

## Evapotranspiración de referencia estimada con Fao-Penman-Monteith, Priestley-Taylor, Hargreaves y RNA \*

### Reference evapotranspiration estimated by Penman-Monteith-Fao, Priestley-Taylor, Hargreaves and ANN

Sandra Santiago-Rodríguez<sup>1</sup>, Ramón Arteaga-Ramírez<sup>1§</sup>, Dora Ma. Sangerman-Jarquín<sup>2</sup>, Rocío Cervantes-Osornio<sup>1</sup> y Agustín Navarro Bravo<sup>2</sup>

<sup>1</sup>Departamento de Irrigación- Universidad Autónoma Chapingo. Carretera México-Texcoco, km 38.5, Chapingo, Estado de México, C. P. 56230. (ssantiagor@hotmail.com), (rcervanteso@colpos.mx). <sup>2</sup>Campo experimental Valle de México, INIFAP. Km. 18.5 Carretera los Reyes-Lechería A. P. 10, C. P. 56230 Chapingo-Texcoco, Estado de México. (sangerman.dora@inifap.gob.mx), (navarro.agustin@inifap.gob.mx). <sup>§</sup>Autor para correspondencia arteagar@correo.chapingo.mx.

#### Resumen

Las necesidades de agua de riego de los cultivos se basan en la estimación de la evapotranspiración de referencia (ET<sub>o</sub>) de cada zona en particular, están sujetas a la limitación de información meteorológica existente. El objetivo fue calcular ET<sub>o</sub> con FAO-Penman-Monteith (FAO-P-M), Hargreaves (H), Priestly-Taylor (P-T) y redes neuronales artificiales (RNA). Se utilizaron datos de la estación meteorológica de la Universidad Autónoma Chapingo para el periodo 2003-2009. En los métodos de H y P-T, se utilizaron cuatro variables climáticas para su cálculo y en RNA se construyeron diferentes escenarios para evaluar el comportamiento de la red, al cambiar las variables climáticas de entrada y la cantidad de neuronas en la capa oculta. Los resultados del coeficiente de determinación ( $r^2$ ) y raíz cuadrada del cuadrado medio del error (RMSE) de H y P-T son: 0.5378, 0.8553 y 0.6977, 0.6501 respectivamente. Para RNA se encontró que con el mayor número de variables y de neuronas en la capa oculta se obtuvo una  $r^2$  0.9986, y RMSE 0.0297 y en el escenario con el menor número de variables y de neuronas en la capa oculta fueron: 0.7549 y 0.5555. Si se tienen todas las variables climáticas es mejor RNA debido a que los resultados RMSE son cercanos a cero

#### Abstract

The irrigation water is a requirement of crops and is based on the estimation of reference evapotranspiration (ET<sub>o</sub>) of each particular area, are subject to the limitation of existing meteorological data. The objective was to calculate ET<sub>o</sub> with FAO-Penman-Monteith (FAO-PM), Hargreaves (H), Priestly-Taylor (PT) and artificial neural networks (ANN). We used data from the weather station of Chapingo for the period 2003-2009. In the H and PT methods, four climatic variables were used for their calculation and in ANN were constructed different scenarios to evaluate the performance of the network, by changing the input climatic variables and the number of neurons in the hidden layer. The results of the coefficient of determination ( $r^2$ ) and root mean square error (RMSE) of H and PT are: 0.5378, 0.8553 and 0.6977, 0.6501 respectively. For ANN was found that with the largest number of variables and neurons in the hidden layer was obtained an  $r^2$  0.9986, and RMSE 0.0297 and in the scenario with the least number of variables and neurons in the hidden layer were 0.7549 and 0.5555. If you count with all the climatic variables ANN is better because the RMSE results are close to zero and its  $r^2$  approaches

\* Recibido: enero de 2012  
Aceptado: octubre de 2012

y su  $r^2$  se aproxima a uno. Si en RNA decrece el número de neuronas en la capa oculta y las variables, da mayor error la estimación de ETo, pero menor a los obtenidos por H y P-T.

