

Artículo publicado en el Repositorio Institucional del IMTA

<i>Título</i>	Predicción de la evapotranspiración de referencia mediante redes neuronales artificiales.
<i>Autor / Adscripción</i>	Juan Manuel González Camacho Rocío Cervantes Osornio Colegio de Postgraduados, México Waldo Ojeda Bustamante Instituto Mexicano de Tecnología del Agua Irineo López Cruz Universidad Autónoma Chapingo, México
<i>Publicación</i>	Ingeniería Hidráulica en México, 23(1): 127-138
<i>Fecha de publicación</i>	2008
<i>Resumen</i>	La evapotranspiración de referencia (ET _o) es una variable climática esencial para el cálculo de los requerimientos hídricos de los cultivos, su previsión a corto plazo es importante para programar la distribución de volúmenes de agua en las zonas de riego. En este trabajo se presenta la aplicación de un modelo de Red Neuronal Artificial (RNA) para predecir la ET _o a partir de datos diarios de temperatura del aire, radiación solar, humedad relativa y velocidad del viento. Este modelo fue aplicado a un conjunto de datos climáticos de la red agroclimática “Valle del Fuerte” del distrito de riego 075, localizada en el norte de Sinaloa, México.
<i>Identificador</i>	http://hdl.handle.net/123456789/852

Predicción de la evapotranspiración de referencia mediante redes neuronales artificiales

Juan Manuel González-Camacho
Rocío Cervantes-Osornio

Colegio de Postgraduados, México

Waldo Ojeda-Bustamante

Instituto Mexicano de Tecnología del Agua

Irineo López-Cruz

Universidad Autónoma Chapingo, México

La evapotranspiración de referencia (ET_o) es una variable climática esencial para el cálculo de los requerimientos hídricos de los cultivos, su previsión a corto plazo es importante para programar la distribución de volúmenes de agua en las zonas de riego. En este trabajo se presenta la aplicación de un modelo de Red Neuronal Artificial (RNA) tipo feedforward backpropagation para predecir la ET_o a partir de datos diarios de temperatura del aire, radiación solar, humedad relativa y velocidad del viento. La arquitectura adoptada del modelo de RNA contiene cuatro neuronas en la capa intermedia, una neurona en la capa de salida y funciones de activación tangente hiperbólica en ambas capas. Este modelo fue aplicado a un conjunto de datos climáticos con cinco años de observaciones de la red agroclimática "Valle del Fuerte" del distrito de riego 075, localizada en el norte de Sinaloa, México. El algoritmo de entrenamiento supervisado de Levenberg-Marquardt permitió obtener un buen desempeño de la red en términos del error cuadrático medio y del coeficiente de determinación R² para estimar la ET_o en los diferentes escenarios considerados. Las predicciones de las RNA fueron comparadas con las predicciones de modelos de regresión lineal múltiple y lineal por partes; los resultados muestran que ambos modelos presentan niveles de ajuste muy similares a los datos experimentales.

Palabras clave: regresión no lineal, algoritmo de Levenberg-Marquardt, variables climáticas, requerimientos de riego, distritos de riego.

Introducción

En los distritos de riego de México, la programación de la distribución de los volúmenes de agua de riego se realiza generalmente a intervalos de una semana, para lo cual se requiere de una estimación confiable y robusta de la evapotranspiración de referencia (ET_o), a fin de estimar los requerimientos hídricos de los cultivos. Comúnmente, la previsión de volúmenes de riego se basa en un análisis histórico de los volúmenes de agua distribuidos en años

anteriores durante los mismos periodos de análisis. Otros métodos utilizan valores promedio de la ET_o de la semana anterior para estimar la demanda de agua de los cultivos de la semana siguiente. Con frecuencia, estos criterios conducen a una sobreestimación de la demanda de agua, originando importantes pérdidas de agua en los sistemas de distribución (Ojeda *et al.*, 2007).

Actualmente, las estaciones climáticas automatizadas facilitan el registro de las variables meteorológicas a

intervalos menores de un minuto, con lo cual puede estimarse la ETo con buena precisión a nivel horario o diario mediante ecuaciones tipo Penman. Sin embargo, cuando no es posible disponer de todas las variables climáticas requeridas se utilizan modelos empíricos para relacionar la ETo con alguna de las variables climáticas, como la temperatura o la radiación global (Sudheer *et al.*, 2003; Trajkovic, 2005). La precisión de estos modelos es limitada debido a la dependencia de la ETo con las variables climáticas no consideradas (Allen *et al.*, 1998). Desde un punto de vista práctico y económico, se prefieren los modelos simples, que no requieren de dispositivos sofisticados y costosos para medir las variables meteorológicas, como es el caso de la temperatura del aire (Samani, 2000).

Las Redes Neuronales Artificiales (RNA) son modelos matemáticos adecuados para aproximar funciones lineales y no lineales. La ETo es un proceso complejo de naturaleza no lineal que depende principalmente de la temperatura, la humedad relativa del aire, la radiación solar y la velocidad del viento, por lo que estos modelos pueden aplicarse a la estimación de la ETo a partir de tales variables climáticas. La aproximación de una función no lineal por medio de una RNA consiste en encontrar, mediante un algoritmo de entrenamiento, un vector óptimo de parámetros de ponderación que, a partir de una combinación lineal con el vector de variables de entrada, minimice el error cuadrático medio entre las respuestas estimadas por el modelo, y las deseadas u observadas. Los modelos de red más comunes son los siguientes: los de tipo *feedforward*, donde las neuronas de cada capa se conectan "hacia adelante" desde la entrada de la red hasta la salida sin crear ciclos, y los de tipo recurrente, donde las neuronas de cada capa pueden presentar conexiones cíclicas. El primero permite aproximar una función de respuesta lineal o no lineal de una o más variables de respuesta a partir de un conjunto de variables de entrada, y el segundo permite predecir el comportamiento temporal de una o más variables de respuesta (Chen y Chen, 1995; Haykin, 1998).

En el sector hidroagrícola, las RNA se han aplicado para predecir la evaporación de tanques evaporímetros tipo A (Sudheer *et al.*, 2002); la variación espacial de la radiación global a partir de la localización geográfica y las horas de insolación de una localidad (Mohandes *et al.*, 1998); la evapotranspiración real a partir de datos climáticos incompletos (Kumar *et al.*, 2002; Sudheer *et al.*, 2003); la distribución espacial de la humedad del suelo en cuencas hidrográficas a partir de factores topográficos e índices de vegetación (Maneta y Schnabel, 2003), y la ocurrencia de heladas a partir de datos de temperatura del aire, humedad relativa, nubosidad,

dirección y velocidad del viento (Ovando *et al.*, 2005). Igualmente, estos modelos se han utilizado para predecir la ETo con datos meteorológicos incompletos después de haber sido entrenados con datos completos usando ecuaciones tipo Penman (Arca *et al.*, 2001).

