



Modelo de redes funcionales orientado a pronóstico de crecidas en cursos de llanura del Gran Rosario, Santa Fe, Argentina

Functional network model oriented to water level forecasting in flatland streams of Gran Rosario, Santa Fe, Argentina

Scuderi, Carlos M. ¹ ✉ - Riccardi, Gerardo A. ^{1,2} - Zimmermann, Erik D. ^{1,3}

Recibido: 4 de febrero de 2015 • Aceptado: 25 de febrero de 2015

Resumen

Se presentan diferentes modelos de redes funcionales orientados a pronóstico de niveles, que fueron aplicados en cuencas del Gran Rosario. Las variables de entrada son precipitación y nivel vinculado a un tiempo t_0 , mientras que la salida está dada por niveles asociados a diferentes horizontes temporales t_{pi} . A partir de los eventos observados, en promedio 10 tormentas sobre 15 estaciones limnométricas, se calculan las combinaciones posibles para constituir dos grupos: uno para aprendizaje y otro para validación de la red. La evaluación de los modelos se efectúa por medio de distintos estadísticos, entre ellos: diferencia máxima en el nivel pico (D_{pico}), coeficiente de eficiencia de Nash-Sutcliffe (NS) y raíz del error cuadrático medio (RECM). Para los cuatro limnómetros presentados en este trabajo el valor de D_{pico} varía entre 0,04 m y 1,07 m, el de NS varía entre 0,99 y 0,75 y el de RECM fluctúa entre 0,03 m y 0,32 m, para tiempos de pronóstico desde 15 minutos hasta 6 horas respectivamente. Este tipo de modelos puede ser implementado en cualquier cuenca que posea datos de precipitación y niveles. Los resultados obtenidos hasta el presente son favorables, demostrando la capacidad de “aprendizaje” y simulación de eventos de estos modelos.

Palabras clave: modelos de caja negra, redes funcionales, pronóstico de niveles, cuencas de llanura.

Abstract

Different models of functional networks oriented to forecasting water levels, which were applied in watersheds of Gran Rosario are presented. The input variables are rainfall and water level linked to a time t_0 , while the output is given by water levels associated with different time horizons t_{pi} . From the observed events, an average of 10 storms over 15 gauge stations, the possible combinations are calculated to form two groups: one

1. Departamento de Hidráulica y Centro Universitario Rosario de Investigaciones HidroAmbientales

✉ cscuderi@fceia.unr.edu.ar

2. Investigador CIC-CIUNR. Universidad Nacional de Rosario

3. Investigador CONICET. Universidad Nacional de Rosario Facultad de Ciencias Exactas, Ingeniería y Agrimensura. Universidad Nacional de Rosario (UNR). Riobamba 250 bis. Rosario (2000). Santa Fe, Argentina

for learning and one for network validation. The evaluation of the models was carried out using different statistics, including: maximum difference in peak water level (D_{pico}), coefficient of efficiency Nash-Sutcliffe (NS) and root mean square error (RECM). For the four gauges presented here D_{pico} value varies between 0,04 m and 1,07 m, the NS varies between 0,99 and 0,75 and the RECM fluctuates between 0,03 m and 0,32 m, for forecasting time from 15 minutes to 6 hours respectively. Such models can be implemented in any basin that has rainfall and water levels data. The results obtained to date are auspicious, showing the ability of "learning" and event simulation of these models.

Keywords: black box models, functional networks, level water forecast, plain watersheds.

INTRODUCCIÓN

Las inundaciones son uno de los desastres naturales de mayor impacto, que provocan miles de muertes, afectados y cuantiosos daños materiales con pérdidas millonarias. Las mismas se producen prácticamente en la totalidad de los países del mundo, razón por la cual es necesario anticiparse a su ocurrencia o al menos atenuar sus consecuencias (Berga Casafont, 1990; Dueñas Molina, 1995). El manejo actual de las inundaciones requiere un enfoque multidisciplinario donde se integren aspectos técnicos, sociales, económicos y políticos (Gruntfest, 1995). Dentro de la ingeniería, las medidas destinadas al control de las inundaciones pueden ser estructurales o no estructurales (Berga Casafont, 1995). Las primeras intervienen durante la formación y ocurrencia del evento al modificar las características hidrológicas e hidráulicas de la cuenca, mientras que las segundas plantean la convivencia del hombre y del agua en un mismo espacio geográfico con el fin de minimizar los daños derivados de las inundaciones. En la actualidad, se recomienda el empleo conjunto de ambos tipos de medidas (Berga Casafont, 1995; Lekkas et al., 2004).

El pronóstico de caudales o niveles en cursos de agua, que se encuentra entre las medidas no estructurales, consiste en estimar con la adecuada anticipación la evolución temporal de dichas variables hidráulicas con el fin de poder ejecutar las medidas tendientes a proteger a la población y a la infraestructura en caso de situaciones con riesgo de inundación. Dicho pronóstico se efectúa a partir de un modelo matemático que puede ser físicamente basado o por el contrario de caja negra. Los modelos físicamente basados tienden a representar con rigurosidad los procesos físicos que se desarrollan en una cuenca durante la ocurrencia de un proceso de tormenta - crecida (Ogden et al., 2000) a través del planteo de las ecuaciones de conservación de masa y momentum; hecho que demanda gran cantidad de datos de entrada, recurso computacional y tiempo de cálculo. En cambio los modelos de tipo caja negra se basan en una concepción diferente: dado que el pronóstico de niveles (y/o caudales) en tiempo real requiere disponer de resultados lo más aproximados en el menor tiempo posible, es válido ignorar ciertos aspectos y componentes físicos del sistema estudiado (Hsu et al., 1995).

Estos últimos relacionan la precipitación con el nivel (y/o caudal) en los cursos de agua de forma muy simplificada, siendo precisamente esta sencillez lo que hace que ganen popularidad en el pronóstico de crecidas. Diferentes modelos de caja negra se utilizan para pronóstico asociados al estudio de inundaciones, entre ellos las redes neuronales (RN) han comenzado a emplearse desde hace aproximadamente unos 15 años (Thirumalaiah y Deo, 1998; Campolo et al., 1999; Bruen y Yang, 2005). Bruen y Yang (2005) destacan tres propiedades de las mismas: (1) la habilidad para aprender a partir de los datos de

entrada, (2) la potencialidad para describir el comportamiento de sistemas no lineales complejos en forma precisa, por ej. el proceso de transformación lluvia - caudal (o lluvia - nivel), y (3) no requerir a priori el conocimiento detallado del proceso a representar. Sin embargo, existe un consenso generalizado (Dawson y Wilby, 1998; Maier y Dandy, 2000) en que las RN no permiten extrapolar resultados más allá de los datos de entrada con las que fueron entrenadas. Dawson y Wilby (1998) junto con Thirumalaiah y Deo (1998) concuerdan en que la selección del período de aprendizaje y de validación afecta la capacidad de pronóstico de la red, mientras que Shrestha et al. (2005) observan que la red puede funcionar muy bien en aprendizaje siendo incapaz de generalizar resultados más allá del rango de datos de entrada.