**Palabras clave:** Matlab, estimación, pronóstico, riego, variables climáticas.

## Introducción

La evapotranspiración es una variable clave que engloba la pérdida de agua de los cultivos por transpiración y del suelo por evaporación, en la práctica se utiliza en la elaboración de calendarios de riego y así optimizar el recurso hídrico durante el ciclo de un cultivo, para obtener los rendimientos deseados. En la actualidad el recurso hídrico para el uso en la agricultura se torna cada vez más limitante debido a la contaminación masiva de este y la disminución de la precipitación por el cambio climático global. En base a todas las dificultades que enfrenta la humanidad es necesario tener un conocimiento real del balance hídrico de cualquier región en sus diferentes niveles: regional, estatal o nacional y se logra con una buena estimación de ETo. Las posibles alternativas para la estimación están sujetas a la limitación de la información meteorológica existente en el país.

El boletín 56 publicado por la FAO (Heuvelink *et al.*, 2008; Allen *et al.*, 2006) ha recibido una aceptación favorable en el cálculo de ETo a nivel mundial, incluso se han realizado múltiples experimentos en diferentes cultivos y condiciones climáticas obteniéndose resultados adecuados (Zhao *et al.*, 2010).

El planteamiento de enfoque es calcular la evapotranspiración de referencia, que es la tasa de evapotranspiración de una superficie de referencia, que ocurre sin restricciones de agua y se conoce como evapotranspiración del cultivo de referencia, ETo. La superficie de referencia corresponde a un cultivo hipotético de pasto con características específicas (Allen *et al.*, 2006; Marcelis *et al.*, 2009).

Es importante señalar que el método FAO-P-M necesita variables climáticas tales como  $R_s$ ,  $T_{\max}$ ,  $T_{\min}$ ,  $H_{\max}$ ,  $H_{\min}$ ,  $U_2$ ,  $(e_s - e_a)$ , para estimar la evapotranspiración de referencia, teniendo resultados significativos en la zona donde se está trabajando, además es el método que es recomendado por la FAO (Allen *et al.*, 2006). H y P-T, estiman la evapotranspiración de referencia y utilizan cuatro variables climáticas.

to one. If ANN decreases the number of neurons in the hidden layer and the variables, gives the greatest error estimate of ETo, but lower than those obtained by H and PT.

**Key words:** Math lab, estimation, forecast, irrigation, weather variables.

## Introduction

Evapotranspiration is a key variable that includes the loss of water for crop transpiration and soil evaporation, in practice is used in the development of irrigation schedules and optimizes water resources during the crop cycle, to obtain the desired yields. At present water resources for use in agriculture is becoming more limited due to massive pollution of this and the decrease of precipitation by global climate change. Based on all the challenges facing humanity is necessary to have a real knowledge of the water balance of any region at different levels: at regional, state or national level and is accomplished with a good estimate of ETo. Possible alternatives for the estimation are subject to the limitation of existing weather information in the country.

The 56 paper published by FAO (Allen *et al.*, 2006; Heuvelink *et al.*, 2008) has received a favorable acceptance in the calculation of ETo worldwide, even many experiments have been conducted in different crops and climatic conditions obtaining results adequate (Zhao *et al.*, 2010).

The approach is to calculate the reference evapotranspiration, which is the rate of evapotranspiration from a reference surface, which occurs without water restrictions and is known as the reference crop evapotranspiration, ETo. The reference surface corresponds to a hypothetical grass crop with specific characteristics (Allen *et al.*, 2006; Marcelis *et al.*, 2009).

Is worth mentioning that the FAO-PM method requires climate variables such as  $R_s$ ,  $T_{\max}$ ,  $T_{\min}$ ,  $H_{\max}$ ,  $H_{\min}$ ,  $U_2$ ,  $(e_s - e_a)$ , to estimate the reference evapotranspiration, having significant results in the area where is being used, also is the method recommended by FAO (Allen *et al.*, 2006). H and PT estimate the reference evapotranspiration and use four climatic variables.

Una alternativa para el cálculo de ETo en la investigación es el método de RNA, este fue originalmente una simulación abstracta de los sistemas nerviosos biológicos, formados por un conjunto de unidades llamadas “neuronas” o “nodos” conectados unas con otras (Buendía *et al.*, 2002), las RNA representan una técnica de modelación matemática, que intenta imitar el proceso de aprendizaje que ocurre en el sistema nervioso (Ovando *et al.*, 2005). El primer antecedente data de mediados del siglo XX y las primeras que se conocieron fueron las redes Perceptrón y Adaline (Freeman y Skapura, 1991; Demuth *et al.*, 2009).