El objetivo de esta investigación fue realizar una aplicación de un modelo de RNA tipo *feedforward backpropagation (ffbp)* entrenado con el algoritmo supervisado de Levenberg-Marquardt para predecir la evapotranspiración de referencia, a partir de registros históricos diarios promedio de temperatura, humedad relativa del aire, radiación solar y velocidad del viento; evaluar su capacidad de predicción con un número reducido de variables climáticas, y evaluar su capacidad de predicción a una semana de intervalo, con datos climáticos históricos promedio.

Materiales y métodos

Los registros climáticos históricos se obtuvieron de la base de datos de la red agroclimática "Valle de Fuerte", localizada en el distrito de riego 075, en los Mochis, Sinaloa, a una latitud de 25° 48.89' N, longitud de 109° 1.53' O, y altitud de 20 m. Las variables meteorológicas se registraron a intervalos de 15 minutos durante el periodo de 1997 a 2001. Las variables diarias promedio analizadas fueron la precipitación (P) en mm para caracterizar el régimen de lluvias; la temperatura media del aire (T) en °C, calculada como $T = ((T_{\text{máx}} + T_{\text{mín}})/2)$, donde $T_{\text{máx}}$ y $T_{\text{mín}}$ son las temperaturas máxima y mínima del aire en °C, respectivamente; la radiación solar (R_g) en MJ m⁻² d⁻¹; la humedad relativa media del aire (Hr) en % y calculada por $Hr = (Hr_{\text{máx}} + Hr_{\text{mín}})/2$, donde $Hr_{\text{máx}}$ y $Hr_{\text{mín}}$ son las humedades relativas máxima y mínima del aire, respectivamente; la velocidad media del viento (u_2) a una altura de 2 m en m s⁻¹, y la ETo, calculada con la ecuación de Penman-Monteith, la cual se considera el método estándar para estimar la ETo a partir de datos meteorológicos (Allen *et al.*, 1998), y se expresa por:

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34 u_2)} \quad (1)$$

donde R_n es la radiación neta en la superficie de cultivo en (MJ m⁻² d⁻¹); G , la densidad de flujo del calor del suelo en (MJ m⁻² d⁻¹); e_s , la presión de vapor a saturación en (kPa); e_a , la presión de vapor actual en (kPa); $e_s - e_a$, el déficit de presión de vapor en (kPa); Δ , la pendiente de la curva de presión de vapor en (kPa °C⁻¹), y γ es la constante psicrométrica en (kPa °C⁻¹).

Implementación de la RNA

La aplicación de un modelo de RNA involucra las siguientes etapas (Turban *et al.*, 2005): a) el preprocesamiento y normalización de las series climáticas de entrada y de salida; b) la subdivisión de las series climáticas en subconjuntos de entrenamiento, validación y prueba; c) la definición de la arquitectura del modelo de RNA: número de capas, número de neuronas por capa, y selección de funciones de transferencia en las capas intermedias y de salida; d) la selección del algoritmo de entrenamiento para optimizar la matriz de pesos o parámetros de ponderación de la red y, e) la evaluación del desempeño de la red para predecir la ETo.

Preprocesamiento de las series climáticas

Las series climáticas de entrada T , Rg , Hr y u_2 fueron integradas en nivel horario y diario. A partir de los valores diarios promedio, se calculó la serie climática de salida ETo mediante la ecuación (1). Luego, las series fueron normalizadas para homogeneizar sus magnitudes. La relación para normalizar las series de datos en el rango de $[-1, 1]$ se expresa por:

$$pn = 2 * [(p - p_{\text{mín}}) / (p_{\text{máx}} - p_{\text{mín}})] - 1 \quad (2)$$

y para el rango $[0, 1]$ está dada por:

$$pn = (p - p_{\text{mín}}) / (p_{\text{máx}} - p_{\text{mín}}) \quad (3)$$

donde pn es el valor normalizado; p es el valor original; $p_{\text{máx}}$ y $p_{\text{mín}}$ son los valores máximo y mínimo de cada variable climática, respectivamente.

Se aplicó un análisis de componentes principales (ACP) a las cuatro variables climáticas de entrada para evaluar su grado de dependencia y su efecto sobre el desempeño de la red. Para ello, las variables de entrada fueron centradas y reducidas con media igual a cero y desviación estándar igual a uno, mediante la transformación $pn = (p - m) / s$, donde pn es el valor transformado; p es el valor original, y m y s son la media y la desviación estándar de los datos originales, respectivamente. Esta técnica tiene tres efectos: tener de forma ortogonal los vectores de entrada para eliminar la posible correlación entre las variables de entrada; ordenar los componentes principales de mayor a menor importancia, y eliminar, en su caso, aquellos componentes que contribuyen en menor grado a la variación total del conjunto de datos (Johnson, 1998).

Las series climáticas de entrada y salida consistieron de 1 591 datos diarios (periodo del 18/02/1997 al

27/06/2001). Para llevar a cabo el entrenamiento y la evaluación del desempeño de la RNA se crearon tres subconjuntos de datos: el primer subconjunto, conformado por 50% del total de los datos, se utilizó para realizar el entrenamiento de la red y obtener el vector de pesos óptimos; el segundo, con 25% de los datos, se utilizó para hacer la prueba del desempeño de la red, y el último, con el 25% restante, fue usado para validar la capacidad de la RNA para predecir la ETo.

Arquitectura de la RNA

La arquitectura de la red *ffbp* (ilustración 1) consiste de cuatro variables de entrada normalizadas; una capa intermedia con cuatro neuronas; una capa de salida con una neurona y una variable de salida normalizada, y funciones de transferencia logística (*logsig*) y tangente hiperbólica (*tansig*). *Logsig* es definida por (Haykin, 1998):

$$f(v) = \frac{1}{1 + \exp(-a1v)} \quad (4)$$

donde $f(v)$ es el valor transformado de v , válido en el rango $[0, 1]$; $a1$ es un parámetro de la función *logsig*; *tansig* es definida por:

$$f(v) = a1 \frac{1 - \exp(-b1v)}{1 + \exp(-b1v)} \quad (5)$$

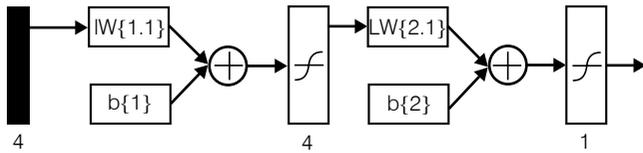
donde $f(v)$ es el valor transformado de v , válido en el rango $[-1, 1]$; v es el nivel de actividad interna de la neurona, y $a1$ y $b1$ son parámetros de la función. Para cada neurona k , la señal de salida v_k se calcula por:

$$v_k = \sum_{j=1}^R w_{kj} p_j - \theta_k \quad (6)$$

donde x_1, x_2, \dots, x_R son los valores de entrada; $w_1, w_{k2}, \dots, w_{kR}$ son los pesos y θ_k es el sesgo de la k -ésima neurona.

