

## Red neuronal artificial base radial en la estimación de la evapotranspiración de referencia

Rocío Cervantes-Osornio<sup>1§</sup>, Ramón Arteaga-Ramírez<sup>1</sup>, M. Alberto Vázquez-Peña<sup>1</sup> y Waldo Ojeda-Bustamante<sup>2</sup>

<sup>1</sup>Universidad Autónoma Chapingo. Carretera México-Texcoco, km. 38.5 C. P. 56230. Tel 01(595) 21500 Chapingo, Estado de México. (arteagar@correo.chapingo.mx, mvazquezp@correo.chapingo.mx). <sup>2</sup>Instituto Mexicano de Tecnología del Agua. Paseo Cuauhnáhuac 8532, Col. Progreso. C. P. 62550, Jiutepec, Morelos. wojeda@tlaloc.imta.mx. <sup>§</sup>Autora para correspondencia: rcervanteso@colpos.mx.

### Resumen

En la agricultura resulta importante conocer con cierto grado de anticipación algunas variables climáticas tal como la evapotranspiración de referencia, variable primordial en la planeación y distribución del recurso agua en los distritos de riego. En el presente trabajo se utilizaron métodos convencionales y modelos de redes neuronales artificiales, específicamente *feedforward backpropagation*, con las mismas variables de entradas que sus homólogos modelos empíricos, para estimación de la evapotranspiración de referencia, esto se realizó para la estación Santa Rosa 1 III AC, ubicada en el Distrito 075, Valle del Fuerte, Los Mochis, Sinaloa. Los resultados obtenidos mostraron que las redes neuronales artificiales representan una alternativa de modelo confiable en la estimación de la evapotranspiración de referencia.

**Palabras clave:** calendarización del riego, evapotranspiración de referencia, redes neuronales artificiales.

### Introducción

Calendarizar el riego redundaría en la idea de estimar con anticipación cuánto y cuándo aplicar riego a los cultivos a lo largo de su ciclo fenológico. Específicamente en cultivos bajo invernadero o en sistemas en tiempo real, resulta particularmente útil contar con un dato ágil de evapotranspiración de referencia, principal componente del ciclo hidrológico, resultando necesario conocerla con antelación para estimar las necesidades de agua de los cultivos y realizar una planeación acertada de las láminas de

riego y distribución del recurso agua de manera adecuada, (Jensen *et al.*, 1990; Ojeda, 2004). El método Penman-Monteith propuesto por la Organización de las Naciones Unidas para la Alimentación en el (FAO) en el boletín 56, es el único método estándar recomendado para el cálculo de la evapotranspiración de referencia ( $ET_0$ ). Las variables climáticas que requieren ser conocidas e influyen en la evapotranspiración son: la temperatura del aire, humedad atmosférica, radiación solar y velocidad del viento (Allen *et al.*, 1998). Debido a que no todas estas variables están disponibles en cualquier estación meteorológica han sido propuestos diferentes modelos para estimar la evapotranspiración de referencia ( $ET_0$ ) como la ecuación de Hargreaves (1993), que la estima en función de temperatura y ha producido resultados razonables de  $ET_0$  con cierta validez global (Allen *et al.*, 1998). Otro modelo para estimar la  $ET_0$  es Priestley-Taylor que relaciona la evapotranspiración con la radiación y demanda el conocimiento de menos datos al usuario (Thornley y France, 2007).

En fechas recientes los modelos de redes neuronales artificiales han demostrado ser una herramienta excelente, debido a su capacidad para manejar las interrelaciones no-lineales existentes al estimar diversos fenómenos climáticos (Tymvios *et al.*, 2008). Trabajos de investigación para estimar la evapotranspiración de referencia ( $ET_0$ ) con redes neuronales artificiales se han hecho, tal como el de Zanetti *et al.* (2007), que evaluaron una red neuronal artificial multicapa en función de las temperaturas máximas y mínimas del aire. De igual manera se encuentra el trabajo

de Kumar *et al.* (2002) que utiliza una RNA con el algoritmo backpropagation para estimar la  $ET_0$  con las variables de entrada: temperatura máxima y mínima, humedad relativa máxima y mínima, velocidad del viento y radiación solar.

