

MODELO HÍBRIDO PARA LA SIMULACIÓN NUMÉRICA DE LA FASE DE AVANCE DEL RIEGO POR SUPERFICIE

José Antonio Rodríguez

Empresa Pública Desarrollo Agrario y Pesquero

Subdirección de Infraestructuras y Desarrollo, Área de Modernización y Regadíos

Bergantín, 39, 41012 Sevilla

jarodriguez@dap.es

Resumen: Se presenta un modelo híbrido que combina una solución convencional de balance de volumen con cuatro redes neuronales artificiales del tipo Perceptrón Multicapa para simular la fase de avance del riego por superficie. Las redes neuronales se encargaron de simular los procesos difíciles de asumir por los modelos de balance de volumen sin renunciar a la facilidad y agilidad de los cálculos que brindan estas soluciones simplificadas. Así, dos redes se entrenaron para calcular la evolución temporal del volumen de agua almacenado sobre la superficie del suelo y, asimismo, el área del flujo superficial al inicio del campo; mientras que otras dos redes se diseñaron para asimilar el efecto transitorio que genera las fluctuaciones temporales del caudal de riego sobre la fase de avance del riego por superficie. El modelo híbrido fue capaz de predecir la distancia de avance y el calado del flujo superficial con una precisión similar a la alcanzada con un modelo numérico de inercia nula tanto en condiciones de régimen permanente como transitorio. La solución del modelo híbrido es explícita, no necesita discretizar los dominios temporal y espacial para resolver las ecuaciones que gobiernan el sistema y logra una rápida convergencia de los cálculos.

INTRODUCCIÓN

La modelización numérica del riego por superficie se basa en la solución de las ecuaciones generales que rigen el movimiento del agua sobre un medio poroso: las ecuaciones de Saint-Venant (1871). Estas ecuaciones expresan dos principios físicos bien conocidos: la conservación de la masa (ecuación de continuidad) y la conservación del momento (ecuación dinámica). Las ecuaciones de Saint-Venant no tienen solución analítica conocida, pero pueden resolverse sin mayores dificultades si se someten a ciertas simplificaciones válidas en el contexto del riego por superficie. El grado máximo de simplificación que puede aplicarse a la aproximación de Saint-Venant es integrar la ecuación de continuidad en los dominios del tiempo y el espacio, y sustituir la ecuación dinámica por un perfil del flujo superficial asumido, dando lugar a los conocidos modelos de balance de volumen (Bassett *et al.*, 1980).

Se han desarrollado numerosos modelos analíticos basados en el principio de balance de volumen (Valiantzas, 1997a,b; Valiantzas, 1999; Alazba, 1999), que si bien no son tan flexibles y sofisticados como los numéricos, pueden ser

aplicados con un grado de precisión aceptable y ser fácilmente integrados en rutinas de optimización. Estos modelos constituyen la base de los procedimientos estándares de diseño y evaluación de los sistemas de riego por superficie referenciados en los libros de textos (Walker y Skogerboe, 1987; Walker, 1989).

Pese a la amplia variedad de modelos simples que se encuentra en la literatura especializada, varios autores (Renault y Wallender, 1996; Gillies *et al.*, 2007) han reconocido que la mayoría de los modelos basados en el principio de balance de volumen incurren en serias violaciones del principio de conservación de la masa. Las violaciones más frecuentes que han identificado estos autores son: (i) ignorar la variación temporal del caudal de riego, (ii) estimar el área del flujo superficial a través de ecuaciones de régimen uniforme, (iii) asumir formas arbitrarias de los flujos superficial e infiltrado y (iv) forzar la trayectoria de avance del agua a seguir una función matemática predeterminada. Estas violaciones pueden ejercer un efecto nocivo en la simulación numérica de la fase de avance del riego por superficie.

El impetuoso desarrollo que ha experimentado en los últimos años los campos de la Inteligencia Artificial y la Exploración de Datos brinda una excelente oportunidad para intentar desarrollar modelos híbridos de riego por superficie que, sin renunciar a la facilidad y agilidad de los cálculos que brindan las soluciones simplificadas, pueden mejorar sensiblemente la fiabilidad, flexibilidad y exactitud de las predicciones. Las redes neuronales artificiales (Bishop, 1995) constituyen una de las áreas de la ingeniería del conocimiento que más se han desarrollado en los últimos años, y pueden situarse dentro de las herramientas esenciales para abordar un nuevo paradigma de modelización numérica. Ha sido demostrado que las redes neuronales pueden reemplazar a los esquemas numéricos de diferencias finitas usualmente utilizados en las soluciones de modelos hidrodinámicos (Dibike, 2002), por lo que esta particularidad puede ser perfectamente aprovechada para el desarrollo de modelos híbridos del riego por superficie.

Por tanto, es posible figurar que los modelos simples de riego por superficie pueden mejorar sensiblemente sus predicciones si se integran con redes neuronales artificiales. Las redes se entrenarían para simular los procesos difíciles de asumir por los modelos convencionales de balance de volumen, en donde usualmente se introducen simplificaciones que degradan la calidad de sus predicciones. Así, el objetivo de este trabajo es formular y evaluar un modelo híbrido para la simulación numérica de la fase de avance del riego por superficie mediante la integración de una solución convencional de balance de volumen con redes neuronales artificiales.

MATERIAL Y MÉTODOS

La ecuación de balance de volumen para la fase de avance del riego por superficie (Walker y Skogerboe, 1987) es:

$$\bar{Q}(ta) \cdot ta = [Ao(ta) \cdot ry(ta) \cdot xa] + [Zo(ta) \cdot rz(ta) \cdot xa] \quad (1)$$

donde Q es el caudal aplicado durante la fase de avance del evento de riego, xa es la distancia de avance del frente de agua para un tiempo de aplicación ta , $Ao(ta)$ es el área de la sección transversal del flujo superficial al inicio del campo, $ry(ta)$ es un factor de forma que supone la relación entre el área media del flujo superficial y $Ao(ta)$, $Zo(ta)$ representa la lámina de agua infiltrada en el inicio del campo y $rz(ta)$ es un factor de forma subsuperficial (Walker y Skogerboe, 1987).

Valiantzas (1997a) obtuvo una expresión analítica para estimar la variación temporal del factor de forma subsuperficial correspondiente al modelo de infiltración de Kostikov (1932). El modelo propuesto en este trabajo utiliza la formulación de Valiantzas, tal como se presenta a continuación:

$$rz(ta) = R1 + (R0 + R1)(2,7 \cdot W^2 - 1,7 \cdot W^{3,2}) \quad (2)$$

siendo:

$$R0 = \frac{1}{(1+a)} \quad (3a)$$

$$R1 = \frac{a \cdot \pi(1-a)}{\text{Sen}(\pi/a)} \quad (3b)$$

$$W = \left[\frac{ry(ta) \cdot Ao(ta) \cdot xa}{\bar{Q}(ta) \cdot ta} \right]^{\frac{1}{1+a}} \quad (3c)$$

a es el exponente adimensional del modelo de infiltración de Kostikov (1932) (Eq.(4)):

$$Z(t) = K \cdot t^a \quad (4)$$

donde Z representa el volumen de agua infiltrado por unidad de longitud (m^3m^{-1}), K es un coeficiente empírico ($\text{m}^3\text{m}^{-1}\text{min}^{-a}$) y t es el tiempo de infiltración (min).