En la ilustración 1, $\mathbf{IW}\{1,1\}$ es la matriz de pesos de entrada de orden $S \times R$ y $\mathbf{b}\{1\}$ es el vector de sesgos de orden $S \times 1$ en la capa intermedia; $\mathbf{LW}\{2,1\}$ es la matriz de pesos de orden $S \times 1$ y $\mathbf{b}\{2\}$ es el vector de sesgos de orden $S \times 1$ de la capa de salida; donde S es el número de neuronas; R , el número de entradas; el primer índice entre corchetes indica el destino de conexión y el segundo, su origen. Se analizaron configuraciones de redes con $R = 4, 3, 2$ y 1 ; $S = 4$ en la capa intermedia, y $S = 1$ en la capa de salida. La implementación de la red *ffbp* se hizo

Ilustración 1. Arquitectura de la RNA feedforward backpropagation con cuatro entradas, una capa intermedia con cuatro neuronas y una capa de salida con una neurona.



con la herramienta de modelación de redes neuronales *nnet* (Demuth y Beale, 2001).

Entrenamiento

Los algoritmos de entrenamiento supervisado *backpropagation* de Levenberg-Marquardt (LM) y gradiente conjugado (GC) fueron utilizados en este estudio, los cuales se basan en el algoritmo del máximo gradiente descendente para aproximar una función no lineal diferenciable (Haykin, 1998). En un algoritmo *backpropagation*, los errores se distribuyen de la capa de salida hacia las capas intermedias para determinar los incrementos de los pesos de la red. La estructura básica de este algoritmo para determinar la matriz de pesos óptimos de una red *ffbp* consiste en (Rumelhart et al., 1986; Hagan et al., 1996):

- Inicializar en forma aleatoria la matriz \mathbf{W} ($IW\{1,1\}$, $LW\{2,1\}$, $\mathbf{b}\{1\}$ y $\mathbf{b}\{2\}$) de pesos y sesgos w de la red con valores positivos y negativos pequeños.
- Calcular el vector \mathbf{a} de M salidas de la red, para cada grupo \mathbf{p} de R entradas y \mathbf{t} de M salidas deseadas. Para el caso de la red descrita en la ilustración 1, se tiene que: $\mathbf{a} = f(LW f(\mathbf{v}) + \mathbf{b}2)$, donde f es la función de activación en cada capa ecuaciones 4 o 5; $\mathbf{v} = IW \mathbf{p} + \mathbf{b}1$ es la expresión matricial de la ecuación (6); $LW f(\mathbf{v}) + \mathbf{b}2$ representa el vector de activación para las neuronas de la capa de salida.
- Calcular el vector de errores $\mathbf{e} = (\mathbf{a} - \mathbf{t})$ para las M salidas.
- Calcular los incrementos Δw de los pesos de la red mediante un algoritmo de optimización (por ejemplo, LM o GCE) para determinar la dirección de búsqueda del óptimo, *i.e.* $\Delta w = w_{k+1} - w_k = -\alpha \nabla \mathbf{e}(w_k)$, donde α es la tasa de aprendizaje y $\nabla \mathbf{e}(w_k) = \mathbf{g}_k$ es el gradiente del vector de errores con respecto a los pesos y sesgos w en el paso k .
- Sumar los incrementos Δw para cada peso y sesgo $w \in W$.
- Repetir los pasos b-e para el conjunto de datos de entrenamiento.

- Calcular los nuevos pesos y sesgos con los valores acumulados de Δw , denotado como ΔW , esto es, $w_{k+1} = w_k + \Delta W$.
- Calcular el error global $\mathbf{e}^T \mathbf{e}$ de la red y determinar si es menor a un valor ϵ especificado o si el número de iteraciones predefinido es rebasado.

La estructura iterativa del algoritmo del máximo gradiente descendente se expresa por (Haykin, 1998):

$$\mathbf{w}_{k+1} = \mathbf{w}_k - \alpha_k \mathbf{g}_k \quad (7)$$

donde \mathbf{w}_{k+1} y \mathbf{w}_k son los vectores de pesos y sesgos en los pasos $k+1$ y k , respectivamente; $\mathbf{g}_k = \mathbf{J}^T \mathbf{e}$ es el gradiente actual, y α_k es la tasa de aprendizaje. \mathbf{J} ($\partial e / \partial w$) es la matriz jacobiana de primeras derivadas de \mathbf{e} con respecto a los pesos y sesgos.

El algoritmo LM posee una tasa de convergencia cuadrática y su esquema iterativo se expresa como (Haykin, 1998):

$$\mathbf{w}_{k+1} = \mathbf{w}_k - [\mathbf{H}_k + \mu \mathbf{I}]^{-1} \mathbf{g}_k \quad (8)$$

donde $\mathbf{H} = \mathbf{J}^T \mathbf{J}$ es la matriz hessiana y μ , un escalar.

Cuando el escalar μ es igual a cero, el algoritmo LM es simplemente el método de Newton, con una aproximación de primer orden de \mathbf{H} . Cuando μ es grande, éste se aproxima al método del máximo gradiente descendente (ecuación 7). El método de Newton converge más rápido y es más exacto cuando los valores iniciales están cerca del óptimo (error cuadrático medio). Esto ocurre cuando μ y el error cuadrático medio disminuyen en cada iteración.

