

PRONÓSTICO DE ALTURAS EN CURSOS DE LLANURA MEDIANTE EL USO DE UN MODELO DE CAJA NEGRA

Carlos M. Scuderi⁽¹⁾, Gerardo A. Riccardi^(1,2) y Erik D. Zimmermann^(1,3)

⁽¹⁾Departamento de Hidráulica y Centro Universitario Rosario de Investigaciones HidroAmbientales

⁽²⁾Investigador CIC-CIUNR

⁽³⁾Investigador CONICET

Facultad de Ciencias Exactas, Ingeniería y Agrimensura. Universidad Nacional de Rosario
Riobamba 250 bis. (2000). Rosario. Santa Fe. Argentina
e-mail: cscuderi@fceia.unr.edu.ar

RESUMEN

Las inundaciones son el desastre más frecuente en nuestro país, produciendo la mayor cantidad de afectados y daños materiales a la infraestructura y a la propiedad. En este trabajo se presenta un tipo de modelo de caja negra denominado de redes funcionales, usado para pronóstico de alturas en cursos de llanura, aplicado 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 pronosticados para diferentes horizontes temporales t_{pi} . A partir de los eventos observados, en promedio 10 por limnómetro, se calculan todas las combinaciones para constituir dos grupos: aprendizaje y validación. La evaluación de los modelos se efectúa por medio de distintos estadísticos, entre ellos: diferencia máxima relativa y absoluta en el nivel pico, coeficiente de eficiencia de Nash-Sutcliffe, raíz del error cuadrático medio y coeficientes de la recta de regresión. Para los resultados presentados en este trabajo se alcanzaron valores medios en la diferencia en el nivel pico para 6 horas de pronóstico de 0.27 m en aprendizaje y de 0.33 m en validación. La potencialidad del modelo es que puede ser aplicado en cualquier cuenca con datos de precipitación y niveles.

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

ABSTRACT

Floods are the most common disaster in our country, producing the largest number of affected and damaging infrastructure and private property. In this paper, a black box model called functional networks is presented. This model was used to forecast water levels in flatland courses and was applied in the Gran Rosario basins. The input variables are rainfall and water level linked to a time t_0 , while the output is given by predicted water levels associated with different time horizons t_{pi} . From the observed events, on average 10 for each gage, all combinations are calculated to form two groups: learning and validation. Model evaluation is done through various statistical index, including: relative and absolute maximum difference in peak level, coefficient of efficiency of Nash-Sutcliffe, root mean square error and coefficients of the regression line. For the results presented in this paper mean values in difference peak level for 6 hours forecasting was 0.27 m in learning and 0.33 m in validation. The potential of the model is that it can be applied in any basin with precipitation data and levels.

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

INTRODUCCIÓN

Las inundaciones son uno de los desastres “naturales” de mayor impacto en la población, produciendo anualmente miles de muertes e importantes daños materiales con cuantiosas pérdidas económicas. Siendo en los países en vías de desarrollo donde se produce la mayor cantidad de víctimas fatales (Berga Casafont, 1990; 1995; Dueñas Molina, 1995; Mimikou y Koustoyannis, 1995).

Sin embargo, la concepción de desastre “natural” asociada a las inundaciones no es del todo correcta, ya que éstas son el resultado de la conjunción de acciones naturales y causas relacionadas a la ocupación de las planicies de inundación por parte del hombre. Tucci (2002) y Singh (2005) señalan entre las causas naturales a las características de la cuenca en su estado original (relieve, cobertura vegetal, capacidad de drenaje, etc.) junto con el tipo de lluvia; mientras que entre las causas provocadas por la acción del hombre se encuentran la urbanización, el uso agrícola, las obras hidráulicas y la deforestación entre las principales. El crecimiento descontrolado y acelerado de las ciudades, a partir de la mitad del siglo pasado, ocupó las áreas inundables provocando perjuicios humanos y económicos considerables.

Cuando la frecuencia de las inundaciones es baja, las personas adquieren una sensación de seguridad que las lleva a aumentar significativamente la inversión y la densificación de las construcciones en las áreas inundables (Tucci, 2002). Paradójicamente, a pesar del avance en la comprensión de los riesgos “naturales” y al empleo de medidas de prevención y protección, los daños anuales causados por las inundaciones siguen aumentando, debido al crecimiento de la población, a la consolidación de áreas urbanas, al uso de zonas vulnerables, a las mayores inversiones de capital y a la fragilidad de los sistemas de comunicaciones (Berga Casafont, 1995).

En nuestro país las inundaciones son el desastre más frecuente: durante el período 1944 a 2013 se informaron 137 desastres de los cuales 48 fueron inundaciones (estadísticas obtenidas por el autor a partir de datos recabados en CRED, 2014). Además de la ocurrencia, las inundaciones producen la mayor cantidad de afectados y daños materiales, incluso si se consideran todos los otros desastres (biológicos, climáticos, geofísicos, meteorológicos, tecnológicos y complejos) en forma conjunta. Estos hechos hacen que la problemática de las inundaciones requiera suma atención por parte de las autoridades públicas

en cuanto a políticas de prevención, emergencia y mitigación y del público en general respecto de la forma de actuación antes, durante y después de un evento de inundación.

Para mitigar los efectos de las inundaciones es necesario implementar diferentes medidas que, según Grunfest (1995) y Marchi et al. (1995), no sólo deben estar vinculadas con aspectos hidráulicos, geológicos y meteorológicos, sino también con aspectos sociales, económicos y políticos. En principio, las medidas pueden ser clasificadas en dos grupos: preventivas, anteriores a la ocurrencia del evento y de emergencia, se ejecutan durante y con posterioridad a la inundación (Berga Casafont, 1995; Aldana Valverde, 2002; Lekkas et al., 2004).

Las medidas preventivas a su vez se dividen en estructurales y no estructurales (Singh, 2005). Las estructurales actúan durante la formación y propagación de las inundaciones modificando la relación lluvia-escurrimiento. Pueden ser extensivas, es decir que actúan sobre la cuenca (conservación de suelos, alteración de la cobertura vegetal, corrección de cuencas, embalses de laminación y regulación); o intensivas, las cuales actúan sobre los cursos de agua (diques, incremento de la capacidad de los cursos, corte de meandros, reservorios, canales).

Las medidas no estructurales reducen los daños derivados de las inundaciones basadas en mejorar la “convivencia” del hombre con las mismas. USACE (1978) clasifica estas medidas en: a) regulación del uso de la tierra estableciendo el riesgo de inundación (mapas de riesgo, zonificación y/o compra de áreas inundables); b) construcciones a prueba de inundaciones (sellado, elevación y/o reubicación de estructuras, reubicación de elementos dentro de la estructura); c) seguro contra crecidas para dar una protección económica por las pérdidas eventuales; y d) previsión y alerta de inundación: adquisición de datos en tiempo real, transmisión de la información a un centro de análisis y pronóstico de niveles en cauces a través del uso de un modelo matemático.

Tradicionalmente, las acciones frente a las inundaciones estaban basadas en la aplicación de medidas estructurales intensivas (Berga Casafont, 1990; 1993; 1995); sin embargo, Singh (2005) cita que estas obras no brindan una completa protección debido a la inviabilidad física y económica de las mismas. La frecuencia de las inundaciones demuestra las limitaciones de las medidas estructurales de protección, por lo que la implementación de medi-

das no estructurales para mitigarlas es una oportunidad para reducir la periodicidad y magnitud de los eventos extremos (Hickey y Salas, [1998]).

Durante las últimas décadas los expertos recomiendan la implementación de soluciones de tipo no estructural en conjunto con las estructurales, dada la eficacia de las primeras en la reducción de los efectos de las inundaciones: muy buena razón costo-beneficio, disminución significativa de los impactos humanos y socioeconómicos (Berga Casafont, 1995; Hickey y Salas, [1998]; Aldana Valverde, 2002; Tucci, 2002; Plate, 2003; Lekkas et al., 2004).

Respecto de las medidas no estructurales, el desarrollo en electrónica, telecomunicaciones y computación contribuyó a mejorar los sistemas automáticos de pronóstico de crecidas en tiempo real (Berga Casafont, 1995). Más aún, Singh (2005) califica al uso de estos sistemas junto con la zonificación del valle de inundación como las medidas no estructurales más efectivas para gestión de las inundaciones.

Un Sistema de Alerta contra Inundaciones (SAI) se compone de un conjunto de instalaciones, equipamientos y procesos que permiten conocer en tiempo real el estado de las variables hidrológicas (principalmente lluvias, niveles y caudales). A partir de estos datos y con la aplicación de un modelo matemático es posible pronosticar la evolución temporal de niveles y/o caudales con el objeto de adoptar medidas de protección de personas y bienes (Dueñas Molina, 1995; Penning-Rowsell et al., 2000; García y Linares Sáez, 2002; Tucci, 2002; De Roo et al., 2003; Goswami et al., 2005; Singh, 2005).

La selección del modelo de pronóstico de niveles posee una fuerte dependencia del tamaño y características de la cuenca, de la disponibilidad de datos hidrometeorológicos, del tiempo de aviso y propósito del pronóstico, de las características del escurrimiento y de la disponibilidad de instalaciones y equipamiento de cómputo (USACE, 1993; Arduino et al., 2005; Singh, 2005). Existe gran variedad de modelos matemáticos utilizados en pronóstico de crecidas, una de las clasificaciones los divide en físicamente basados o de “caja negra”.

Los modelos físicamente basados, en general de parámetros distribuidos, representan los procesos físicos que se desarrollan en todo el dominio de trabajo, la cuenca, durante el proceso de transformación lluvia – caudal (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.

El uso de modelos de “caja negra” se basa en que dado que el pronóstico de niveles (y/o caudales) en tiempo real precisa de resultados lo más aproximados en el menor tiempo posible; es lícito ignorar ciertos aspectos y componentes físicos del sistema estudiado (Hsu et al., 1995). Relacionan en forma simplificada la lluvia, variable de entrada al sistema, con el nivel (o caudal) en cursos como variable de salida (Kothyari y Singh, 1999); con escasa consideración de los procesos hidrológicos implicados.

Las redes neuronales artificiales (RN) y las redes funcionales (FN) son ejemplos de modelos de “caja negra” (Castillo, 1998 y Goswami et al., 2005). Una RN es un sistema paralelo y dinámico con partes que interactúan altamente interconectadas, basado en modelos neurobiológicos (el sistema nervioso consiste en células nerviosas individuales altamente interconectadas llamadas neuronas). Estas neuronas reciben información o estímulos desde el ambiente externo. La RN está diseñada para emular la función humana de reconocimiento de patrones a través del procesamiento en paralelo o múltiples entradas, pudiendo emplearse para construir modelos no lineales (Kanbua y Khetchaturat, 2007).

Zealand et al. (1999) enuncian algunas ventajas de las RN: (a) inferir soluciones desde los datos sin conocimiento previo de las regularidades en los mismos, (b) aprender las similitudes entre los patrones a partir de ejemplos de ellos, (c) poder generalizar a partir de ejemplos anteriores a los nuevos, (d) son no lineales, pudiendo resolver algunos problemas complejos con mayor precisión y, (e) son altamente paralelizadas conteniendo muchas operaciones idénticas e independientes que se pueden ejecutar al mismo tiempo, a menudo haciendo las RN más rápidas que otros métodos.

Estos autores también mencionan ciertas desventajas de las RN: (a) pueden no alcanzar una solución satisfactoria, debido a la no existencia de una función para aprender o a la insuficiente cantidad de datos, (b) la geometría y los parámetros internos óptimos de la red dependen del problema, teniendo que ser definidos por ensayo y error, y (c) no pueden hacer frente a cambios importantes en el sistema por ser entrenadas con datos históricos; es decir de existir algún cambio importante en el sistema la RN deberá ser reajustada para el nuevo proceso.

Las RN han sido empleadas en el ámbito de los recursos hídricos desde hace unos 15 años. Respecto del pronóstico de caudales o niveles de agua asociados a inundaciones existe un gran número de trabajos donde se emplean RN con diferentes horizontes temporales, abarcando desde análisis estacionales o mensuales hasta rangos de 5 minutos en casos de cuencas urbanas pequeñas de gran pendiente donde suelen producirse inundaciones repentinas.

En la Tabla 1 (página siguiente) se presentan algunos de los trabajos hallados en la revisión bibliográfica. En dicha tabla constan los autores y año del trabajo, el país, la variable a pronosticar (nivel o caudal), el nombre y área de la cuenca donde se realizó la investigación, el horizonte temporal del pronóstico, y los índices estadísticos que son empleados más comunmente para evaluar la bondad del modelo: raíz del error cuadrático medio RECM, coeficiente de determinación r^2 , coeficiente de eficiencia del modelo E_{NS} (Nash-Sutcliffe) y error en el caudal o nivel pico E_{pico} .

Diferentes autores (See et al., 1997; Campolo et al., 1999; Campolo et al., 2003; Alvisi et al., 2006; Chidthong et al., 2009) coinciden en que la exactitud del modelo se degrada a medida que el horizonte de pronóstico se incrementa, afectándose su confiabilidad. Alvisi et al. (2006) indican que un tiempo de pronóstico de 6 horas es considerado aceptable. No obstante, Han (2002) afirma que la disminución en la fiabilidad del modelo dentro de ciertos límites es tolerable, si se alcanzan los objetivos de alerta temprana en forma razonable.

Por otra parte, como las RN son modelos fuertemente dependientes de los datos, Dawson y Wilby (1998) junto con Thirumalaiah y Deo (1998) indican que la selección del período de aprendizaje y de validación es fundamental, pudiendo afectar la capacidad de pronóstico de la red. Por último, una observación importante sobre el empleo de RN, es que el mismo se restringe al rango de datos usado en la etapa de aprendizaje (Ponce, 1989).