Valiantzas (1997a) obtuvo la expresión de $rz(ta)$ a partir del análisis dimensional de los resultados de un modelo numérico que no asume función alguna para describir la trayectoria de avance del agua, evitando así, un sobrecondicionamiento del problema y una posible violación al principio de conservación de la masa.

Determinación del volumen de agua almacenado sobre el suelo

Los modelos de balance de volumen convencionales estiman el volumen de agua almacenado sobre la superficie del suelo asumiendo que $ry(ta)$ es constante y que $Ao(ta)$ puede ser estimada a través de expresiones de régimen uniforme, tales como la ecuación de Manning. Sin embargo, en los modelos numéricos más sofisticados (hidrodinámico completo e inercia nula) el volumen superficial se obtiene como resultado de la solución simultánea de las ecuaciones de continuidad y dinámica; y depende de las fuerzas gravitacionales y de inercia, la resistencia hidráulica, la geometría del flujo superficial y la capacidad de infiltración del suelo. Puede entenderse entonces que la estimación precisa del volumen de agua superficial es muy compleja

Parámetro	Patrón de entrenamiento ($N = 3320$)				Patrón de verificación ($N = 980$)			
	Valor mínimo	Valor medio	Valor máximo	Desviac. estándar	Valor mínimo	Valor medio	Valor máximo	Desviac. estándar
$p1$	0,233	0,672	1,143	0,335	0,317	0,574	0,955	0,264
$p2$	2,667	2,933	3,333	0,237	2,700	2,793	2,900	0,082
$a1$	0,312	0,737	1,000	0,259	0,700	0,793	0,900	0,082
$a2$	1,000	1,457	2,000	0,363	1,500	1,719	1,900	0,175
n	0,015	0,027	0,050	0,009	0,030	0,030	0,030	0,000
K ($m^3 m^{-1} min^{-a}$)	0,001	0,011	0,030	0,009	0,004	0,006	0,008	0,002
a	0,200	0,573	0,800	0,210	0,300	0,551	0,700	0,158
Q (Ls^{-1})	0,500	2,855	6,00	1,459	1,500	1,500	1,500	0,000
So ($m m^{-1}$)	0,000	0,0008	0,010	0,002	0,00003	0,002	0,020	0,005
ta (min)	5,00	213,92	1080,00	240,56	10,00	307,67	1000,00	286,27
xa (m)	10,60	137,54	300,00	71,07	20,50	157,80	300,00	68,68

$p1$, $p2$, $a1$ y $a2$ son coeficientes que se obtienen al asumir que las relaciones entre el área, el perímetro mojado y el calado del flujo superficial pueden ser representadas por simples funciones potenciales (Walker, 1989).

n es el coeficiente de rugosidad de Manning.

So es la pendiente longitudinal del campo.

N representa el número de casos que contiene cada patrón.

Tabla 1. Características de los patrones de datos usados en el entrenamiento y optimización (verificación) de las redes neuronales diseñadas para simular la evolución temporal del área y el volumen del flujo superficial

para ser formulada con simples ecuaciones fundamentadas en fuertes simplificaciones. En este trabajo se intenta resolver este problema mediante la técnica conocida como Redes Neuronales Artificiales (RNA).

La arquitectura de red neuronal elegida para simular la evolución temporal del volumen de agua almacenado sobre la superficie del suelo y, asimismo, el área del flujo superficial al inicio del campo, fue el Perceptrón Multicapa (MLP) con una capa oculta (Bishop, 1995). Para el entrenamiento, verificación y optimización de las redes se prepararon dos patrones de datos con los resultados de múltiples experimentos numéricos ejecutados con el modelo SRFR (Bautista *et al.*, 2009) para una amplia gama de las variables de entrada (Tabla 1).

A fin de reducir la dimensionalidad del problema y garantizar la generalización de los resultados de las RNA, los parámetros originales (Tabla 1) se expresaron en notación adimensional según el esquema propuesto por Katopodes y Strelkoff (1977):

$$X^* = \frac{xa}{Xr} \quad (5a)$$

$$T^* = \frac{ta}{Tr} \quad (5b)$$

$$A^* = \frac{Ao(ta)}{Ar} \quad (5c)$$

$$K^* = \frac{KTr^a}{Ar} \quad (5d)$$

$$V^* = \frac{Vy(ta)}{Vr} \quad (5e)$$

Las variables de referencia (con subíndice r) se definieron como:

$$Ar = An \quad (6a)$$

$$Xr = \frac{Q \cdot 0,06 \cdot Tr}{Ar} \quad (6b)$$

$$Tr = \frac{Yn \cdot An}{Aso \cdot Q \cdot 0,06} \quad (6c)$$

$$Vr = Q \cdot 0,06 \cdot Tr \quad (6d)$$

$$An = \left(\frac{Q \cdot n}{1000 \cdot \sqrt{p1} \cdot \sqrt{So}} \right)^{\frac{1}{p2/2}} \quad (7a)$$

$$Yn = \left(\frac{An}{a1} \right)^{\frac{1}{a2}} \quad (7b)$$

Los casos con So igual a cero se sustituyeron con un valor igual a 10^{-10} a fin de evitar indefiniciones en los cálculos de las variables de referencia.

La RNA para estimar la evolución temporal del área del flujo superficial se entrenó con $p1, p2, a1, a2, a, X^*, T^*$ y K^* como variables de entrada y A^* como variable dependiente. Por su parte, la RNA para calcular el volumen del flujo




Figura 1. Funciones de activación evaluadas. (a) Función Sigmoidal. (b) Función Tangente hiperbólica. (c) Función Lineal

superficial utilizó $p1, p2, a1, a2, a, T^*, X^*, K^*$ y A^* como entrada y V^* como salida. También se analizaron las transformaciones logarítmicas de algunas variables (X^*, T^*, A^* y V^*) en ambas redes. Todas las variables independientes se normalizaron acorde con los límites de las funciones de activación utilizadas en los Elementos de Proceso (neuronas) de la capa oculta. Se evaluaron las funciones de activación Sigmoidal y Tangente hiperbólica en la capa oculta y las funciones Sigmoidal, Tangente hiperbólica y Lineal en la capa de salida. Estas funciones y sus límites se muestran en la Figura 1.

La regla de aprendizaje aplicada para el entrenamiento de las redes fue conducida por el algoritmo Levenberg-Marquadt (Hagan y Menhaj, 1994), usando como función objetivo la minimización del Error Cuadrático Medio (ECM):

$$ECM = \frac{1}{N} \sum_{i=1}^N (D_i - C_i)^2 \quad (8)$$

donde D_i representa los valores deseados (obtenidos por el modelo SRFR), C_i son los valores calculados por las redes neuronales y N es el número total de casos evaluados.

