

Tormentas de Diseño usando Redes Neuronales Artificiales.

Oscar Raúl Dölling

Eduardo A. Varas

RESUMEN

Varios autores han propuesto procedimientos para distribuir la magnitud total de la lluvia en función del tiempo, con el fin de producir hietogramas representativos para las tormentas de diseño. Este trabajo generaliza resultados anteriores, planteando una formulación matemática que incorpora redes neuronales artificiales para clasificar tormentas y generar hietogramas de diseño para un lugar de interés sin mediciones de lluvia, en un entorno de simulación continua.

Los resultados muestran la capacidad de la red neuronal para representar un espacio tridimensional de interpolación del porcentaje de lluvia acumulada en función de tres dimensiones principales que son el identificador de Grupo de tormenta; el porcentaje de duración acumulada de la lluvia y la Probabilidad de Excedencia asociada a la tormenta. Esta habilidad de generalizar conceptos permite la complementación de información en casos de datos escasos. Este potencial es importante en el ámbito de las ciencias hidrológicas, especialmente en países latinoamericanos que sufren de falta de datos hidrológicos debido a la escasez de recursos financieros.

Palabras Clave: tormentas de diseño – Redes Neuronales Artificiales – Simulación continua - Hietogramas probabilísticas.

Storms of Design using Artificial Neural Networks.

Oscar Raúl Dölling

Eduardo A. Varas

ABSTRACT

Several researchers suggested procedures to distribute the total magnitude of rain as a function of time, with the purpose to produce representative design storms. This work generalizes previous results, outlining a mathematical formulation that incorporates artificial neural networks to classify storms and to generate design hyetograms for a place of interest without rain observations, in an environment of continuous simulation. The paper demonstrates the capacity of neuronal networks as a tool that allows to represent a three-dimensional space representing cumulative rain percentage based in three dimensions that are storm Group; the percentage of accumulated duration of rain and the Probability of exceedence associated to the storm. This ability to generalize concepts complements scarce data, an important capacity in hydrological sciences, specially in Latin American countries that suffer of lack of hydrological data, derived from shortage of financial resources.

KeyWords: Design Storms – Artificial Neural Networks – Continue Simulation – Probabilistics Hyetograms.

1. INTRODUCCIÓN

La distribución en el tiempo de la lluvia es un factor determinante de la forma, magnitud y volumen de la crecida resultante. Su conocimiento es esencial para estimar tormentas de diseño para proyectos de redes de aguas lluvias, sistemas de drenaje de carreteras, estudios de erosión, estimación de arrastres y socavación y otros problemas de ingeniería hidráulica. Varas (1985), utilizó el modelo RORB propuesto por Laurenson y Mein (1983) para cuantificar la influencia de la forma del hietograma sobre las características de la onda de crecida que genera una tormenta. El estudio consistió en calcular y comparar los hidrogramas de respuesta del modelo sometido a distintos hietogramas de tormentas de distinta distribución temporal pero de igual magnitud y duración, suponiendo idénticas condiciones de infiltración en la cuenca. Los resultados mostraron que el rango de los caudales máximos calculados podían variar del simple al doble.

Para estimar hietogramas representativos para las tormentas de diseño se han propuesto varios procedimientos para distribuir la magnitud total de la lluvia en función del tiempo (Huff, 1967; SCS - USDA, 1986 ; Varas, 1986).

Huff (1967) clasificó las tormentas en Illinois, dependiendo si la mayor precipitación es observada en el primer, segundo, tercer o último cuarto de la duración total del temporal. Posteriormente realizó un análisis de frecuencia de todas las tormentas registradas con el fin de asociar a cada una de la curvas de distribución acumulada una probabilidad de ocurrencia. Propuso curvas para distribuir una tormenta cuya duración y magnitud total se conoce, en intervalos de tiempo menores, teniendo al mismo tiempo, una idea de la probabilidad de ocurrencia de dicho hietograma.

El Soil Conservation Service del U.S. Department of Agriculture (1986) desarrolló hietogramas sintéticos de tormentas para utilizarse en los Estados Unidos con duraciones de tormentas de 6 a 24 horas. Estos hietogramas se dedujeron al utilizar la información presentada por Hershfield (1961) y Miller, Frederick y Tracey (1973) y datos de tormentas adicionales. Se clasificaron las tormentas de 24 horas de duración en cuatro tipos llamados Tipo I, IA, II y III, de acuerdo al clima del lugar (húmedo, seco, costero y tropical) respectivamente.

Varas (1985), a diferencia del de Huff, obtuvo para Chile curvas de distribución acumulada de lluvia para distintas tormentas seleccionando en cada tormenta los intervalos más lluviosos para cada una de las duraciones elegidas. La muestra así formada, constituye un subconjunto de todas las horas de lluvia ocurridas. Para cada una de las tormentas registradas en las estaciones ubicó los intervalos de 2, 4, 6, 8 y 12 horas de duración con mayor lluvia. Siguiendo la idea empleada por Huff, cada tormenta se clasificó en uno de cuatro grupos. El Grupo I se formó con aquellos temporales en los cuales la mayor proporción de lluvia cae en el primer cuarto de la duración total de la tormenta. El Grupo II lo forman aquellas tormentas en que la mayor parte de la lluvia cae en el segundo cuarto de la duración y de igual manera para los otros dos grupos. Los hietogramas de las tormentas clasificadas se expresaron en forma adimensional, calculando el porcentaje de lluvia acumulada en función del porcentaje de tiempo acumulado y se efectuó un análisis de frecuencia de las lluvias. El estudio concluyó que las curvas adimensionales eran representativas de las tormentas frontales de una amplia variedad de climas.