El objetivo del presente trabajo es la aplicación y evaluación del desempeño de diferentes modelos de redes funcionales (RF), que son una generalización de las RN (Castillo, 1998), con el fin de pronosticar niveles. Los mismos son utilizados en secciones particulares de los arroyos Ludueña y Saladillo, situados en la zona del Gran Rosario (sur de la provincia de Santa Fe, Argentina). Se proponen tres familias de funciones: polinómica, exponencial y de

Fourier con diferentes grados de aproximación cada una. Son usadas la lluvia y el nivel limnimétrico para un tiempo t_0 como variables de entrada, para pronosticar niveles limnimétricos asociados a diferentes horizontes temporales tp_i , desde 15 minutos hasta 6 horas de anticipación (variables de salida).

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 pueden consultar en Scuderi et al. (2011), Scuderi et al. (2012) y Scuderi et al. (2014).

MATERIALES Y MÉTODOS

La zona centro – este de la República Argentina, la Llanura Pampeana, posee buenos suelos para agricultura y ganadería y dispone de fuentes seguras de agua para abastecimiento de las necesidades de sus habitantes. Estas condiciones promueven la cada vez mayor consolidación de grandes urbes que concentran un gran número de personas en espacios reducidos (Tucci y Bertoni, 2003). Durante años, la migración de la población desde el campo hacia las ciudades en busca de un mejor nivel de ingresos, hizo que el 91.3% de la población viva en ciudades (Celade, 2014), acrecentando fuertemente la presión sobre estos conglomerados urbanos y sus sistemas.

Dentro de esta zona, la región del Gran Rosario situada en el sureste de la provincia de Santa Fe constituye la tercera metrópoli del país. El relieve es sumamente plano con escasa pendiente y suelo arcilloso – limoso con permeabilidad moderada a moderadamente lenta (INTA, 1983). Estas características naturales sumadas al aumento en la densidad poblacional a través de emprendimientos urbanísticos (principalmente por barrios cerrados) y a la impermeabilización de los suelos debido a prácticas agrícolas intensivas (primariamente por cultivo de soja), incrementan la generación de volumen de escurrimiento superficial junto con la disminución en los tiempos de respuesta de las cuencas.

La zona del Gran Rosario ha sido impactada por tormentas de variada intensidad (en las décadas de 1940 y de 1960, y en los años 1986, 2007 y 2012), que produjeron inundaciones con diferente grado de severidad, grandes pérdidas económicas y en algunos casos hasta la pérdida de vidas humanas. Estos hechos han llevado a la ejecución de distintas obras de conducción y alivio por parte de las autoridades públicas, tanto provinciales como municipales.

Tabla 1. Aplicación de redes neuronales al pronóstico de niveles/caudales

Fuente	País	Var ⁽¹⁾	Río o cuenca	Área ⁽²⁾	Δt ⁽³⁾	RMSE	r ²	E_NS	E_pico
Thirumalaiah y Deo (1998)	India	C	Bhatsa	391	3		0.66		22 %
Campolo et al. (1999)	Italia	N	Tagliamento	1950	6	0.28 / 0.36		0.87 / 0.81	20 %
Dawson y Wilby (1999)	Inglaterra	C	Mole (oto / inv)	142	15 min	- / 1.15	- / 0.96	- / 0.97	
Cameron et al. (2002)	Inglaterra	N	South Tyne	751	4			0.98 / 0.97	7 %
Han (2002)	EUA	N	Crabtree	313	3	0.23	0.96		
Campolo et al. (2003)	Italia	C	subc. Arno	4000	1	30 / 20	0.99 / 0.98		18 % / 21 %
Chiang et al. (2004)	Taiwán	C	Lan-Yang	980	1	94 / 102			17 % / 4 %
Bruen y Yang (2005)	Irlanda	C	Citywest	1.83	20 min			0.98 / 0.96	
Bruen y Yang (2005)	Irlanda	C	Dargle	122	4			0.76 / 0.88	
de Vos y Rientjes (2005)	Bélgica	C	Geer	494	6	0.36		0.79	
Shrestha et al. (2005)	Alemania	C	Neckar s1	13787	1	56	0.99	0.99	- 36
Alvisi et al. (2006)	Italia	N	Reno	1051	1	0.09 / 0.06	0.96 / 0.96		
Alvisi et al. (2006)	Italia	N	Reno	1051	6	0.22 / 0.16	0.77 / 0.92		
Kang et al. (2006)	Rep. Corea	C	Youngsan / Naju	2509	1	10.74 / 15.92	1.00 / 1.00	1.00 / 1.00	
Kang et al. (2006)	Rep. Corea	C	Youngsan / Naju	2509	6	135.34	0.92	0.91	
Aqil et al. (2007)	Indonesia	C	Cilalawi	60	1	0.41 / 1.27	0.98 / 0.97		
Chang et al. (2007)	Taiwán	C	Da-Chia / Son-Mou	514	1	19.8 / 22.4			
Kim y Kim (2008)	Corea	N	Wi	473	1	0.09 / 0.13	0.98 / 0.93	0.97 / 0.89	
Kim y Kim (2008)	Corea	N	Wi	473	5	0.10 / 0.16	0.97 / 0.90	0.96 / 0.82	
Chang et al. (2009)	Taiwán	C	Lan-Yang	980	1	74 / 74			
Chang et al. (2009)	Taiwán	C	Lan-Yang	980	2	111 / 110			
Chiang y Chang (2009)	Taiwán	C	Wu-Tu	-	3	160	0.81	0.65	26 %
Chidhong et al. (2009)	Tailandia	N	Ping	-	6	0.04 / 0.06		0.99 / 0.99	0.03 / 0.05
Lin et al. (2009)	Taiwán	C	Fei-Tsui	303	3	236		0.72	12 %

⁽¹⁾ variable pronosticada, C: caudal / N: nivel; ⁽²⁾ Área de la cuenca en km²; ⁽³⁾ horizonte temporal en horas, excepto que se indique otra unidad

Las condiciones descritas anteriormente favorecen un escenario cada vez más vulnerable a las inundaciones y el incremento del riesgo de la población, razones por las que la protección de la vida humana (generalmente de habitantes que ocupan el valle de inundación de los cursos o sectores bajos) como de la infraestructura pública y de bienes materiales cobra cada vez mayor importancia.

Cuencas en estudio

Las cuencas de los arroyos Ludueña y Saladillo (Figura 1), situadas en el sureste de la provincia de Santa Fe, República Argentina, comparten el mismo cuerpo receptor; el río Paraná. El clima de la región puede caracterizarse como templado subtropical sin estación seca (verano cálido) clasificado según Köppen como Cfa. La precipitación media anual de la zona es de 1014.4 mm (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% (Rosario Aero, SMN, serie 1973-2012).

Las cuencas presentan una fuerte intervención antrópica, principalmente la cuenca del arroyo Ludueña, encontrándose atravesadas por numerosas vías de comunicación (rutas y ferrocarriles); en tanto que la agricultura constituye el principal uso del suelo, destacándose la producción de soja, maíz y trigo. Desde hace aproximadamente unos 15 años la proliferación de barrios cerrados y abiertos, con escasa

planificación por parte de la autoridad provincial, ha contribuido sostenidamente al incremento de la impermeabilización del suelo.

La cuenca del arroyo Ludueña se encuentra ubicada entre los paralelos 32° 45' y 33° 07' S y los meridianos 60° 41' y 61° 06' O. La red hídrica está compuesta por el 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 sitúa entre los paralelos 32° 59' y 33° 37' S y los meridianos 60° 36' y 61° 54' O. La red hídrica principal está constituida por el 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 durante eventos extraordinarios los 1140 m³.s⁻¹ (Riccardi et al., 2008).

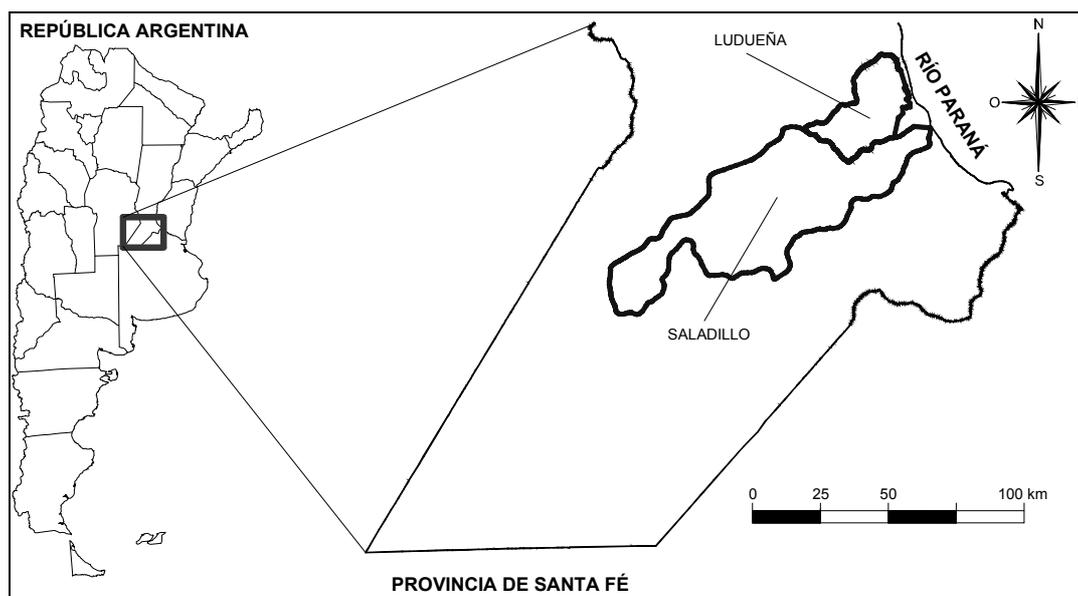


Figura 1. Situación geográfica de las cuencas en estudio.

La dinámica en el uso del suelo, particularmente la cuenca del arroyo Ludueña, sin políticas de ordenamiento territorial por parte de las autoridades provinciales y municipales en el pasado, ha incrementado la vulnerabilidad de los habitantes asentados en ciertas zonas, particularmente sensibles a las inundaciones. Esta situación sumada a numerosas tormentas de variada intensidad han llevado a las autoridades, en un lapso de unos 50 años, a ejecutar un conjunto de grandes obras de saneamiento en la cuenca del arroyo Ludueña con el objeto de incrementar la capacidad de evacuación del sistema de $75 \text{ m}^3 \cdot \text{s}^{-1}$ (en la década de 1940) a $285 \text{ m}^3 \cdot \text{s}^{-1}$ (en el año 1994). Además, en el año 1996 se puso en operación una presa de retención de crecidas que regula aproximadamente el 50% del área de la cuenca.

Con respecto a la cuenca del arroyo Saladillo, se registran problemas de saneamiento pluvial en varias localidades, entre ellas Arequito, Bombal, Casilda, Chabás, Firmat, Fuentes y Sanford. En general estos problemas están circunscriptos y se deben a particularidades del relieve local y en ocasiones a deficiencias en el macro drenaje. El criterio empleado, en la generalidad de los casos, para la resolución de problemas ha sido la ejecución de canales artificiales con el objeto de evacuar “lo más rápidamente posible” las aguas de la zona urbana.

Es importante conocer estos hechos para explicar como la transformación de la cuenca por parte del hombre, hace que cada vez sea necesaria una mayor capacidad de conducción para intentar mantener el nivel de protección de sus habitantes.

Datos de precipitación y niveles

La autoridad hídrica provincial, el Ministerio de Aguas, Servicios Públicos y Medio Ambiente (MASPyMA), instaló en el año 2007 una red telemétrica de sensores de precipitación y niveles en ambas cuencas, en el marco del uso de medidas preventivas no estructurales para disminuir la vulnerabilidad de áreas con riesgo de inundación. En la cuenca del arroyo Ludueña fueron instalados 4 sensores de lluvia y 11 registradores de niveles, mientras que en la cuenca del arroyo Saladillo se emplazaron 6 sensores de lluvia y 7 medidores de niveles.

Los datos son registrados cada 15 minutos, siendo luego transmitidos a una estación central donde son almacenados y disponibilizados a través de una página web. El acceso a los datos fue realizado manualmente desde la página web, gracias a la cesión de los mismos por parte del MASPyMA. El período de datos utilizado en este trabajo comprende desde julio de 2007 hasta junio de 2012 inclusive; siendo empleada la estación Rosario AERO (dependiente del Servicio Meteorológico Nacional) para el contraste de los datos pluviométricos medidos.

La distribución geográfica de los pluviómetros, identificados mediante triángulos, se presenta en la Figura 2, donde también se muestra la localización de la estación Rosario AERO. En dicha figura se exhibe, además, en línea continua el límite de cuenca, en línea de trazo los polígonos de Thiessen asociados a cada pluviómetro y en el interior de cada cuenca y con línea continua la red de cursos.

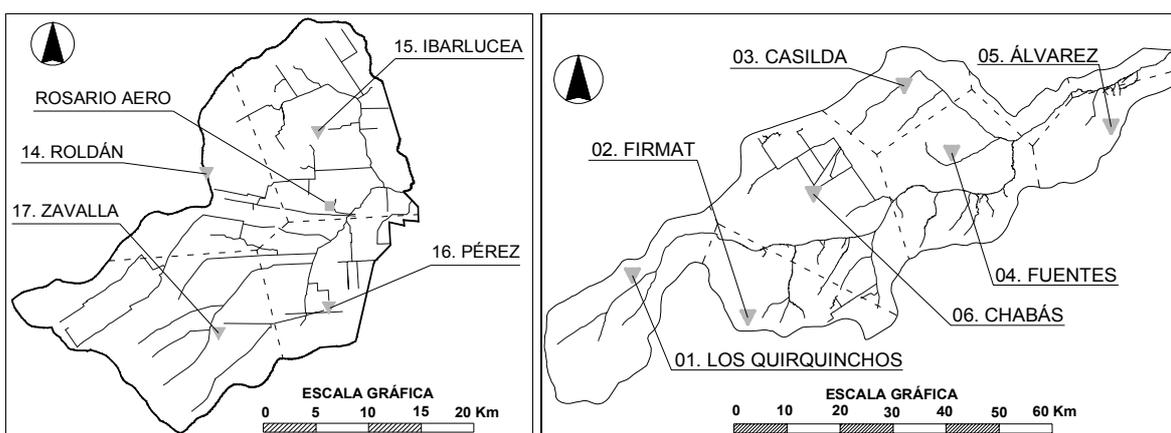


Figura 2. Estaciones pluviométricas y polígonos de Thiessen asociados: (izq.) cuenca Ludueña, (der.) cuenca Saladillo.