El número de Elementos de Proceso (EP) de la capa oculta de cada red se determinó por prueba y error. Cada configuración analizada (caracterizada por un número de EP en la capa oculta) se entrenó con el patrón de entrenamiento y posteriormente se evaluó con el patrón de verificación (compuesto por casos que no intervinieron en el entrenamiento). El número óptimo de EP fue aquel que permitió minimizar el error de predicción de la red (representado por el Error Cuadrático Medio) correspondiente al patrón de verificación. Para evitar el sobre-entrenamiento de las redes durante todo el proceso de diseño se utilizó el método de validación cruzada. Este método monitoriza el error de un conjunto

de casos elegidos al azar en el patrón de entrenamiento (20 % del total de casos) y detiene el entrenamiento de la red cuando detecta que el error comienza a aumentar.

Las variables que finalmente intervinieron en el entrenamiento de las redes se obtuvieron mediante análisis de sensibilidad. El procedimiento utilizado fue el método de "Perturbación", que consiste en evaluar el efecto de un pequeño cambio o perturbación en cada variable de entrada sobre la salida de la red. De esta forma fue posible identificar las variables independientes irrelevantes y eliminarlas antes de entrenar definitivamente las redes.

Finalmente, los índices que se utilizaron para evaluar la capacidad predictiva de las RNA se exponen a continuación:

$$RECM = \sqrt{\frac{\sum_{i=1}^N (D_i - C_i)^2}{N}} \quad (9)$$

$$ERM = \frac{100}{N} \left| \frac{(D_i - C_i)}{D_i} \right| \quad (10)$$

$$r = \frac{\sum_{i=1}^N (C_i - \bar{C})(D_i - \bar{D})}{\sqrt{\frac{\sum_{i=1}^N (D_i - \bar{D})^2}{N}} \sqrt{\frac{\sum_{i=1}^N (C_i - \bar{C})^2}{N}}} \quad (11)$$

siendo RECM la raíz del Error Cuadrático Medio, ERM el Error Relativo Medio (%), r el coeficiente de correlación, $\bar{C}$ el valor medio de los valores calculados por las redes y $\bar{D}$ el valor medio de los valores deseados. Estos índices se calcularon tanto para patrón de entrenamiento como para el patrón de verificación.

Parámetro	Patrón de entrenamiento ($N = 30743$)				Patrón de verificación ($N = 1672$)			
	Valor mínimo	Valor medio	Valor máximo	Desviac. estándar	Valor mínimo	Valor medio	Valor máximo	Desviac. estándar
$p1$	0,236	0,632	3,311	0,561	0,407	1,137	2,505	0,582
$p2$	2,666	2,851	3,285	0,214	2,799	3,010	3,197	0,109
$a1$	0,249	0,939	1,500	0,510	0,287	0,348	0,448	0,043
$a2$	1,000	1,505	2,000	0,454	1,026	1,079	1,169	0,0388
n	0,015	0,033	0,060	0,0154	0,017	0,031	0,052	0,012
K ($m^3 m^{-1} min^{-a}$)	0,0049	0,0078	0,0113	0,0025	0,0051	0,0064	0,0081	0,0014
a	0,250	0,511	0,756	0,192	0,314	0,455	0,628	0,129
Q_{ins} (Ls^{-1})	0,118	1,671	4,000	0,824	0,205	1,063	2,000	0,498
Q_{med} (Ls^{-1})	0,109	1,549	4,000	0,818	0,203	1,002	2,000	0,485
So ($m m^{-1}$)	0,0000	0,0019	0,0100	0,0026	$3 \cdot 10^{-5}$	0,0018	0,0054	0,0020
ta (min)	0,02	104,32	1816,67	140,49	0,146	181,19	1781,67	235,06
xa (m)	0,938	98,40	300,00	73,79	3,75	127,84	300,00	84,29

Q_{ins} es el caudal instantáneo de riego.

Q_{med} es el caudal medio de riego.

Tabla 2. Características de los patrones de datos usados en el entrenamiento y optimización (verificación) de las redes neuronales diseñadas para estimar los caudales equivalentes para la simulación de la fase de avance en condiciones de fluctuación temporal del caudal de riego

Asimilación de las fluctuaciones temporales del caudal de riego

El modelo propuesto en este trabajo intenta asimilar las fluctuaciones temporales del caudal de riego en el proceso de solución de la ecuación de balance de volumen. Para esto fue necesario, primeramente, sustituir el miembro izquierdo de la ecuación (1) por la expresión $\sum_{t=0}^{t=ta} Q(t) \cdot dt$, que supone interpolar el hidrograma de riego para calcular el volumen de agua aplicado en cada instante de tiempo. Ahora bien, si se intenta estimar $Ao(ta)$ y el volumen superficial con el caudal instantáneo obtenido directamente interpolado del hidrograma de riego, se podrían cometer errores muy significativos. La razón de esto es que el volumen superficial y el calado no fluctúan en la misma proporción que el caudal instantáneo de riego (Gillies et al., 2007), sobre todo cuando la variación de éste último se produce de forma repentina. Para evitar estos errores se diseñaron otras dos redes MLP que fueron capaces de corregir el efecto transitorio descrito sobre la fase de avance del riego por superficie. Estas RNA se entrenaron para estimar unos caudales equivalentes que permitieron utilizar las mismas expresiones desarrolladas en régimen permanente para simular las condiciones de régimen transitorio. Así, una RNA se encarga de determinar el caudal equivalente para calcular el área del flujo superficial, mientras que la otra red estima el caudal equivalente para calcular el

volumen de agua almacenado sobre la superficie del suelo. Para entrenar y verificar las nuevas redes se ejecutaron otros experimentos numéricos con el modelo SRFR bajo condiciones de fluctuación temporal (repentina y gradual) del caudal de riego (Tabla 2).

Las variables originales que intervinieron en las redes se transformaron acorde con la notación adimensional reseñada anteriormente. La RNA que simula el caudal equivalente para calcular el área del flujo superficial se entrenó con $p1, p2, a1, a2, a, X^*, T^*, K^*$ y Q^* como variables de entrada y Qa^* como variable de salida. La red encargada de simular el caudal equivalente para estimar el volumen del flujo superficial utilizó las mismas variables de entrada y Qv^* como salida. Las nuevas variables adimensionales se definieron como:

$$Q^* = \frac{Q_{med}(ta)}{Q_{ins}(ta)} \quad (12)$$

$$Qa^* = \frac{Qa(ta)}{Q_{ins}(ta)} \quad (13)$$

$$Qv^* = \frac{Qv(ta)}{Q_{ins}(ta)} \quad (14)$$

siendo $Q_{med}(ta)$ el caudal medio de riego aplicado durante el intervalo de tiempo ta , $Q_{ins}(ta)$ es el caudal de riego aplicado en el instante ta , mientras que $Qa(ta)$ y $Qv(ta)$ son los caudales equivalentes para calcular el área y el volumen del flujo superficial respectivamente.




Figura 2. Diagrama de flujo del modelo Híbrido para simular la fase de avance del riego por superficie

Para diseñar, entrenar y evaluar las nuevas redes se siguió la misma metodología descrita en el apartado anterior.