Este trabajo plantea una formulación matemática general para los hietogramas de diseño encontrados y propone un procedimiento para clasificar las tormentas de un lugar de interés y con el fin de facilitar el uso de la metodología planteada previamente.

Los resultados generalizan las curvas de distribución y facilitan el uso del procedimiento en otros lugares.

2. MODELOS DE TORMENTAS

2.1 Distribuciones de lluvia acumulada en función del tiempo.

Varas (1985) analizando un total de 296 tormentas registradas en la zona centro y sur de Chile determinó curvas acumuladas de lluvia en función del tiempo, representativas de tormentas de tipo frontal. Las curvas de distribución acumulada de lluvia para distintas tormentas representan los intervalos más lluviosos para cada una de las duraciones elegidas. El estudio concluyó que la clasificación de los temporales en función del tiempo en que ocurre la mayor parte de la precipitación era más importante que la heterogeneidad espacial de las tormentas.

El estudio recomendó curvas de distribución típicas para tormentas clasificadas en cuatro grupos. En cada grupo se definieron distribuciones representativas para diferentes probabilidades de excedencia. Las curvas de distribución se definieron en forma gráfica (ilustración 1) y numérica (cuadro 1).

Este trabajo obtuvo un modelo general para tormentas de tipo frontal que se usa para distribuir en intervalos menores de tiempo, una magnitud total de lluvia caída en una duración conocida. De esta manera, se generalizan las mediciones obtenidas con un pluviómetro.

El estudio realizado no contó con antecedentes que justificaran el uso de estas familias de curvas de distribución en otros lugares. La extensión del procedimiento a otros lugares requería repetir el estudio con las lluvias observadas en otras partes.

La aplicación posterior de esta metodología indicó que las familias de curvas son también representativas de otras zonas y por ello se buscó generalizar las curvas y facilitar la determinación de los parámetros necesarios en otras localidades, modelando los coeficientes empíricos mediante redes neuronales artificiales y desarrollando un esquema para clasificar las tormentas observadas para adecuarlas al esquema propuesto.

2.2 Representación del universo de tormentas mediante una red neuronal.

Para representar estas familias de curvas de distribución acumulada y permitir la generalización de los valores obtenidos, se utilizó el potencial de la técnica de redes neuronales artificiales multi-capa, que entregan una representación continua de una superficie cualquiera.

La metodología de identificación de la arquitectura, estrategia de entrenamiento y validación de la red neuronal artificial se basó en el método propuesto por Dölling (2000). El método (Ilustración 2) consiste en un procedimiento recursivo que permite converger a un modelo óptimo de red y que incluye las siguientes etapas principales:

- 1- Análisis de información: etapa relacionada al tratamiento de los datos que serán utilizados en el entrenamiento y validación de la red neuronal, la identificación de la arquitectura de las capas de entrada y salida y el armado de las duplas de entrada-salida.
- 2- Identificación de modelos candidatos: Etapa que consiste en identificar cuantas neuronas ocultas se incluirán en el modelo y cual será la estrategia de entrenamiento que se utilizará para lograr el correcto ajuste de los parámetros de la red neuronal.

- 3- Validación de candidatos: Etapa que consiste en evaluar la capacidad de la red neuronal entrenada anteriormente, para representar correctamente la superficie que se intenta modelar.
- 4- Selección del Modelo óptimo: Etapa que consiste en verificar con herramientas estadísticas los resultados de la validación y comparar los modelos candidatos. Esta etapa permite encontrar problemas de distinta naturaleza que pueden obligar a volver recursivamente a ejecutar distintas fases de las etapas 1 y 2 hasta lograr corregir el problema que impide encontrar el modelo buscado.

Siguiendo este método de trabajo se adoptó una arquitectura principal de red neuronal que corresponde a un esquema MISO (Multiple Input Simple Output). La capa de entrada se formó con tres neuronas que corresponden al identificador del grupo de la tormenta, la probabilidad de excedencia y el porcentaje de tiempo acumulado. La capa de salida tiene una sola neurona que corresponde al porcentaje de lluvia acumulada.

La topología de la red neuronal usada incluye una función de activación identidad en las neuronas de entrada y sigmoide en las neuronas ocultas y de salida con respuesta continua en el intervalo $[0,1]$.

En base a la información disponible de la Cuadro 1, se armaron 200 ejemplos consistentes en duplas (entrada-salida). Para evitar saturar la respuesta de la red neuronal durante el entrenamiento se escalaron los datos de entrada y salida entre 0 y 0.7.