El objetivo de este estudio es evaluar el desempeño de diferentes modelos de redes funcionales (RF), que son una generalización de las redes neuronales (Castillo y Gutiérrez, 1998), aplicados al pronóstico de niveles en distintas secciones características de los arroyos Ludueña y Saladillo, situados en la zona del Gran Rosario (sur de la provincia de Santa Fe, Argentina). Para ello se proponen tres familias de funciones: polinómica, exponencial y de Fourier, con diferentes grados de aproximación. Como variables de entrada son utilizadas la precipitación y el nivel limnimétrico para un tiempo t_0 con el objetivo de pronosticar como variable de salida los niveles limnimétricos para diferentes tiempos de pronóstico t_{pi} , que comprenden horizontes temporales desde 15 minutos hasta 6 horas de anticipación. Algunos resultados preliminares de este trabajo, que forman parte de los estudios de doctorado que están siendo llevados a cabo por el primer autor, se presentan en Scuderi et al. (2011) y en Scuderi et al. (2012).

MATERIALES Y MÉTODOS

La zona centro - este de la República Argentina, conocida como Llanura Pampeana, posee suelos de excelente calidad para agricultura y ganadería y dispone de fuentes seguras de agua para consumo humano. Estas condiciones alientan el establecimiento de grandes urbes que tienden a concentrar un elevado número de personas en espacios reducidos (Tucci y Bertoni, 2003) y de esta forma incrementar la presión sobre los conglomerados urbanos y sus sistemas.

La región del Gran Rosario, tercera metrópoli del país, se encuentra situada al sur - este de la provincia de Santa Fe y a la vera del río Paraná; presentando un relieve sumamente plano con escasa pendiente y suelo arcilloso - limoso con permeabilidad moderada a moderadamente lenta (INTA, 1983). Estos hechos particulares de características naturales sumados al incremento en la densidad poblacional a través de emprendimientos urbanísticos (esencialmente por la construcción de barrios cerrados) y a la impermeabilización de los suelos debido a prácticas

agrícolas intensivas (principalmente por el cultivo de soja), favorecen la generación de un mayor volumen de escurrimiento superficial junto con una disminución en los tiempos de respuesta de las cuencas. La zona del Gran Rosario ha sufrido el impacto periódico de diferentes eventos pluviométricos intensos (en las décadas de 1940 y de 1960, y en los años 1986, 2007 y 2012), que generaron inundaciones con diferente grado de severidad, provocando grandes pérdidas económicas y en algunos casos hasta la pérdida de vidas humanas. Estos hechos han llevado a la ejecución de obras de conducción y alivio por parte de las autoridades públicas. Las condiciones descritas anteriormente favorecen un escenario cada vez más vulnerable a las inundaciones, razón por la cual la protección de la población (generalmente de sectores marginados que ocupan las adyacencias de los cursos de agua o sectores deprimidos, ambos de escaso valor inmobiliario) como de infraestructura pública y de bienes materiales cobra cada vez mayor importancia.

Cuencas en estudio

Las cuencas de los arroyos Ludueña y Saladillo (Figura 1) se sitúan en el sureste de la provincia de Santa Fe (República Argentina). El clima de la región es templado subtropical sin estación seca (verano cálido) o Cfa (según la clasificación climática de Köppen). La precipitación media anual es de 1014,4 mm (estación Rosario Aero, SMN, serie 1936-2013), registrándose el 70% en el período primavera-verano (octubre a marzo). La temperatura media anual es de 17,5 °C, mientras que la humedad relativa media anual es de 72% (estación Rosario Aero, SMN, serie 1973-2012). Ambas cuencas presentan una fuerte intervención antrópica, encontrándose atravesadas por numerosas vías de comunicación (rutas y ferrocarriles); mientras que la agricultura constituye el principal uso del suelo, destacándose la producción de soja, maíz y trigo.

La cuenca del arroyo Ludueña se ubica entre los paralelos 32° 45' y 33° 07' S y los meridianos 60° 41' y 61° 06' O. La red hídrica se compone del arroyo Ludueña y los canales Ibarlucea y Salvat con sus tributarios, cuya longitud total es de 140 km; sin embargo en época de lluvias la gran cantidad de pequeños cursos intermitentes acrecienta dicha longitud hasta los 370 km. El área de aporte es de 740 km² y su elevación varía entre 70 m y 18 m sobre el nivel del mar, con pendiente media del orden de 1,5 m.km⁻¹. El caudal base del arroyo Ludueña es de 0,5 m³.s⁻¹, alcanzando los 80 m³.s⁻¹ en crecidas ordinarias y caudales superiores a los 400 m³.s⁻¹ en eventos extraordinarios con recurrencia mayor a los 50 años (Riccardi et al., 2002).

La cuenca del arroyo Saladillo se ubica entre los paralelos 32° 59' y 33° 37' S y los meridianos 60° 36' y 61° 54' O. La red hídrica principal se compone del arroyo Saladillo, el arroyo La Candelaria y el canal Sanford-Arequito, entre otros. La longitud del curso principal (arroyo Saladillo) es de 145 km, mientras que la red total de cursos (considerando los afluentes de los anteriores) es de 359 km. El área de aporte es de 3150 km² y su elevación varía entre 115 m y 18 m sobre el nivel del mar. El caudal base del arroyo Saladillo es de 1 m³.s⁻¹, alcanzando los 1140 m³.s⁻¹ para eventos extraordinarios (Riccardi et al., 2008).

Datos de precipitación y niveles

La autoridad hídrica provincial, el Ministerio de Aguas, Servicios Públicos y Medio Ambiente, MASPMA, instaló en el año 2007 una red telemétrica de sensores de precipitación y niveles en cada una de las cuencas en estudio. Ambas redes se componen de 10 sensores pluviométricos (4 en Ludueña y 6 en Saladillo) y de 18 sensores limnimétricos (11 en Ludueña y 7 en Saladillo).