El algoritmo GC requiere una estrategia de búsqueda lineal en cada iteración (Moller, 1993). Los algoritmos de gradiente conjugado inician con la dirección del máximo gradiente descendente en la primera iteración, esto es:

$$\mathbf{u}_0 = -\mathbf{g}_0 \quad (9)$$

Posteriormente, se efectúa una búsqueda lineal para determinar la dirección de búsqueda del óptimo, *i.e.*:

$$\mathbf{w}_{k+1} = \mathbf{w}_k - \alpha_k \mathbf{u}_k \quad (10)$$

La nueva dirección de búsqueda consiste en combinar la nueva dirección de máximo gradiente descendente con la dirección de búsqueda previa.

$$\mathbf{u}_k = -\mathbf{g}_k + \beta_k \mathbf{u}_{k-1} \quad (11)$$

donde el escalar β_k puede calcularse por el método de Fletcher y Reeves (Fletcher, 1980) expresado por:

$$\beta_k = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}} \quad (12)$$

Evaluación del desempeño de la red

Los criterios para evaluar el desempeño de la RNA fueron el coeficiente de determinación (R^2), el error cuadrático medio (ECM), el coeficiente de correlación (r) y los parámetros de regresión (ordenada b , y pendiente m), entre las respuestas estimadas a_i y las respuestas deseadas t_i para $i = 1, 2, \dots, n$ observaciones de conjunto de datos climáticos (Montgomery y Runger, 2002).

El coeficiente R^2 se define por:

$$R^2 = 1 - \frac{\sum_{i=1}^n (t_i - a_i)^2}{\sum_{i=1}^n (t_i - \bar{t})^2} \quad (13)$$

El coeficiente r se expresa por:

$$r = \frac{\sum_{i=1}^n t_i (a_i - \bar{a})}{\left[\sum_{i=1}^n (a_i - \bar{a})^2 \sum_{i=1}^n (t_i - \bar{t})^2 \right]^{1/2}} \quad (14)$$

ECM se calcula por:

$$ECM = \frac{1}{n} \sum_{i=1}^n (t_i - a_i)^2 \quad (15)$$

donde \bar{t} es el promedio de las respuestas deseadas t_i .

Resultados y discusión

Análisis de las series climáticas de T , Rg , Hr , u_2 y ET_o

En la ilustración 2 se presenta la distribución de la precipitación mensual en el distrito de riego 075 "Valle del Fuerte", Sinaloa. Se observa una concentración de la precipitación en los meses de junio a octubre, que no coincide con el periodo principal de riegos (noviembre a abril). Las precipitaciones mensuales varían de 0 a 320 mm en el periodo analizado; las precipitaciones anuales en el lapso 1997-2001 fueron de 541, 131, 213, 119 y 380 mm, respectivamente. Lo anterior indica una alta variabilidad en la precipitación anual de la zona de estudio.

En la ilustración 3 se describe el comportamiento horario de las series de T , Rg , Hr , u_2 y ET_o , usando datos del día 5 de mayo de 1997. Durante el día, las variables meteorológicas Hr , T , ET_o y u_2 responden a la intensidad de la radiación solar (Rg), alcanzando valores mínimos Hr y valores máximos las tres restantes.

Ilustración 2. Distribución de la precipitación mensual durante el periodo 01/1997-12/2001 en el distrito de riego 075 "Valle del Fuerte", Sinaloa.

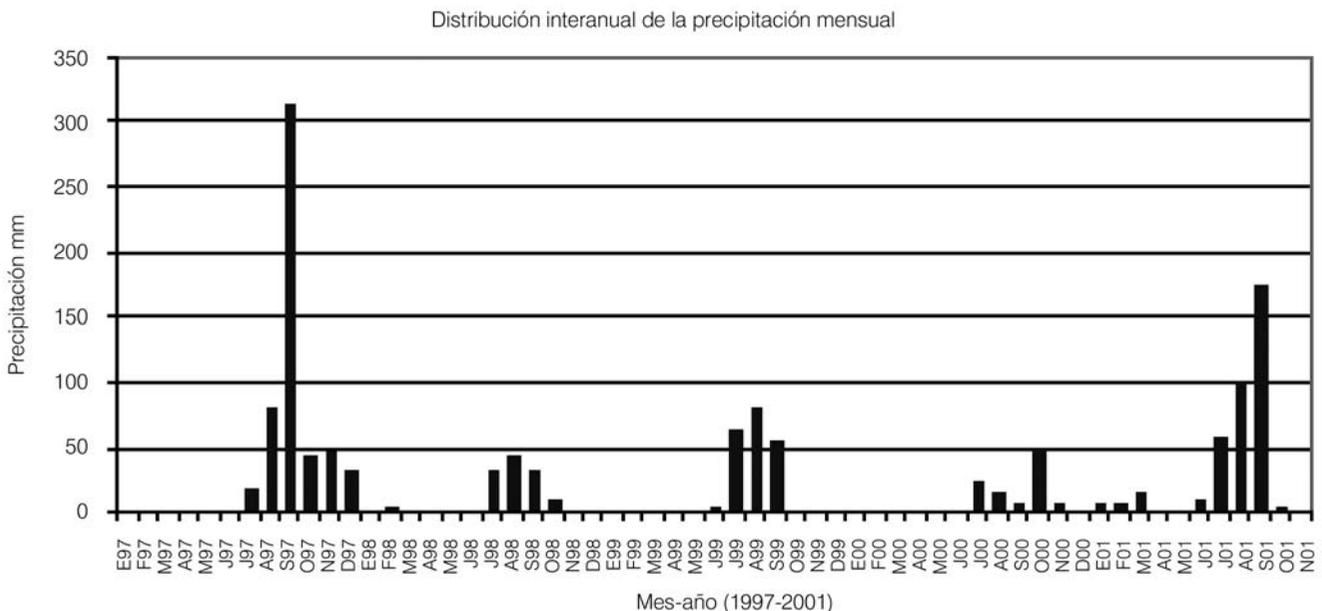
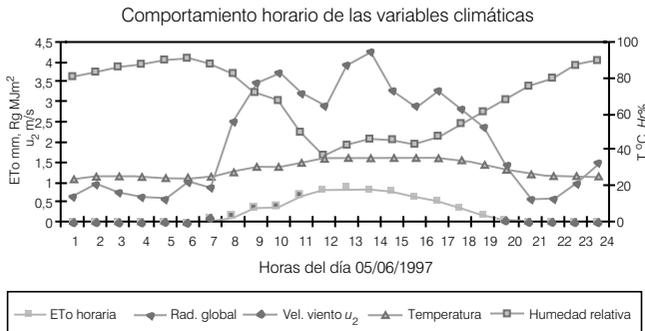


Ilustración 3. Comportamiento horario de las variables climáticas: temperatura, radiación global, humedad relativa, velocidad del viento y evapotranspiración, de referencia en el distrito de riego 075 “Valle del Fuerte”, Sinaloa.