El contraste entre las precipitaciones registradas en las estaciones pluviométricas remotas y la estación Rosario AERO, realizado mediante doubles acumu-

laciones, indica que las estaciones remotas registran por debajo de la estación de testeo en un rango comprendido entre 28% y 46% (valor medio del

35%). No obstante, cuando se realiza la misma comparación, pero considerando solamente eventos aislados para un total de 20 tormentas, el contraste produce una diferencia en menos que varía entre 11% y 28% (valor medio del 18%) con un coeficiente de determinación $r = 0.78$. Esta particularidad pone de manifiesto la necesidad de efectuar el seguimiento sistemático del funcionamiento de los sensores pluviométricos.

Respecto de los sensores limnimétricos, en la Figura 3 se exhibe la posición de los mismos identificados por medio de círculos. También se presenta en línea continua el límite de cuenca y de las subcuencas

asociadas a cada sensor y en el interior de la cuenca la red de cursos. La evaluación de la calidad de estos registros limnimétricos es más difícil de realizar que en el caso de los sensores de precipitación. No obstante, algunos de los niveles medidos durante la ocurrencia de diferentes eventos pudieron ser comparados con la lectura de la regla localizada junto a la sección considerada.

Es importante destacar que los equipos, en particular, los sensores de niveles estuvieron sometidos a situaciones de vandalismo. Un análisis pormenorizado sobre el comportamiento de los sensores puede ser consultado en Scuderi et al. (2009).

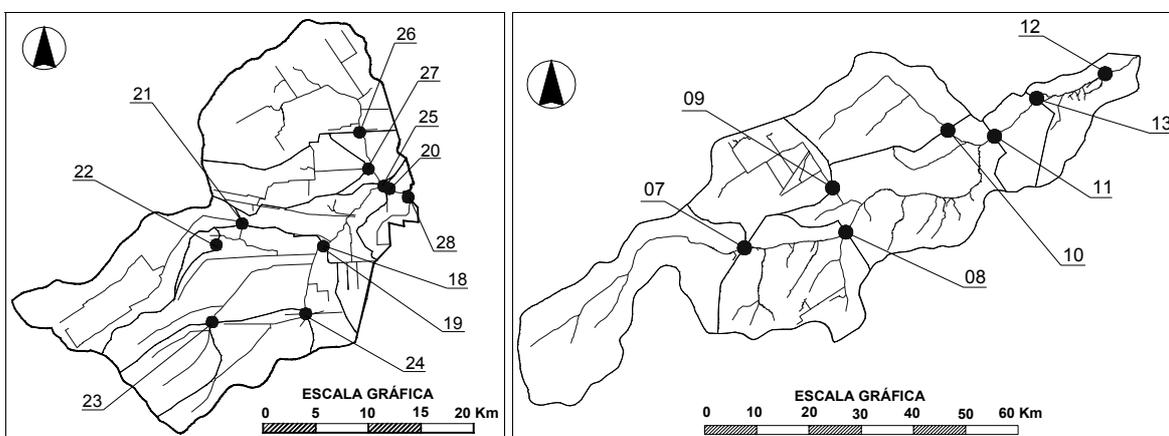


Figura 3. Estaciones limnimétricas y subcuencas asociadas: (izq.) cuenca Ludueña, (der.) cuenca Saladillo.

Concluida la fase de verificación de la calidad de los datos, fueron efectuados una serie de procedimientos adicionales, según el siguiente detalle:

- (1) cada cuenca fue dividida en subcuencas asociadas al área de aporte de cada sensor limnimétrico, empleando curvas de nivel cada 1.25 m y la traza de los diferentes terraplenes viales y ferroviarios;
- (2) fue determinada el área de influencia de cada sensor pluviométrico mediante la metodología de polígonos de Thiessen;
- (3) en función de las áreas obtenidas en los dos puntos anteriores se procedió al cálculo del porcentaje de contribución con que cada sensor pluviométrico aporta a cada subcuenca a través de la intersección de ambas superficies.

Posteriormente fue cotejada la concordancia temporal entre registros de precipitación y de niveles, seleccionando las fechas en que ocurrieron las tormentas y donde hubo medición de niveles simultáneamente. Finalmente, se definieron como eventos válidos aquellos que cumplieran los siguientes requisitos establecidos en forma arbitraria:

- (1) la precipitación caída en cada una de las subcuencas de aporte al limnómetro considerado supera los 10 mm (calculada en función del aporte proporcional de cada pluviómetro);
- (2) el nivel de agua en la sección estudiada registra un incremento superior al 15% de la diferencia máxima entre nivel pico y nivel base, considerando la totalidad de eventos medidos en dicha sección.

De la aplicación del procedimiento citado se obtuvieron diferentes cantidades de eventos válidos para cada sensor limnimétrico, entre 4 y 15 tormentas, con un valor medio de 10 tormentas por sensor.

Modelo de redes funcionales

Castillo (1998) cita que las RN están compuestas por diferentes capas de neuronas conectadas a través de enlaces (Figura 4). Cada unidad de cómputo o neurona puede realizar un cálculo simple, consistente en una función escalar f típicamente monótona (función de activación), a partir de la suma ponderada de los datos de entrada. Las funciones f asocia-

das a las neuronas son fijas y los pesos w deben ser aprendidos por medio de algoritmos a partir de los datos de entrada. El método de aprendizaje y los algoritmos son importantes para el uso de las RN.

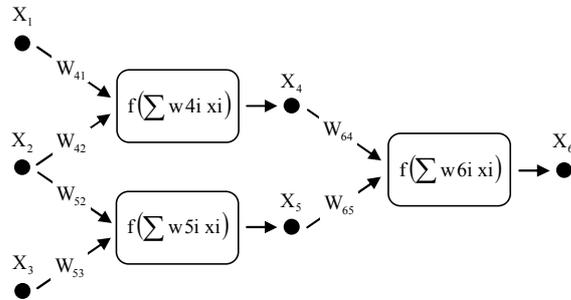


Figura 4. Esquema típico de una red neuronal (Fuente: Bruen y Yang, 2005).

Por otra parte, según lo manifestado por Castillo y Gutiérrez (1998), las redes funcionales (RF) son una generalización o extensión de las RN; en la Figura 5 se muestra un esquema típico de la organización y de los componentes de una RF. En el caso de las RF las funciones de activación f son funciones desconocidas, aunque definidas a partir de familias conocidas, a ser estimadas en el proceso de aprendizaje.

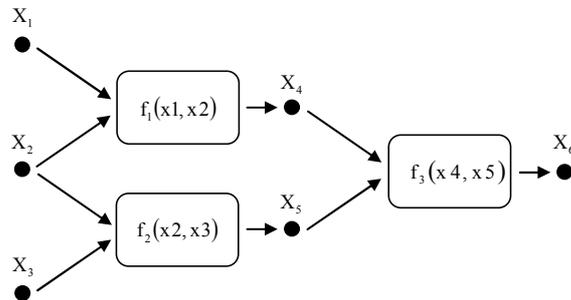


Figura 5. Esquema típico de una red funcional (Fuente: Bruen y Yang, 2005).

Los elementos componentes de una RF (Figura 5) son (Castillo, 1988):

- (1) una capa de unidades de entrada, que contiene los datos de entrada (x_1, x_2, x_3);
- (2) una capa de unidades de salida, es la última capa y contiene los datos de salida (x_6);
- (3) 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 otro conjunto de valores de salida a la próxima capa (f_1, f_2 y f_3);
- (4) 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 es única, desde la capa de entrada hacia la capa de salida.

- (5) una o más capas de unidades de almacenamiento intermedio (x_4, x_5) que almacena la información producida por las unidades neuronales.

Una de las principales diferencias entre las RN y las RF, citadas por Castillo (1998), es que en las primeras las funciones de activación f son fijas e iguales (funciones sigmoideas), debiendo ser aprendidos los pesos w . En forma contrapuesta en las RF se suprimen los pesos w (en realidad se encuentran contenidos dentro de las funciones de activación) de forma tal que las funciones de activación f son las que deben ser aprendidas; no obstante dichas funciones de activación se derivan de familias funcionales previamente conocidas.

Este mismo autor manifiesta una propiedad importante de las RF, en caso de tener m enlaces partiendo de la última capa de neuronas a una unidad de salida, el valor de dicha unidad de salida puede ser escrito en formas diferentes (una por cada enlace); generando así un sistema de $m-1$ ecuaciones funcionales que pueden ser escritas a partir de la topología de la red.

A continuación son señaladas otras diferencias entre las RN y las RF, que hacen a las particularidades de cada una de ellas, presentadas en Castillo (1998) y Castillo et al. (2000):

- (1) respecto de la topología: en las RN se elige mediante ensayo y error, mientras que la topología inicial en las RF está dada por el problema, pudiendo simplificarse usando ecuaciones funcionales;
- (2) respecto de las funciones neuronales: en las RN las funciones neuronales (funciones sigmoideas) son fijas, univariadas y de un solo argumento (suma ponderada de los valores de entrada o combinación lineal de ellos). En forma opuesta, en las RF las funciones neuronales pueden ser diferentes, multivariadas y/o de múltiples argumentos;
- (3) respecto de las unidades de salida: en las RN las unidades de salida son la salida de una neurona individual (la última), por el contrario en las RF las unidades de salida son la salida de una o más neuronas. Este hecho produce ciertas condiciones de compatibilidad de modo que, a mayor número de neuronas conectadas a las unidades de salida menor será el número de grados de libertad;
- (4) en algunas RF el método de aprendizaje conduce a un óptimo global en un solo paso, reduciendo de esta manera el tiempo de aprendizaje y los problemas asociados con el óptimo local y global.

Red funcional simple separable

En este trabajo se propone el empleo de una RF simple separable con dos variables de entrada x e y , y una de salida z . La variable x corresponde al valor de precipitación, la variable y al nivel de agua para un tiempo t_0 y la variable z al nivel de agua para diferentes tiempos de pronóstico t_{pi} .

La RF separable es de uso habitual y, como su nombre lo indica, se define a partir de una expresión que considera el efecto de cada una de las variables de entrada en forma separada. De esta manera, al considerar dos variables de entrada y una de salida, la RF queda formulada matemáticamente a través de la siguiente expresión (Bruen y Yang, 2005):

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

donde x e y son las variables de entrada, z es la variable de salida, y f_i y g_i son las funciones neuronales a ser calculadas.

Dentro de esta familia (ec. 1) se selecciona el caso más simple, que considera la contribución independiente de cada una de las entradas, sin contemplar las interacciones entre ellas. De esta forma, si en la expresión anterior se supone $n = 2$ y $g_1 = f_2 = 1$, se obtiene (Bruen y Yang, 2005):

$$z = F(x, y) = f(x) + g(y) \quad (2)$$

Aprendizaje de la red funcional

Bruen y Yang (2005) señalan que el proceso de aprendizaje o entrenamiento es, en la práctica, se-

mejante a la tarea de calcular los parámetros de un modelo hidrológico convencional.

Para la RF dada en la ec. 2, el proceso de aprendizaje consiste en estimar las funciones neuronales f y g a partir de los datos de entrada (Castillo y Gutiérrez, 1998). Dichas funciones pueden ser propuestas como una combinación lineal de funciones conocidas, de orden p , a partir de una familia dada, como por ejemplo un polinomio o serie de Fourier (Bruen y Yang, 2005):

$$\begin{cases} \hat{f}(x) = \sum_{j=1}^p a_j \varphi_j(x) \\ \hat{g}(y) = \sum_{j=p+1}^{p+q} a_j \varphi_{j-p}(y) \end{cases} \quad (3)$$

en que los coeficientes a_j son los parámetros de las funciones neuronales φ_j a ser aprendidos durante el 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, la cual se encuentra expresada por la ecuación 4. Para asegurar la unicidad en la representación de la red es necesario y suficiente dar un valor inicial a alguna de las funciones neuronales, pudiendo utilizar cualquiera de las dos condiciones iniciales: $f(x_0) = u$ o $g(y_0) = v$. Este término se agrega a la FO, quedando la ecuación 5 (Bruen y Yang, 2005):

$$FO = \sum_{i=1}^k \hat{e}^2 = \sum_{i=1}^k \left[z_i - \hat{f}(x_i) - \hat{g}(y_i) \right]^2 = \sum_{i=1}^k \left[z_i - \sum_{j=1}^p a_j \varphi_j(x_i) - \sum_{j=p+1}^{p+q} a_j \varphi_{j-p}(y_i) \right]^2 \quad (4)$$

$$FO = \sum_{i=1}^k \left[z_i - \sum_{j=1}^p a_j \varphi_j(x_i) - \sum_{j=p+1}^{p+q} a_j \varphi_{j-p}(y_i) \right]^2 + c \left[\sum_{j=1}^p a_j \varphi_j(x_0) - u \right] \quad (5)$$

siendo k la cantidad de datos de entrenamiento y c una constante.

Minimizar la 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 (ecuación 6). Para conocer con detalle el desarrollo del modelo consultar Bruen y Yang (2005).