Formulación y evaluación del modelo híbrido para simular la fase de avance

En la Figura 2 se muestra el diagrama de flujo del modelo Híbrido desarrollado para simular la fase de avance del riego por superficie. El procedimiento de cálculo ha sido diseñado para estimar la distancia de avance xa y el área del flujo superficial al inicio del campo $Ao(ta)$ correspondiente a un tiempo de aplicación ta . Asimismo, el modelo es capaz de calcular el calado al inicio del campo $Yo(ta)$ según la expresión (15) (Walker, 1989):

$$Yo(ta) = \left(\frac{Ao(ta)}{a1} \right)^{\frac{1}{a2}} \quad (15)$$

Tal como puede apreciarse en la Figura 2, el procedimiento de cálculo se basó en la solución de la ecuación de balance de volumen (ecuación 1) sustituyendo las expresiones convencionales para estimar el volumen de agua y el área del flujo superficial por dos RNA. Para cada tiempo de aplicación, el procedimiento comprueba si se encuentra ante un caso de fluctuación temporal del caudal de riego mediante la comparación de $Qins$ con $Qmed$. Si $Qins$ difiere de $Qmed$ entonces se determinan los caudales equivalentes correspondientes con otras dos RNA antes de continuar con los cálculos.

El modelo Híbrido se evaluó mediante la comparación de sus resultados con las salidas del modelo SRFR. Para esto se utilizaron los experimentos numéricos preparados para generar los patrones de entrenamiento y verificación de las redes neuronales. Para evaluar el modelo Híbrido en condiciones de régimen permanente se utilizaron todos los casos descritos en la Tabla 1, así como los casos con $Qins = Qmed$ de la Tabla 2. Asimismo, para verificar el modelo en condiciones de régimen transitorio se utilizaron los casos descritos en la Tabla 2 que cumplieron la condición de $Qins \neq Qmed$. Se utilizaron varios índices para evaluar el nivel de funcionalidad, precisión y exactitud de las predicciones del modelo Híbrido siguiendo las recomendaciones de Tedeschi (2006). Se ejecutan regresiones lineales entre los valores estimados por el modelo Híbrido (predicciones) y calculados por SRFR (observaciones). Por otro lado, se verificaron las diferencias estadísticas entre las medianas, las varianzas y las distribuciones de frecuencia de las predic-

ciones y las observaciones mediante las pruebas de Wilcoxon-Mann-Whitney (Mann y Whitney, 1947; Wilcoxon, 1945), Brown-Forsythe (Brown y Forsythe, 1974) y Kolmogoroff-Smirnov (Kolmogoroff, 1933; Smirnov, 1933) respectivamente. Adicionalmente, se calcularon los RECM y ERM según las ecuaciones (9) y (10).

RESULTADOS Y DISCUSIÓN

Redes neuronales para estimar el área y el volumen del flujo superficial

La exploración preliminar de las variables adimensionales permitió elegir las transformaciones adecuadas para facilitar el entrenamiento de las redes neuronales. La transformación logarítmica de V^* redujo la dispersión de los datos y permitió obtener una relación prácticamente lineal con $Ln(X^*)$. Por otro lado, se observó una relación no lineal muy bien definida entre X^* y A^* , mientras que la transformación logarítmica de estas variables no aportó prácticamente ninguna mejora. Considerando estos aspectos, se decidió utilizar la transformación logarítmica de las variables X^* , T^* y V^* para entrenar la red neuronal que simula la evolución temporal del volumen del flujo superficial, mientras que la red destinada a calcular el área del flujo superficial utilizó las variables adimensionales sin transformación alguna.

El análisis de sensibilidad permitió determinar que las variables $p1$ y $a1$ fueron irrelevantes para el entrenamiento de la RNA que simula el área del flujo superficial. Asimismo, las variables $p1$, $a1$ y $a2$ ejercieron muy poca influencia en la simulación el volumen del flujo superficial. Por lo tanto, la red para simular la evolución temporal del área del flujo superficial se entrenó definitivamente con $p2$, $a2$, a , X^* , T^* y K^* como variables de entrada y A^* como variable dependiente. Por su parte la RNA para calcular el volumen del flujo superficial utilizó $p2$, a , $Ln(T^*)$, $Ln(X^*)$, K^* y A^* como entrada y $Ln(V^*)$ como salida. Las topologías de las redes MLP que finalmente resultaron óptimas para simular estos procesos se resumen en la Tabla 3.

La capacidad de predicción y generalización de las RNA diseñadas se muestra en la Tabla 4. Puede apreciarse que las redes fueron capaces de simular los procesos con un elevado nivel de precisión y exactitud. Para los patrones de datos analizados se obtuvieron coeficientes de correlación cercanos a 1 y errores relativos medios inferiores al 4 %.

Proceso	Variables independientes	Variable dependiente	No. de EP en la capa oculta	Funciones de activación capa oculta/salida
Área del Flujo Superficial	$p2, a2, a, X^*, T^*, K^*$	A^*	5 EP	Sigmoidal/Sigmoidal
Volumen del Flujo Superficial	$p2, a, Ln(T^*), Ln(X^*), K^*, A^*$	$Ln(V^*)$	7 EP	Sigmoidal/Lineal

Tabla 3. Topologías de las RNA utilizadas para simular la evolución temporal del área y el volumen del flujo superficial

Variable dependiente	Patrón de entrenamiento			Patrón de verificación		
	RECM	ERM (%)	r	RECM	ERM (%)	r
A^*	0,0084	1,3546	0,9994	0,0146	2,0841	0,9977
$Ln(V^*)$	0,0780	3,1613	0,9985	0,1167	3,1865	0,9978

Tabla 4. Evaluación de la precisión y exactitud de las RNA para simular la evolución temporal del área y el volumen del flujo superficial

Estos resultados no sorprenden si se considera que las redes MLP son capaces de aproximar cualquier función continua con suficiente precisión (Smith, 1993). Lo que realmente importa en el diseño de las redes MLP es que sean capaces de generalizar los resultados de los procesos para las que fueron entrenadas. En la Tabla 4 se puede apreciar que los índices de evaluación del patrón de verificación alcanzaron valores similares a los obtenidos en el patrón de entrenamiento. Esto es un indicador de la excelente capacidad de generalización de las redes diseñadas, toda vez que el patrón de verificación fue totalmente independiente del utilizado para entrenar las redes.

Wolpert (1996a, 1996b) identificó tres condiciones necesarias para que las RNA alcancen buena capacidad de generalización. Primero, las variables de entrada de la red deben contener suficiente información sobre el proceso que se desee simular. No debe esperarse que una RNA sea capaz de simular un proceso pobremente definido. Segundo, la relación entre las variables de entrada y salida debe ser continua y poco dispersa. Los procesos muy aleatorios son difíciles de generalizar con las RNA. Usualmente una transformación no lineal de las variables de entrada puede suavizar la función y mejorar la generalización de la red. Tercero, el patrón de entrenamiento debe ser suficientemente extenso y representativo de la población que se desea modelar.