El objetivo del presente trabajo fue determinar si un modelo de red neuronal *backpropagation* con las mismas variables de entrada que utilizan los métodos convencionales de: Hargreaves (*HARG*), Hargreaves calibrado (*HARGC*) y Priestley-Taylor (*P-T*), es mejor al estimar la evapotranspiración de referencia obtenida con Penman-Monteith (*P-M*) FAO-56.

### Cuadro 1. Nombre, clave, longitud, latitud y altitud de la estación objeto de este estudio.

| Clave de estación | Nombre estación | Longitud     | Latitud     | Altitud (m) |
|-------------------|-----------------|--------------|-------------|-------------|
| 3765 III-1        | AC Santa Rosa 1 | 108° 57' 21" | 25° 45' 03" | 40          |

Estos datos se pre procesaron a nivel diario, comprendieron del periodo abril de 1997 a mayo de 2001, generando vectores de 1484 datos, los cuales se utilizaron para el ajuste de los modelos estimándose la evapotranspiración de referencia ( $ET_0$ ), así como para entrenamiento, validación y prueba de las RNA. Un nuevo conjunto de datos de 229 días se utilizó para realizar la validación de los modelos realizando una predicción de la evapotranspiración de referencia. Los datos se pre procesaron en hojas de cálculo y el software a usado para el entrenamiento de las RNA es el toolbox de redes neuronales para Matlab 7.0<sup>TM</sup>.

### Penman-Monteith FAO 56

Debido a la dificultad de obtener datos de lisímetro de evapotranspiración se tomaron como datos observados la evapotranspiración de referencia obtenida por el método FAO Penman-Monteith. La ecuación utilizada por éste método de manera diaria es:

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 2.73} u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 u_2)} \quad (1)$$

Donde:  $ET_0$ = evapotranspiración de referencia en mm día<sup>-1</sup>;  $R_n$ = radiación neta en la superficie del pasto en MJ m<sup>-2</sup> día<sup>-1</sup>;  $G$ = densidad de flujo de calor del suelo en MJ m<sup>-2</sup> día<sup>-1</sup>;  $T$ = temperatura media del aire a 2 m de altura en °C;  $u_2$ = velocidad del viento media a 2 m de altura en m s<sup>-1</sup>;  $e_s$ = presión de vapor a saturación a la temperatura del aire  $T$  en

## Materiales y métodos

Se utilizaron datos climatológicos de la estación: temperaturas máximas y mínimas en °C, radiación global en MJ m<sup>-2</sup> día<sup>-1</sup>, humedad relativa en (%) y velocidad del viento en m s<sup>-1</sup>; obtenidos de la base datos de la red agroclimática automatizada Valle del Fuerte proporcionada por el Distrito de Riego 075, ubicada en Los Mochis, Sinaloa. Las coordenadas de dichas estación se presentan en el Cuadro 1.

kPa;  $e_a$ = presión de vapor actual en kPa;  $e_s - e_a$ = déficit de presión de vapor en kPa;  $\Delta$ = pendiente de la curva de presión de vapor a saturación en kPa °C<sup>-1</sup>;  $\gamma$ = constante psicométrica en kPa °C<sup>-1</sup> (Allen *et al.*, 1998).

