -x$$

En el caso de este estudio se utilizó la función sigmoide, ya que proveía las características necesarias para un acercamiento gradual al óptimo del sistema. Hay que hacer notar que existe una variedad muy grande de funciones que pueden ser utilizadas como funciones neuronales, sin



embargo, debe cumplirse que la función tenga un comportamiento suave con respecto a la entrada proporcionada, para lograr que la red tenga posibilidades de ajustarse a la salida observada y no sólo oscilar en torno de ella.

• **Arquitectura de la Red**

La arquitectura de una Red Neuronal está dada por la cantidad de neuronas que posee una capa y la cantidad de capas que componen la red. Además define el tipo de conexiones que existe entre las neuronas. En el caso que se estudia, se utilizó el modelo de neurona de la figura 2 y la configuración que se muestra en la figura 3.




Figura 2: Modelo de Neurona




Figura 3: Esquema de la Red Neuronal

• **Algoritmo de Aprendizaje**

Las Redes Neuronales son capaces de construir relaciones entre sistemas totalmente arbitrarios, los cuales pueden ser representados mediante procesos estocásticos variables en el tiempo sobre algún espacio vectorial (Jiménez, 1996). Si se supone que existe una relación entre una "entrada" y una "salida" ésta puede ser modelada por una Red Neuronal. Por medio de un proceso de aprendizaje el cual provee a la red el ajuste de los vínculos que producen una respuesta de la red mínima en error, respecto de la salida esperada. El aprendizaje se entiende aquí como la manera en que se construye el mapa de vínculos de la red (Camargo, 1990).

Para lograr el proceso de aprendizaje se requiere que se le muestre a la red un suficiente número de ejemplos de pares entrada-salida, y forzar a la Red Neuronal que se adapte a ellos, para con ello generalizar su comportamiento y obtener buenos resultados frente a nuevas situaciones.

• **Back Propagation o Retropropagación del Error.**

Existen varios sistemas o algoritmos para entrenar las Redes Neuronales, siendo la Retropropagación del error o regla del gradiente uno de los más utilizados por su rápida convergencia en un número finito de pasos. Gracias a este algoritmo se puede modificar los pesos de interacción entre las neuronas, de manera que el error de la red sea mínimo. El algoritmo de entrenamiento de la red es el siguiente:

- Inicializar todos los pesos con valores arbitrarios y pequeños.
- Presentar un estímulo de entrada
- Determinar la salida de la red
- Adaptar los pesos según el siguiente algoritmo, partiendo de la capa de salida hasta la primera capa oculta.

$$\Delta w_{ij} = \eta \delta_j x'_j \quad (3)$$

En que  $w_{ij}$  es el peso entre la neurona oculta o entrada  $i$  y la neurona oculta o salida  $j$ .  
 $x'_j$  es la salida de la neurona  $j$  o una entrada general del sistema;  
 $\eta$  es un término de ganancia del sistema, que se determina iterativamente en la etapa de entrenamiento.  
 $\delta_j$  es el término de error que se determina de la siguiente forma:

- Si neurona  $j$  pertenece a la capa de salida:  

$$\delta_j = o_j - y_j \quad (4a)$$
en que  $o_j$  es la salida observada del sistema.  
 $y_j$  es la salida calculada por la red.

- Si la neurona  $j$  pertenece a una capa interna:

$$\delta_j = x_j'(1 - x_j') \sum_k \delta_j w_{jk} \quad (4b)$$

en que  $k$  recorre todas las neuronas de la capa que se encuentra sobre la neurona  $j$ .

Los pesos de los valores umbral  $I_i$  se consideran dentro de la suma como si fuesen una entrada más de valor constante 1.

Volver al paso 2 en el siguiente intervalo de tiempo, mientras no se satisfaga el valor de error o número de iteraciones deseado.