El proceso de diseño y entrenamiento de las RNA utilizado en este trabajo consideró las tres condiciones descritas, pero sin duda la actuación que mayor impacto ejerció sobre la buena capacidad generalizadora de las redes fue la elección de las variables de entrada. Inicialmente se intentó entrenar las redes con las variables de entrada y salida en su estado natural (expresadas en notación dimensional). Las redes diseñadas en estas condiciones fueron capaces de reproducir adecuadamente el patrón de entrenamiento, pero no lograron simular el patrón de verificación con una precisión adecuada (Figura 3a), en otras palabras, no alcanzaron capacidades de generalización aceptables.

Redes neuronales para asimilar las fluctuaciones temporales del caudal de riego

El análisis preliminar de los experimentos numéricos permitió constatar que los caudales equivalentes permanecieron acotados por los caudales medio e instantáneo de riego. Como regla general, el caudal equivalente para estimar el área del flujo superficial tiende rápidamente al caudal instantáneo de riego, mientras que el caudal equivalente para estimar el volumen superficial se aproxima al caudal medio de riego. En la Figura 4 se muestran dos ejemplos de este comportamiento típico, que puede variar en función de las características geométricas del flujo superficial, la capacidad de infiltración del suelo y la pendiente longitudinal del campo.




Figura 3. Comparación de los resultados obtenidos por el modelo SRFR y las RNA en la simulación del área del flujo superficial (figuras a la izquierda) y el volumen del flujo superficial (figuras a la derecha). (a) Redes diseñadas con las variables en notación dimensional. (b) Redes diseñadas con las variables transformadas en notación adimensional




Figura 4. Ejemplos del comportamiento típico de los caudales equivalentes para simular la fase de avance en condiciones de fluctuación temporal del caudal de riego

El hecho de que los caudales equivalentes permanecieron acotados por los caudales medio e instantáneo facilitó considerablemente el entrenamiento de estas redes. La variable adimensional Q^* (Q_{med}/Q_{ins}) aportó una información muy importante en la predicción de los caudales equivalentes o sus variantes adimensionales (Qa^* y Qv^*), mientras que el resto de va-

riables independientes se encargaron de definir los gradientes con que los caudales equivalentes se aproximaron a los caudales medio e instantáneo. De hecho, el análisis de sensibilidad no reveló ninguna variable irrelevante en la simulación de los procesos, por esta razón las redes se diseñaron con todas las variables independientes originalmente consideradas.

Las topologías óptimas y las capacidades de predicción y generalización de las Redes MLP utilizadas para estimar los caudales equivalentes se presentan en las Tablas 5 y 6 respectivamente. Una vez más, las redes MLP fueron capaces de simular los procesos con un elevado nivel de precisión y exactitud tanto en el patrón de entrenamiento como en el patrón de verificación. Los coeficientes de correlación alcanzaron valores cercanos a 1, los errores relativos medios fueron inferiores al 2 %, mientras que los RECM, que son medidas muy fiables de la exactitud de las predicciones de las redes, fueron muy bajos para todos los casos analizados.

Evaluación del modelo híbrido en condiciones de régimen permanente

La Tabla 7 contiene el resumen estadístico

de los resultados (distancia de avance y calado) obtenidos por los modelos Híbrido y SRFR en condiciones de régimen permanente ($Q_{ins} = Q_{med}$). De particular interés resultan los coeficientes de asimetría y curtosis estandarizados contenidos en la Tabla 7, que pueden usarse para determinar si las muestras proceden de distribuciones normales. Los valores de estos estadísticos fuera del rango de -2 a +2 indican desviaciones significativas de la distribución normal. En la Tabla 7 se puede observar que ambas muestras alcanzaron valores de asimetría y curtosis estandarizadas fuera del rango normal. Estos resultados invalidan las pruebas que comparan las muestras bajo el supuesto de que siguen distribuciones normales. Por esta razón, las comparaciones de las medianas y las varianzas se realizaron con pruebas no paramétricas.

Proceso	Variables independientes	Variable dependiente	No. de EP en la capa oculta	Funciones de activación capa oculta/salida
Caudal Equivalente Área del Flujo Superficial	$p1, p2, a1, a2, a, X^*, T^*, K^*, Q^*$	Qa^*	5 EP	Tangente Hiperbólica/Lineal
Caudal Equivalente Volumen del Flujo Superficial	$p1, p2, a1, a2, a, X^*, T^*, K^*, Q^*$	Qv^*	7 EP	Tangente Hiperbólica/Lineal

Tabla 5. Topologías de las Redes MLP utilizadas para estimar los caudales equivalentes para la simulación de la fase de avance en condiciones de fluctuación temporal del caudal de riego

Variable dependiente	Patrón de entrenamiento			Patrón de verificación		
	RECM	ERM (%)	r	RECM	ERM (%)	r
Qa^*	0,0468	1,6925	0,9879	0,0310	1,0665	0,9927
Qv^*	0,0283	1,8709	0,9897	0,0215	1,5568	0,9942

Tabla 6. Evaluación de la precisión y exactitud de las RNA para simular los caudales equivalentes

Estadísticos	Distancia de avance SRFR	Distancia de avance Híbrido	Calado al inicio del campo SRFR	Calado al inicio del campo Híbrido
Frecuencia	7800	7800	7800	7800
Media (m)	104,53	104,27	0,0799	0,0799
Mediana (m)	86,15	85,71	0,0829	0,0834
Varianza (m ²)	5192,11	5186,48	0,00138	0,00137
Desviación estándar (m)	72,06	72,02	0,0371	0,0370
Valor mínimo (m)	2,38	2,35	0,0092	0,0097
Valor máximo (m)	299,90	300,20	0,163	0,163
Primer cuartil (m)	49,60	49,44	0,0518	0,0517
Segundo cuartil (m)	147,45	147,52	0,109	0,109
Asimetría estandarizada	30,16	30,16	-2,86	-2,14
Curtosis estandarizada	-2,18	-2,26	-16,56	-16,44

Tabla 7. Resumen estadístico de los resultados obtenidos por los modelos Híbrido y SRFR en condiciones de régimen permanente

Estadísticos	Distancia de avance		Calado al inicio del campo	
	Modelo SRFR	Modelo Híbrido	Modelo SRFR	Modelo Híbrido
Mediana de la muestra	86,15	85,71	0,0829	0,0834
Hipótesis nula	Mediana modelo SRFR = Mediana modelo Híbrido			
Hipótesis alternativa	Mediana modelo SRFR $\neq$ Mediana modelo Híbrido			
Rango medio de la muestra	7811,14	7789,86	7800,41	7800,59
W	3,033*10 ⁷		3,042*10 ⁷	
p	0,768		0,998	

Tabla 8. Resultados de la prueba de Wilcoxon-Mann-Whitney para comparar las medianas de los resultados obtenidos por los modelos SRFR e Híbrido

Estadísticos	Distancia de avance		Calado al inicio del campo	
	Modelo SRFR	Modelo Híbrido	Modelo SRFR	Modelo Híbrido
Mediana de la muestra	104,53	104,27	0,0799	0,0799
Hipótesis nula	Varianza modelo SRFR = Varianza modelo Híbrido			
Hipótesis alternativa	Varianza modelo SRFR $\neq$ Varianza modelo Híbrido			
Desviación Estándar	72,06	72,02	0,0371	0,0370
W	0,00044		0,08745	
p	0,983		0,767	