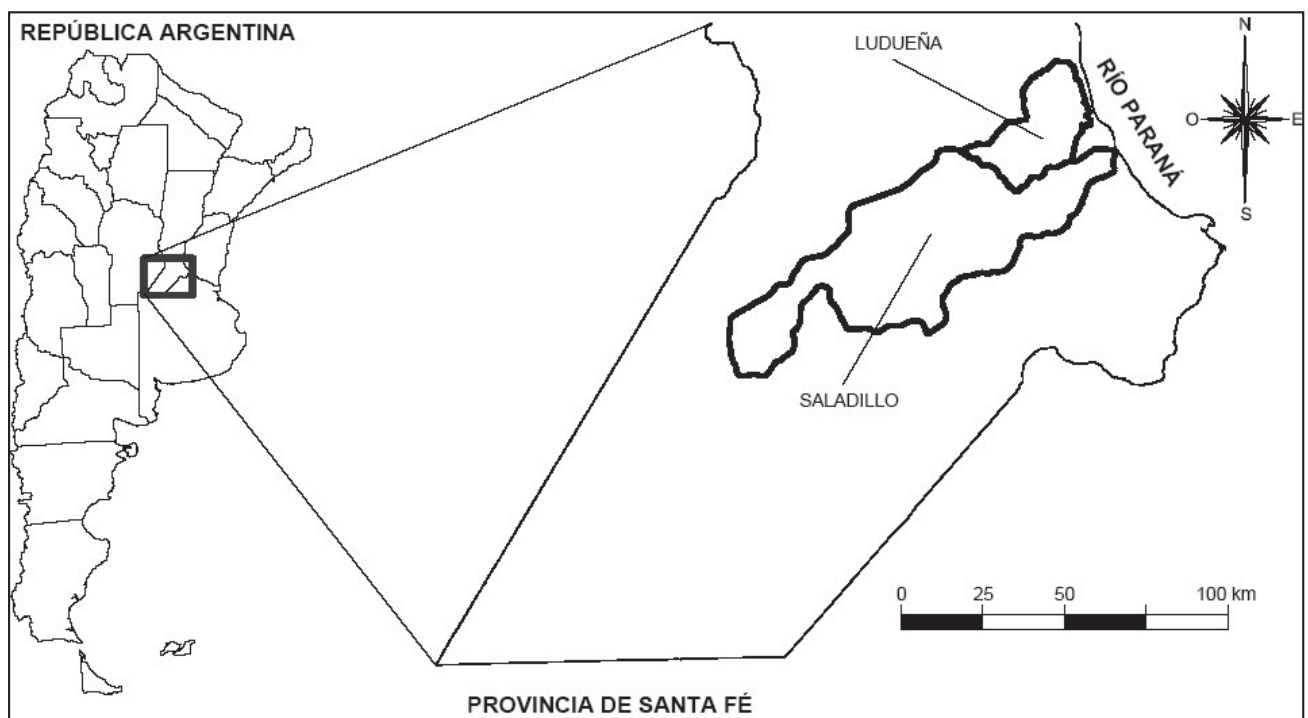


Figura 1. localización esquemática de las cuencas de los arroyos Ludueña y Saladillo.

En la Figura 2 se señala la posición de los pluviómetros en cada cuenca mediante un triángulo, donde además en línea continua gruesa se exhiben los límites de cuenca, en línea de trazo los polígonos de Thiessen y línea continua delgada la red de cursos. En la Figura 3 se presenta la posición de los limnímetros dentro de cada cuenca mediante círculos, donde además en línea continua negra se exhiben las subcuencas y la red de cursos. Los datos son registrados cada 15 minutos, siendo luego transmitidos automáticamente a una estación central, donde se almacenan en un servidor y se disponibilizan en estado crudo mediante una página web. El acceso a los datos fue realizado manualmente desde la página web, gracias a la cesión de los mismos por parte de la autoridad hídrica provincial. El período de datos utilizado abarca desde julio de 2007 hasta junio de 2012, inclusive, siendo empleada la estación Rosario AERO (dependiente del Servicio Meteorológico Nacional, SMN) para el contraste de los datos pluviométricos.

El contraste entre lluvias registradas y la estación Rosario AERO, mediante dobles acumulaciones, arroja lo siguiente: las estaciones registran por debajo de la estación de testeo en un rango entre 28% y 46% (valor medio 35%). No obstante cuando se compara evento por evento, con un total de 20 tormentas, el contraste produce una diferencia, también en

menos, que fluctúa entre 11% y 28% (valor medio 18%) con un coeficiente de determinación $r = 0,78$. Respecto de los registros limnimétricos, algunos de ellos fueron cotejados con reglas en ciertas secciones; no obstante los equipos haber estado sometidos a situaciones de vandalismo. Un análisis más profundo sobre el desempeño de los sensores puede ser consultado en Scuderi et al. (2009).

Realizada la verificación de calidad de los datos, se efectuaron una serie de procedimientos complementarios: (1) cada una de las cuencas fue dividida en subcuencas en correspondencia con el área de aporte a cada sensor limnimétrico, empleando curvas de nivel espaciadas cada 1,25 m y la traza de los diferentes terraplenes viales y ferroviarios; (2) fue estimada el área de influencia de cada sensor pluviométrico mediante polígonos de Thiessen; (3) en función de las áreas obtenidas en los dos puntos anteriores se calculó el porcentaje de contribución de cada sensor pluviométrico a cada subcuenca a través de la intersección de ambas superficies.