Las redes neuronales han tenido múltiples aplicaciones en la industria alimenticia (Cardona *et al.*, 2007) para la detección y pronóstico de coberturas vegetales (Buendía *et al.*, 2002), en la agricultura para la estimación de ETo (Martínez *et al.*, 2005) y en la predicción de heladas (Ovando *et al.*, 2005), entre muchas más.

El objetivo fue calcular la evapotranspiración de referencia por: FAO-Penman-Monteith, Hargreaves, Priestley-Taylor y el modelo de red neuronal artificial (RNA) tipo feedforward backpropagation, para el área de Chapingo. En adición se utilizaron como estadísticos de prueba RMSE y  $r^2$ .

## Materiales y métodos

El análisis se hizo con información de la estación meteorológica automática de la Universidad Autónoma Chapingo (UACH) en 2008, los datos son de cada media hora correspondientes al periodo (2003-2009), la información se procesó para tener datos diarios. Para el cálculo de ETo y sus parámetros estadísticos, se utilizó una hoja de cálculo de Excel.

Para calcular ETo con el método de RNA y sus parámetros estadísticos se utilizó el software de (Matlab) versión 7.8.0.347 (R2009), copyright 1984-2009 the Mathworks, Inc. en la cual se recurrió a la herramienta de Toolbox feedforward Backpropagation.

### Determinación de la evapotranspiración de referencia

#### Método de FAO-Penman-Monteith

El método FAO Penman-Monteith fue desarrollado con la definición del cultivo de referencia que es cultivo hipotético de altura de 0.12 m, con una resistencia superficial de  $70 \text{ s m}^{-1}$

An alternative for calculating ETo in research is the method of ANN, this was originally an abstract simulation of biological nervous systems, consisting of a set of units called “neurons” or “nodes” connected to each other (Buendía *et al.*, 2002), ANNs represent a mathematical modeling technique, which tries to imitate the learning process that occurs in the nervous system (Ovando *et al.*, 2005). The first record dates from the mid twentieth century and the first to be known were Perceptron and Adaline networks (Freeman and Skapura, 1991; Demuth *et al.*, 2009).

Neural networks have many applications in the food industry (Cardona *et al.*, 2007) for the detection and prediction of vegetative coverage (Buendía *et al.*, 2002), in agriculture for the estimation of ETo (Martínez *et al.*, 2005) and the prediction of frost (Ovando *et al.*, 2005), among many others.

The objective was to calculate the reference evapotranspiration by FAO-Penman-Monteith, Hargreaves, Priestley-Taylor and the model of artificial neural network (ANN) feedforward backpropagation type for the Chapingo area. In addition were used as statistics test RMSE and  $r^2$ .

## Materials and methods

The analysis was made with data from the automatic weather station of the Universidad Autónoma de Chapingo (UACH) in 2008; data are every half hour for the period (2003-2009), the information was processed to have daily data. To calculate ETo and its statistical parameters, we used an Excel spreadsheet.

To calculate ETo with the ANN method and its parameters was used the statistical software (Math lab) version 7.8.0.347 (R2009), copyright 1984-2009 The MathWorks, Inc. in which the tool feedforward Backpropagation Toolbox was used.

### Determination of the reference evapotranspiration

#### FAO-Penman-Monteith method

The FAO Penman-Monteith method was developed with the definition of the reference crop that is a hypothetical crop height of 0.12 m, with a surface resistance of  $70 \text{ s m}^{-1}$  and an albedo of 0.23 and represents the evapotranspiration of a large surface of green grass of uniform height, actively growing and adequately watered (Allen *et al.*, 2006).

y un albedo de 0.23 y que representa la evapotranspiración de una superficie extensa de pasto verde de altura uniforme, creciendo activamente y adecuadamente regado (Allen *et al.*, 2006).

Se trabajó con datos de radiación solar diaria, temperatura máxima, temperatura mínima, humedad relativa máxima, humedad relativa mínima y velocidad de viento, para estimar la evapotranspiración de referencia, se utilizó la ecuación 1, ésta fue revisada por el ASCE (American Society of Civil Engineers), (Walter *et al.*, 2005).