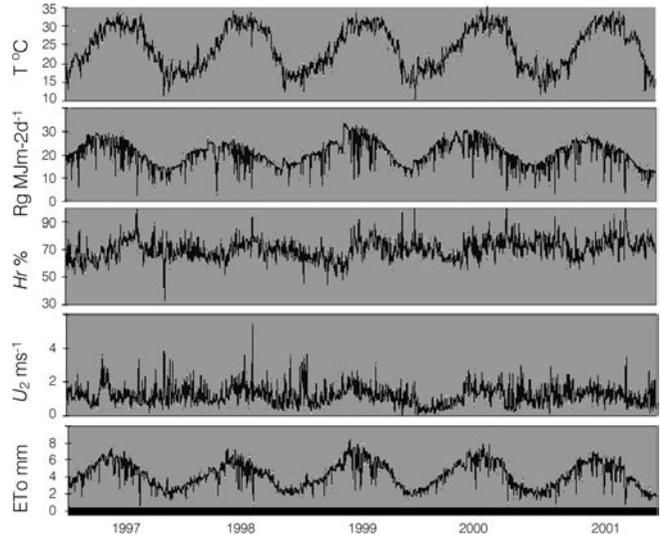


En la ilustración 4 se presentan las series diarias de T , Rg , Hr y u_2 para los cinco años de registros analizados, donde se observa su comportamiento periódico y su variabilidad inter e intra anual.

Entrenamiento de la red feedforward backpropagation

Se consideraron diferentes escenarios de modelación para evaluar el desempeño de la red *ffbp*, a fin de estimar la ETo. Los parámetros de desempeño se calcularon utilizando la totalidad de los datos de entrada disponibles para cada escenario. El ACP permitió eliminar la correlación entre las variables climáticas de entrada, centradas y reducidas previamente. En el cuadro 1 se presentan los componentes principales (vectores propios), las varianzas (valores propios) de cada componente y su porcentaje de variación, donde se observa que el primer componente representa 40% de variación total inicial de los datos. Se consideraron los cuatro componentes principales para modelar la RNA, por lo cual no se redujo el número de entradas; sin embargo, el desempeño de la red (escenario 1a) fue ligeramente superior al escenario 1b, que no considera el ACP. En consecuencia, por razones de simplicidad, en los análisis posteriores no se consideró este preprocesamiento. En el cuadro 2 se presentan los

Ilustración 4. Comportamiento de las series diarias de temperatura del aire, radiación global, humedad relativa, velocidad del viento y evapotranspiración de referencia en el periodo 1997-2001, distrito de riego 075 “Valle del Fuerte”, Sinaloa.



resultados del entrenamiento de la red para estimar los valores de ETo a partir de las variables T , Rg , Hr y u_2 .

El mejor desempeño de la RNA, sin considerar el ACP, se obtuvo con el escenario 1b, utilizando cuatro neuronas en la capa intermedia y una en la capa de salida, con funciones *tansig* en ambas capas. Una $R^2 = 0.992$, con parámetros de regresión $b = 0.031$ y $m = 0.992$, evidencia el alto grado de correlación entre los valores deseados y los estimados por la red. El desempeño de la red entrenada con el algoritmo GC (escenario 1d) fue inferior al algoritmo LM (escenario 1b). Para este escenario, el número de iteraciones para converger fue mayor que el del algoritmo LM (cuadro 2).

En el cuadro 3 se presentan los valores óptimos de los pesos y sesgos para la capa intermedia y la capa de salida de la red, correspondientes al escenario 1b y estimados con el algoritmo LM.

Cuadro 1. Resultados del análisis de componentes principales de la variables climáticas de entrada temperatura, radiación solar, humedad relativa y velocidad del viento.

Variables climáticas	Componentes principales				Valores propios	Varianza relativa %	Varianza acumulada %
	CP1	CP2	CP3	CP4			
T	0.622	-0.320	0.389	0.600	1.616	40	40
Rg	0.691	0.220	0.121	-0.677	1.163	29	69
Hr	-0.227	-0.797	0.364	-0.426	0.876	22	91
u_2	0.290	-0.463	-0.838	-0.004	0.345	9	100

Cuadro 2. Desempeño de la RNA ffbp para estimar la evapotranspiración de referencia diaria con los algoritmos de entrenamiento de Levenberg-Marquardt y gradiente conjugado.

Escenario	r	R^2	ECM	m	b	Algoritmo (iteraciones)
1a ACP; $E\{T, Rg, Hr, u_2\}$ 4N;CI-tansig 1N;CS-tansig	0.996	0.993	0.0157	0.993	0.032	LM(35)
1b $E\{T, Rg, Hr, u_2\}$ 4E;4N;CI-tansig 1N-CS-tansig	0.996	0.992	0.0172	0.992	0.031	LM(25)
1c $E\{T, Rg, Hr, u_2\}$ 4E;4N;CI-tansig 1N-CS-logsig	0.997	0.989	7.1768	7.556	-0.642	No convergió LM(100)
1d $E\{T, Rg, Hr, u_2\}$ 4N-CI-tansig 1N-CS-tansig	0.995	0.991	0.02087	0.98776	0.049056	GC(95)
1e $E\{T, Rg, Hr, u_2\}$ 4N;CI-tansig 1N-CS-logsig	0.924	0.853	0.44083	1.0563	-0.30894	GC(36)

E: variables de entrada; ACP: análisis de componentes principales; CI: capa intermedia; CS: capa de salida; N: neurona(s); tansig: función tangente hiperbólica; logsig: función logística; ECM: error cuadrático medio; R^2 : coeficiente de determinación; r : coeficiente de correlación; b y m : ordenada y pendiente de la regresión lineal entre los valores de ETo estimados y los deseados.

Cuadro 3. Parámetros de ponderación óptimos de la RNA ffbp entrenada con el algoritmo de Levenberg-Marquardt (escenario 1b, cuadro 2).

	IW{1,1} 4x4			b{1}4x1	LW{2,1}4x1	b{2}1x1
0.4384	0.8286	-0.2423	0.4387	-1.5783	2.2935	1.0363
0.3797	0.9785	0.0616	0.9276	0.9491	0.6757	
0.5763	0.1826	-1.0335	-1.3093	-0.0681	0.2830	
-0.2246	-2.7698	2.3761	0.8924	-4.5429	-0.4585	

Desempeño de la RNA ffbp con un número reducido de variables climáticas

Se analizó el efecto de la reducción del número de variables de entrada sobre el desempeño de la red. En el cuadro 4 se presentan los diferentes escenarios. La temperatura se consideró en todos los escenarios por ser una variable de fácil medición. El escenario 2a, con tres variables de entrada (T, Rg, u_2), obtuvo el mejor desempeño de la red, con una $R^2 = 0.98$. El escenario 2b presentó el mejor desempeño de la red con dos entradas (T y Rg), con una $R^2 = 0.96$. Similarmente, los escenarios 2c y 2d presentaron los mejores desempeños de la red con una entrada. La temperatura y la radiación global inciden de manera determinante en la estimación de la ETo; la temperatura explica 63% y la radiación solar,

82% de la variación de la ETo en la zona de estudio. Sin embargo, en situaciones prácticas, es más fácil y económico medir la temperatura del aire que la radiación solar.