Para identificar la mejor arquitectura de la capa oculta se inició la búsqueda del modelo con una estructura de capa oculta consistente en una sola neurona y luego se incrementó gradualmente el número de neuronas ocultas hasta lograr una buena

convergencia de las curvas de entrenamiento. El mejor resultado se obtuvo con una capa oculta compuesta por cinco neuronas para lograr un interpolador confiable.

El procedimiento concluyó que la red neuronal artificial que representa mejor la superficie de respuesta es una red ANN constituida por tres neuronas de entrada, cinco neuronas ocultas y una neurona de salida (Ilustración 3).

Los pesos asociados a los enlaces y el sesgo incorporados a las ecuaciones de las funciones sigmoideas de activación para cada neurona obtenidos del entrenamiento se presentan en los cuadros 2 y 3 respectivamente.

La estrategia de entrenamiento tuvo las siguientes características. El algoritmo de aprendizaje utilizado para el entrenamiento de la red neuronal fue el *backpropagation momentum*, el modo de inicialización de pesos fue aleatorio entre -1 y 1, el modo de actualización de pesos fue de tipo batch, la tasa de aprendizaje fue 0.05, el término de momentum fue 0.01, la presentación de ejemplos de entrenamiento fue en orden y el punto de término de entrenamiento fue a los 4000 ciclos.

La ecuación resultante para la lluvia acumulada en función del tiempo queda dada por la ecuación 1. El algoritmo representado por esta ecuación se muestra en el Cuadro 4.

$$o_9 = \frac{1}{1 + e^{-\theta_9 + \sum_{j=4}^8 \left[w_{j,9} \cdot \frac{1}{1 + e^{-\left(\theta_j + \sum_{i=1}^3 w_{i,j} \cdot X_i \right)}} \right]}}$$

Ecuación 1

Donde

X_i $i=1,2,3$ variables de entrada

X_1 = identificador de Grupo

X_2 = % de tiempo acumulado

X_3 = % Probabilidad de excedencia

$w_{i,j}$ = pesos entre la neurona i y la neurona j

$w_{i,j}$ = pesos entre la neurona j y la neurona k

θ_j $j=4,5,6,7$ y 8 valor de sesgo de la neurona j

θ_9 = valor de sesgo de la neurona de salida

O_9 = salida de la red neuronal = % lluvia acumulada

Esta red neuronal es capaz de representar y generalizar los resultados obtenidos en el estudio inicial, con un coeficiente de determinación igual al 0.85. La Ilustración 4 presenta los gráficos comparativos de las curvas de distribución de probabilidad de ocurrencia para distintos Grupos probabilísticos.

2.3 Generador de tormentas de diseño

El algoritmo que representa la red neuronal fue transformado en código de programación e incluido en un módulo, orientado a objetos, desarrollado para generar tormentas de diseño en el ambiente de simulación Extend®. El usuario entrega a este módulo la magnitud, la duración, el identificador del grupo y la probabilidad de excedencia de la tormenta a generar. El módulo desarrollado generaliza esta

información y produce un hietograma de la tormenta para la escala de tiempo, magnitud y duración dadas y con la forma correspondiente al grupo y probabilidad definidos por el usuario (Ilustración 5).

2.4 Clasificador de tormentas

Una tormenta de diseño es un patrón de precipitación definido para utilizarse en el diseño de un sistema hidrológico. Las tormentas de diseño se basan en la información histórica de precipitación en un sitio o pueden construirse utilizando las características generales de la precipitación en regiones adyacentes. En este último caso, es importante poder definir la secuencia temporal típica de la precipitación en la región de interés. Para poder definir la distribución temporal de la lluvia patrón en un sitio sin mediciones, es necesario clasificar las tormentas registradas en una región representativa del lugar de interés. Para lograrlo es indispensable contar con un sistema que permita clasificar correctamente las tormentas registradas a fin de poder realizar un estudio probabilístico de patrones de tormenta en la zona de estudio.

El modulo generador de tormentas desarrollado permite generar un hietograma de lluvia para cualquier magnitud total de lluvia caída, cualquier duración de lluvia, cualquier grupo y cualquier valor de probabilidad de excedencia. Esta capacidad, sumada a la capacidad de simulación Montecarlo del ambiente Extend® permite utilizar a este módulo generador como base para la creación de un modelo que permita al usuario clasificar cualquier tormenta observada.

Por ello se formuló un clasificador de tormentas que consiste en un modelo que realiza una búsqueda estocástica del perfil de tormenta más parecido al perfil de

distribución de lluvia a clasificar. Para lograr este objetivo el clasificador está programado para realizar las siguientes operaciones:

- 1- El usuario ingresa el hietograma observado que se quiere clasificar.
- 2- Se Ingresa la magnitud y duración de la tormenta a clasificar.
- 3- Se generan valores aleatorios, distribuidos según una función uniforme real, del número de grupo (rango 1-4) y de la Probabilidad de Excedencia (rango de 0 a 100).
- 4- El módulo generador de lluvias genera múltiples hietogramas de tormentas artificiales (la cantidad de tormentas la define el usuario) con perfiles de distribución temporal de la lluvia aleatorios a partir de los valores definidos en 1 y generados en 2.
- 5- Se calcula la suma de las diferencias entre la magnitud caída del hietograma observado (objetivo) y la correspondiente del hietograma aleatorio generado para los 10 intervalos de duración parcial en el que se ha dividido al hietograma analizado.
- 6- Se guardan los datos de generación (número de grupo y Probabilidad de Excedencia) del perfil de tormenta que obtenga la mínima suma de errores cuadráticos calculada en 5.