Los autores anteriores destacan que el proceso de entrenamiento es más fácil y rápido para las RF que para las RN; siendo ésta una ventaja considerable,

en particular para modelos complejos o con series extensas de datos. En contrapartida, un aspecto negativo de las RF (a diferencia de las RN) es que

cambios en cualquier parte de la red requieren la modificación de las ecuaciones para entrenamiento y por lo tanto de la programación.

$$\left\{ \begin{array}{l} \frac{\partial FO}{\partial a_r} = -2 \sum_{i=1}^k \left[z_i - \sum_{j=1}^p a_j \varphi_j(x_i) - \sum_{j=p+1}^{p+q} a_j \varphi_{j-p}(y_i) \right] \cdot \varphi_r(x_i) + c \cdot \varphi_r(x_0) = 0, \quad r = 1, \dots, p \\ \frac{\partial FO}{\partial a_r} = -2 \sum_{i=1}^k \left[z_i - \sum_{j=1}^p a_j \varphi_j(x_i) - \sum_{j=p+1}^{p+q} a_j \varphi_{j-p}(y_i) \right] \cdot \varphi_{r-p}(y_i) = 0, \quad r = p+1, \dots, p+q \\ \frac{\partial FO}{\partial c} = \sum_{j=1}^p a_j \varphi_j(x_0) - u = 0, \quad r = 1, \dots, p \end{array} \right. \quad (6)$$

Las familias funcionales que se emplean en el trabajo son la polinómica, la exponencial y la serie de Fourier. 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.

Implementación del modelo de RF

Según lo referido por Dawson y Wilby (1998), este tipo de modelos es fuertemente dependiente de los datos de entrada, por lo que fueron generadas a partir de las tormentas válidas todas las combinaciones de datos posibles, en cada estación limnométrica. Cada una de las combinaciones fue dividida a su vez en dos grupos o muestras complementarios: uno para aprendizaje y otro para validación de la red.

Una restricción adicional implementada sobre las muestras es descartar aquellas donde la cantidad de tormentas utilizadas en aprendizaje y en validación sea muy dispar. El criterio excluye las muestras en que 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 1, 2 o 3 tormentas en alguno de los grupos.

Luego de determinadas las n muestras definitivas, para cada limnómetro, fueron aplicados los siete modelos de RF. En esta instancia la rutina programada calcula la matriz de coeficientes y el vector de términos independientes en función de los datos de entrada asociados a cada muestra i (i = 1, ..., n). Posteriormente se resuelve el sistema de ecuaciones planteado en la ec. 6, generando el vector de coeficientes resultado. A partir del vector de coeficientes resultado el modelo realiza el pronóstico de los niveles, para la muestra i considerada, en la etapa de

aprendizaje. Haciendo uso del mismo vector de coeficientes resultado, el programa realiza el pronóstico de niveles para la muestra complementaria asociada a la etapa de validación. En la Figura 6 se presenta un diagrama de flujo del modelo de RF empleado, donde se esquematiza el procedimiento descrito precedentemente.

Tener en cuenta que en cada uno de los siete modelos de RF fueron considerados 9 grados de aproximación diferentes, siendo además planteados nueve horizontes temporales de cálculo: 15, 30 y 45 minutos y 1, 2, 3, 4, 5 y 6 horas.

Realizado el pronóstico de niveles para cada muestra i en las etapas de aprendizaje y de validación, y debido a la gran cantidad de datos generados en función del análisis combinatorio efectuado, interesa restringir el número de muestras a las cuales se les realizará el análisis estadístico. Para reducir el universo de muestras se aplicaron tres pruebas estadísticas a los resultados obtenidos para cada muestra i, considerando los niveles medidos y los pronosticados: una para determinar si el coeficiente de correlación r es diferente de 0, otra para evaluar si los coeficientes a y b de la recta de regresión no son diferentes de 1 y 0, y la tercera para conocer si el desvío medio es diferente de 0.

El primer procedimiento corresponde a la prueba t de Student para determinar si el coeficiente de correlación r es diferente de 0 (ec. 7):

$$tr_{(\alpha, n-2)} = \frac{r}{\sqrt{\frac{1-r^2}{n-2}}} \quad (7)$$

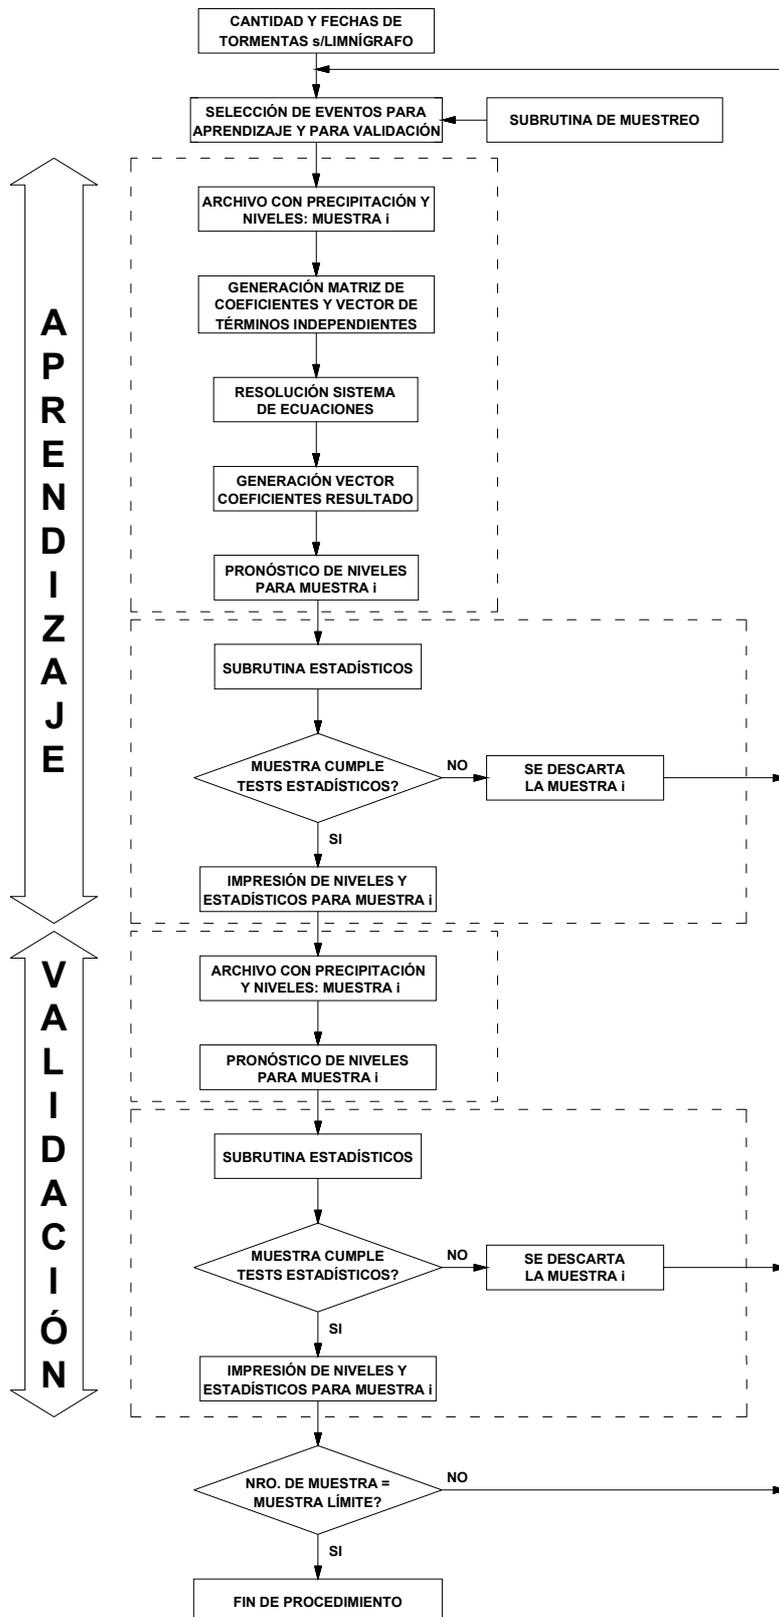


Figura 6. Modelo de RF de pronóstico de niveles. Diagrama de flujo.

donde t_r es el valor calculado del test de Student; α es el grado de significancia (95%); n es la cantidad de registros de la muestra y r es el coeficiente de correlación. El valor de t_r calculado es contrastado con el valor crítico de la distribución t de Student t_c asociado a $\alpha=0.05$ y $n-2$. Si $t_r > t_c$ entonces se dice que r es estadísticamente distinto de cero y que ambas variables están correlacionadas.

El segundo test, sugerido por Dent y Blackie en 1979 (Tedeschi, 2006) permite evaluar en forma simultánea si los coeficientes a y b de la recta de regresión no son diferentes de 1 y 0 respectivamente, en función del test F de Fisher. La expresión asociada al mismo está dada por la ec. 8:

$$F_1 = \frac{(n-2) \left\{ n.b^2 + 2.n.\bar{p}.b.(a-1) + \sum |p_i^2.(a-1)^2 \right\}}{2.n.ECM} \quad (8)$$

$$ECM = \frac{\sum_{i=1}^n (p_i - o_i)^2}{(n-2)} \quad (9)$$

siendo F_1 el valor calculado del test F de Dent y Blackie; b la ordenada al origen de la recta de regresión; \bar{p} el valor medio de los valores pronosticados; a la pendiente de la recta de regresión; p_i es cada uno de los valores pronosticados; ECM es el error cuadrático medio; y o_i es cada uno de los valores observados. El valor de F_1 calculado es comparado con el valor crítico de la distribución F de Fisher F_c asociado a $\alpha=0.05$ y $n-2$. En caso que $F_1 < F_c$ se concluye que a y b no son estadísticamente diferentes de 1 y 0.

El tercer control, sugerido por Jacovides y Kontoyiannis (1995), evalúa si el desvío medio DM es diferente de 0 aplicando la distribución t de Student:

$$t_{DM(\alpha, n-1)} = \frac{DM}{\sqrt{\sum \frac{(o_i - p_i - DM)^2}{n(n-1)}}} \quad (10)$$

en que DM es el desvío medio. El valor de t_{DM} calculado es comparado con el valor crítico de la distribución t de Student t_c asociado a $\alpha=0.05$ y $n-1$. En circunstancias en que $t_{DM} > t_c$ se considera que el desvío medio DM es estadísticamente diferente del valor cero.

Los pronósticos asociados a cada muestra i (para aprendizaje y validación) que responden satisfactoriamente a las tres pruebas estadísticas aplicadas, son los que se consideran para la evaluación de resultados en el punto siguiente.

RESULTADOS

Como el número de muestras válidas resultantes asociado a cada limnómetro es elevado, llegando en 2 de las estaciones a alrededor de 28900, se torna dificultoso visualizar cada una de ellas, por lo que se decidió emplear parámetros estadísticos para su presentación. Una complejidad adicional que se suma al análisis de los resultados es que cada una de las estaciones limnimétricas tiene diferente número de muestras válidas, por lo que no es posible realizar una estricta comparación entre las mismas. No obstante, teniendo en cuenta esta limitación es factible, en la práctica, elaborar las comparaciones entre estaciones y establecer conclusiones generales sobre los resultados obtenidos.

La evaluación de los resultados se divide en dos fases, la primera en términos estadísticos analiza las estaciones en su conjunto, mientras que la segunda en términos de niveles se enfoca específicamente sobre una muestra representativa de dos estaciones limnimétricas particulares.

Análisis en términos estadísticos

Para evaluar los pronósticos fueron empleados diferentes estadísticos; en este sentido no hay consenso entre los investigadores respecto de un criterio único para la evaluación de modelos. Por esta razón se calcularon 12 estadísticos, entre ellos la diferencia máxima absoluta [m] y relativa [%] en el nivel pico, la raíz del error cuadrático medio [m], el coeficiente de eficiencia del modelo de Nash-Sutcliffe y los coeficientes a y b de la recta de regresión (que son los seis indicadores que se presentan y analizan a continuación), diferencias máximas y mínimas en el limnograma completo, diferentes coeficientes de correlación y desvío medio.

En las Figuras 7 a 11 se presentan los estadísticos medios calculados asociados a los 11 sensores limnimétricos situados en la cuenca del arroyo Ludueña. En dichas figuras se representan en línea delgada los valores máximos y mínimos para cada estadístico analizado y en línea gruesa el valor medio del mismo, para diferentes horizontes temporales.

En la Figura 7 se muestra la diferencia relativa porcentual en el nivel pico, dicha magnitud expresa la proporción en que se encuentran los valores pronosticados por debajo de los valores observados, lo que constituye una condición crítica para un modelo de pronóstico de crecidas. Los resultados indican que, en promedio, para la etapa de aprendizaje, se obtuvieron valores mínimos de 0.7% para 15 minutos y máximos de 15.7% para 6 horas de pronóstico (valor medio 5.0%). En tanto que en validación se registró, en promedio, un mínimo de 0.5% para 15 minutos y un máximo de 19.2% para 6 horas de pronóstico (valor medio 6.5%).

Por otro lado, también se consideró la diferencia anterior en términos absolutos, es decir evaluada en metros (Figura 8). De esta forma se obtuvieron los siguientes valores medios: en aprendizaje un mínimo de 0.01 m para 15 minutos y un máximo de 0.29 m para 6 horas (valor medio 0.09 m); mientras que en validación se obtuvo un valor mínimo de 0.01 m para 15 minutos y un máximo de 0.35 m para 6 horas (valor medio 0.11 m). Dado que el valor crítico para una aplicación en alerta de crecidas es el nivel máximo alcanzado por el limnigrama, resultan sumamente auspiciosas las diferencias obtenidas por los pronósticos generados por los modelos de RF.