Agregando un término de momentum se puede aumentar la velocidad de convergencia, de modo que la ecuación 3 queda:

$$\Delta w_{ij}^t = \eta \delta_j x_j' + m \Delta w_{ij}^{t-1} \quad (5)$$

Se puede mejorar la capacidad de la red de generalizar incorporando o definiendo una frecuencia distinta de actualización de los pesos. En este sentido se define la época como el número de ejemplos que se le entregan a la red sin modificar sus pesos, de esta forma los errores se acumulan hasta que se haga la modificación. Para épocas muy pequeñas o iguales a 1 el proceso de aprendizaje es más lento ya que está involucrado un mayor número de cálculos; con valores muy grandes o iguales al total de ejemplos, la red aprende tendencias globales.

No existe hasta el momento ningún método establecido para definir la arquitectura de la red o la estrategia de entrenamiento adecuados para resolver ciertos problemas en particular quedando todas las posibilidades abiertas en el diseño y entrenamiento. En este sentido, la única forma que asegura la obtención de un modelo adecuado para cada caso es la simulación computacional.

### 3. APLICACIÓN

Se seleccionaron para el estudio las cuencas que se detallan en la tabla 1, donde además se indican las respectivas estaciones de medición de caudal y precipitación.

- Datos de Entrenamiento y Prueba

Con la información que se disponía para cada cuenca se eliminaron los intervalos de tiempo para los cuales no se producía una crecida sustancial del caudal del río o estero en cuestión, es decir, cuando el caudal medio diario era inferior al 10% del caudal máximo registrado en el periodo en estudio. Luego de esto se dividió la información en dos grupos, uno para la etapa de entrenamiento y otro para la etapa de prueba, dejando para éste último del orden de un 10% de días del total, tal como se muestra en la tabla 2.

Tabla 1: Estaciones de medición

Estaciones Fluviométricas		Estaciones Pluviométricas		Años Considerados
Nombre de la estación	ROL de la DGA	Nombre de la estación	ROL de la DGA	
Puangue en Boqueron	057-41001-9	Melipilla	057-40051-K	1978-1995
Alhué en Quilamuta		Villa Alhué	060-41051-8	1979-1988
Purapel en Nirivilo	073-41001-0	Nirivilo	073-41050-9	1981-1995
Mulchén en Mulchén	083-30001-9	Mulchén	083-32050-8	1975-1995
Bureo en Mulchén	083-32001-K	Mulchén	083-32050-8	1975-1995

Tabla 2: Número de Días para la Etapa de Entrenamiento y Prueba

Cuenca	Número total de días válidos registrados	Número de días en la etapa de entrenamiento	Número de días en la etapa de Prueba
Puangue en Boquerón	5921	631	190
Alhué en Quilamuta	3684	751	72
Purapel en Nirivilo	5245	1743	173
Mulchén en Mulchén	6404	2974	374
Bureo en Mulchén	7606	3134	760

Se buscó un tamaño de red que ajustara los datos de entrenamiento de la mejor forma, este ajuste se midió por medio de dos parámetros que se obtienen en el entrenamiento, estos son: porcentaje de valores del total de datos que obtenían un error porcentual menor al 10% y un error porcentual menor al 20%. Este análisis se hizo para un número fijo de iteraciones<sup>3</sup> y un valor de  $\eta = 1$ . Se probó esto variando dos parámetros de la red, como son el número de neuronas en la primera y segunda capa oculta. Los resultados que se lograron en esta etapa se presentan en la Tabla 3, para la cuenca de Alhué<sup>4</sup> con un total de 100 iteraciones.

- Selección de la Cantidad de Variables de Entrada

Para esta prueba, realizada con los datos de la cuenca Alhué en Quilamuta, se consideró el fenómeno en estudio, por lo cual se tomó dos configuraciones y se comparó entre ellas. Una configuración fue tomar cuatro días de precipitación anteriores al día de predicción y un día de caudal anterior al día de predicción; en la otra se tomó cuatro días de precipitación anteriores al día de predicción y cuatro días de caudal anterior al día de predicción.

<sup>3</sup> Una iteración corresponde a presentarle a la red la lista completa de eventos una vez.

<sup>4</sup> Como el tamaño de la red es una variable que depende del fenómeno, se escogió arbitrariamente ésta cuenca.