Previsión de la ETo a corto plazo

Se compararon dos métodos para predecir la ETo a corto plazo: el primero consiste en calcular el promedio de las ETo diarias de Penman-Monteith de la semana anterior s-1 y utilizar ese promedio como valor estimado de los valores de ETo para los días de la semana siguiente s; el segundo método consiste en predecir la ETo mediante la RNA, a partir de los valores diarios promedio observados de T, Rg, Hr y u_2 para la misma semana s, pero de años anteriores (en este estudio, de 1997 a

Cuadro 4. Desempeño de la RNA *ffbp* para estimar la evapotranspiración de referencia con un número reducido de variables de entrada (descripción de variables y parámetros en el cuadro 2).

Escenario	<i>r</i>	<i>R</i> ²	ECM	<i>m</i>	<i>b</i>	Algoritmo (iteraciones)
2a <i>E</i> { <i>T</i> , <i>Rg</i> , <i>u</i> ₂ }; 4N-CI- <i>tansig</i> 1N-CS- <i>tansig</i>	0.990	0.980	0.045	0.979	0.084	LM(62)
2b <i>E</i> { <i>T</i> , <i>Rg</i> }; 4N en CI- <i>tansig</i> 1N en CS- <i>tansig</i>	0.982	0.964	0.080	0.965	0.146	LM(49)
2c <i>E</i> { <i>T</i> }; 4N -CI- <i>tansig</i> 1N-CS- <i>tansig</i>	0.792	0.627	0.832	0.626	1.577	LM(36)
2d <i>E</i> { <i>Rg</i> }; 4N en CI- <i>tansig</i> 1N en CS- <i>tansig</i>	0.910	0.827	0.384	0.823	0.738	LM(64)

2000). Las previsiones de ETo fueron comparadas con los valores de ETo de Penman-Monteith (ecuación 1) calculados con los valores de *T*, *Rg*, *Hr* y *u*₂ observados en la semana s.

En la ilustración 5 se presenta una comparación de las tres series de ETo para el periodo del 28-06-2001 al 4-07-2001, donde se observa que la ETo promedio de la semana anterior (21-06-2001 al 27-06-2001) subestima la ETo de Penman-Monteith de la semana s. Por otro lado, la serie de ETo predicha con la RNA presenta en general un ajuste adecuado a la tendencia de los datos. Esto ilustra dos hechos: por un lado, el uso de los valores promedio de las variables climáticas de años anteriores para predecir la ETo puede ser un criterio adecuado cuando la presencia de lluvias se comporta de manera similar al promedio de años anteriores, de otra forma, este criterio puede conducir a una sobreestimación o subestimación de la ETo; por otro lado, la *Rg* es una variable que presenta alta variabilidad en periodos húmedos, como es el caso del periodo analizado (ver ilustraciones 2 y 4). Específicamente en los días de precipitación, la predicción de la RNA tiene la mayor discrepancia con los datos observados.

Predicción de la ETo mediante un modelo de regresión lineal múltiple

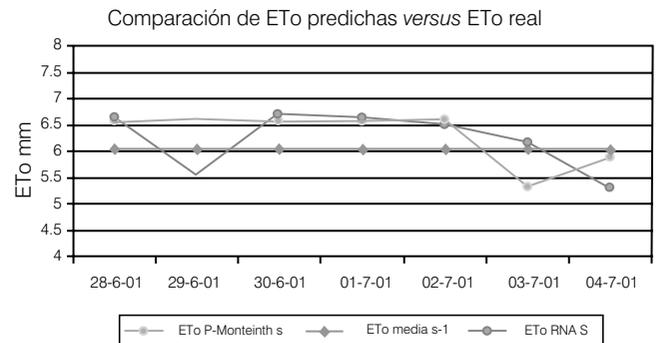
El modelo estadístico de regresión lineal múltiple (RLM) se aplicó para predecir la ETo, con la finalidad de compararlo con las RNA entrenadas con diferente número de variables de entrada. La estructura general del

modelo de regresión lineal está dada por (Montgomery y Runger, 2002):

$$ETo = \beta_0 + \beta_1 T + \beta_2 Rg + \beta_3 Hr + \beta_4 u_2 + \epsilon \quad (16)$$

Se analizaron cuatro modelos de regresión correspondientes a los mejores escenarios obtenidos con las RNA entrenadas. Los modelos de regresión fueron ajustados con el conjunto de datos climáticos original. Los resultados se presentan en el cuadro 5, en donde se observa que la RNA obtiene valores de *R*² ligeramente mayores que los obtenidos por los modelos de regresión lineal múltiple. Sin embargo, para propósitos prácticos, puede considerarse que ambos modelos tienen el mismo grado de ajuste a los datos.

Ilustración 5. Comparación de dos métodos para predecir a corto plazo la ETo versus la ETo de Penman-Monteith, periodo del 28-06-2001 al 4-07-2001, distrito de riego 075 “Valle del Fuerte”, Sinaloa.



Cuadro 5. Comparación del ajuste de los modelos de regresión lineal múltiple (RLM) y la RNA para estimar la evapotranspiración de referencia.

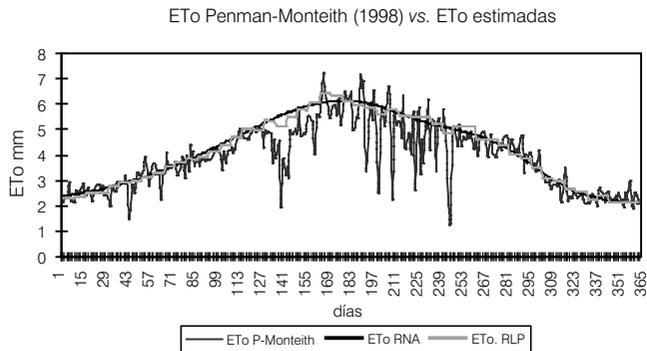
Variables de entrada	R ² RNA	R ² RLM	β ₀	β ₁	β ₂	β ₃	β ₄
T, Rg, Hr, u ₂	0.99	0.98	-1.0858	0.1224	0.1699	-0.0229	0.3534
T, Rg, u ₂	0.98	0.97	-2.7459	0.1113	0.1867	0.3332	
T, Rg	0.96	0.95	-2.5133	0.1164	0.1890		
T	0.63	0.61	0.2102				

β₀, β₁, β₂, β₃ y β₄: parámetros de los modelos de regresión lineal múltiple.