Tabla 9. Resultados de la prueba de Brown-Forsythe para comparar las varianzas de los resultados obtenidos por los modelos SRFR e Híbrido

En la Tabla 8 se muestran los resultados de la prueba de Wilcoxon-Mann-Whitney para determinar si existen diferencias significativas entre las medianas de las distancias de avance y los calados estimados por los modelos SRFR e Híbrido. Dado que los valores de p fueron mayores a 0,01, no existen diferencias estadísticamente significativa entre las medianas de ambas muestras para un nivel de confianza del 99,0 %. Por otro lado, la Tabla 9 contiene los resultados de la prueba de Brown-Forsythe para comparar las varianzas de los resultados de ambos modelos. La prueba de Brown-Forsythe es un test no paramétrico equivalente a la prueba F para determinar las diferencias de las varianzas. Según los resultados de esta prueba, se puede concluir que no existen diferencia estadísticamente significativa entre las varianzas de ambas muestras para un nivel de confianza del 99,0 %, toda vez que los valores de p fueron superiores a 0,01.

Otra procedimiento robusto para determinar la validez de un modelo es la comparación entre las distribuciones de frecuencia de los valores observados y estimados (Tedeshi, 2006). En la Figura 5 se comparan las distribuciones de frecuencia de los resultados de los modelos Híbrido y SRFR. Puede apreciarse que las frecuencias acumuladas coinciden claramente en los dos

procesos modelados. La prueba de Kolmogoroff-Smirnov permitió evaluar estadísticamente la probabilidad de que las observaciones y las predicciones pertenecen a una misma distribución de frecuencia. Esta prueba se basa en el cálculo de la distancia máxima entre las distribuciones acumuladas de las dos muestras. Dado que los valores de p fueron mayores a 0,01 (Figura 5), se confirma que no existen diferencias estadísticamente significativas entre las distribuciones analizadas para un nivel de confianza del 99,0 %.

Kleijnen *et al.* (1998) propusieron un procedimiento riguroso para evaluar los resultados de un modelo. Según estos autores, un modelo es estadísticamente válido si, y solo si, los valores observados (en este caso las salidas del modelo SRFR) y las predicciones (salidas del modelo Híbrido) tienen medias (o medianas) y varianzas estadísticamente idénticas. De acuerdo con los resultados de las pruebas anteriores, y considerando los criterios propuestos por Kleijnen *et al.* (1998), se puede concluir que las predicciones del modelo Híbrido fueron estadísticamente válidas en comparación con las salidas del modelo SRFR. Resulta oportuno destacar que el modelo SRFR es un referente mundial en la simulación unidimensional del riego por superficie, y ha sido




Figura 5. Distribuciones de frecuencia acumulada de los resultados de los modelos Híbrido y SRFR. (a) Simulación de la distancia de avance. (b) Simulación del calado al inicio del campo




Figura 6. Regresión lineal de los resultados obtenidos con los modelos Híbrido y SRFR. (a) Distancia de avance. (b) Calado del flujo superficial al inicio del campo

ampliamente evaluado y aplicado en disímiles situaciones (Bautista et al., 2009). Sin embargo, para completar la evaluación del modelo desarrollado fue necesario además, analizar el nivel de funcionalidad, la precisión y la exactitud de sus predicciones.

En la Figura 6 se muestran las regresiones lineales de los resultados obtenidos con los modelos Híbrido y SRFR. El modelo Híbrido fue capaz de predecir la distancia de avance y el calado del flujo superficial con una precisión similar a la alcanzada con SRFR en condiciones de régimen permanente. Se obtuvieron coeficientes de determinación superiores a 0,99 en las regresiones de ambos procesos. Además, las pendientes e interceptos de las líneas de regresión fueron muy cercanos a 1 y 0 respectivamente, reflejando la

elevada exactitud de los predicciones del modelo Híbrido. El RECM fue tan solo de 1,289 m en la simulación de la distancia de avance y de 1,2 mm en la predicción del calado del flujo superficial, mientras que los ERM no superaron el 1,2 % en ambos procesos.

Otro aspecto importante en la evaluación de un modelo es su nivel de funcionalidad. El modelo Híbrido es capaz de calcular la distancia de avance y el calado explícitamente, es decir, para cualquier tiempo de avance el modelo puede estimar la distancia y el calado directamente sin necesidad de discretizar los dominios temporal y espacial. Los modelos más sofisticados (hidrodinámico completo o inercia nula) tienen necesariamente que discretizar los dominios del tiempo y el espacio para resolver numéricamen-

te las ecuaciones completas de Saint-Venant o algunas de sus simplificaciones. La presencia de términos no lineales en estas ecuaciones imponen la necesidad de utilizar métodos iterativos especiales (Newton-Raphson, por ejemplo) para acelerar la convergencia de los cálculos (Walker y Skogerboe, 1987). La solución del modelo Híbrido converge rápidamente sin necesidad de aplicar técnicas iterativas especiales. De hecho, el valor medio de las iteraciones necesarias para lograr la convergencia de los cálculos fue de tan solo 4,24 en los 7800 casos evaluados en condiciones de régimen permanente.

Evaluación del modelo híbrido en condiciones de régimen transitorio

El resumen estadístico de los resultados obtenidos por los modelos Híbrido y SRFR en condiciones de régimen transitorio ($Q_{ins} \neq Q_{med}$) se muestra en la Tabla 10. Al igual que en los re-

sultados obtenidos en régimen permanente, los coeficientes de asimetría y curtosis estandarizadas alcanzaron valores fuera del rango normal, por lo que las comparaciones de las muestras se realizaron con pruebas no paramétricas.

La Tabla 11 contiene los resultados de las pruebas de Wilcoxon-Mann-Whitney y Brown-Forsythe para determinar si existen diferencias significativas entre las distancias de avance y los calados estimados por los modelos SRFR e Híbrido en condiciones de régimen transitorio. Los valores de p obtenidos en ambas pruebas fueron superiores a 0,01, sugiriendo que no existen diferencias significativas entre las medianas y las varianzas de las muestras analizadas para un nivel de confianza del 99,0 %. Asimismo, la prueba de Kolmogoroff-Smirnov permitió confirmar que tampoco se encontraron diferencias significativas entre las distribuciones de frecuencia para un nivel de confianza del 99,0 %.