### Modelos utilizados en la estimación de la evapotranspiración de referencia ( $ET_0$ )

Se consideraron los siguientes modelos para la estimación de la  $ET_0$

#### Modelo 1. Hargreaves

La  $ET_0$  se puede estimar usando la ecuación de Hargreaves:

$$ET_0 = 0.0023(T_{media} + 17.8)(T_{max} - T_{min})^{0.5} R_a \quad (2)$$

Donde:  $T_{media}$ = temperatura media en °C;  $T_{max}$ ,  $T_{min}$ = temperaturas máximas y mínimas respectivamente y  $R_a$ = radiación extraterrestre en mm día<sup>-1</sup>. Este parámetro de acuerdo con Allen *et al.* (1998) se calcula como:

$$R_a = \frac{24 \cdot 60}{\pi} 0.082 d_r [\omega_s \sin(\varphi) \sin(\delta) + \cos(\varphi) \cos(\delta) \sin(\omega_s)] \quad (3)$$

Donde:  $d_r = 10.033 \cos\left(J \frac{2\pi}{365}\right)$ , es la distancia relativa inversa Tierra-Sol,  $J$ = número de día en el año;  $\omega_s = \arccos[-\tan(\varphi) \tan(\delta)]$ , es el ángulo de radiación a la puesta del sol en radianes;  $\varphi$ = latitud positiva para el hemisferio norte y negativa para el hemisferio sur en radianes;

$\delta = 0.409 \left[ \sin \left( \frac{2\pi}{365} J - 1.39 \right) \right]$ , es la declinación solar en radianes.

### Modelo 2. Hargreaves calibrado

De acuerdo con Trajkovic (2007) la ecuación de Hargreaves se puede reescribir como:

$$ET_{0,PM} = 0.0023(T_{media} + 17.8)(T_{max} - T_{min})^{HE} R_a \quad (4)$$

Donde:  $ET_{0,PM}$  = evapotranspiración de referencia calculada con la metodología de Penman-Monteith (Allen *et al.*, 1998);  $HE$  = exponente empírico ajustado de Hargreaves, que es calibrado con los vectores de los 1 484 datos disponibles para cada una de las estaciones.

### Modelo 3. Priestley y Taylor

La ecuación de Priestley y Taylor (1972) se define como:

$$E = \frac{\alpha}{\lambda} \frac{\Delta}{\Delta + \gamma} (R_n - G) \quad (5)$$

Donde:  $E$  = evapotranspiración de referencia mm día<sup>-1</sup>;  $R_n$  es la radiación neta medida a 2 m en MJ m<sup>-2</sup> día<sup>-1</sup>;  $G$  = densidad de flujo de calor en el suelo, en MJ m<sup>-2</sup> día<sup>-1</sup>;  $G = 0$  en una escala en el tiempo diaria de acuerdo con Allen *et al.* (1998);  $\lambda$  = calor latente de vaporización igual a 2.45 MJ kg<sup>-1</sup>;  $\gamma = \frac{c_p P}{\varepsilon \lambda} = 0.665 \times 10^{-3} \times P$ , es la constante psicrométrica;  $c_p$  = calor específico a presión constante, 1.013 x 10<sup>-3</sup> en MJ kg<sup>-1</sup> °C<sup>-1</sup>;  $\varepsilon$  = cociente del peso molecular de vapor de agua/aire seco = 0.622;  $P = 101.3 \left( \frac{293 - 0.0065z}{293} \right)^{5.26}$ , es la presión atmosférica en kPa;  $z$  = altitud en m.

### Modelo 4. RNA función de base radial (RBF)

La red neuronal de función de base radial con  $n$  entradas y un escalar como salida se representa en la ecuación 6 tal red implementa un mapeo  $f_r: R^n \rightarrow R$  de acuerdo con:

$$f_r(x) = \lambda_0 + \sum_{i=1}^{n_r} \lambda_i \phi(\|x - c_i\|) \quad (6)$$

Donde:  $x \in R^n$  es el vector de entrada,  $\phi(\cdot)$  es una función dada de  $R^+ \rightarrow R$ ,  $\|\cdot\|$  denota la norma euclidiana,  $\lambda_i$ ,  $0 \leq i \leq n_r$ , son los pesos o parámetros,  $c_i \in R^n$ ,  $1 \leq i \leq n_r$ , son conocidas como los centros *RBF*, y  $n_r$  es el número de centros. Aunque el caso de salida escalar es considerado aquí por simplicidad rotacional. De hecho, una red *RBF* multisalida puede separarse siempre