Tabla 4.1. Configuración de Red

Modelo de red <sup>5</sup>	Error menor al 10%	Error menor al 20%
8-3-20-1	12,52%	25,98%
<b>8-5-20-1</b>	<b>12,98%</b>	<b>27,45%</b>
8-7-20-1	12,93%	27,48%
8-5-10-1	11,84%	25,17%
8-5-30-1	13,06%	27,07%
8-5-40-1	13,20%	27,07%

Utilizando el modelo con información de un día de caudal, la red lograba un ajuste bueno o similar al con cuatro días de caudal, sin embargo, no conseguía simular crecidas que se producían en meses de verano. Además de esto, cuando se le pedía que simulara crecidas basándose en la información predicha, el comportamiento de la red no era satisfactorio, ya que no distinguía si se encontraba en un máximo o en otro punto, aumentando el error en la predicción.

Basándose en los resultados anteriores se optó por considerar la configuración que incluía cuatro días de precipitación y cuatro días de caudal anteriores al día de predicción.

#### • Resultados de Predicción para cada una de las Cuencas

Como se dijo anteriormente, se consideró dos grupos de datos, uno para la etapa de entrenamiento y otro para la etapa de prueba o predicción. Cabe hacer notar que la información en la etapa de prueba era totalmente desconocida para la red y se consideró así para verificar la capacidad de predicción y generalización que lograba la red.

Para medir el nivel de acierto en la predicción, se tomó el error porcentual<sup>6</sup> del caudal predicho y se observó el porcentaje de valores que obtenían errores menores al 50%, el porcentaje de valores que obtenían errores menores al 20% y el porcentaje de valores que obtenían errores menores al 10%.

Los valores de error en la predicción para las cuencas en estudio, se muestran en la Tabla 4.

<sup>5</sup> Esto corresponde al número de neuronas en la capa de entrada, en la primera capa, segunda capa oculta y capa de salida

<sup>6</sup> Diferencia entre el valor observado y el predicho dividido por el observado

Tabla 4: Porcentaje de Veces en que Error porcentual es Inferior a Umbral Especificado

Cuenca	<10%		<20%		<50%	
	Entren. (%)	Predicción (%)	Entren. (%)	Predicción (%)	Entren. (%)	Predicción (%)
Puangue en Boquerón	34,1	50,3	53,7	73,5	79,8	87,6
Alhué en Quilamuta	40,5	42,0	60,1	73,9	79,2	91,3
Purapel en Nirivilo	30,4	29,2	55,5	43,8	79,9	60,0
Mulchén en Mulchén	69,5	61,0	86,3	82,0	98,1	97,8
Bureo en Mulchén	55,2	51,2	74,6	71,9	94,0	91,9

Se aprecia que los errores obtenidos en Puangue en Boquerón en la etapa de predicción son menores que los obtenidos en la etapa de entrenamiento; esto se puede deber a que los datos que se consideraron en la etapa de predicción fueron tomados arbitrariamente al final del periodo, periodo en el cual, en muchos casos las condiciones de las estaciones de medición han mejorado, por lo que representan adecuadamente el comportamiento de la cuenca.

En Alhué en Quilamuta ocurre algo similar al anterior, los valores de error en la etapa de predicción son menores que en la etapa de entrenamiento y esto se puede deber, de la misma forma que la anterior, a las condiciones en que se tomó la información en cada etapa.

En cuanto a Purapel en Nirivilo, se observa que la predicción tuvo más error que en la etapa de entrenamiento, pero el ajuste con poco error, o sea error menor al 10%, es prácticamente el mismo.

En Mulchén en Mulchén y en Bureo en Mulchén, los resultados pueden calificarse como muy buenos ya que la cantidad de valores con errores menores al 10% y 20% es muy alta. Esto se puede deber a que la estación pluviométrica caracteriza adecuadamente el comportamiento pluviométrico de ambas cuencas.

#### 4. Conclusiones

El procesamiento de la información usando Redes Neuronales proporcionó una alternativa distinta a los métodos tradicionales de modelación que se perfila como herramienta interesante para el pronóstico de caudales en el corto plazo.

La modelación de Redes Neuronales por medio de la integración de operaciones matriciales, permite optimizar el tiempo de procesamiento, como también simplificar la interpretación del modelo. La incorporación del umbral de excitación de la neurona, mejora el comportamiento de la red, eliminando la conducta irregular por entradas nulas, manteniendo el nivel de excitación siempre sobre un nivel mínimo, el cual, de igual forma se modifica en el proceso de Retropropagación.