Estadísticos	Distancia de avance SRFR	Distancia de avance Híbrido	Calado al inicio del campo SRFR	Calado al inicio del campo Híbrido
Frecuencia	27000	27000	27000	27000
Media (m)	97,37	96,81	0,0608	0,0607
Mediana (m)	81,14	80,21	0,0537	0,0536
Varianza (m ²)	4761,95	4736,38	0,00127	0,00127
Desviación estándar (m)	69,01	68,82	0,0356	0,0357
Valor mínimo (m)	0,94	0,86	0,00455	0,00446
Valor máximo (m)	300,00	306,62	0,175	0,174
Primer cuartil (m)	43,87	43,51	0,0312	0,0309
Segundo cuartil (m)	140,00	138,90	0,0862	0,0864
Asimetría estandarizada	57,75	58,68	40,52	40,91
Curtosis estandarizada	2,50	2,73	-18,27	-18,06

Tabla 10. Resumen estadístico de los resultados obtenidos por los modelos Híbrido y SRFR en condiciones de régimen transitorio




Figura 7. Regresión lineal de los resultados obtenidos con los modelos Híbrido y SRFR en condiciones de régimen transitorio. (a) Distancia de avance. (b) Calado del flujo superficial al inicio del campo

PRUEBA DE WILCOXON-MANN-WHITNEY				
Estadísticos	Distancia de avance		Calado al inicio del campo	
	Modelo SRFR	Modelo Híbrido	Modelo SRFR	Modelo Híbrido
Mediana de la muestra	81,15	80,21	0,0537	0,0535
Hipótesis nula	Mediana modelo SRFR = Mediana modelo Híbrido			
Hipótesis alternativa	Mediana modelo SRFR $\neq$ Mediana modelo Híbrido			
Rango medio de la muestra	27066,4	26934,6	27028,0	26973,0
W	3,627*10 ⁸		3,637*10 ⁸	
p	0,326		0,681	

PRUEBA DE BROWN-FORSYTHE				
Estadísticos	Distancia de avance		Calado al inicio del campo	
	Modelo SRFR	Modelo Híbrido	Modelo SRFR	Modelo Híbrido
Mediana de la muestra	97,37	96,81	0,0608	0,0607
Hipótesis nula	Varianza modelo SRFR = Varianza modelo Híbrido			
Hipótesis alternativa	Varianza modelo SRFR $\neq$ Varianza modelo Híbrido			
Desviación Estándar	69,01	68,82	0,0356	0,0357
W	0,337		0,0838	
p	0,562		0,772	

Tabla 11. Resultados de las pruebas de Wilcoxon-Mann-Whitney y Brown-Forsythe para comparar las medianas y varianzas de los resultados obtenidos por los modelos SRFR e Híbrido en condiciones de régimen transitorio

Siendo el modelo Híbrido estadísticamente válido según los criterios propuestos por Kleijnen *et al.* (1998), queda evaluar el nivel de precisión y exactitud de sus predicciones. En la Figura 7 se comparan los resultados de los modelos Híbrido y SRFR en condiciones de régimen transitorio. Las fluctuaciones temporales del caudal del riego inducen un efecto transitorio muy complejo sobre la fase de avance del riego por superficie (Gillies *et al.*, 2007). Pese a la complejidad añadida que supone la simulación numérica de la fase de avance en estas condiciones, el modelo Híbrido fue capaz de alcanzar predicciones excelentes. Se puede apreciar en la Figura 7 que los resultados de las regresiones lineales fueron muy similares a las logradas en régimen permanente. Se obtuvieron coeficientes de determinación cercanos a 1, mientras que las pendientes y los coeficientes de las regresiones lineales fueron muy próximo a 1 y 0 respectivamente. Los ERM no superaron el 1,8 %, y los RECM fueron de 2,19 m en la predicción de la distancia de avance y de 1,3 mm en la predicción del calado al inicio del campo. La convergencia de los cálculos se alcanzó en 3,87 iteraciones como valor medio de los 27000 ca-

los evaluados. Estos resultados reflejan una vez más el alto grado de precisión, exactitud y funcionalidad del modelo Híbrido en condiciones de régimen transitorio.

La variación temporal del caudal de riego ejerce un impacto muy significativo sobre la fase de avance del riego por superficie (Renault y Wallender, 1996). El caudal de riego influye sobre el volumen de agua que se almacena en la superficie del suelo y por tanto, determina en buena medida la velocidad de avance del frente de agua. Gillies *et al.* (2007) intentaron considerar el efecto de la fluctuación temporal del caudal de riego mediante una simple interpolación lineal del hidrograma para calcular el volumen de agua aplicado en cada instante de tiempo. Estos autores asumieron que el volumen de agua temporalmente almacenado sobre el suelo fluctuó en la misma proporción que el caudal de riego. Como consecuencia de estas simplificaciones, el modelo propuesto por Gillies *et al.* (2007) solo fue capaz de simular correctamente las fluctuaciones muy graduales del caudal de riego, pero no logró asimilar adecuadamente el impacto que supone las fluctuaciones repentinas del caudal.




Figura 8. Variaciones de la velocidad de avance considerando que el volumen superficial fluctúa en igual proporción al caudal de riego (sin corrección de Q) y corrigiendo el efecto transitorio con los caudales equivalentes (corrección de Q)

En la Figura 8 se muestran dos ejemplos de la aproximación descrita por Gillies *et al.* (2007). Se han representado las curvas de velocidad de avance porque permiten visualizar mejor el impacto del cambio de caudal sobre la fase de avance del riego por superficie. En esta figura se muestran las variaciones de la velocidad de avance considerando que el volumen superficial fluctúa en igual proporción al caudal de riego (sin corrección de Q), tal como propusieron Gillies *et al.* (2007). También se representa la curva de velocidad de avance obtenida al corregir el efecto transitorio con los caudales equivalentes (con corrección de Q), tal como lo hace el modelo Híbrido desarrollado en este trabajo. Ambos resultados se comparan con las salidas del modelo SRFR.

En la Figura 8 resulta evidente que los resultados sin corrección de Q son incorrectos. El incremento repentino del caudal de riego indujo una velocidad de avance negativa, que representa un retroceso del frente de agua, cuando el efecto real fue completamente opuesto. Al asumir que el área del flujo superficial es proporcional al caudal de riego, un incremento repentino de éste provoca una sobreestimación importante en el volumen del flujo superficial y consecuentemente, se subestiman la distancia y la velocidad de avance del frente. Sin embargo, el modelo Híbrido fue capaz de atenuar los cambios bruscos de caudales (mediante los caudales equivalentes) antes de calcular el área y el volumen del flujo superficial, consiguiendo resultados muy similares a los obtenidos por el modelo SRFR.

CONCLUSIONES

1. La integración de un modelo convencional de balance de volumen con redes neu-

ronales artificiales conformaron el modelo Híbrido propuesto en este trabajo. Las redes neuronales se encargaron de simular los procesos difíciles de asumir por los modelos convencionales de balance de volumen sin necesidad de renunciar a la facilidad y agilidad de los cálculos que brindan estas soluciones simplificadas.

2. Las redes neuronales artificiales diseñadas fueron capaces de simular la evolución temporal del calado y el volumen del flujo superficial durante la fase de avance del riego por superficie con un elevado nivel de precisión y exactitud.
3. La simple transformación de las principales variables que dominan los sistemas de riego por superficie en notación adimensional permitió que las redes neuronales diseñadas adquirieran excelentes capacidades de generalización.
4. Las redes neuronales artificiales permitieron asimilar correctamente el impacto de las variaciones graduales y repentinas del caudal de riego sobre el comportamiento de la fase de avance del riego por superficie.
5. El modelo Híbrido fue capaz de predecir la distancia de avance y el calado del flujo superficial con una precisión similar a la alcanzada con un modelo numérico de inercia nula, tanto en condiciones de régimen permanente como transitorio. La solución del modelo Híbrido es explícita, no necesita discretizar los dominios temporal y espacial para resolver las ecuaciones que

gobiernan el sistema y logra una rápida convergencia de los cálculos.