en un grupo de una red *RBF* de una sola salida. En la red *RBF* la forma funcional  $\phi(\cdot)$  y los centros  $c_i$  se asumen son fijos. Se suministra un conjunto a la entrada  $x(t)$  y la salida deseada correspondiente  $d(t)$  para  $t = 1$  hasta  $N$ , los valores de los pesos  $\lambda_i$  pueden determinarse usando el método lineal de mínimos cuadrados. Sin embargo, las elecciones de  $\phi(\cdot)$  y  $c_i$  deben considerarse cuidadosamente para que la red *RBF* sea capaz de igualar exactamente la representación de la red neuronal de dos capas.

Resultados teóricos y prácticos de investigación sugieren que la elección de la no-linealidad  $\phi(\cdot)$  no es crucial para la realización de la red *RBF*. Por ejemplo; sea la elección una función Gaussiana

$$\phi(v) = \exp(-v^2/\beta^2) \quad (7)$$

Donde:  $\beta$  es una constante real. Para la no-linealidad  $\phi(v) \rightarrow 0$  así como  $v \rightarrow \infty$ , (Chen *et al.*, 1991).

### Escenarios y variables de entrada utilizados en las RNA de base radial

Se utilizaron seis escenarios para las redes neuronales artificiales de base radial (*RNABR*) que a continuación se presentan, así como las {variables de entrada} que se utilizaron en cada una de ellas: *RNABR1* { $T_{min}$ ,  $T_{max}$ }, *RNABR2* { $T_{media}$ ,  $R_a$ }, *RNABR3* { $T_{min}$ ,  $T_{max}$ ,  $R_a$ }, *RNABR5* { $T_{media}$ ,  $R_n$ }, *RNABR7* { $T_{min}$ ,  $T_{max}$ ,  $R_n$ }. Donde:  $T_{min}$  y  $T_{max}$  son temperatura máxima y mínima respectivamente,  $T_{media}$  promedio de las temperaturas,  $R_a$  radiación extraterrestre,  $R_n$  radiación neta.

### Índices estadísticos para evaluar los modelos

Se obtuvieron los siguientes estadísticos de prueba para los diferentes modelos el error estándar promedio o raíz cuadrada del cuadrado medio del error (*RMSE*), calculándose con la siguiente ecuación:

$$RMSE = \frac{\sum_{i=1}^N (a_i - t_i)^2}{N}, \quad (8)$$

se obtuvo también el índice de Willmot (Willmot, 1981):

$$d = 1 - \frac{\sum_{i=1}^n (a_i - t_i)^2}{\sum_{i=1}^n (|a_i - \bar{t}| + |t_i - \bar{t}|)^2} \quad (9)$$

el coeficiente de determinación,  $R^2$ , dado por:

$$R^2 = \frac{\left[ \sum_{i=1}^N (a_i - \bar{a})(t_i - \bar{t}) \right]^2}{\left[ \sum_{i=1}^N (a_i - \bar{a})^2 \right] \left[ \sum_{i=1}^N (t_i - \bar{t})^2 \right]} \quad (10)$$

Donde:  $R$  = coeficiente de correlación,  $a_i$  es el dato estimado por el modelo,  $t_i$  es el dato observado,  $N$  es el número de observaciones o estimaciones,  $\bar{a}$  es el promedio de los datos estimados por el modelo,  $\bar{t}$  es el promedio de los datos observados (Cai *et al.*, 2007).

## Resultados y discusión

El valor de HE del exponente de la formula de Hargreaves calibrada fue 0.1051. Se observó que el modelo HARGC presentó mejor ajuste que el HARG, esto concuerda con lo

encontrado por Trajnovic (2007), que comenta que la ecuación de Hargreaves sin calibrar tiende a sobreestimar la evapotranspiración en regiones húmedas y puesto que Valle del Fuerte Los Mochis, Sinaloa, es una zona de riego presentando una humedad relativa de 70.4%, clasificándose de acuerdo con Doorenbos y Pruitt (1980) como zona de humedad relativa alta.