Como etapa final fueron compatibilizados los datos de precipitación y niveles registrados, considerando como eventos válidos aquellos que cumplieran los siguientes requisitos establecidos en forma arbitraria: (a) la precipitación caída en la subcuenca supera los 10 mm (calculada en función del aporte

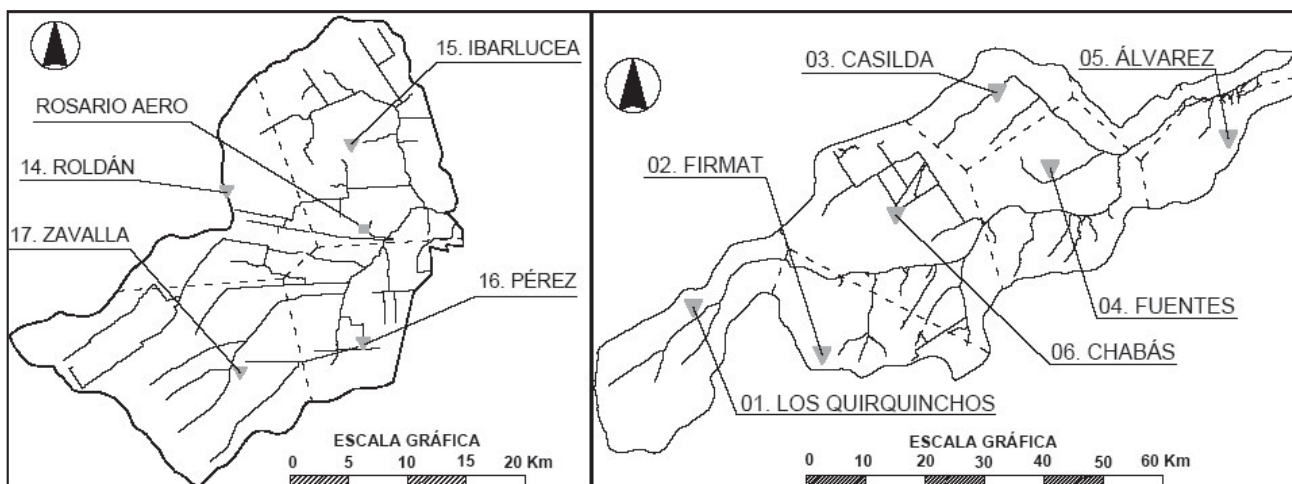


Figura 2. Estaciones pluviométricas, (izq) Ludueña y (der) Saladillo.

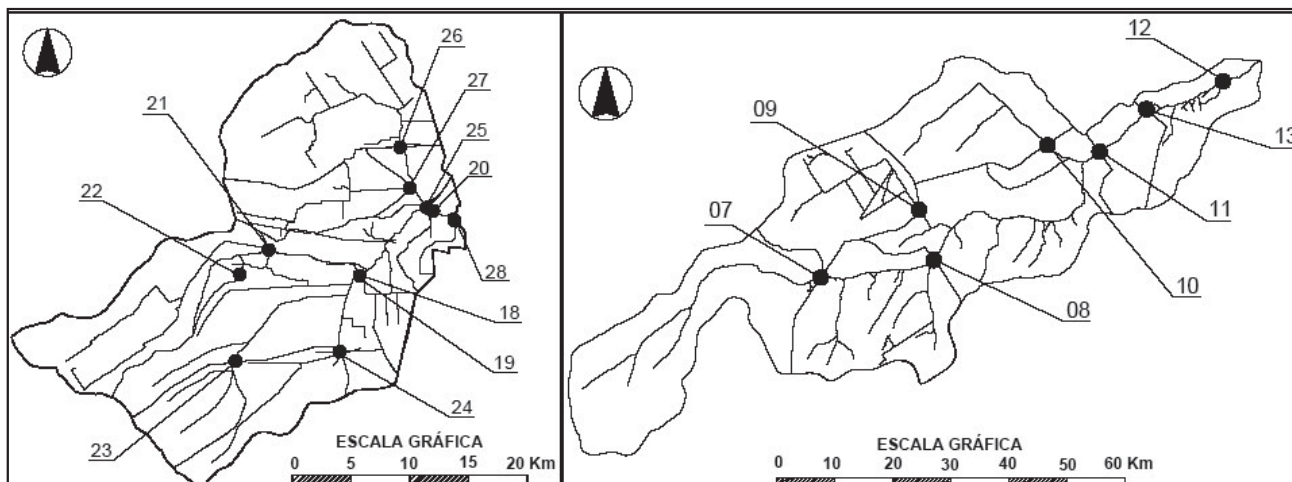


Figura 3. Estaciones limnimétricas, (izq) Ludueña y (der) Saladillo.

proporcional de cada pluviómetro) y (b) el nivel de agua en la sección estudiada registra un incremento mayor al 15% de la diferencia máxima entre nivel pico y nivel base de todos los eventos medidos en la sección. Se obtuvieron diferentes cantidades de eventos válidos para cada subcuena, entre 4 y 15 tormentas, con un valor medio de 10 tormentas por subcuena.

Modelo de redes funcionales

Los elementos componentes de una red funcional (RF), Figura 4, son (Castillo, 1988): a) una capa de unidades de

entrada, que contiene los datos de entrada; b) una capa de unidades de salida, es la última capa y contiene los datos de salida; c) una o varias capas de neuronas o unidades de cómputo, donde se evalúa un conjunto de valores de entrada provenientes de la capa anterior y produce un conjunto de valores de salida a la próxima capa; d) un conjunto de enlaces dirigidos, que conectan la capa de entrada a la primera capa de neuronas, neuronas de una capa a otras de la próxima capa, y la última capa de neuronas con la capa de salida. La dirección de la información se produce en una única dirección, desde la capa de entrada hacia la capa de salida.