La Ilustración 6 presenta un ejemplo de clasificación usando el módulo descrito. La línea continua representa el perfil de distribución de la lluvia objetivo a clasificar, con una magnitud de 200 mm, una duración total de 24 horas, Grupo 1 y probabilidad de excedencia igual a 10%. El resultado del clasificador, tras analizar 200 tormentas generadas en forma aleatoria, indica que

la tormenta corresponde a un Grupo 1,049 y a una probabilidad de excedencia de 10,33% (línea quebrada). Los valores reales, no enteros, que adoptan los parámetros de la tormenta calculada, se deben a la interpolación continua que realiza la red neuronal, tanto entre curvas de distinta probabilidad pertenecientes a un mismo Grupo como también entre Grupos de tormentas. La capacidad de la red para suavizar el universo de búsqueda del clasificador hace posible utilizar una distribución Uniforme para generar los valores aleatorios de estos parámetros.

3. CONCLUSIONES

El presente trabajo presenta un modelo computacional para generar tormentas de diseño en un entorno de simulación continua. Su aplicación a ingeniería hidráulica es tan amplio que va desde el uso de los valores puntuales de la precipitación resultante en el método racional para determinar caudales máximos de crecida en alcantarillados de aguas lluvia hasta el uso de los hietogramas generados como entradas para el análisis de lluvia – escorrentía en embalses de detención de aguas urbanas o rurales o en el diseño de elementos de control de caudales superficiales como vertederos con compuertas colocados en grandes obras hidráulicas de regulación. Este desarrollo muestra la capacidad de una red neuronal como herramienta de interpolación no lineal en cuadros con múltiples entradas. En particular, se resalta la complejidad del universo conceptual capturado por la red neuronal. El universo representa un espacio tridimensional de interpolación del porcentaje de lluvia acumulada a partir de estas tres dimensiones principales que son el identificador de Grupo; el porcentaje de duración acumulada de la lluvia y la

Probabilidad de Excedencia. La capacidad de generar tormentas de diseño y también de clasificar tormentas observadas y asignarle probabilidades de excedencia no observadas, abre un campo de aplicación importante a las redes neuronales en la generación de tormentas de diseño para lugares sin observaciones pluviográficas. Esta habilidad de generalizar conceptos permite la complementación de información a partir de datos escasos, capacidad esencial en el ámbito de las ciencias hidrológicas, en especial útil para países latinoamericanos que sufren por la escasez de recursos financieros para encarar la medición de intensidades de lluvia.

4. REFERENCIAS

Dölling, O. (2000) Utilización de redes neuronales artificiales al pronóstico de caudales en cuencas con Precipitación Nival. *XVIII Congreso Nacional del Agua*. Libro de Resúmenes pp-15-17. ISBN 987-99083-4-1- Trabajo completo publicado en CD. Santiago del Estero, Termas de Río Hondo, Argentina.

Dölling O., Varas, E. (2000). Pronóstico de caudales en cuencas nivales usando redes neuronales artificiales. *XIX Congreso Latinoamericano de Hidráulica Argentina*, Volumen II, pp 81-90, Octubre, Córdoba Argentina.

Dölling, O. y Varas E. (2002) Artificial Neural Networks For Streamflow Prediction, *Journal of Hydraulic Research*, Vol. 40, nº 5, pp 547-554.

Hershfield, D.M., (1961) Rainfall Frequency atlas of the United States for durations from 30 minutes to 24 hours and return periods from 1 to 100 years, *tech. paper 40*, U.S. Dept. of Comm., Weather Bureau, Washington, D.C., May.

Huff, F. A. (1967) Time distribution of rainfall in heavy storms, *Water Resource Research*, Vol 3, Nro. 4, pp 1007-1019.

Laurenson E.M. y R.G. Mein, (1983), RORB Runoff Routing Program. User Manual, Monash University, Department of Civil engineering, Second Ed.

Miller, J.F., R.H. Frederick and R.J. Tracey, (1973) Precipitation-frequency atlas of the conterminous western United States (by states), NOAA atlas 2, 11 vols., *National Weather Service*, Silver Spring, Maryland.

U.S. Department of Agriculture Soil Conservation Service (1986) Urban hydrology for small watersheds, *U.S. Department of Agriculture Soil Conservation*, Service tech release No. 55, June.

Varas. E. C. (1985) Influencia del Hietograma de una tormenta en la crecida resultante, *Anales de la Universidad de Chile (Estudios en Honor de Francisco Javier Domínguez)* Quinta serie, Nro. 8 , Agosto. Santiago de Chile.

Varas E. C. (1985) Hietogramas de tormentas de diseño *Anales VII Congreso Nacional del Agua de Chile – Sociedad Chilena de Ingeniería Hidráulica*. pp 533-548, Noviembre, Concepción , Chile.