Predicción de la ETo con el modelo de RNA temporal

La red *ffbp* fue entrenada con el algoritmo LM para predecir la ETo en función del tiempo (t), expresado en días julianos, utilizando el conjunto de datos completo (periodo del 8-02-1997 al 27-06-2001). La RNA consiste de una entrada, tres neuronas en la capa intermedia, una neurona en la capa de salida, con funciones *tansig* en ambas capas. Los parámetros de desempeño fueron R² = 0.76; ECM = 0.53; r = 0.87; con parámetros de regresión m = 0.766 y b = 0.993. El desempeño de la red tuvo una R² superior al desempeño de la red con la temperatura como entrada (escenario 2c, cuadro 4). La ilustración 6 muestra la curva promedio de ETo predicha por la RNA para el conjunto de datos completo y la serie calculada de ETo correspondiente a 1998, donde se observa una variabilidad mayor en la parte media de la curva. Los valores de ETo predichos para los días julianos 179-185 (28-06-2001 al 04-07-2001) son 6.08, 6.08, 6.08, 6.08, 6.07, 6.07, 6.06 mm/día, respectivamente, los cuales son próximos a los valores de ETo calculados con datos de ETo de Penman-Monteith (ilustraciones 5 y 6).

Ilustración 6. Comparación de la estimación de la evapotranspiración de referencia predicha con los modelos de RNA y lineal por partes, en función del tiempo versus la serie de ETo Penman-Monteith, periodo del 01-01-1998 al 31-12-1998.



Dado que la estimación de la ETo en función del tiempo representa el comportamiento promedio de la ETo, su precisión depende de su variabilidad en el periodo analizado.

En la región estudiada, la variabilidad de la ETo es mayor en la época de lluvias (de junio a octubre) y menor en la época seca, que corresponde a la temporada de riegos. Por lo tanto, las predicciones son más robustas en el periodo más necesitado para estimar los requerimientos hídricos de los cultivos (ilustración 6). En el distrito de riego 075 "Valle del Fuerte", la principal temporada de riegos corresponde al periodo de noviembre a abril.

Predicción temporal de la ETo con un modelo lineal por partes

Con el propósito de comparar el desempeño del modelo de RNA como una función del tiempo, se planteó un modelo de regresión lineal por partes para ajustar la serie de ETo en función del tiempo en días julianos, el cual se expresa por (Drapper y Smith, 1981):

$$ET_o = \beta_0 + \beta_1 \text{ juliano} + \beta_2 s_2 + \dots + \beta_{52} s_{52} + \epsilon \quad (17)$$

Donde β₀, β₁, ..., β₅₂ son los parámetros del modelo; juliano es el tiempo en días julianos, y s₂-s₅₂ son variables binarias (0,1), que toman un valor de 1 si la ETo corresponde a la semana de observación y un valor de 0 de otra forma. En la ilustración 6 se presenta la curva ETo promedio estimada por un modelo lineal por partes, la cual es una aproximación de la generada por el modelo no lineal de RNA. El modelo de regresión generó una R² = 0.77 y un coeficiente de variación de 18%.

El valor predicho de ETo fue de 6.05 mm/día para el periodo del 28-06-2001 al 4-07-2001, que corresponde a los días julianos 179-185, el cual es muy aproximado a los valores estimados con la RNA en función del tiempo.

Conclusiones

Recibido: 17/07/2006

Aprobado: 08/03/2007

El modelo de red neuronal artificial tipo *feedforward backpropagation*, con cuatro neuronas en la capa intermedia y una neurona en la capa de salida, con funciones de transferencia tangente hiperbólica en ambas capas y entrenada con el algoritmo de Levenberg-Marquardt, permitió obtener el mejor desempeño de la red para predecir la evapotranspiración de referencia diaria a partir de la temperatura del aire, la radiación solar, la humedad relativa y la velocidad del viento con una buena aproximación ($R^2=0.99$).

El análisis de la predicción de la ETo diaria, con un número reducido de variables climáticas, permitió constatar que la radiación global y la temperatura del aire explican de manera conjunta el 96% de la variación de la ETo. Asimismo, la radiación solar explica 83% y la temperatura, 63% de la variación total de la ETo en el distrito de riego 075 "Valle del Fuerte", Sinaloa.

La comparación realizada entre las predicciones de la ETo con los modelos de RNA y con los modelos de regresión lineal múltiple muestra que las RNA presentan mejores ajustes a los datos observados; sin embargo, para propósitos prácticos, ambos pueden considerarse equivalentes.

El criterio propuesto para la previsión de la ETo con una semana de anticipación, utilizando valores diarios históricos de las variables climáticas, es más apropiado que el criterio basado en el promedio de las ETo de la semana anterior. La previsión de la ETo es más robusta en los periodos secos, dado que la variabilidad diaria de la radiación global y de la ETo, en consecuencia, es menor en días despejados.

El modelo de RNA temporal propuesto permitió estimar con una R^2 de 0.76, una curva promedio de ETo, en función de los días julianos, la cual puede utilizarse como una curva de referencia en la zona de riego estudiada; su confiabilidad es más alta en los periodos secos que en los periodos húmedos. Las predicciones de la ETo con el modelo de regresión lineal por partes, a una semana de intervalo, presentó prácticamente el mismo grado de ajuste que el modelo de RNA temporal propuesto.

Agradecimientos

A José Luis Zárate E., encargado de la gestión de la red agroclimática del "Valle del Fuerte", administrada por la sociedad de responsabilidad limitada del distrito de riego 075, Sinaloa, por el apoyo otorgado para tener acceso a la base de datos climática. Al doctor Pierre Ruelle, del Centro de Investigación en Ingeniería Agrícola y Ambiental Francés, Cemagref UMR G-EAU de Montpellier, por las facilidades brindadas para concluir esta investigación.