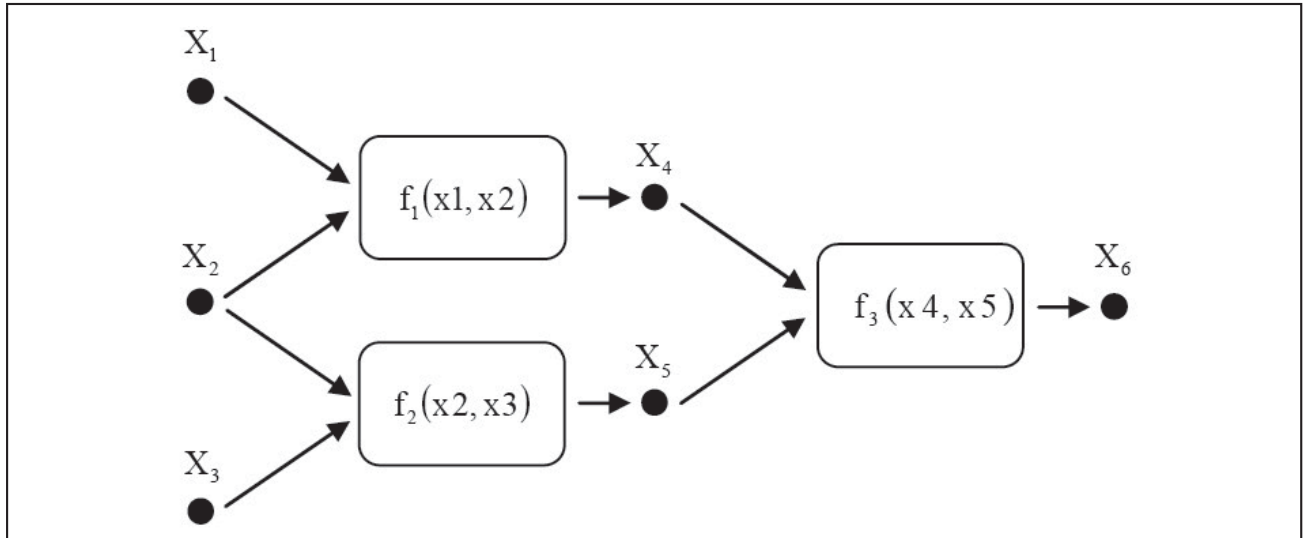


Figura 4. Esquema típico de una RF (Fuente: Bruen y Yang, 2005).

Se propone emplear un esquema de red funcional simple separable con dos variables de entrada x e y (precipitación acumulada cada 15 minutos y nivel para un tiempo t₀) y una de salida z (nivel para diferentes tiempos t_{pi}). Como su nombre lo indica, en este tipo de red se considera el efecto de cada una de las variables de entrada en forma separada. La relación matemática entre las variables x, y y z puede ser establecida según la ecuación (1) (Bruen y Yang, 2005):

$$z = F(x, y) = \sum_{i=1}^n f_i(x)g_i(y) \tag{1}$$

donde x e y son las variables de entrada, z es la variable de salida, f_i y g_i son las funciones neuronales a ser calculadas y n es el orden máximo de la función neuronal. El proceso de entrenamiento de la red consiste en obtener las funciones f y g a partir de los datos de entrada, siendo en la práctica equivalente al proceso de calibración de un modelo hidrológico convencional. Las funciones neuronales f y g pueden ser expresadas según la ecuación 2 (Bruen y Yang, 2005):

$$\hat{f}(x) = \sum_{j=1}^p a_j \varphi_j(x) \quad , \quad \hat{g}(y) = \sum_{j=p+1}^{p+q} a_j \varphi_{j-p}(y) \tag{2}$$

en que los coeficientes a_j son los parámetros de las funciones neuronales φ_j que serán aprendidos durante el proceso de entrenamiento de la red, y p y q son los órdenes de cada familia de funciones. El objetivo durante el entrenamiento es minimizar una función de error que contempla la diferencia entre el valor calculado por el modelo y el valor medido. La función objetivo FO usada es la suma de los errores cuadráticos. Para lograr una representación única de la red es necesario dar un valor inicial a alguna de las funciones neuronales. En este caso pueden utilizarse cualquiera de las dos condiciones iniciales: f(x₀) = u o g(y₀) = v. Este término se agrega a la función objetivo, quedando como se presenta en la ecuación 3 (Bruen y Yang, 2005):

$$FO = \sum_{i=1}^k \left[z_i - \sum_{j=1}^p a_j \varphi_j(x_i) - \sum_{j=p+1}^{p+q} a_j \varphi_{j-p}(y_i) \right]^2 + c \left[\sum_{j=1}^p a_j \varphi_j(x_0) - u \right] \tag{3}$$

siendo k la cantidad de datos de entrenamiento y c una constante. La resolución de la función objetivo FO es equivalente a resolver un conjunto de derivadas de FO respecto de los parámetros a_j y del multiplicador c, obteniendo un sistema de p+q+1 ecuaciones lineales donde los coeficientes a calcular son los parámetros a_j y la constante c. Para conocer con mayor detalle el desarrollo matemático del modelo se debe consultar a Bruen y Yang (2005).

Se adopta la utilización de tres familias funcionales: polinómica, exponencial y de Fourier; y además se plantea usar cuatro modificaciones de las mismas (tres exponenciales y una de Fourier) por lo que en definitiva se obtienen siete familias funcionales a ser estudiadas (Tabla 1).

Tabla 1. Familias funcionales testeadas.

Familia funcional	Términos considerados
1. polinómica	1, x, x ² , ... x ⁹
2. exponencial A	1, e ^x , e ^{-x} , e ^{2x} , e ^{-2x} , ... e ^{5x}
3. exponencial B	1, e ^x e ^{-x} , e ^{2x} e ^{-2x} , ... , e ^{9x} e ^{-9x}
4. exponencial C	1, e ^x , e ^{2x} , ... , e ^{9x}
5. exponencial D	1, e ^{-x} , e ^{-2x} , ... , e ^{-9x}
6. Fourier A	1, senx, cos x, sen2x, cos2x, ... , sen5x
7. Fourier B	1, senx cosx, sen2x cos2x, ... , sen9x cos9x

Implementación del modelo

En este tipo de modelos los datos de entrada son de fundamental importancia (*Dawson y Wilby, 1998*), por esta razón se calculó para cada estación limnimétrica la totalidad de combinaciones de tormentas en función de los eventos válidos. Cada combinación se divide a su vez en dos grupos complementarios: uno para aprendizaje y otro para validación. Posteriormente se propone una restricción a la cantidad de muestras a emplear, consistente en descartar aquellas donde la cantidad de tormentas utilizadas en aprendizaje y en validación sea muy dispar. El criterio es quitar las muestras donde el número de tormentas para aprendizaje o validación es inferior al 50% de la cantidad de tormentas del grupo complementario; si tomamos

como ejemplo 10 tormentas se descartan las muestras que utilizan solamente 1, 2 o 3 tormentas en alguno de los grupos. Una vez generadas las muestras, según el limnómetro considerado, se aplicaron los siete modelos de redes funcionales. Se debe tener en cuenta que en cada uno de estos modelos de redes fueron considerados 9 grados de aproximación diferentes (Tabla 1); siendo planteados para nueve horizontes temporales diferentes: 15, 30 y 45 minutos y 1, 2, 3, 4, 5 y 6 horas.

RESULTADOS

Debido a la elevada cantidad de muestras, los resultados fueron evaluados a través de diferentes estadísticos; en este sentido existe una falta de acuerdo entre los investigadores respecto a un criterio único para la evaluación de modelos. Por esta razón, se calcularon 12 estadísticos, entre ellos la diferencia máxima en el nivel pico [m], la raíz del error cuadrático medio [m], el coeficiente de eficiencia del modelo de Nash-Sutcliffe (que son los tres indicadores que se presentan a continuación), diferencias máximas y mínimas en el limnograma completo, diferentes coeficientes de correlación, desvío medio y los coeficientes a y b de la recta de regresión.