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

### Método Hargreaves

La fórmula de Hargreaves (Hargreaves y Sumani, 1985) y (Hargreaves y Allen, 2003) para evaluar la Evapotranspiración de referencia necesita datos de temperaturas y de radiación solar, en la ecuación 2 se muestra la expresión simplificada para la estimación de ésta (Trezza, 2008).

$$ET_o = 0.0023 * (T_{med} + 17.78) R_a (T_{max} - T_{min})^{0.5} \quad (2)$$

### Método Priestley-Taylor

En una superficie evaporante si no hay limitación de agua (ejemplo, después de un riego o de la precipitación) la atmósfera se mantiene en equilibrio con la superficie, el gradiente del déficit de presión de vapor se considera nulo por lo que (Priestley y Taylor, 1972) concluyeron que raramente se obtenía la situación de equilibrio, incluso sobre superficies de agua líquida, y en consecuencia propusieron la ecuación 3 para la estimación de ETo (Donatelli *et al.*, 2006):

$$ET_o = \alpha \frac{\Delta}{\Delta + \gamma} \frac{(R_n - G)}{\lambda} \quad (3)$$

Para las condiciones de Chapingo se seleccionó un valor  $\alpha$  de 1.26, propuesto por Priestley y Taylor (Venturini *et al.*, 2007).

### Método de redes neuronales artificiales (RNA)

Según Demuth y Beale (2008), las redes neuronales se componen de elementos simples que funcionan en paralelo. Se entrena una red neuronal para realizar una función particular, al ajustar los valores de las conexiones (pesos) entre los elementos. Una RNA está compuesta de neuronas artificiales que constituyen los elementos de procesamiento.

It was worked with daily solar radiation, maximum temperature, minimum temperature, relative humidity, minimum relative humidity and wind speed data to estimate the reference evapotranspiration, using the equation 1, it was reviewed by the ASCE (American Society of civil Engineers) (Walter *et al.*, 2005).

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

### Hargreaves method

The Hargreaves formula (Hargreaves and Sumani, 1985) and (Hargreaves and Allen, 2003) to assess the reference evapotranspiration needs data of temperatures and solar radiation, Equation 2 shows the simplified expression to estimate it (Trezza, 2008).

$$ET_o = 0.0023 * (T_{med} + 17.78) R_a (T_{max} - T_{min})^{0.5} \quad (2)$$

### Priestley-Taylor method

In an evaporating surface if there is no limitation of water (eg, after an irrigation or precipitation) the atmosphere is maintained in equilibrium with the surface, the gradient of vapor pressure deficit is void so (Priestley and Taylor, 1972) concluded that rarely obtained the equilibrium situation, even on surfaces of liquid water, and therefore equation 3 was proposed for the estimation of ETo (Donatelli *et al.*, 2006):

$$ET_o = \alpha \frac{\Delta}{\Delta + \gamma} \frac{(R_n - G)}{\lambda} \quad (3)$$

For the conditions of Chapingo it was selected a value of 1.26 proposed by Priestley and Taylor (Venturini *et al.*, 2007).

### Artificial neural network (ANN) method

According to Demuth and Beale (2008), neural networks are composed of simple elements working in parallel. A neural network is train to perform a particular function by adjusting the values of the connections (weights) between elements. The ANN consists of artificial neurons constituting the processing elements. Neurons receive input, this process information and send a single output by a transfer function or activation (Ljung, 2008).

Las neuronas reciben entradas, estas procesan la información y envían una sola salida por medio de una función de transferencia o activación (Ljung, 2008).

Una neurona es una unidad de procesamiento de información que es fundamental para la operación de una red neuronal, la Figura 1 muestra el modelo para una neurona. Se identifican tres elementos básicos del modelo de una neurona a continuación se describen, (Haykin, 2005).

- un conjunto de sinapsis o links conectores, cada uno del cual es caracterizado por un peso o proporción propia. Específicamente, una señal  $x_j$  en la entrada de la sinapsis  $j$  conectada a la neurona  $k$  es multiplicada por el peso sináptico  $w_{kj}$ , es importante hacer notar la manera en la cual los subíndices del peso sináptico  $w_{kj}$  están escritos. El primer subíndice se refiere a la neurona y el segundo alude a la entrada de la sinapsis a la cual el peso se refiere.
- un adicionador para sumar las señales de entrada, ponderadas por las respectivas sinapsis de la neurona; las operaciones descritas constituyen una combinación lineal. Una función de activación para limitar la amplitud de la salida de la neurona (Orta *et al.*, 2003; Rivas-Martínez, 2008).

Los datos de entrada se tienen que normalizar en la amplitud o rango descrito entre el intervalo de  $[0.1]$  o  $[-1.1]$ . Para estimar la evapotranspiración de referencia con el método de RNA se utilizaron los datos de evapotranspiración calculados con el método de FAO-Penman-Monteith.