La función sigmoide utilizada como función neuronal, otorga una conducta moderada a la red, es decir, elimina la posibilidad de encontrarse con salidas desmesuradas cuando el estímulo es muy grande.

Se utilizó como arquitectura de red, un patrón con dos capas ocultas, el cual proporcionó la capacidad de modelar un fenómeno en el que la función que lo gobernaba era no-lineal. La cantidad de neuronas que se determinó como la óptima, permitió realizar un menor número de cálculos, sin perder la representación cabal del fenómeno.

El método de aprendizaje utilizado<sup>7</sup> fue el indicado para lograr el ajuste de la Red Neuronal al fenómeno en estudio. Este método tiene la virtud de asegurar la convergencia de la red a un mínimo, sin embargo no asegura que este mínimo sea el global. Teniendo en cuenta este punto, en el momento del aprendizaje el factor  $\eta$  fue imprescindible para alcanzar el mínimo global. Utilizando un factor cercano a 3 al comienzo de la iteraciones y terminando con un factor cercano a 0,01 al final, se lograba acercarse lo más posible al mínimo que se suponía era el global.

Con respecto al momentum, el uso de este concepto no permitió tener un avance significativo en los resultados y si un aumento en el número de cálculos, por lo que se desechó su utilización.

Finalmente, se puede concluir que es posible aplicar un modelo de Redes Neuronales para predecir caudales medios diarios de crecidas en cuencas pluviales. Se considera además, que el uso de modelación basada en Redes Neuronales ofrece una alternativa real que permite obtener resultados aceptables del fenómeno precipitación - escorrentía.

#### Referencias Bibliográficas

- Aracena J. B., 1997 *Aplicación de Redes Neuronales al Reconocimiento de Características en la Madera y Figuras Geométricas*. Memoria de título de Ingeniero Civil Matemático. Universidad de Chile, Santiago
- Camargo F. A., 1990 *Learning Algorithms in Neural Networks*, The DCC Laboratory, Computer Science Department Columbia University, New York
- Haykin, S. S. 1994 *Neural Networks : a Comprehensive Foundation*, MacMillan College Publishing. New York
- Jiménez C., 1996 *Predicción de Precio de Acciones Utilizando Redes Neuronales*, memoria de Ingeniero Industrial, Universidad de Chile
- Minns, A. W. 1996 *Analysis of experimental data using artificial neural networks*. In: *Hydra 2000* (Proc. XXVI Congress IAHR), vol. 1, 218-223. Thomas Telford Services Ltda. London, UK.

<sup>7</sup> Método de Retropropagación del error o Back propagation

Toledo V., 1996 *Redes Neuronales en Modelado Hidrológico: Predicción de Avenidas en la Presa Huites*. Tesis de maestría en ingeniería hidráulica, DEPI, Universidad Nacional Autónoma de México.

XIV CONGRESO CHILENO DE HIDRAULICA

#### INFLUENCIA DE LA DISTRIBUCION TEMPORAL DE LA PRECIPITACION EN EL CAUDAL MAXIMO DE CRECIDAS

VICTOR CUEVAS V. (1)  
LUDWIG STOWIAS B. (2)

Se presenta un análisis teórico, utilizando el método del Hidrograma Unitario para la generación de crecidas, de la influencia de la distribución temporal del pico de la tormenta de diseño, en la magnitud que alcanza el caudal máximo de la crecida generada. Se analizan distintas distribuciones temporales tipo, que en la literatura especializada, considerando distintos escenarios en cuanto a la infiltración y tamaños o tiempos de respuesta de la cuenca, estableciendo la influencia de cada variable en la magnitud del caudal de crecida.

La variable de mayor influencia se practicó en la forma del hidrograma, produciendo diferencias en la magnitud del caudal máximo hasta de un factor del orden de 5, cuando crecidas de respuesta rápida.

(1) Ingeniero Civil, Dirección de Obras Portuarias, MOP.

(2) Ingeniero Civil, Universidad Técnica Federico Santa María