A continuación, se presentan algunos resultados correspondientes a dos sensores limnimétricos por cuenca, seleccionados por ser los que registraron mayor cantidad de tormentas. Para la cuenca Saladillo, se muestran los sensores 10 y 13, el primero con 11 tormentas y el segundo con 10 (Figura 5); mientras que para la cuenca Ludueña, se exhiben los sensores 22 y 28, ambos con 15 tormentas (Figura 6). En dichas figuras se representan en negro los estadísticos correspondientes a la etapa de aprendizaje y en azul a la de validación, en función del tiempo de pronóstico. Cada una de estas gráficas fue confeccionada con el mejor resultado producto de la aplicación de las siete familias funcionales con sus 9 grados de aproximación.




Figura 5. Cuenca Saladillo, sensores 10 y 13: (izq) Dif_P, (centro) RECM, (der) eficiencia NS.




Figura 6. Cuenca Ludueña, sensores 22 y 28: (izq) Dif_P, (centro) RECM, (der) eficiencia NS.

De la Figura 5 se observa que, en promedio, para el sensor 10 se obtiene una diferencia en el pico de +0,07 m tanto en aprendizaje como en validación; mientras que para el sensor 13 se tiene una diferencia en el pico de +0,04 m en aprendizaje y de +0,07 m en validación. Respecto a la raíz del error cuadrático medio se observan valores para aprendizaje y validación de 0,14 m y de 0,16 m para el sensor 10 y de 0,14 m y de 0,15 m para el sensor 13, respectivamente. En cuanto a la eficiencia del modelo NS los valores obtenidos para aprendizaje y validación fueron, para el sensor 10 de 0,94 y de 0,93 y para el sensor 13 de 0,97 y de 0,96, respectivamente.

Analizando la Figura 6 se verifica que en promedio, para el sensor 22 se obtiene una diferencia en el pico de +0,03 m en aprendizaje y de +0,07 m en validación; mientras que para el sensor 28 se observa una diferencia en el pico de +0,34 m en aprendizaje y de +0,40 m en validación. Respecto a la raíz del error cuadrático medio se tienen valores de 0,08 m para calibración y de 0,07 m para validación (sensor 22) y de 0,12 m para calibración y de 0,13 m para validación (sensor 28). En cuanto a la eficiencia del modelo NS, los resultados verificados fueron, para el sensor 22, 0,95 y 0,94 para aprendizaje y validación, respectivamente. Mientras que para el sensor 28 se obtuvieron valores de NS de 0,92 y de 0,90 para aprendizaje y validación, respectivamente. Los resultados citados anteriormente se encuentran consignados en la Tabla 2.

Si ahora se consideran los 4 sensores en forma conjunta, respecto de la evolución temporal del parámetro RECM (Figuras 5 y 6) puede observarse que, para tiempos de pronóstico de hasta 1 hora los valores se encuentran por debajo de 0,10 m, para tiempos de antecedencia de hasta 4 horas ascienden a 0,25 m y para 6 horas de antelación trepan hasta 0,32 m. De la misma forma, si ahora se estudia la variación del parámetro de eficiencia NS se verifica que, para tiempos de pronóstico de hasta 1 hora los valores se encuentran por arriba de 0,97, para tiempos de antecedencia de hasta 4 horas son mayores a 0,82 y para 6 horas de antelación los valores superan 0,75. Finalmente, si ahora se analiza la diferencia en el pico, se observa que hasta 3 horas de pronóstico se produce el aumento sostenido de la misma hasta llegar a un valor de 0,98 m, mientras que curiosamente para 4 y 5 horas de antecedencia se obtienen diferencias sustancialmente menores (0,78 m y 0,21 m respectivamente). Para 6 horas de pronóstico las diferencias ascienden a 1,07 m.

En las Figuras 7 y 8, se presentan los resultados en niveles pronosticados para dos sensores. La Figura 7 muestra los niveles para aprendizaje y validación del sensor 10 para tiempos de pronóstico de 1 hora en la parte superior y de 6 horas en la parte inferior asociados a la muestra 1787 (7 tormentas para aprendizaje y 4 para validación). Mientras que la Figura 8 exhibe los mismos horizontes de pronóstico para el sensor 28, asociados con la muestra 29040 (10 tormentas para aprendizaje y 5 para validación). Las líneas verticales negras separan las diferentes tormentas.

Tabla 2. Resumen de indicadores estadísticos medios según sensor.

Sensor	DifP_apr[m]	RECM_apr [m]	NS_apr [adim]	DifP_val[m]	RECM_val [m]	NS_val [adim]
10 (Saladillo)	0,07	0,14	0,94	0,07	0,16	0,93
13 (Saladillo)	0,04	0,14	0,97	0,07	0,15	0,96
22 (Ludueña)	0,03	0,08	0,95	0,07	0,07	0,94
28 (Ludueña)	0,34	0,12	0,92	0,40	0,13	0,90