Del Cuadro 2 se observa que el Modelo *RNABR1* presentó un mejor ajuste que el Modelo HARG pero no que HARGC. El Modelo que obtuvo RMSE más cercano a cero fue el *RNABR7* con las variables de entrada temperatura mínima, máxima y radiación neta, siendo el Modelo que mejor ajuste presentó y corroborándolo el valor más cercano a uno del índice de Willmott ( $d$ ). De los modelos convencionales el que mejor ajuste presentó fue el de  $P-T$ .

**Cuadro 2. Estadísticos de prueba de ajuste entre la evapotranspiración de referencia observada y la estimada para Santa Rosa 1 AC.**

| Modelo                                         | $m$    | $b$     | $R^2$  | $RMSE$ | $d$    |
|------------------------------------------------|--------|---------|--------|--------|--------|
| Estación Santa Rosa 1                          |        |         |        |        |        |
| <i>HARG</i>                                    | 0.7856 | 1.654   | 0.6642 | 1.1727 | 0.8498 |
| <i>HARGC</i>                                   | 0.7088 | 1.1656  | 0.7679 | 0.7553 | 0.9234 |
| <i>RNABR1</i> { $T_{min}$ , $T_{max}$ }        | 0.6816 | 1.3787  | 0.6816 | 0.8691 | 0.8977 |
| <i>RNABR2</i> { $T_{media}$ , $Ra$ }           | 0.788  | 0.9181  | 0.788  | 0.7092 | 0.9382 |
| <i>RNABR3</i> { $T_{min}$ , $T_{max}$ , $Ra$ } | 0.8473 | 0.6611  | 0.8473 | 0.6019 | 0.9572 |
| $P-T$                                          | 1.0914 | -0.3613 | 0.9099 | 0.5482 | 0.9719 |
| <i>RNABR5</i> { $T_{media}$ , $Rn$ }           | 0.9143 | 0.3710  | 0.9143 | 0.4508 | 0.9772 |
| <i>RNABR7</i> { $T_{min}$ , $T_{max}$ , $Rn$ } | 0.9342 | 0.2848  | 0.9341 | 0.3951 | 0.9827 |

$m$  = pendiente;  $b$  = intercepto;  $R^2$  = coeficiente de determinación;  $RMSE$  = raíz cuadrada del cuadrado medio del error ( $\text{mm d}^{-1}$ );  $d$  = índice de Willmott.  $T_{min}$ ,  $T_{max}$  = temperatura mínima y máxima respectivamente;  $T_{media}$  = temperatura media;  $Rn$  = radiación neta;  $Ra$  = radiación extraterrestre, ésta última variable calculada con la metodología que propone Allen *et al.* (1998).

Estos resultados indican que una variable, la cual resulta imprescindible, es la radiación neta, puesto que el Modelo de  $P-T$  la utiliza para su calibración, al igual que el Modelo *RNABR7* y los estadísticos de ambos modelos presentan un mejor ajuste que los modelos que no incluyen a la radiación neta. Se realizó un entrenamiento adicional de red neuronal artificial con las variables de entrada temperatura mínima, máxima, humedad relativa mínima, máxima y velocidad del viento obteniendo valores de  $R^2 = 0.9938$ ,  $RMSE = 0.1221$  y  $d = 0.9984$ .

Estos resultados presentaron mejor ajuste que cualquiera de los escenarios presentados en el Cuadro 2, dichos resultados muestra que entre mayor número de variables de entrada

se incluyan para entrenar la red neuronal, se obtienen mejores ajustes. El problema aquí radica en que no todas las estaciones cuentan con todos los sensores para medir el global de variables, aunque la mayoría de estaciones si cuenta con aparatos para medir al menos temperaturas máximas y mínimas (la radiación neta se calcula), entonces es donde cobran importancia los entrenamientos que sólo toman en consideración dichas variables.

### Validación de los modelos

Se realizó una estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia, los resultados se muestran en el Cuadro 3 y en la Figura 1.