Referencias

- ALLEN, G.R., PEREIRA, L.S., RAES, D. y SMITH, M. Crop evapotranspiration. Guidelines for computing crop water requirements. *FAO Irrigation and drainage*. Paper 56. Roma: FAO, 1998.
- ARCA, B., BENINCASA, F. y DE VINCENZI, M. Evaluation of neural network techniques for estimating evapotranspiration. *Evolving Solution with Neural Networks, EANIN2001*. Baratti, R. y De Canete, J.F. (editores). Cagliari, Italia: CUSL, 16-18 de julio, 2001, pp. 62-69.
- CHEN, T. y CHEN, H. Universal approximation to nonlinear operators by neural networks with arbitrary functions and its application to dynamical systems. *IEEE Transactions on Neural Networks*. Vol. 6, núm. 4, 1995, pp. 911-917.
- DEMUTH, H. y BEALE, M. *Neural network toolbox user's guide*. The MathWorks Natick, Massachusetts, 2001, 844 pp.
- DRAPPER, N.R. y SMITH, H. *Applied regression analysis*. 2nd ed. New York: Wiley, 1981, 580 pp.
- FLETCHER, R. *Practical methods of optimization. Unconstrained optimization*. Vol. 1. New York: Wiley, 1980, 540 pp.
- HAGAN, M.T., DEMUTH, H.B. y BEALE, M.H. *Neural Network Design*. Boston: PWS Publishing, 1996.
- HAYKIN, S.S. *Neural networks: a comprehensive foundation*. 2nd ed. New Jersey: Prentice Hall, 1998, 846 pp.
- JOHNSON, D.E. *Applied multivariate methods for data analysis*. New York: Brooks Cole Publishing, 1998, 560 pp.
- KUMAR, M., RAGHUWANSHI, S.N., SINGH, R., WALLENDER, W.W. y PRUITT, O.W. Estimating evapotranspiration using artificial neural network. *J. Irrig. Drain. Eng.* Vol. 128, núm. 4, 2002, pp. 224-233.
- MANETA, M. y SCHNABEL, S. Aplicación de redes neuronales artificiales para determinar la distribución espacial de la humedad del suelo en una pequeña cuenca de drenaje, estudios preliminares. *Estudios de la zona no saturada del suelo*. Vol. VI, núm.1, 2003, pp. 295-304.
- MOHANDÉS, M., REHMAN, S. y HALAWANI, T.O. Estimation of global solar radiation using artificial neural networks. *Renewable Energy*. Vol.14, núm. 4, 1998, pp.179-184.
- MOLLER, M.F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*. Vol. 6, 1993, pp. 525-533.
- MONTGOMERY, D.C. y RUNGER, G.C. *Applied statistics and probability for engineers*. 3rd. ed. New York: John Wiley & Sons, 2002, 706 pp.
- OJEDA, W., GONZÁLEZ, J.M., SIFUENTES, E., ISIDRO, E. y RENDÓN, L. Using spatial information systems to improve water management in Mexico. *Agric. Wat. Manag.* Vol. 89, 2007, pp. 81-87.

- OVANDO, G., BOCCO, M. y SAYAZO, S. Redes neuronales para predicción de heladas. *Agricultura Técnica*. Vol. 65, núm. 1, 2005, pp. 65-73.
- RUMELHART, D.E., HINTON, G.E. y WILLIAMS, R.J. Learning internal representations by error propagation. *Parallel Data Processing*. Rumelhart, D.E. y McClelland, J.L. (editores). Vol.1, Cambridg: The MIT Press, 1986, pp. 318-362.
- SAMANI, Z. Estimating solar radiation and evapotranspiration using minimum climatological data. *J. Irrig. Drain. Eng.* Vol. 126, núm. 4, 2000, pp. 265-267.
- SUDHEER, P.K., GOSAIN, A.K., MOHANA RANGAN, D. y SABE, S.M. Modeling evaporation using an artificial neural network algorithm. *Hydrological Processes*. Vol. 16, núm. 16, 2002, pp. 3189-3202.
- SUDHEER, P.K., GOSAIN, A.K. y RAMASASTRI, K.S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *J. Irrig. Drain. Eng.* Vol. 129, núm. 3, 2003, pp. 214-218.
- TRAJKOVIC, S. Temperature-based approaches for estimating reference evapotranspiration. *J. Irrig. Drain. Eng.* Vol. 131, núm. 4, 2005, pp. 316-323.
- TURBAN, E., ARONSON, J.E. y TIN-PENG, L. *Decision support systems and intelligent systems*. 7th edition. New York: Prentice Hall, 2005, 960 pp.

Abstract

GONZÁLEZ-CAMACHO, J.M., CERVANTES-OSORNIO, R., OJEDA-BUSTAMANTE, W. & LÓPEZ-CRUZ, I. Forecasting reference evapotranspiration using artificial neural networks. *Hydraulic engineering in Mexico (in Spanish)*. Vol. XXIII, no. 1, January-March, 2008, pp. 127-138.

Reference evapotranspiration (ET_o) is a fundamental weather-related variable to compute crop water requirements. Short-term ET_o forecasting is important to program water deliveries in irrigation schemes. In this paper, a feedforward backpropagation artificial neural network (ANN) was trained to estimate the ET_o from weather data such as air temperature, solar radiation, relative humidity, and wind velocity. An ANN with four neurons in the hidden layer, one neuron in the output layer, and hyperbolic tangent transfer functions was applied to a five-year weather database from an automated meteorological station located at irrigation district 075, "Valle del Fuerte", in Sinaloa, Mexico. The supervised training algorithm of Levenberg-Marquardt allowed a good performance of the ANN to estimate the ET_o in all the scenarios considered in terms of mean square error and determination coefficient R². Classical linear regression models were compared with the ANN's solutions. The results show that ANN models are good alternative prediction tools to statistical models such as linear and non linear regression models.

Keywords: non-linear regression, Levenberg-Marquardt algorithm, climatic variables, irrigation requirements, irrigation districts.

Dirección institucional de los autores:

Dr. Juan Manuel González-Camacho

Profesor-Investigador.
Posgrado en Cómputo Aplicado,
Colegio de Postgraduados,
Campus Montecillo,
Km 36.5 carretera México-Texcoco,
56230 Montecillo Texcoco, Estado de México, México,
teléfono: + (52) (55) 58 04 59 48,
fax: + (52) (55) 58 04 59 49,
jmgc@colpos.mx

M.C. Rocío Cervantes-Osornio

Posgrado en Cómputo Aplicado,
Colegio de Postgraduados,
Campus Montecillo,
Km 36.5 carretera México-Texcoco,

56230 Montecillo, Texcoco, Estado de México, México,
teléfono: + (52) (55) 5804 5948,
fax: + (52) (55) 58 04 59 49,
rcervanteso@colpos.mx

Dr. Waldo Ojeda-Bustamante

Instituto Mexicano de Tecnología del Agua,
Paseo Cuauhnáhuac 8532, colonia Progreso,
62550 Jiutepec, Morelos, México,
teléfono: + (52) (777) 329 3600, extensión 445,
fax: + (52) (777) 329 3658,
wojeda@tlaloc.imta.mx

Dr. Irineo López-Cruz

Universidad Autónoma Chapingo
56230 Chapingo, Estado de México, México,
ilopez@correo.chapingo.mx