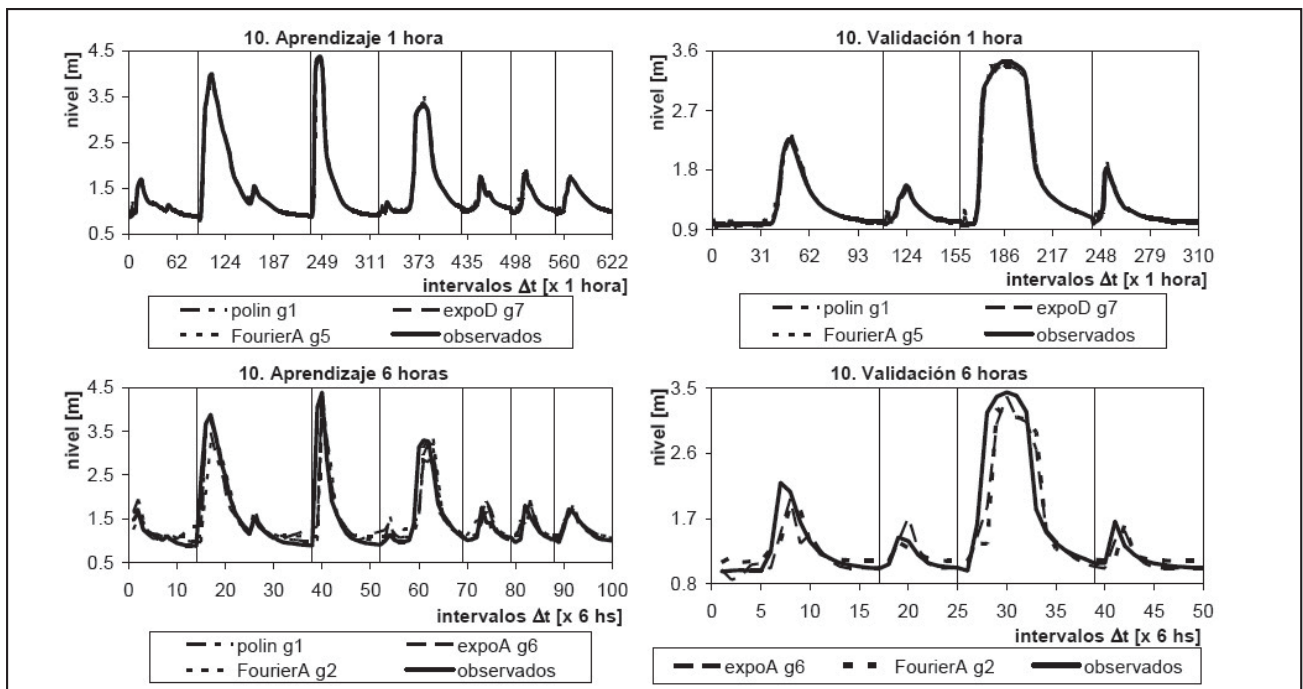


Figura 7. Cuenca Saladillo, sensor 10, muestra 1787: (izq) aprendizaje, (der) validación.

CONCLUSIONES

Analizando los indicadores estadísticos presentados (Figuras 5 y 6 y Tabla 2) se verifica la tendencia general de que a medida que el horizonte temporal se incrementa, desmejoran los índices considerados. En el caso del parámetro RECM, se obtuvieron en promedio valores que fluctúan entre 0,03 m y 0,32 m; mientras que para la eficiencia NS, se verificaron en promedio valores que variaron entre 0,99 y 0,75; en tanto que respecto de la diferencia en el pico, se registraron valores entre 0,04 m y 1,07 m; para 15 minutos a 6 horas de tiempo de pronóstico respectivamente. Esto pone de manifiesto el hecho de que al ampliar el tiempo de pronóstico, aumentan las incertidumbres asociadas al proceso de transformación lluvia – escurrimiento superficial, con la consecuente desmejora de los pronósticos.

Contrastando las etapas de aprendizaje y de validación se observa que, en general, la mayoría de los estadísticos presentan resultados levemente mejores en la primera. Dado que los parámetros de la red son calculados a partir de los datos de entrada en la fase de aprendizaje, es lógico pensar que la red presentará un mejor comportamiento frente a dicho juego de datos de entrada antes que a un segundo juego de datos para el cual se deberá verificar su desempeño.

El empleo de medidas estructurales en conjunto con medidas no estructurales parece ser el método más eficaz en la lucha contra las inundaciones. Dentro de las segundas, el pronóstico de crecidas brinda una herramienta de ayuda en la toma de decisiones por parte de las autoridades.

La confiabilidad en el registro de datos es de vital importancia para el buen desempeño de los modelos analizados, ya que son altamente dependientes de los datos de entrada. Es importante tener una serie continua de datos para aumentar la robustez de los pronósticos, para lo cual se recomienda el seguimiento constante del funcionamiento de los sensores. Los modelos de caja negra no demandan gran variedad de datos para su puesta en funcionamiento; por lo que su aplicación resulta relativamente sencilla en otras cuencas, una vez programada la red funcional.

Aunque la cantidad de eventos registrados no es muy elevada, media de 10 tormentas por subcuenca, los resultados obtenidos son alentadores; evidenciando la capacidad de aprendizaje y reproducción de eventos de este tipo de modelo. En caso de incrementarse el número de eventos, su incorporación al modelo de pronóstico es sumamente sencilla dada la arquitectura planteada del software; permitiendo reajustar los parámetros del mismo.