Varas E. C. (1986) Comparación entre perfiles de tormentas, *XII Congreso Latinoamericano de Hidráulica – AHIR - IARH – AIPH*. Volumen II pp 41-50 del 31 de Agosto al 4 de Septiembre.

5. Cuadros e Ilustraciones

CUADROS

Cuadro 1: Grupos de curvas de distribución típicas para tormentas frontales en Chile.

Cuadro 2 : Pesos $w_{i,j}$ en los enlaces de la red

Cuadro 3 : Valores de sesgo θ_j en las funciones de activación sigmoide de las neuronas de la red

Cuadro 4: Formulación matemática de la red neuronal ANN 3-5-1

ILUSTRACIONES

Ilustración 1: Curvas de distribución de lluvia acumulada en función del tiempo para distintas probabilidades de excedencia.

Ilustración 2: Método de elaboración y validación de una red neuronal artificial Dölling (2000).

Ilustración 3: red Neuronal ANN 3-5-1 entrenada con el simulador SNNS

Ilustración 4 Curvas de distribución de lluvia acumulada en función del tiempo observada y calculada con red neuronal ANN 3-5-1.

Ilustración 5: Tormenta generada por el modelo elaborado en Extend® con inclusión de Red Neuronal ANN 3-5-1.

Ilustración 6. Clasificador de tormentas en ambiente EXTEND®.

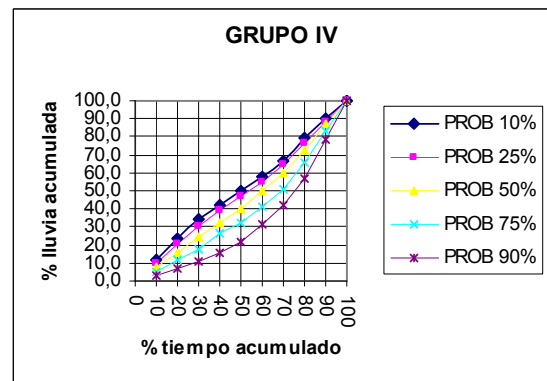

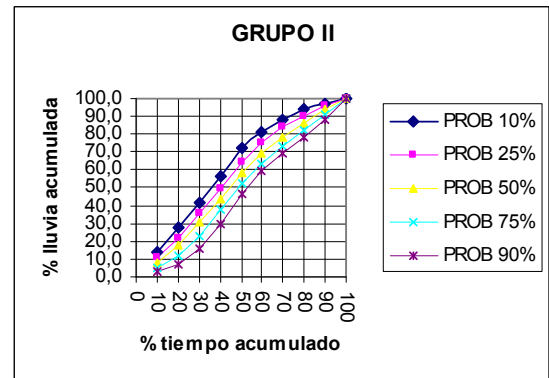



Ilustración 1: Curvas de distribución de lluvia acumulada en función del tiempo para distintas probabilidades de excedencia.

GRUPO I					
tiempo/Prob.	10%	25%	50%	75%	90%
10%	20	18	15	13	12
20%	20	17	16	13	11
30%	14	13	11	10	10
40%	9	10	9	8	8
50%	8	10	8	9	8
60%	7	6	9	9	9
70%	7	8	8	9	9
80%	6	6	7	10	10
90%	4	6	8	9	12
100%	5	6	9	10	11

GRUPO III					
tiempo/Prob.	10%	25%	50%	75%	90%
10%	13	10	6	3	2
20%	12	9	8	6	3
30%	10	10	8	6	5
40%	10	10	9	9	7
50%	9	9	11	11	8
60%	15	15	15	14	19
70%	13	14	14	16	17
80%	9	10	12	13	13
90%	4	7	10	11	12
100%	5	6	7	11	14

GRUPO II					
tiempo/Prob.	10%	25%	50%	75%	90%
10%	14	11	8	5	3
20%	14	11	10	7	4
30%	14	14	13	11	9
40%	14	14	13	15	14
50%	16	14	14	14	17
60%	9	11	11	11	12
70%	7	9	9	10	10
80%	6	6	8	9	9
90%	3	6	8	9	10
100%	3	4	6	9	12

GRUPO IV					
tiempo/Prob.	10%	25%	50%	75%	90%
10%	12	10	8	5	3
20%	12	11	8	7	4
30%	10	9	9	6	4
40%	8	9	7	8	5
50%	8	8	8	6	6
60%	8	8	10	9	9
70%	9	10	10	10	11
80%	12	11	13	15	15
90%	11	12	14	17	21
100%	10	12	13	17	22

Cuadro 1: Grupos de curvas de distribución típicas para tormentas

frontales en Chile.