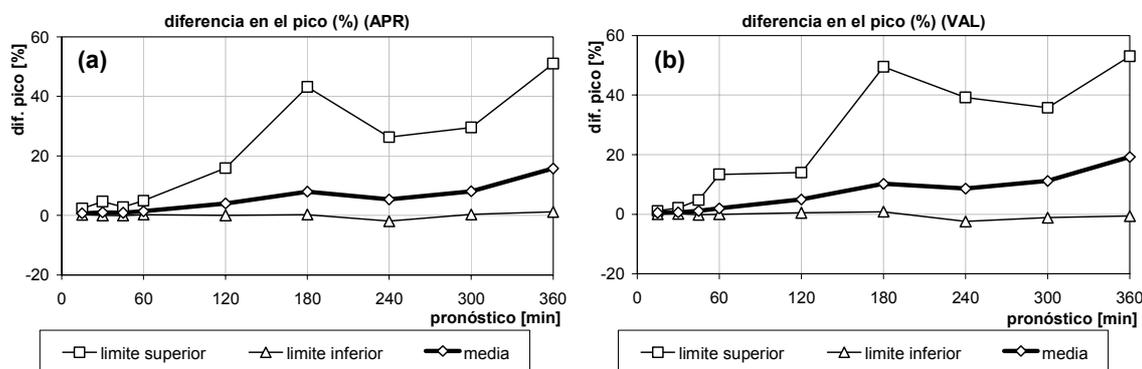


Figura 7. Diferencia relativa en el pico dpico(%): (a) aprendizaje, (b) validación. Cuenca Ludueña.

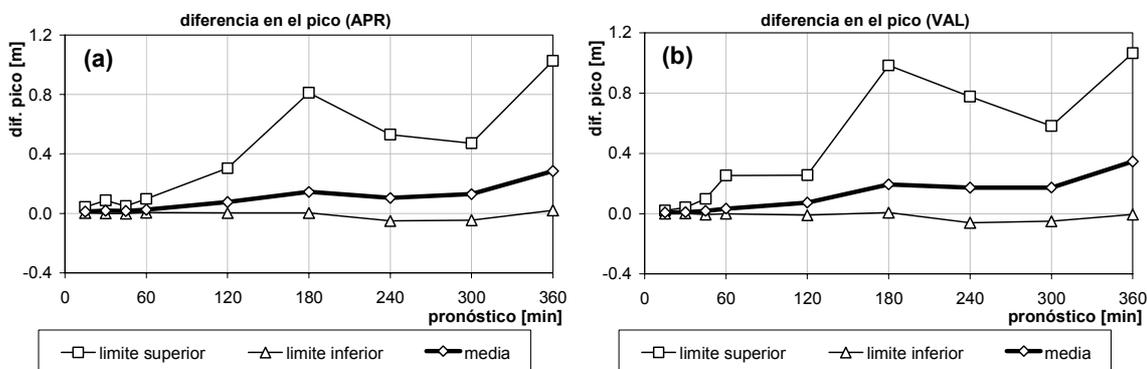


Figura 8. Diferencia absoluta en el pico dpico: (a) aprendizaje, (b) validación. Cuenca Ludueña.

Posteriormente, se empleó un índice para evaluar el grado de correlación entre niveles observados y pronosticados: el coeficiente eficiencia del modelo CE (Figura 9). Este coeficiente, desarrollado por Nash y Sutcliffe, es ampliamente utilizado en hidrología. Los resultados surgidos del cálculo de este índice arrojan los siguientes valores: durante el proceso de aprendizaje, en promedio un máximo de 0.998 para 15 minutos y un mínimo de 0.812 para 6 horas de horizonte temporal (valor medio 0.939); mientras que durante la etapa de validación, en promedio se obtuvo un máximo de 0.998 para 15

minutos y un mínimo de 0.729 para 6 horas de antecedencia (valor medio 0.908).

Además, fue calculada la raíz del error cuadrático medio RECM (Figura 10), que es un parámetro que tiene la ventaja de dar información en las mismas unidades de la variable en estudio, permitiendo de esta forma tener una idea de proporción entre el error y los valores observados. Este estadístico arroja los siguientes resultados: durante el aprendizaje, en promedio un mínimo de 0.02 m para 15 minutos de pronóstico y un máximo de 0.18 m para 6 horas

de anticipación (valor medio 0.08 m); mientras que durante la validación se presentó, en promedio un mínimo de 0.01 m para 15 minutos y un máximo de 0.20 m para 6 horas de antecedencia (valor medio 0.09 m). A partir de estos resultados se aprecia que la diferencia, en valores medios, de este índice entre aprendizaje y validación es prácticamente nula.

observados y pronosticados para cada todas las estaciones y los distintos tiempos de pronóstico, obtenidos en validación. Se observa que existe, en promedio, una escasa desviación de los valores teóricos $a = 1$ y $b = 0$; los mayores desvíos obtenidos fueron $a = 0.873$ en la hora 5 de pronóstico y $b = 0.077$ en la hora 6 de tiempo pronóstico.

En la Figura 11 se presentan los coeficientes a y b promedios de la recta de regresión entre valores

La tendencia general de estos índices es deteriorarse a medida que el tiempo de pronóstico se incrementa.

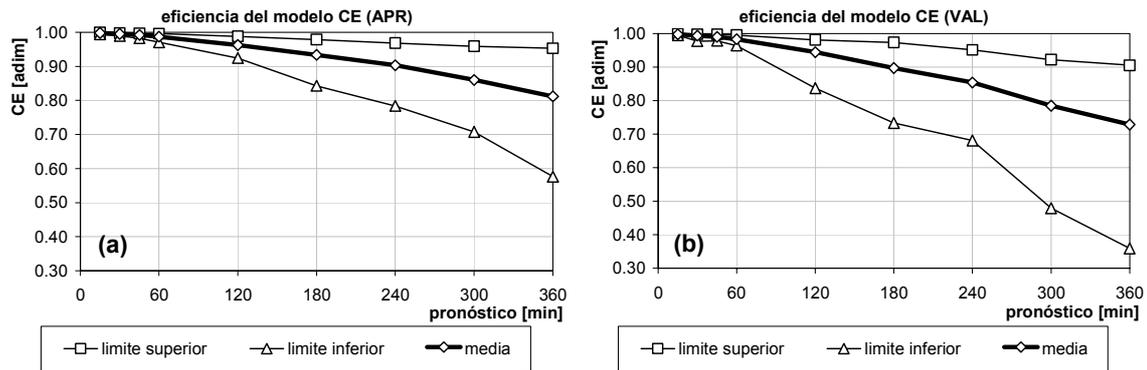


Figura 9. Eficiencia del modelo CE: (a) aprendizaje, (b) validación. Cuenca Ludueña.

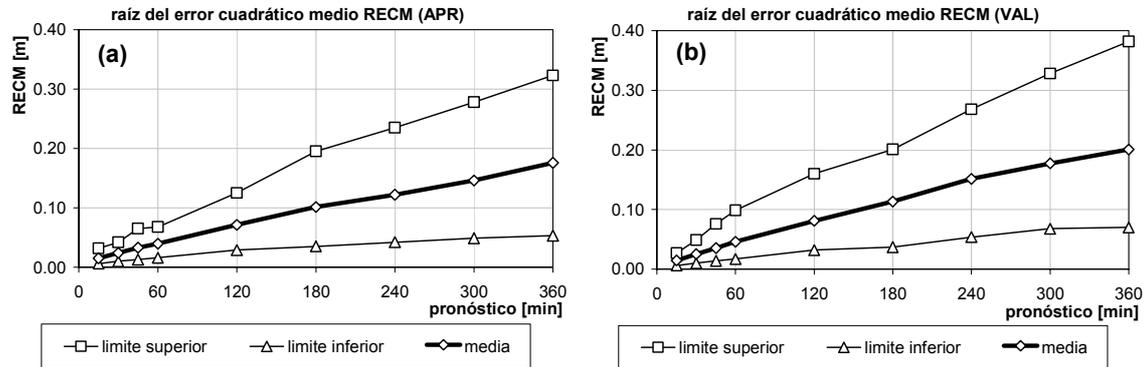


Figura 10. Raíz del error cuadrático medio RECM: (a) aprendizaje, (b) validación. Cuenca Ludueña.

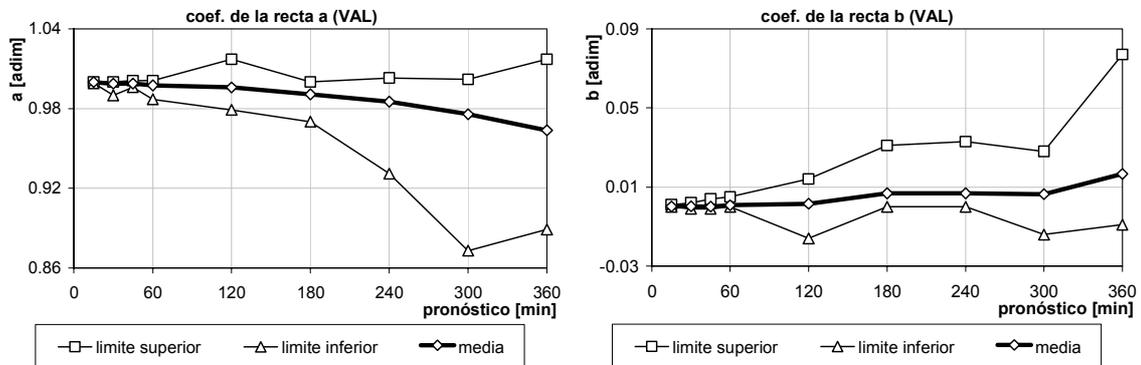


Figura 11. Coeficientes a y b de la recta de regresión. Cuenca Ludueña.

A continuación en la Tabla 2 se presenta un resumen de los estadísticos calculados para la cuenca del arroyo Ludueña. De la misma puede apreciarse que en general los estadísticos en aprendizaje son de “mejor calidad” que en validación.

Tabla 2: Resumen de estadísticos. Cuenca Ludueña.

		aprendizaje	validación
dif_pico [%]	máx	15.7	19.2
	med	5.0	6.5
	min	0.7	0.5
dif_pico [m]	máx	0.29	0.35
	med	0.09	0.11
	min	0.01	0.01
CE	máx	0.998	0.998
	med	0.939	0.908
	min	0.812	0.729
RECM	máx	0.18	0.20
	med	0.08	0.09
	min	0.02	0.01

En las Figuras 12 a 16 se muestran los índices medios estimados para los limnómetros de la cuenca del arroyo Saladillo. En dichas figuras se representan en línea fina los valores máximos y mínimos de cada estadístico analizado y en línea más gruesa el valor medio del mismo, para los horizontes temporales que abarcan desde 15 minutos hasta 6 horas.

En la Figura 12 se evalúa el comportamiento de los modelos en el momento en que se registra el nivel máximo a partir de las diferentes muestras *i* consideradas, para los que se analiza la diferencia porcentual respecto del nivel máximo observado. Los resultados indican que, en promedio, durante el periodo de aprendizaje se obtuvieron valores mínimos de 0.6% para 30 minutos y máximos de 15.4% para 5 horas de antelación (valor medio 6.3%). Mientras que durante la fase de validación los resultados obtenidos en promedio fueron de un mínimo de 0.4% para 30 minutos y un máximo de 18.7% para 5 horas de pronóstico (valor medio 7.7%).

Además de la diferencia relativa entre valores observados y pronosticados en el nivel pico, también se evalúa la diferencia absoluta en metros entre los mismos (Figura 13). Se verificaron los siguientes valores promedio: en la etapa de aprendizaje un valor mínimo de 0.01 m para 15 minutos y un máximo de 0.25 m para 6 horas (valor medio 0.10 m); mientras que en la etapa de validación se obtuvo un valor mínimo de 0.01 m para 15 minutos y un máximo de 0.30 m para 5 horas (valor medio 0.12 m). Para usos en alerta de crecidas es prioritario el nivel máximo (o nivel pico) alcanzado en el limnograma y de esta forma las diferencias obtenidas pueden ser consideradas muy adecuadas para estos fines. Por otra parte, los valores estimados para estos índices en esta cuenca concuerdan con los hallados en la cuenca del arroyo Ludueña.

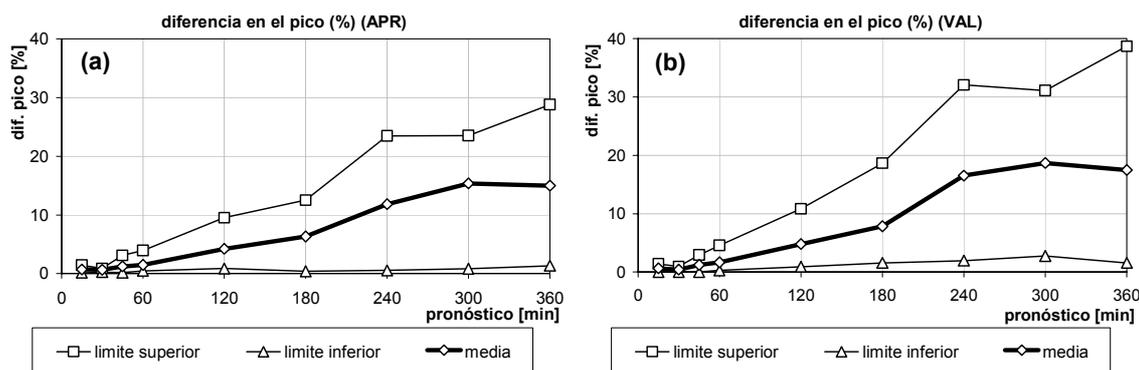


Figura 12. Diferencia relativa en el pico dpico(%): (a) aprendizaje, (b) validación. Cuenca Saladillo.

Para inferir el grado de correlación existente entre niveles observados y pronosticados se empleó el coeficiente eficiencia del modelo CE, el cual se presenta en la Figura 14. A partir de los niveles calculados surgen los siguientes resultados: en el período de aprendizaje, en promedio un máximo de 0.998 para 15 minutos y un mínimo de 0.796 para 6 horas

de pronóstico (valor medio 0.927); mientras que en validación, en promedio se obtuvo un máximo de 0.998 para 15 minutos y un mínimo de 0.735 para 6 horas de antelación (valor medio 0.898). Se verifica que los valores de este coeficiente son siempre mayores en aprendizaje que en validación, independientemente del tiempo de pronóstico.