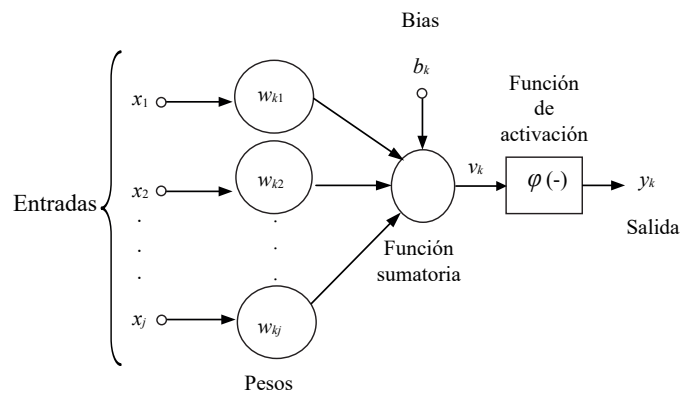
La forma en que se realizó fue la siguiente:

Se entrenó, validó y evaluó con datos de entrada: día juliano, radiación solar, temperatura máxima, temperatura mínima, humedad máxima, humedad mínima, velocidad del viento, déficit de presión de vapor y como target ETo de FAO-P-M, para el periodo 2003-2008. Se dejó el año 2009 para pronóstico, en el cual se dio las mismas variables de entrada pero sin ningún target, ya que se pronosticaría con el vector de datos aprendido por la red. Esto se realizó para cada uno de los cinco escenarios propuestos, la variación que hubo entre estos se denota por el decremento de las variables de entrada y el número de neuronas de la capa oculta (López-Cruz y Hernández-Larragoiti, 2010).

De los datos correspondientes al periodo (2003-2008), con 25% se evaluó, 25% validó y 50% se entrenó. Los diferentes escenarios con los cuales se entrenó la red neuronal se identificaran como se muestra en la Figura 2.

A neuron is a processing unit of information that is critical to the operation of a neural network, Figure 1 shows the model for a neuron. It identifies three basic elements of a neuron model described below (Haykin, 2005).

- A set of synapses or links connectors, each of which is characterized by a weight or proportion of its own. Specifically, a signal  $x_j$  at the input of synapse  $j$  connected to neuron  $k$  is multiplied by the synaptic weight  $w_{kj}$ , it is important to note the manner in which the synaptic weight  $w_{kj}$  subscripts are written. The first subscript refers to the neuron and the second refers to the input of the synapse to which the weight is referred.
- An adder for adding the input signals weighted by the respective synapses of the neuron, the operations described are a linear combination. An activation function for limiting the amplitude of the output of the neuron (Orta *et al.*, 2003; Rivas-Martínez, 2008).



**Figura 1. Esquema general de una neurona.**  
**Figure 1. General scheme of a neuron.**

The input data must be normalized in amplitude or range described between the intervals of  $[0.1]$  or  $[-1.1]$ . To estimate the reference evapotranspiration by the method of ANN were used the evapotranspiration data calculated with the method of Penman-Monteith FAO.

The way in which was carried out was as follows:

It was trained, validated and tested with input data: Julian day, solar radiation, maximum temperature, minimum temperature, maximum humidity, minimum humidity, wind speed, vapor pressure deficit and as target the FAO-PM ETo for the period 2003-2008. The year 2009 was left for prognosis, which gave the same input variables but without any target, as would be predicted with the data vector learned by the network. This was done for each of the



Los datos para el cálculo de ETo fueron introducidos al software Matlab y se procesaron para obtener el resultado de la red neuronal, esta red itera, lo que comúnmente se le denomina aprendizaje de la red, al finalizar este paso se procede cargar los datos para el pronóstico, introduciendo el mismo número de variables de entrada, pero esta vez sin ningún target (Ajayi y Olufayo, 2004).

El Cuadro 1, se observan las combinaciones de variables de entrada, número de neuronas en la capa oculta, número de salida y el arreglo que se les proporcionó para su identificación.