Fases de elaboración de un ANN

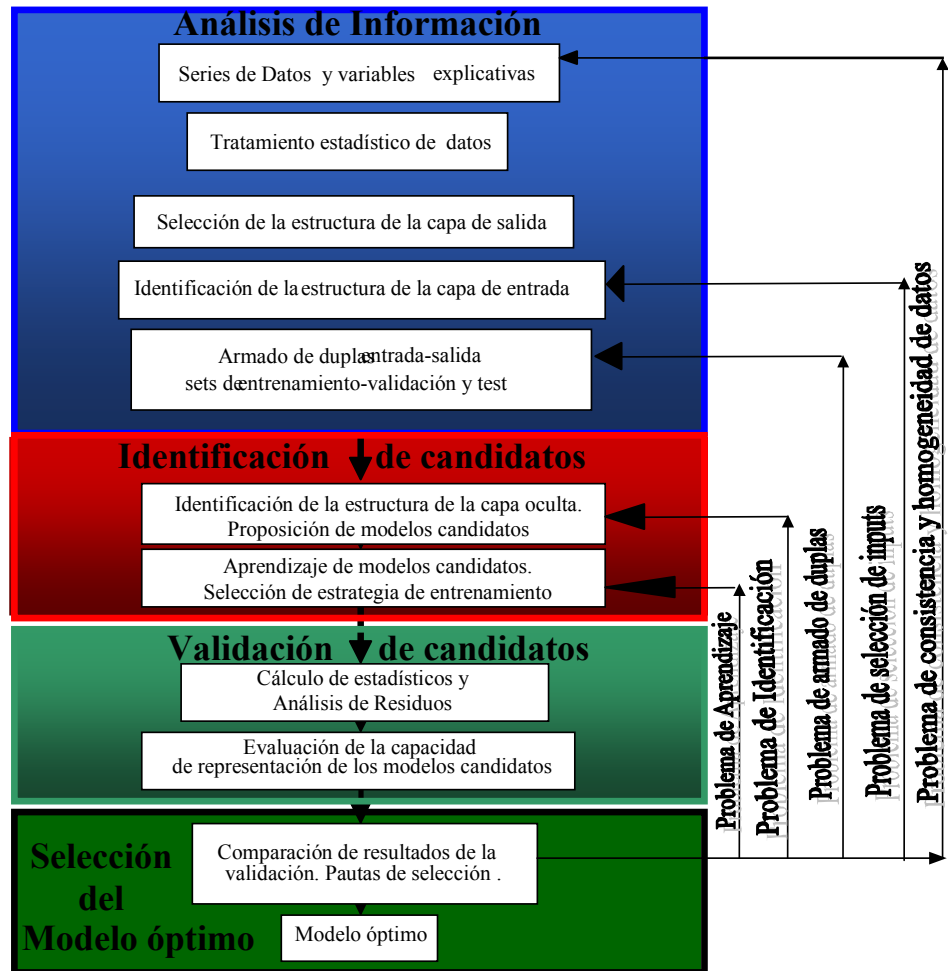


Ilustración 2: Método de elaboración y validación de una red neuronal artificial Dölling (2000).

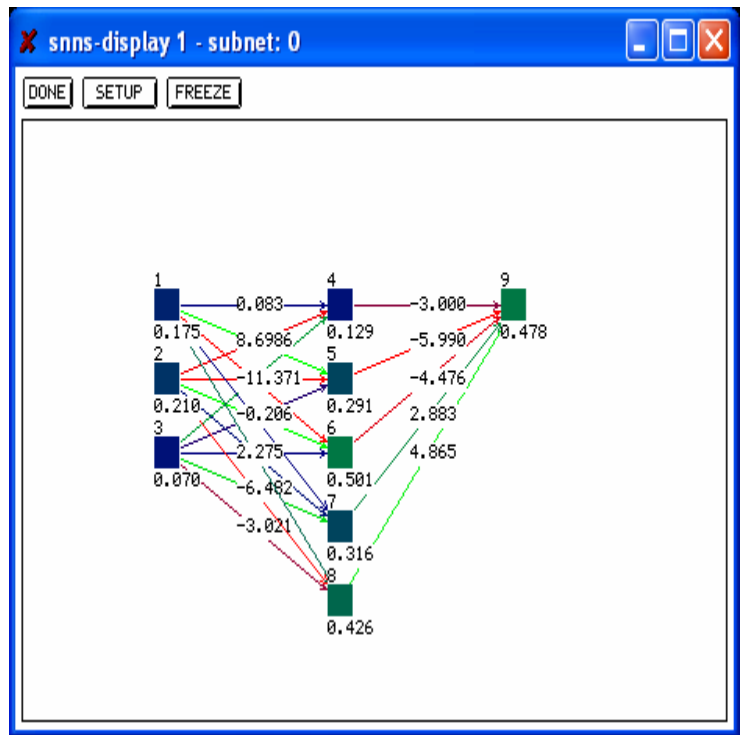


Ilustración 3: red Neuronal ANN 3-5-1 entrenada con el simulador SNNS

Neurona	Neuronas finales del enlace (j)				
Inicial (i)	4	5	6	7	8
1	0,08313	8,69785	-11,37134	-0,20567	2,27512
2	-4,77604	-10,11349	12,15274	0,40580	-6,48171
3	3,30788	-0,73184	0,06181	4,62173	-3,0213
9	-2,99958	-5,99028	-4,47618	2,88329	4,86482

Cuadro 2 : Pesos $w_{i,j}$ en los enlaces de la red

Neurona	1	2	3	4	5	6	7	8	9
Sesgo	0	0	0	-1,15145	-0,23726	-0,56105	-1,14585	0,87796	1,30207

Cuadro 3 : Valores de sesgo θ_j en las funciones de activación sigmoide de las neuronas de la red