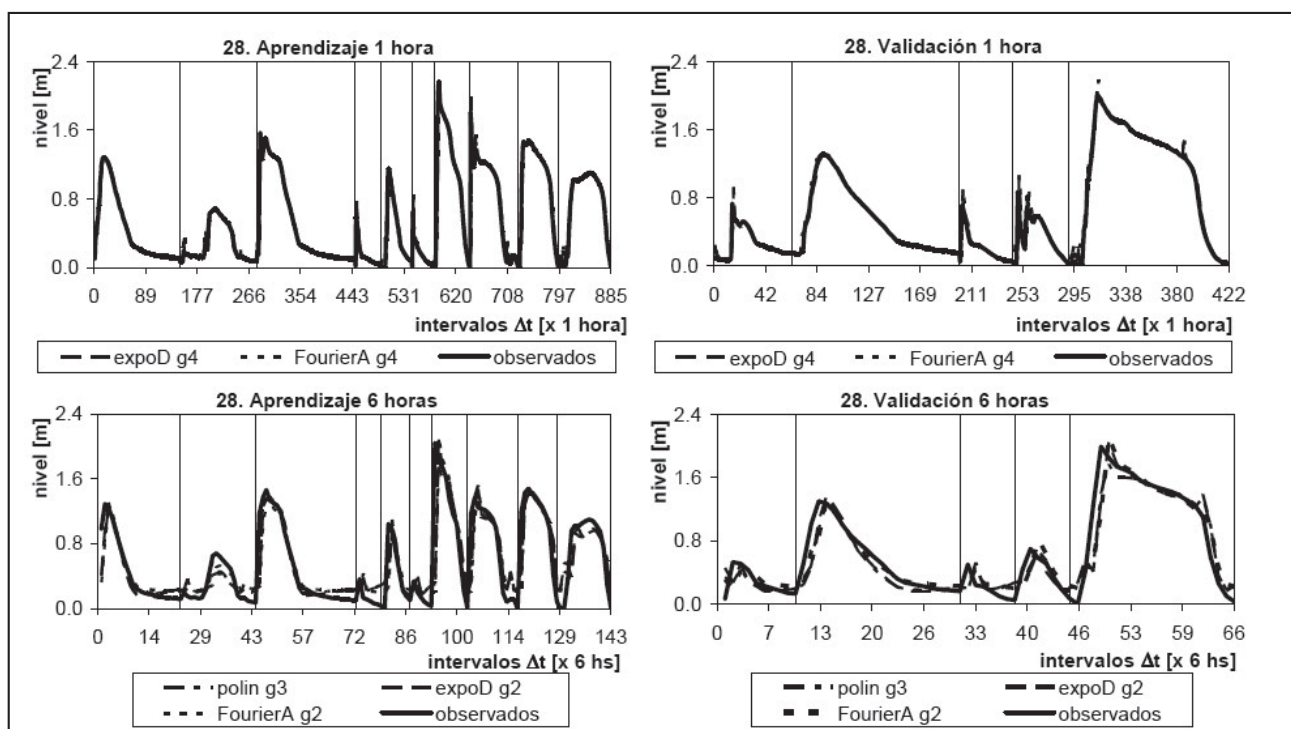


Figura 8. Cuenca Ludueña, sensor 28, muestra 29040: (izq) aprendizaje, (der) validación.

TRABAJOS CITADOS EN EL TEXTO

BERGA CASAFONT, L., 1990.

La problemática de las inundaciones. Actuaciones estructurales y no estructurales frente a las avenidas. *Revista de Obras Públicas*, diciembre 1990, p. 17-23.

BERGA CASAFONT, L, 1995.

Aplicación de los sistemas de previsión de avenidas. Experiencias y problemática. *Jornadas sobre el SAIH en la Gestión Hídrica, Ministerio de Obras Públicas, Transportes y Medio Ambiente. Dirección General de Obras Hidráulicas. Confederación Hidrográfica del Ebro, Marzo de 1995.*

- BRUEN, M. Y YANG, J., 2005.
Functional networks in real-time flood forecasting - a novel application.
Advances in Water Resources, 28: 899-909.
- CAMPOLO, M., ANDREUSSI, P. Y SOLDATI, A., 1999.
River flood forecasting with a neural network model.
Water Resources Research, 35(4):1191-1197.
- CASTILLO, E., 1998.
Functional Networks.
Neural Processing Letters, 7:151-159.
- CASTILLO, E. Y GUTIÉRREZ, J., 1998.
Nonlinear time series modeling and prediction using functional networks.
Extracting information masked by chaos. Physics Letters A, 244:71-84.
- DAWSON C. Y WILBY, R., 1998.
An artificial neural network approach to rainfall-runoff modelling.
Hydrological Sciences - Journal - des Sciences Hydrologiques, 43(1):47-66.
- DUEÑAS MOLINA, C., 1995.
El SAIH y su aplicación a la Protección Civil. Jornadas sobre el SAIH en la Gestión Hídrica,
Ministerio de Obras Públicas, Transportes y Medio Ambiente. Dirección General de Obras Hidráulicas. Confederación Hidrográfica del Ebro, Marzo de 1995.
- GRUNTFEST, E., 1995.
Long term social and economic impacts of extreme floods.
US-Italy Research Workshop on the Hydrometeorology, Impacts and Management of Extreme Floods. Perugia (Italy). November 1995.
- HSU, K., GUPTA, V. Y SOROOSHIAN, S., 1995.
Artificial neural network modeling of the rainfall-runoff process.
Water Resources Research, 31:2517-2530.
- INTA, 1983. INSTITUTO NACIONAL DE TECNOLOGÍA AGROPECUARIA.
Cartas de Suelos de la República Argentina, Provincia de Santa Fe.
Cartas varias.
- LEKKAS, D., MAXEY, R. Y WHEATER, H., 2004.
Intercomparison of forecasting methods for flood warning in the river cam catchment.
Global Nest: the International Journal, 5(2):89-97.
- MAIER, H. Y DANDY, G., 2000.
Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications.
Environmental Modelling & Software, 15:101-124.
- OGDEN, F., SHARIF, H., SENARATH, S., SMITH, J., BAECK, M. Y RICHARDSON, J., 2000.
Hydrologic analysis of the Fort Collins, Colorado, flash flood of 1997.
Journal of Hydrology, 228:82-100.
- RICCARDI, G., SCUDERI, C. Y STENTA, H., 2002.
Modelado de escurrimiento superficial con alto nivel de detalle en la cuenca del arroyo Ludueña, Santa Fe, Argentina.
XIX Congreso Nacional del Agua, T33, Villa Carlos Paz, Córdoba, Argentina.
- RICCARDI, G., ZIMMERMANN, E., BASILE, P., MANCINELLI, A., SCUDERI, C., RENTERÍA J. Y GARCÍA P., 2008.
Rehidrología y Modelo de Simulación a Tiempo Real en Sistema de Alerta Hidrológico en las Cuencas de los Arroyos Ludueña y Saladillo.
Informes Técnicos. Convenio entre el Ministerio del Aguas, Servicios Públicos y Medio Ambiente de Santa Fe y la Facultad de Ciencias Exactas, Ingeniería y Agrimensura de Rosario.
- SCUDERI, C., RICCARDI, G. Y ZIMMERMANN, E., 2009.
Sistema de alerta a tiempo real en la zona del Gran Rosario. Resultados Preliminares.
XXII Congreso Nacional del Agua, Trelew, Chubut, nov. de 2009, 11 p.
- SCUDERI, C., RICCARDI, G. Y ZIMMERMANN, E., 2011.
Redes funcionales aplicadas al pronóstico de niveles para un curso de llanura del Gran Rosario.
XXIII Congreso Nacional del Agua, Resistencia, Chaco, 28 p.
- SCUDERI, C., RICCARDI, G., Y ZIMMERMANN, E., 2012.
Aplicación de Redes Funcionales al pronóstico de niveles en dos cursos de llanura del Gran Rosario.
1er. Encuentro de Investigadores en Formación en Recursos Hídricos, Ezeiza, Buenos Aires, Junio 2012, 15 p.
- SHRESTHA, R., THEOBALD, S. Y NESTMANN, F., 2005.
Simulation of flood flow in river system using artificial neural networks.
Hydrology and Earth System Sciences, 9(4):313-321.

- THIRUMALAIAH, K. Y DEO, M. 1998.
Real-Time Flood Forecasting Using Neural Networks.
Computer-Aided Civil and Infrastructure Engineering, 13:101–111.
- TUCCI, C. Y BERTONI, C., 2003.
Inundações Urbanas na América do Sul.
Porto Alegre: Associação Brasileira de Recursos Hídricos, 150 p.