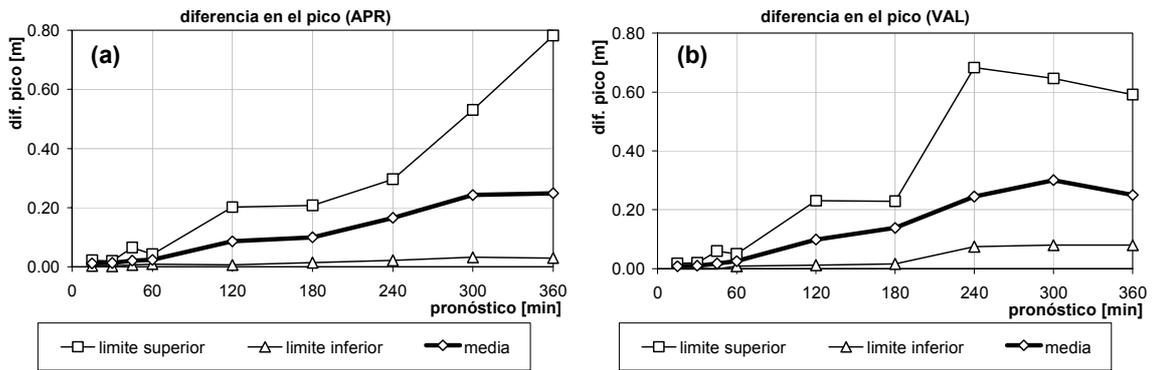


Figura 13. Diferencia absoluta en el pico dpico: (a) aprendizaje, (b) validación. Cuenca Saladillo.

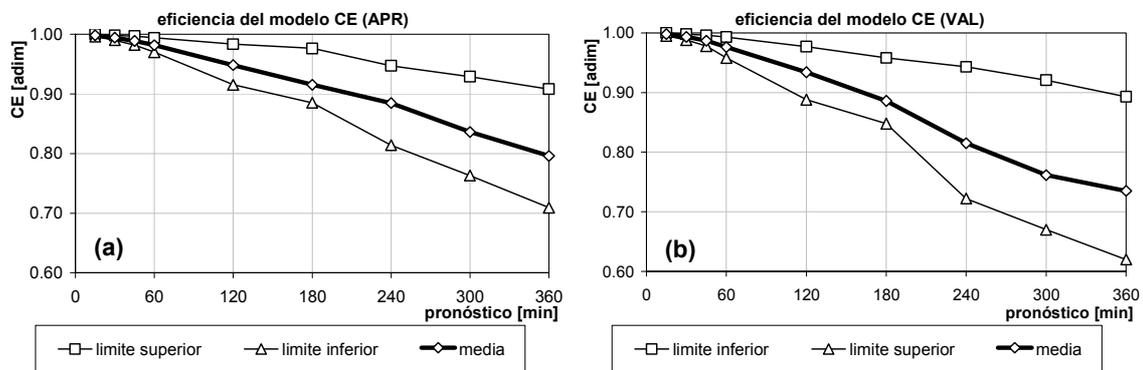


Figura 14. Eficiencia del modelo CE: (a) aprendizaje, (b) validación. Cuenca Saladillo.

La raíz del error cuadrático medio RECM, Figura 15, presenta los siguientes valores: en el período de aprendizaje, en promedio un mínimo de 0.02 m para 15 minutos de pronóstico y un máximo de 0.18 m para 6 horas de anticipación (valor medio 0.09 m); mientras que durante la validación, en promedio un mínimo de 0.02 m para 15 minutos y un máximo de 0.19 m para 6 horas de antecedencia (valor medio 0.10 m). Se verifica que la diferencia en valores medios para este índice en aprendizaje y validación es despreciable.

Por último, en la Figura 16, se muestran los coeficientes a y b promedio de la recta de regresión entre niveles observados y pronosticados, para todos los limnómetros y diferentes horizontes temporales, obtenidos en validación. Las desviaciones medias de los valores teóricos $a = 1$ y $b = 0$ registradas son pequeñas; los mayores desvíos obtenidos fueron $a = 0.908$ y $b = 0.061$, ambas en la hora 5 de tiempo de pronóstico. La tendencia general de estos índices es a desmejorar a medida que el tiempo de pronóstico se incrementa.

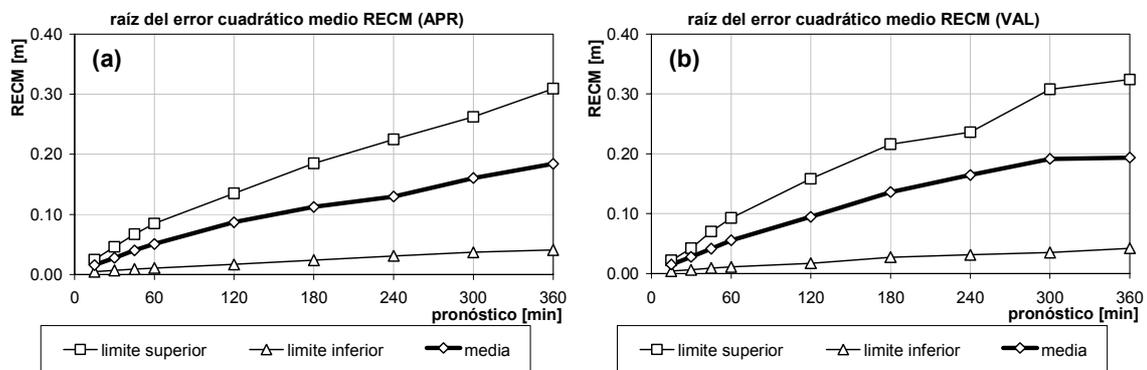


Figura 15. Raíz del error cuadrático medio RECM: (a) aprendizaje, (b) validación. Cuenca Saladillo.

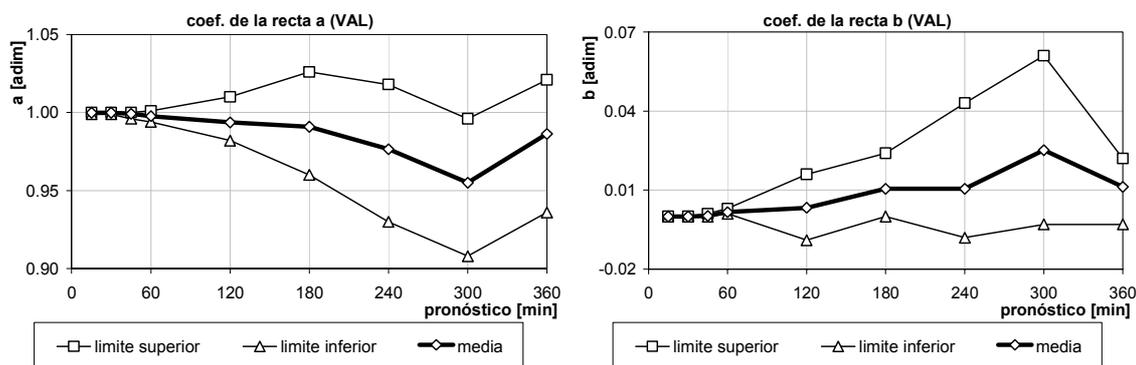


Figura 16. Coeficientes a y b de la recta de regresión. Cuenca Saladillo.

Seguidamente, en la Tabla 3, se exhibe un resumen de los estadísticos calculados para la cuenca del arroyo Saladillo. De la misma forma que para los estadísticos calculados en el caso de la cuenca del arroyo Ludueña (Tabla 2), los estadísticos durante aprendizaje muestran un mejor desempeño que en el período de validación.

Tabla 3: Resumen de estadísticos. Cuenca Saladillo.

		aprendizaje	validación
dif_pico [%]	máx	15.4	18.7
	med	6.3	7.7
	min	0.6	0.4
dif_pico [m]	máx	0.25	0.30
	med	0.10	0.12
	min	0.01	0.01
CE	máx	0.998	0.998
	med	0.927	0.898
	min	0.796	0.735
RECM	máx	0.18	0.19
	med	0.09	0.10
	min	0.02	0.02

Análisis en términos de niveles

Dado que obviamente también es necesario visualizar y analizar el comportamiento del modelo en términos de niveles, a continuación se presentan los niveles observados y pronosticados asociados a la “muestra representativa” para el caso de dos limnigramas, uno por cada cuenca estudiada.

El primer caso corresponde a la estación Rtu 24 Pérez-Peretti, perteneciente a la cuenca del arroyo Ludueña. Por cuestiones de espacio, se seleccionó la estación que registró la mayor cantidad de tormen-

tas, en este caso 14. La evaluación de los resultados se efectuó a partir de la comparación de niveles observados y pronosticados, los cuales fueron representados conjuntamente para los distintos tiempos de pronóstico considerados. Respecto de los tiempos de pronóstico, si bien fueron generados resultados para nueve horizontes temporales, se presentan solamente los resultados para 1 hora y 6 horas.

El análisis efectuado a continuación se refiere a la “muestra representativa” número 12981, formada por la siguiente combinación de eventos en aprendizaje: evento 1 (07-01-2008), 2 (28-01-2008), 3 (07-02-2008), 4 (22-02-2008), 5 (27-11-2008), 7 (10-02-2009), 8 (20-02-2009), 13 (12-03-2012) y 14 (19-03-2012); y para validación, los eventos complementarios, evento 6 (29-11-2008), 9 (04-04-2009), 10 (10-10-2009), 11 (13-04-2010) y 12 (28-05-2010). Los niveles observados y pronosticados para 1 hora y 6 horas de tiempo de pronóstico, se presentan en las Figuras 17 y 18 respectivamente.

En cada una de las figuras se representa en la parte izquierda los limnigramas medidos y pronosticados, y a la derecha los valores observados confrontados con los pronosticados junto con la línea 1:1 de correlación perfecta en línea de trazo. A su vez, cada una de las figuras se divide en dos partes, la superior contiene los resultados obtenidos en la etapa de aprendizaje y la inferior durante la validación. En cada representación de limnigramas, correspondiente a la muestra evaluada, la línea vertical negra de trazo fino indica la separación entre los diferentes eventos y sus limnigramas asociados.

Cuando se comparan las Figuras 17 y 18, puede establecerse preliminarmente que el pronóstico con 1 hora de antelación genera niveles más precisos que el de 6 horas de antecedencia.

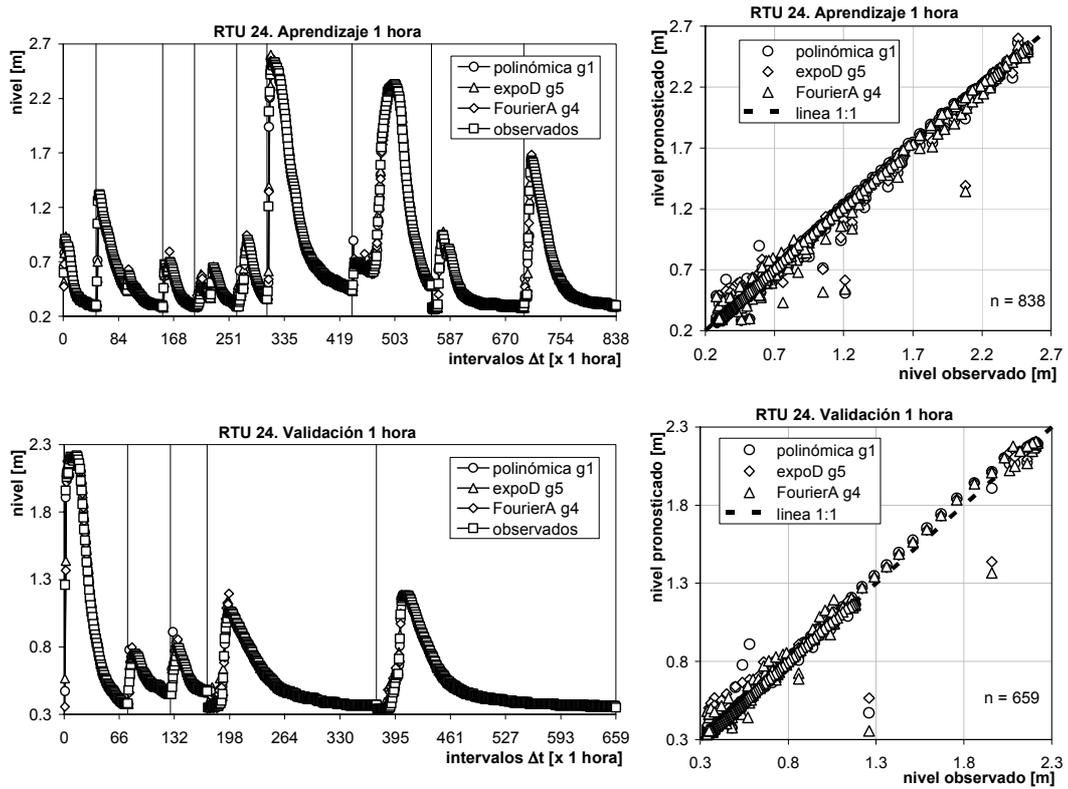


Figura 17. Limnigramas para la muestra 12981. Horizonte de pronóstico 1 hora.