$X_1 =$ identificador de Grupo

$X_2 =$ % de tiempo acumulado

$X_3 =$ % Probabilidad de excedencia

$$V_j = \sum_{i=1}^3 w_{i,j} \cdot X_i \quad \forall j = 4, 8$$

$y_j = \theta_j + V_j \quad \forall j = 4, 8$ valor de activación neurona oculta j

$$\sigma(y_j) = \frac{1}{1 + e^{-y_j}} \quad \forall j = 4, 8 \quad \text{valor de salida neurona oculta j}$$

$$V_k = \sum_{j=4}^8 w_{j,k} \cdot \sigma(y_j) \quad \forall k = 9$$

$y_k = \theta_k + V_k \quad \forall k = 9$ valor de activación neurona de salida 9

$$\sigma(y_k) = \frac{1}{1 + e^{-y_k}} \quad \text{valor de salida neurona de salida 9}$$

$o_9 = \sigma(y_9) =$ % lluvia acumulada

Cuadro 4: Formulación matemática de la red neuronal ANN 3-5-1

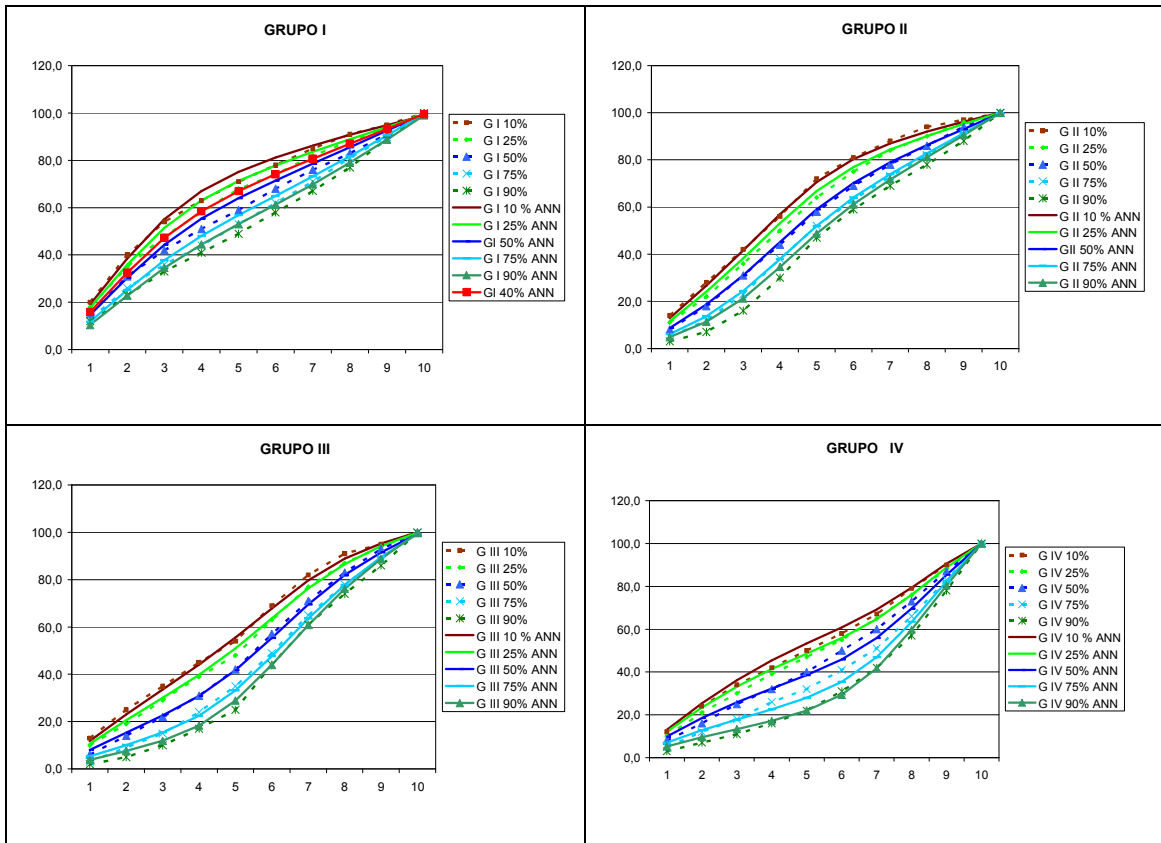


Ilustración 4 Curvas de distribución de lluvia acumulada en función del tiempo observada y calculada con red neuronal ANN 3-5-1.