Cuadro 3. Estadísticos de prueba de los datos de validación entre la evapotranspiración de referencia observada y la estimada.

| Modelo                                                  | <i>m</i> | <i>b</i> | <i>R</i> <sup>2</sup> | <i>RMSE</i> | <i>d</i> |
|---------------------------------------------------------|----------|----------|-----------------------|-------------|----------|
| <i>HARG</i>                                             | 0.7993   | 1.6840   | 0.8750                | 1.0046      | 0.9009   |
| <i>HARGC</i>                                            | 0.7180   | 1.4231   | 0.856                 | 0.7055      | 0.9425   |
| <i>RNABR1</i> { <i>Tmin</i> , <i>Tmax</i> }             | 0.6572   | 2.0211   | 0.7394                | 1.0085      | 0.8835   |
| <i>RNABR2</i> { <i>Tmedia</i> , <i>Ra</i> }             | 0.8214   | 1.1456   | 0.8534                | 0.7365      | 0.9452   |
| <i>RNABR3</i> { <i>Tmin</i> , <i>Tmax</i> , <i>Ra</i> } | 0.8827   | 0.8998   | 0.9137                | 0.6254      | 0.9621   |
| <i>P-T</i>                                              | 1.0827   | -0.1282  | 0.9518                | 0.4904      | 0.9805   |
| <i>RNABR5</i> { <i>Tmedia</i> , <i>Rn</i> }             | 0.9106   | 0.5614   | 0.9561                | 0.3961      | 0.9848   |
| <i>RNABR7</i> { <i>Tmin</i> , <i>Tmax</i> , <i>Rn</i> } | 0.9127   | 0.5637   | 0.972                 | 0.347       | 0.9883   |

*m*= pendiente; *b*= intercepto; *R*<sup>2</sup>= coeficiente de determinación; *RMSE*= raíz cuadrada del cuadrado medio del error (mm d<sup>-1</sup>); *d*= índice de Willmott. *Tmin*, *Tmax*= temperatura mínima y máxima respectivamente; *Tmedia*= temperatura media; *Rn*= radiación neta; *Ra*= radiación extraterrestre, ésta última variable calculada con la metodología que propone Allen *et al.* (1998).




Figura 1. Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia, comparación de Modelos *HARG* vs *RNABR3*, *HARGC* vs *RNABR3*, *P-T* vs *RNABR7*.



En esta validación, en el Cuadro 3, se observó mayor error en la estimación únicamente de los modelos convencionales por el modelo HARG, que por los modelos de redes neuronales artificiales. En la Figura 1 se observa que HARG sobreestima a los datos observados, mientras que HARGC los subestima. Los errores se comportaron en esta validación de igual forma que en el ajuste.

Los resultados de los modelos en todos sus escenarios son similares a lo encontrado por Trajnovic *et al.* (2003), que utilizó una *RNA RBF* para estimar  $ET_0$  pero de manera mensual, puesto que el coeficiente de correlación que obtuvieron en su trabajo fue de 0.97 proporcionando una  $R^2$  de 0.94. De igual forma Sudheer *et al.* (2003) encontraron coeficientes de correlación para diferentes combinaciones de variables de entrada con una *RNA* función de base radial, para un escenario similar al de este trabajo, cuyas variables de entrada fueron temperatura media, humedad relativa, velocidad del viento y duración de las horas brillo sol, y encontraron una  $R$  de 0.93.

Se desprende de aquí que los modelos de redes neuronales artificiales integran en la estimación de los pesos características diversas entre ellas la flexibilidad que repercute en un buen ajuste en la estimación de la  $ET_0$ . Se puede afirmar que los modelos convencionales tienen ya parámetros definidos para su uso en la estimación de  $ET_0$ . El Modelo Hargreaves calibrado posee también esta flexibilidad de integrar en el ajuste de  $HE$  conocimiento que ayuda en la estimación de la evapotranspiración de referencia, sin embargo no mejoró la estimación que realizó el modelo de *RNA*.