Finalmente, debe mencionarse que el modelo híbrido desarrollado en este trabajo ha sido utilizado con excelentes resultados en una herramienta informática para la modelización inversa multi-objetivo del riego por superficie con vista a identificar los parámetros de infiltración y resistencia hidráulica del suelo (Rodríguez y Martos, 2009).

LISTA DE SÍMBOLOS

Q : Caudal aplicado durante la fase de avance del evento de riego
 xa : Distancia de avance del frente de agua
 ta : Tiempo de aplicación del caudal del riego durante la fase de avance
 $Ao(ta)$: Área de la sección transversal del flujo superficial al inicio del campo
 $ry(ta)$: Factor de forma del flujo superficial
 $Zo(ta)$: Lámina de agua infiltrada en el inicio del campo
 $rz(ta)$: Factor de forma del flujo subsuperficial
 Z : Volumen de agua infiltrado por unidad de longitud
 K : Coeficiente empírico del modelo de infiltración del Kostiakov
 a : Exponente adimensional del modelo de infiltración de Kostiakov
 t : Tiempo de infiltración del modelo de infiltración de Kostiakov
RNA: Red Neuronal Artificial
MLP: Arquitectura de RNA conocida como Perceptrón Multicapa
EP: Elemento de Proceso de la capa oculta de una RNA
 $p1, p2, a1, a2$: Coeficientes que dependen de la geometría del flujo superficial
 n : Coeficiente de rugosidad de Manning
 So : Pendiente longitudinal del campo
ECM: Error Cuadrático Medio
RECM: Raíz del Error Cuadrático Medio
ERM: Error Relativo Medio
 r : coeficiente de correlación
 $Qins$: Caudal instantáneo de riego
 $Qmed$: Caudal medio de riego

$Qa(ta)$: Caudal equivalentes para calcular el área del flujo superficial en régimen transitorio

$Qv(ta)$: Caudal equivalente para calcular el volumen del flujo superficial en régimen transitorio

$Yo(ta)$: Calado del flujo superficial al inicio del campo

REFERENCIAS

- Al-Azba, A.A., (1999). Explicit volume balance model solution. *Journal of Irrigation and Drainage Engineering*, ASCE, 125(5), 273–279.
- Bassett, D.L., Frangmeier, D.D. y Strelkoff, T., (1980). *Hydraulics of surface irrigation systems*. En: *Design and operation of farm irrigation systems*. ASAE Monograph No.3, St. Joseph, Michigan, 829 pp.
- Bautista, E., Clemmens, A.J., Strelkoff, T. y Schlegel, J.L., (2009). Modern analysis of surface irrigation systems with WinSRFR. *Agricultural Water Management*, 96, 1146–1154.
- Bishop, M., (1995). *Neural Networks for Pattern Recognition*. Oxford University Press.
- Brown, M.B. y Forsythe, A.B., (1974). Robust Tests for Equality of Variances. *Journal of the American Statistical Association*, 69: 364–367.
- Dibike, Y.B., (2002). Developing generic hydrodynamic models using artificial neural networks. *Journal of Hydraulic Research*, 40(2), 183–190.
- Gillies, M.H., Smith, R.J. y Raine, S.R., (2007). Accounting for temporal inflow variation in the inverse solution for infiltration in surface irrigation. *Irrigation Science*, 25(2): 87–97.
- Hagan, M.T. y Menhaj, M.B., (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Trans. Neural Net.*, 5, 989–993.
- Katopodes, N.D. y Strelkoff, T., (1977). Dimensionless solutions of border-irrigation advance. *Journal of Irrigation and Drainage Engineering*, ASCE, 103(4), 401–417.
- Kleijnen, J.P., Bettonvil, B., y Van Groenendall, W., (1998). Validation of trace-driven simulation models: a novel regression test. *Management Science*, 44, 812–819.

- Kolmogoroff, A.N., (1933). Sulla determinazione empirica di una legge di distribuzione. *Giornale dell'Istituto Italiano degli Attuari*, 4, 83–91.
- Kostiakov, A.N., (1932). On the dynamics of coefficient of water-percolation in soils and the necessity of studying it from a dynamic point of view for purposes of amelioration. *Trans. Com. Int. Soc. Soil Sci.* 6th, Moscú, Part A, 267–272.
- Mann, H.B. y Whitney, D.R., (1947). On a test of whether one of two random variables is stochastically larger than the other. *Annals of Mathematical Statistics*, 18, 50–60.
- Renault, D. y Wallender, W.W., (1996). Initial-inflow variation impacts on furrow irrigation evaluation. *Journal of Irrigation and Drainage Engineering*, ASCE, 122(1), 7–14.
- Rodríguez, J.A. y Martos, J.C., (2009). SIPAR_ID: Freeware for surface irrigation parameter identification. *Environ. Model. Softw.* Artículo en imprenta.
- Saint-Venant, A.J.C., (1871). Théorie du mouvement non permanent des eaux, avec application aux des rivières et a l'introduction des marées dans eut lits. *Comptes rendus des séances de l'Académie Sciences*, 73, 147–154.
- Smirnov, N., (1933). Estimate of deviation between empirical distribution functions in two independent samples. *Moscow University Mathematics Bulletin*, 2, 3–16.
- Smith, M., (1993). *Neural networks for statistical modeling*. Van Nostrand Reinhold, New York.
- Tedeschi, L.O., (2006). Assessment of the adequacy of mathematical models. *Agricultural Systems*, 89, 225–247.
- Valiantzas, J.D., (1997a). Surface irrigation advance equation: Variation of subsurface shape factor. *Journal of Irrigation and Drainage Engineering*, ASCE, 123(4), 300–306.
- Valiantzas, J.D., (1997b). Volume balance irrigation advance equation: Variation of surface shape factor. *Journal of Irrigation and Drainage Engineering*, ASCE, 123(4), 307–312.
- Valiantzas, J.D., (1999). Explicit time of advance formula for furrow design. *Journal of Irrigation and Drainage Engineering*, ASCE, 125(1), 19–25.
- Walker, W.R., (1989). *Guidelines for designing and evaluating surface irrigation system*. FAO Irrigation and Drainage Paper No. 45, Rome, 137pp.
- Walker, W.R. y Skogerboe, G.V., (1987). *Surface irrigation: Theory and Practice*. Prentice-Hall, Englewood Cliffs, New Jersey, 386pp.
- Wilcoxon, F., (1945). Individual comparisons by ranking methods. *Biometrics Bulletin*, 1, 80–83.
- Wolpert, D.H., (1996a). The lack of a priori distinctions between learning algorithms. *Neural Computation*, 8, 1341–1390.
- Wolpert, D.H., (1996b). The existence of a priori distinctions between learning algorithms. *Neural Computation*, 8, 1391–1420.