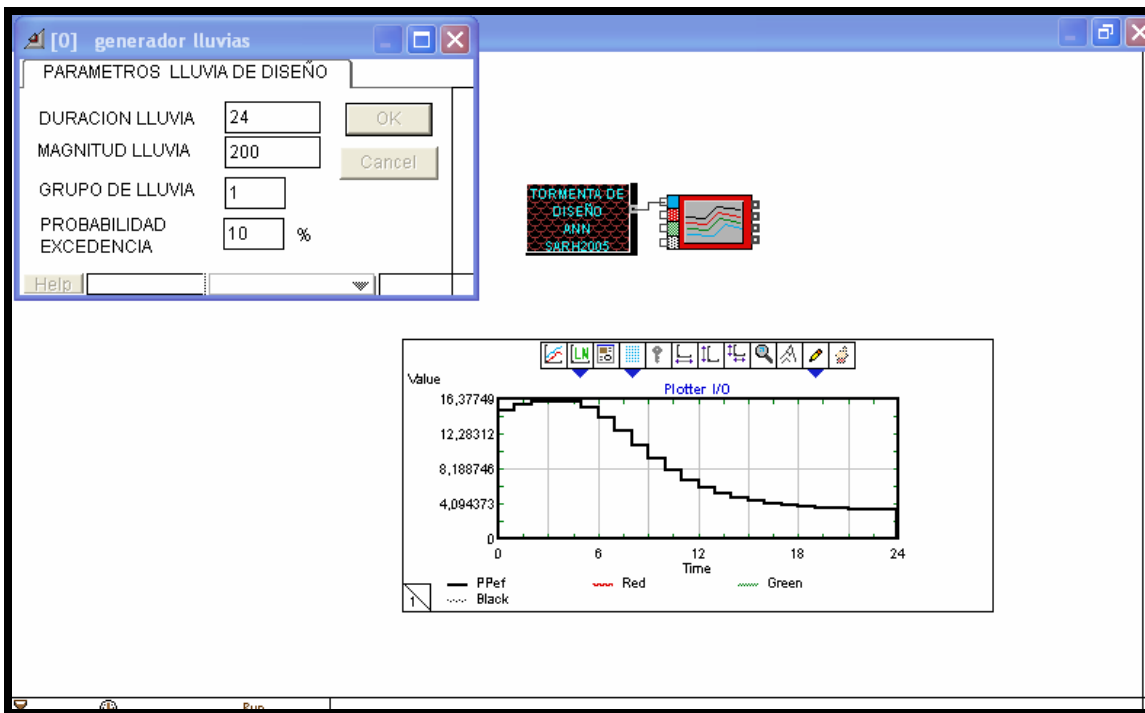


Ilustración 5: Tormenta generada por el modelo elaborado en Extend® con inclusión de Red Neuronal ANN 3-5-1.

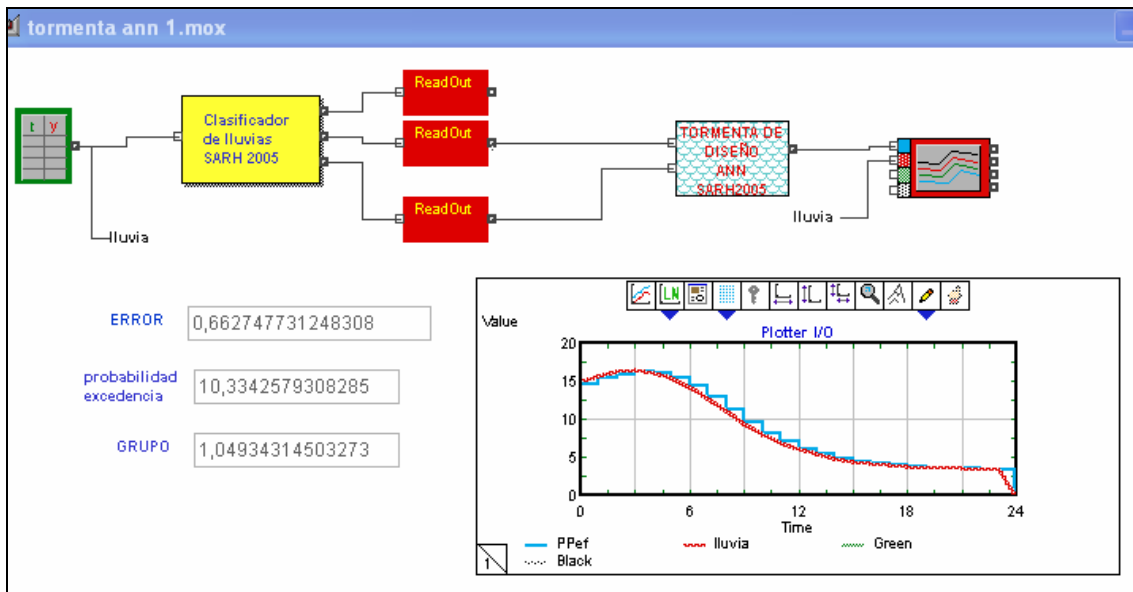


Ilustración 6. Clasificador de tormentas en ambiente EXTEND®.

Dirección Institucional de los Autores

Eduardo A. Varas

PhD. Ingeniero Civil

Profesor Pontificia Universidad Católica de Chile

Dpto. Ingeniería Hidráulica y Ambiental

Vicuña Mackenna 4860 – Santiago de Chile

evaras@ing.puc.cl

Tel: ++56-2-3544227

Oscar Raúl Dölling

Doctor en Ciencias de la Ingeniería- Ingeniero Civil

Profesor Universidad Nacional de San Juan

Dpto. Ingeniería Civil

Urquiza 91 Norte – C.P. 5400 – San Juan Argentina

odolling@unsj.edu.ar

Tel: ++54-0264-4211700 int: 381