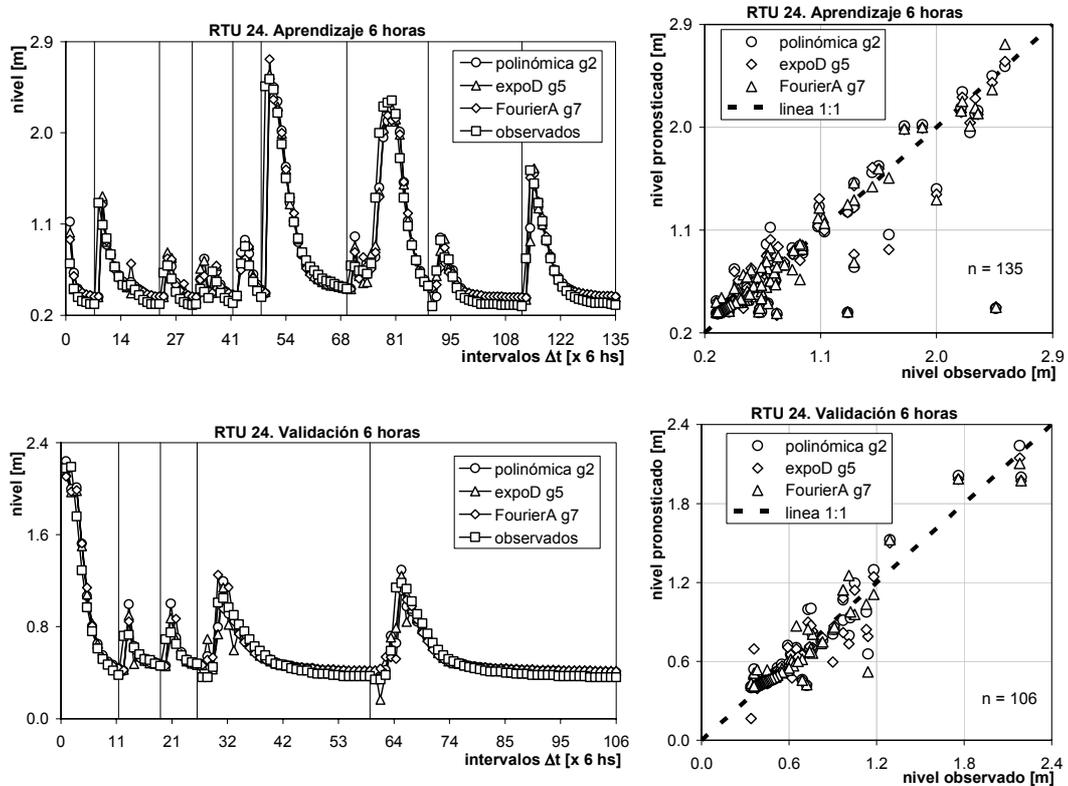


Figura 18. Limnigramas para la muestra 12981. Horizonte de pronóstico 6 horas.

Los pronósticos para 1 hora de antecedencia durante el aprendizaje (Figura 17) derivados de las familias funcionales propuestas son semejantes entre sí. Si se evalúa la diferencia en el pico del mayor de los limnigramas (correspondiente a 2.53 m para aprendizaje y a 2.22 m para validación) se verifica para cualquiera de las familias funcionales que no se supera 0.03 m en menos. Sin embargo existe cierto comportamiento irregular para la familia FourierA g4 que queda evidenciado en la parte derecha de la figura mediante el alejamiento de los triángulos (que representan a dicha familia) de la recta 1:1. Por otra parte, en la fase de validación, si bien la familia de FourierA g4 es la que presenta mayores errores, también se verifican algunas irregularidades para las otras dos (polinómica g1 y expoD g5), aunque en menor medida.

Se concluye que para el pronóstico de 1 hora de antecedencia, las familias funcionales analizadas pronostican valores muy similares entre sí, recomendando el uso de la familia polinómica g1 por su simplicidad en el cálculo de los coeficientes respecto de las otras dos, expoD g5 y FourierA g4.

Cuando se evalúa el tiempo de pronóstico de 6 horas (Figura 18), se verifica que en aprendizaje, la familia FourierA g7 es la que presenta mayores diferencias, seguida de la función expoD g5 y de la polinómica g2. No obstante, en validación, no se verifica la mencionada tendencia, siendo la función polinómica g2 la que presenta mayores incertezas, seguida de la expoD g5 y en menor grado por la de FourierA g7. Evaluando la discrepancia en el pico del mayor de los limnigramas (correspondiente a 2.53 m para aprendizaje y a 2.19 m para validación) se verifica que la misma se incrementa hasta 0.22 m en menos, para las familias funcionales expoD g5 y FourierA g7 durante el proceso de validación. La familia que ofrece mejores resultados, respecto al nivel pico para 6 horas de pronóstico, es la polinómica g2 por sobre las otras dos.

El segundo análisis corresponde a la estación Rtu 13 Piñero, perteneciente a la cuenca del arroyo Saladillo; en este caso se registraron 10 tormentas. Respecto de la representación de los resultados, tanto de niveles observados y pronosticados como de los estadísticos calculados, caben todas las consideraciones realizadas en el caso de la cuenca del arroyo Ludueña. Se deja constancia, nuevamente, que el análisis efectuado en esta sección se refiere solamente a la muestra “representativa” de cada una de las estaciones de aforo estudiadas.

El análisis corresponde a la muestra “representativa” 650, constituida a partir de 10 tormentas: los eventos 1 (27-01-2008), 2 (21-02-2008), 3 (27-11-2008), 4 (10-02-2009), 8 (13-11-2009) y 9 (18-11-2009) para aprendizaje y los eventos 5 (20-07-2009), 6 (17-09-2009), 7 (10-10-2009) y 10 (19-12-2009) para validación. Los niveles observados y pronosticados para 1 hora y 6 horas de antecedencia se muestran en las Figuras 19 y 20 respectivamente.

Se aprecia que los pronósticos derivados de la aplicación de las familias funcionales propuestas son semejantes para un tiempo de antecedencia de 1 hora (Figura 19), no obstante se observan algunas inestabilidades para la familia FourierA g6, tanto en aprendizaje como en validación. En este sentido, para 1 hora de pronóstico, el error en el pico del mayor de los limnigramas (correspondiente a un nivel de 4.48 m en aprendizaje y de 4.13 m en validación) que constituye la muestra en análisis no supera 0.03 m en menos, tanto para aprendizaje como para validación para las distintas familias funcionales propuestas.

Se concluye que para el pronóstico de 1 hora de antecedencia, las familias funcionales analizadas pronostican valores muy similares entre sí, recomendando el uso de la familia polinómica g2 por generar pronósticos levemente superiores a las otras dos, expoD g9 y FourierA g6.

Si analizamos la situación de 6 horas de pronóstico (Figura 20) se observa que para la fase de aprendizaje, los modelos aplicados generan valores por debajo de los niveles “altos” y por exceso para los niveles “bajos”. No obstante, las discrepancias en el pico del mayor limnigrama constitutivo de la muestra (valor observado de 4.47 m para aprendizaje) no superan el valor de 0.30 m en menos, para las familias polinómica g1 y FourierA g4. Durante la validación de los modelos, fueron estimadas diferencias en el nivel pico (con un valor medido de 4.13 m) de 0.34 m y de 0.06 m (ambos en menos) para la familia polinómica g1 y FourierA g4, respectivamente, sin obtenerse resultados para la familia expoD g8 dado que no logra “pasar” alguna de las tres pruebas estadísticas aplicadas. Por lo tanto, la familia que ofrece mejores resultados, respecto al nivel pico para 6 horas de pronóstico, es la polinómica g1, sobre las otras dos, expoD g8 y Fourier A g4.

Coincidiendo con el análisis de la estación Rtu 24, las inestabilidades en los resultados se incrementa a medida que aumenta el horizonte de pronóstico.

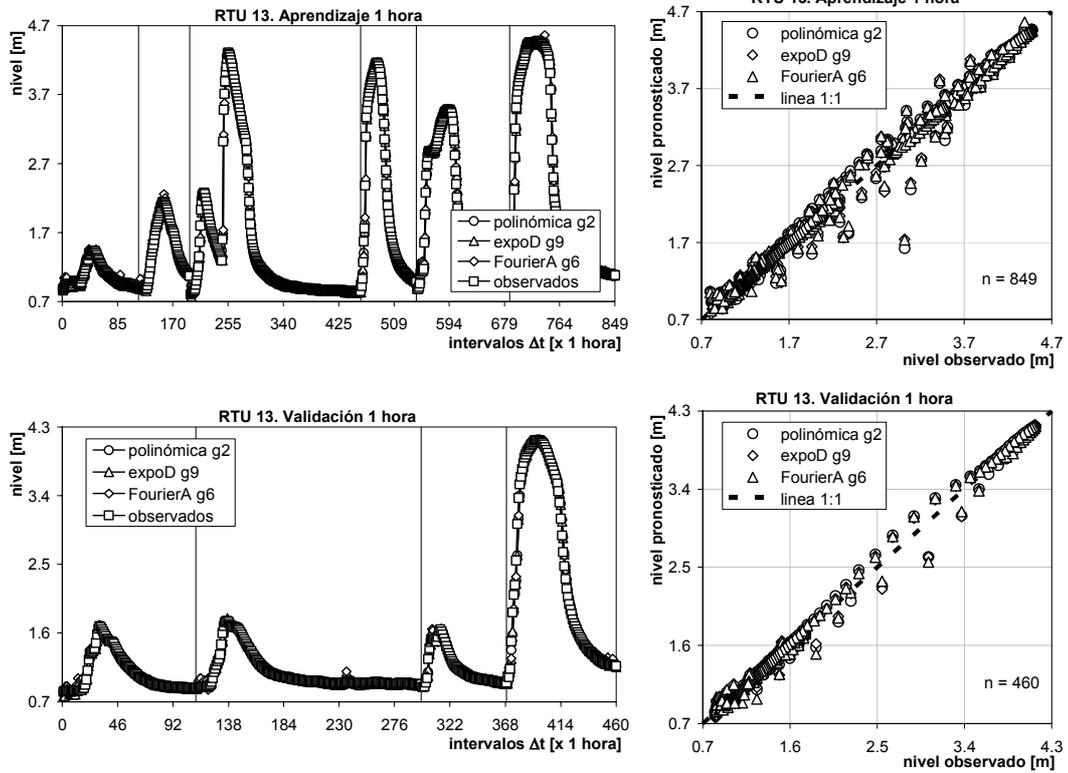


Figura 19. Limnigramas para la muestra 650. Horizonte de pronóstico 1 hora.

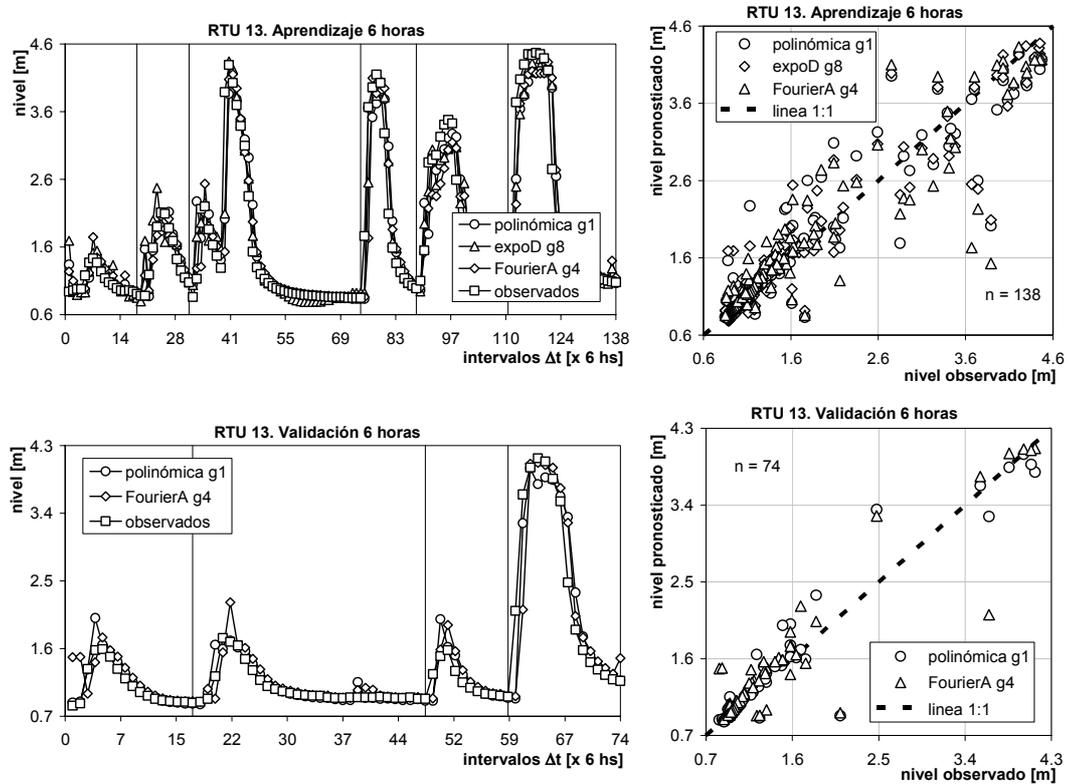


Figura 20. Limnigramas para la muestra 650. Horizonte de pronóstico 6 horas.

CONCLUSIONES

El empleo conjunto de medidas estructurales y no estructurales es la metodología que produce mejores resultados en la lucha contra las inundaciones. Entre las segundas se encuentran los sistemas de alerta contra inundaciones (SAI) que permiten pronosticar el estado futuro del nivel de agua en ciertas secciones características de los cursos de agua. Estos sistemas son una herramienta de ayuda fundamental en la toma de decisiones por parte de las autoridades encargadas de la defensa civil ante una posible situación de inundación.

La confiabilidad en el registro de los datos hidrológicos (principalmente precipitación y niveles) es de vital importancia para el buen desempeño del sistema, demandando un seguimiento constante tanto desde la estación central como en cada uno de los lugares donde se encuentran instalados. Es recomendable ejecutar tareas de mantenimiento preventivo de la red en forma periódica como de mantenimiento correctivo inmediatamente sean detectados problemas en la recepción de los datos. El objetivo es lograr una serie continua de datos, tanto de precipitaciones como de niveles, para evitar periodos sin registros y aumentar la robustez de los pronósticos.

Dado que el modelo empleado es tipo 'caja negra', se observa que para su puesta en funcionamiento no demanda gran cantidad de datos de la cuenca a estudiar; como las características físicas, la topografía, el detalle de las obras de arte presentes, el uso del suelo o la condición de humedad para cada evento. Por lo que su aplicación, resulta relativamente sencilla de llevar a cabo en otras cuencas una vez programada la red funcional. El tiempo de cálculo para este tipo de modelos es sumamente corto, del orden de algunos segundos, ya que su funcionamiento está basado en la resolución de un sistema de ecuaciones; lo que le otorga cierta ventaja frente a los modelos distribuidos en cuanto al tiempo de cálculo.