## Conclusiones

De los modelos convencionales el que mejor estimó a los datos observados de evapotranspiración de referencia fue el de Priestley y Taylor; sin embargo, no superó a los modelos de redes neuronales en los escenarios *RNABR5* y *RNABR7*.

El modelo de red neuronal artificial función de base radial (*RBF*) con las variables de entrada temperatura máxima, mínima y radiación neta es el modelo que mejor desempeño mostró en la estimación de la evapotranspiración de referencia.

## Literatura citada

- Allen, R. G.; Pereira, S. L.; Raes, D. and Smith, M. 1998. Crop evapotranspiration Guidelines for computing crop water requirements. FAO Irrig. Drain. Paper 56. Roma. 29-86 pp.
- Cai, J.; Liu Y.; Lei, T. and Pereira, S. L. 2007. Estimating reference evapotranspiration with the FAO Penman-Monteith equation using daily weather forecast messages. Agric. Forest Meteorol. ISSN: 0168-1923. 145:22-35 pp.
- Chen, S. J.; Cowan, N. C. F. and Grant, M. P. 1991. Orthogonal least squares learning algorithm for Radial Basis Functions networks. IEEE transactions on neural networks. ISSN: 1045-9227. 2(2):302-309.
- Doorenbos, J. and Pruitt, W. O. 1980. Las necesidades de agua de los cultivos. Estudios FAO: riego y drenaje. Paper 24. Organización de las naciones unidas para la agricultura y la alimentación. Roma, Italy. 15-16 pp.
- Jensen, M. E.; Burman, R. D. and Allen, R. G. 1990. Evapotranspiration and Irrigation Water Requirements. ASCE manuals and reports on engineering practices No. 70. Published by American Society of Civil Engineers. New York, EUA. 164-265 pp.
- Kumar, M.; Raghuwanshi, N. S.; Singh, R.; Wallender, W. W. and Pruitt, W. O. 2002. Estimating evapotranspiration using artificial neural network. J. Irrig. Drain. Eng. ASCE. ISSN: 0733-9437. 128:224-233.
- Ojeda-Bustamante, W. 2004. Calendarización del riego en tiempo real. En: Fundamentos del riego y riego por gravedad. Vol. 1. In: X curso internacional de Sistemas de Riego. Departamen de Irrigación. Universidad Autónoma Chapingo (UACH). 79-111 pp.
- Sudheer, K. P.; Gosain, A. K. and Ramasastri, K. S. 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. J. Irrig. Drain. Eng. ASCE. ISSN: 0733-9437. 129(3):214-218.
- Thornley, J. H. M and France, J. 2007. Mathematical models in agriculture. Quantitative methods for the plant, animal and ecological sciences. 2<sup>nd</sup> Ed. Cromwell Press. Trowbridge United Kingdom. 362-363 pp.
- Trajkovic, S. 2007. Hargreaves versus Penman-Monteith under humid conditions. J. Irrig. Drain. Eng. ASCE. ISSN: 0733-9437. 133(1):38-42.

- Trajkovic, S.; Todorovic, B. and Stankovic, M. 2003. Forecasting of reference evapotranspiration by artificial neural. J. Irrig. Drain. Eng. ASCE. ISSN: 0733-9437. 129(6):454-457.
- Tymvios, F. S.; Michaelides, S. C. and Skouteli, C. S. 2008. Estimation of surface solar radiation with artificial neural networks. *In: modeling solar radiation at the Earth's surface. Recent advances.* Bodescu, V. (Ed). Heidelberg Berlin, 2008. ISBN: 978-3-540-77454-9. Springer. 221-256.
- Willmott, C. J. 1981. On the validation of model. Physical geography. J. Irrig. Drain. Eng. ISSN: 0272-3646. 2:84-194.
- Zanetti, S. S.; Sousa, E. F.; Oliveira, V. P. S.; Almeida, F. T. and Bernardo, S. 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. J. Irrig. Drain. Eng. ASCE. ISSN: 0733-9437. 133(2): 83-89.