Analizando los indicadores estadísticos presentados (Figuras 7 a 16 y Tablas 2 y 3) se verifica la tendencia general de que a medida que el horizonte temporal se incrementa, desmejoran los índices considerados. Para la cuenca del arroyo Ludueña se registraron valores promedios de la diferencia en el pico de 0.01 m (0.7%) para 15 minutos y de 0.29 m (15.7%) para 6 horas en aprendizaje y de 0.01 m (0.5%) para 15 minutos y de 0.35 m (19.2%) para 6 horas en validación. Para la cuenca del arroyo Saladillo este indicador arroja los siguientes resultados: 0.01 m

(0.6%) para 15 minutos y 0.25 m (15.4%) para 6 horas en aprendizaje y 0.01 m (0.4%) para 15 minutos y 0.30 m (18.7%) en validación.

Respecto del coeficiente de Nash-Sutcliffe o eficiencia del modelo CE, los resultados arrojan los siguientes valores medios para la cuenca del arroyo Ludueña: en aprendizaje 0.998 para 15 minutos y 0.812 para 6 horas, y en validación 0.998 para 15 minutos y 0.729 para 6 horas. Mientras que para la cuenca del arroyo Saladillo los valores fueron: en aprendizaje 0.998 para 15 minutos y 0.796 para 6 horas, y en validación 0.998 para 15 minutos y 0.735 para 6 horas.

Por otro lado, referente a la raíz del error cuadrático medio RECM, se obtuvo en promedio, para la cuenca del arroyo Ludueña: en aprendizaje 0.02 m para 15 minutos y 0.18 m para 6 horas y en validación 0.01 m para 15 minutos y 0.20 m para 6 horas. Mientras que para la cuenca del arroyo Saladillo se halló: en aprendizaje 0.02 m para 15 minutos y 0.18 m para 6 horas y en validación 0.02 m para 15 minutos y 0.19 m para 6 horas. De los resultados obtenidos se observa que para ambas cuencas los parámetros estadísticos son similares.

Los resultados en términos de niveles limnimétricos fueron evaluados para diferentes familias funcionales y varios tiempos de pronóstico a través de diferentes estadísticos. Los mejores resultados, se obtuvieron en general para la función polinómica; aunque no existe una superioridad notable de la misma por sobre la función exponencial o de Fourier. Además se observó que no existe un grado predominante para las funciones consideradas. El hecho de realizar pronósticos con mayor tiempo de antecedencia produce un aumento de las incertidumbres asociadas al proceso de transformación lluvia – escurrimiento superficial, con la consecuente desmejora de los mismos.

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 con dicho juego de datos de entrada, antes que con un segundo juego de datos para el cual se verificará su desempeño.

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. De esta forma, la mayor cantidad de datos de entrada al modelo permitirá mejorar la robustez del mismo.

Un comentario con relación a los parámetros empleados para evaluar el grado de bondad de los modelos, es que no existe en la actualidad un criterio unánime por parte de la comunidad científica en cuanto a la superioridad de un parámetro sobre otro; siendo deseable profundizar en el estudio de estos índices estadísticos para mejorar el criterio de selección de los modelos.

Una consideración aparte merece la selección de los eventos que son utilizados para aprendizaje, debido a que estos modelos son altamente dependiente de los datos, si se utilizan eventos donde se registraron niveles ‘bajos’, es probable que calibrado el modelo con dicha serie de eventos, el mismo no logre representar situaciones de niveles ‘altos’. Por lo que una duda latente es poder evaluar el comportamiento que tienen estos modelos frente a eventos de mayor magnitud que los utilizados en la etapa de calibración o entrenamiento.

Como posibles líneas de investigación a seguir se plantean: a) analizar el uso de diferentes parámetros estadísticos y generar un criterio para evaluar la bondad de diferentes modelos; b) utilizar otras familias de funciones, como por ejemplo la logarítmica, para evaluar su comportamiento; c) implementar las funciones utilizadas en este trabajo a otras cuencas de la zona para evaluar su desempeño.

REFERENCIAS

- Aldana Valverde, A. 2002. Planificación, Diseño y Utilización de Herramientas de Ayuda a la Toma de Decisiones en Tiempo Real. Jornadas sobre sistemas de ayuda a la decisión ante problemas hidráulicos e hidrológicos en tiempo real, CEDEX, Marzo de 2002, pp. 7-16.
- Alvisi, S.; Mascellani, G. y Franchini, M. y Bárdossy, A. 2006. “Water level forecasting through fuzzy logic and artificial neural network approaches”. *Hydrology and Earth System Sciences*, 10: 1-17.
- Aqil, M.; Kita, I.; Yano, A. y Nishiyama, S. 2007. “A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff”. *Journal of Hydrology*, 337: 22-34.
- Arduino, G.; Reggiani, P. y Todini, E. 2005. Recent advances in flood forecasting and flood risk assessment. *Hydrology and Earth System Sciences*, (94): 280-284.
- 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. 1993. Los sistemas de previsión de avenidas en España. *Revista de Obras Públicas*. Nº 3317. año 140. enero 1993, pp 69-71.
- 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.
- Cameron, D.; Kneale, P. y See, L. 2002. “An evaluation of a traditional and a neural net modeling approach to flood forecasting for an upland catchment”. *Hydrological Processes*, 16:1033-1046.
- Campolo, M., Andreussi, P. y Soldati, A., 1999. River flood forecasting with a neural network model. *Water Resources Research*, 35(4):1191-1197.
- Campolo, M.; Soldati, A. y Andreussi, P. 2003. “Artificial neural network approach to flood forecasting in the River Arno”. *Hydrological Sciences – Journal – des Sciences Hydrologiques*, 48(3): 381-398.
- 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.
- Castillo, E.; Cobo, A.; Gutiérrez, J. y Pruneda, E. 2000. “Functional Networks: A New Network-Based Methodology”. *Computer-Aided Civil and Infrastructure Engineering*, 15: 90-106.
- Celade. 2014. Centro Latinoamericano y Caribeño de Demografía, División de Población de la Comisión Económica para América Latina (CEPAL). <http://celade.cepal.org/>. Acceso octubre 2014.
- Chang, F.; Chang, L. y Wang, Y. 2007. “Enforced self-organization map neural networks for river

- flood forecasting". *Hydrological Processes*, 21:741-749.
- Chang, L.; Chang, F. y Wang, Y. 2009. "Auto-configuring radial basis function networks for chaotic time series and flood forecasting". *Hydrological Processes*, 23:2450-2459.
- Chiang, Y.; Chang, L. y Chang, F. 2004. "Comparison of static-feedforward and dynamic-feedback neural networks for rainfall-runoff modeling". *Journal of Hydrology*, 290: 297-311.
- Chiang, Y. y Chang, F. 2009. "Integrating hydrometeorological information for rainfall-runoff modeling by artificial neural networks". *Hydrological Processes*, 23: 1650-1659.
- Chidthong, Y.; Tanaka, H. y Supharatid, S. 2009. "Developing a hybrid multi-model for peak flood forecasting". *Hydrological Processes*, 23: 1725-1738.
- CRED. 2014. Centre for Research on the Epidemiology of Disasters. Acceso internet: <http://www.emdat.be/classification>.
- 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.
- Dawson C. y Wilby, R. 1999. "A comparison of artificial neural networks used for river flow forecasting". *Hydrology and Earth System Sciences*, 3(4): 529-540.
- De Roo, A.; Gouweleeuw, B.; Thielen, J.; Bartholmes, J.; Bongioannini-Cerlini, P.; Todini, E.; Bates, P.; Horritt, M.; Hunter, N.; Beven, K.; Pappenberger, F.; Heise, E.; Rivin, G.; Hils, M.; Hollingsworth, A.; Holst, B.; Kwadijk, J.; Reggiani, P.; Van Dijk, M.; Sattler, K. y Sprokkereef, E. 2003. Development of a European flood forecasting system. *International Journal of River Basin Management*, 1(1): 49-59.
- de Vos, N. y Rientjes, T. 2005. "Constraints of artificial neural networks for rainfall-runoff modelling: trade-offs in hydrological state representation and model evaluation". *Hydrology and Earth System Sciences*, 9:111-126.
- 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.
- García, R. y Linares Sáez, A. 2002. Experiencias en el uso de la red SAIH-EBRO en la optimización de la gestión de embalses durante episodios de avenidas. Jornadas sobre sistemas de ayuda a la decisión ante problemas hidráulicos e hidrológicos en tiempo real, CEDEX, Marzo de 2002. pp. 362-382.
- Goswami, M.; O'Connor, K.; Bhattarai, K. y Shamseldin, A. 2005. Assessing the performance of eight real-time updating models and procedures for the Brosna River. *Hydrology and Earth System Sciences*, 9(4): 394-411.
- 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.
- Han, J. 2002. "Application of Artificial Neural Networks for Flood Warning Systems". Civil and Environmental Engineering, Raleigh, North Carolina. Tesis de Doctorado. 137 p.
- Hickey, J. y Salas, J. [1998]. Environmental effects 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.
- Jacovides, C. y Kontoyiannis, H. 1995. "Statistical procedures for the evaluation of evapotranspiration computing models". *Agricultural Water Management*, 27: 365-371.
- Kanbua, W. y Khetchaturat, C. 2007. Decision Support System for Flash Flood Warning Management using Artificial Neural Network. The 11th Annual National Symposium on Computational Science and Engineering (ANSCSE11), Phuket, Thailand, March 28-30.
- Kang, M.; Kang, M.; Park, S.; Lee, J. y Yoo, K. 2006. "Application of grey model and artificial neural networks to flood forecasting". *Journal of the American Water Resources Association (JAWRA)*, 42(2): 473-486.
- Kim, S. y Kim, H. 2008. "Uncertainty reduction of the flood stage forecasting using neural networks model". *Journal of the American Water Resources Association (JAWRA)*, 44(1): 148-165.
- Kothyari, U. y Singh, V. 1999. A multiple-input single-output model for flow forecasting. *Journal of Hydrology*, 220: 12-26.
- Lekkas, D., Maxey, R. y Wheeler, H., 2004. Inter-comparison of forecasting methods for flood warning in the river cam catchment. *Global Nest: the International Journal*, 5(2):89-97.
- Lin, G.; Chen, G.; Huang, P. y Chou, Y. 2009. "Support vector machine-based models for hourly reservoir inflow forecasting during typhoon-warning periods". *Journal of Hydrology* 372: 17-29.

- Marchi, E., Roth, G. y Siccardi, F. 1995. The November 1994 flood event on the Po river: structural and non-structural measures against inundations. US-Italy Research Workshop on the Hydrometeorology, Impacts and Management of Extreme Floods. Perugia (Italy). November 1995. 28 p.
- Mimikou, M. y Koustoyannis, D. 1995. 1994 Extreme floods in Greece. U.S.-Italy Research Workshop on the Hydrometeorology, Impacts, and Management of Extreme Floods. Perugia (Italy), November 1995, 11p.
- 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.
- Penning-Rowsell, E.; Tunstall, S.; Tapsell, S. y Parker, D. 2000. The benefits of flood warnings: real but elusive, and politically significant. *J. CIWEM*, 14: 7-14, February, 2000.
- Plate, E. 2003. Regional Consultation Europe – Report for EWC II. Second International Conference on Early Warning. 28 – 29 July 2003, Potsdam, Germany, 38 p.
- Ponce, V. 1989. Catchment Modeling. En: *Engineering Hydrology: Principles and Practices*. Prentice Hall, Englewood Cliffs, NJ. 640 pp.
- 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.
- Scuderi, C., Riccardi, G. y Zimmermann, E., 2014. “Modelo de Redes Funcionales orientado a pronóstico de crecidas en cursos de llanura del Gran Rosario, Santa Fe, Argentina”. 2do. Congreso Internacional de Hidrología de Llanuras. Santa Fe. Santa Fe. Setiembre 2014. 10 p.
- See, L.; Corne, S.; Dougherty, M. y Openshaw, S. 1997. “Some Initial Experiments with Neural Network Models of Flood Forecasting on the River Ouse”. Proceedings of the second annual conference of GeoComputation '97 & SIRC '97. University of Otago, New Zealand, 26-29 agosto 1997. pp. 15-22.
- 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.
- Singh, R. 2005. Real time flood forecasting – Indian experiences. International G-WADI Modelling Workshop, National Institute of Hydrology, Roorkee, India, 28/02 al 05/03 de 2005, 34 pp.
- SMN, 2014. Servicio Meteorológico Nacional. Series de precipitaciones, temperaturas y humedad.
- Tedeschi, L. 2006. “Assessment of the adequacy of mathematical models”. *Agricultural Systems*, 89:225-247.
- Thirumalaiah, K. y Deo, M. 1998. Real-Time Flood Forecasting Using Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 13:101–111.
- Tucci, C. 2002. Controle de enchentes. En: *Hidrologia: ciência e aplicacao*. Tucci, C. Organizador. 3 ed. Porto Alegre: editora da UFRGS / ABRH, 2002, 943 pp.
- Tucci, C. y Bertoni, C., 2003. Inundações Urbanas na América do Sul. Porto Alegre: Associação Brasileira de Recursos Hídricos, 150 p.
- USACE 1978. Physical and Economic Feasibility of Nonstructural Flood Plain Management Measures. Institute for Water Resources. Hydrologic Engineering Center. Research Document 11. March 1978. 240 pp.
- USACE 1993. Application of Rainfall-Runoff Simulation for Flood Forecasting. Hydrologic Engineering Center. Technical Paper No. 145. Jun 1993. 20 pp.
- Zealand, C.; Burn, D. y Simonovic, S. 1999. “Short term streamflow forecasting using artificial neural networks”. *Journal of Hydrology* 214: 32-48.

Artículo recibido el 11/2014 y aprobado para su publicación el 02/2015.