**Cuadro 1. Resumen de escenarios propuestos para el cálculo de ETo para el método de RNA.**

**Table 1. Summary of scenarios proposed for calculating ETo for the method of ANN.**

	Resumen de escenarios propuestos			
	Variables de entrada	Neuronas en la capa oculta	Núm. de salidas	Arreglo
E1810	8	10	1	8x10x1
E1808	8	8	1	8x8x1
E1806	8	6	1	8x6x1
E2406	4	6	1	4x6x1
E2404	4	4	1	4x4x1
E2402	4	2	1	4x2x1
E3406	4	6	1	4x6x1
E3404	4	4	1	4x4x1
E3402	4	2	1	4x2x1
E4304	3	4	1	3x4x1
E4303	3	3	1	3x3x1
E4302	3	2	1	3x2x1
E5304	3	4	1	3x4x1
E5303	3	3	1	3x3x1
E5302	3	2	1	3x2x1

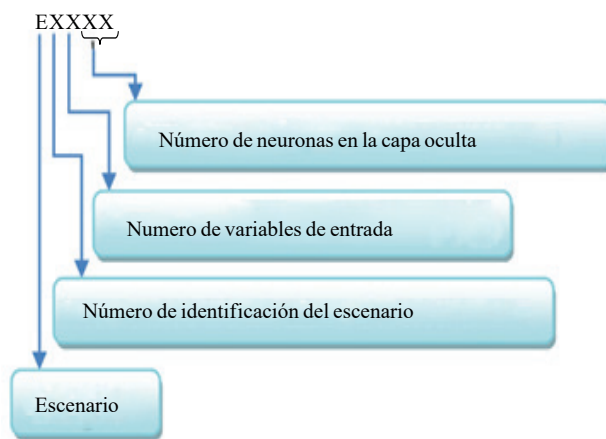
Las variables que se utilizaron en cada escenario se citan a continuación: 1)  $J, R_s, T_{max}, T_{min}, H_{max}, H_{min}, U_2, (e_s - e_a)$ ; 2)  $R_s, T_{med}, H_{max}, U_2$ ; 3)  $R_s, T_{med}, U_2, (e_s - e_a)$ ; 4)  $R_s, T_{med}, (e_s - e_a)$ ; y 5)  $R_s, T_{med}$  y  $H_{med}$ .

**Estadísticos de prueba: raíz cuadrada del cuadrado medio del error (RMSE) y coeficiente de determinación ( $r^2$ )**

En las estadísticas, RMSE de un estimador es una de las muchas maneras de cuantificar la diferencia entre un estimador y el valor real de la cantidad que se estima. RMSE es una función de riesgo, que corresponde al valor esperado

five proposed scenarios; the variation that existed between these is denoted by the decrease of the input variables and the number of hidden layer neurons (López-Cruz and Hernández-Larragoiti, 2010).

From the data corresponding to the period (2003-2008), with 25% was evaluated, 25% validate and 50% was trained. The different scenarios with which the neural network will be identify as shown in Figure 2.



**Figura 2. Esquema de identificación de cada escenario.**  
**Figure 2. Identification scheme for each scenario.**

The data for the calculation of ETo were introduced to the software Matlab and processed to obtain the result of the neural network, this network iterate, which is commonly called network learning, at the end of this step is necessary to load data for the prognosis, introducing the same number of input variables, but this time without any target (and Olufayo Ajayi, 2004).

Table 1, shows the combinations of input variables, number of neurons in the hidden layer, output number and the arrangement was provided for identification.

**Test statistics: root mean square error (RMSE) and coefficient of determination ( $r^2$ )**

In statistics, RMSE of an estimator is one of many ways to quantify the difference between an estimator and the true value of the amount that is estimated. RMSE is a function of risk, which corresponds to the expected value of the squared error loss and quadratic loss. RMSE measures the mean square error. The error is the amount by which the estimator differs from the amount that is estimated (Rahimi, 2008).

de la pérdida de error al cuadrado o pérdida cuadrática. RMSE mide el promedio del cuadrado del error. El error es la cantidad en que el estimador difiere de la cantidad que se estima (Rahimi, 2008).

$$RMSE = \sqrt{\frac{1}{n} \sum (ET_{o_{P-M}} - ET_{o_i})^2} \quad (4)$$

Donde:  $n$  es el número total de observaciones,  $ET_{o_{P-M}}$  es el estimado por la ecuación de FAO-Penman-Monteith y  $ET_{o_i}$  son los datos calculados con Hargreaves, Priestley-Taylor y RNA.

El coeficiente de determinación muestra el porcentaje de la variabilidad de los datos que se explica por la asociación entre las dos variables y se calcula con la ecuación 5.

$$r^2 = \frac{\left[ \frac{\sum x_i y_i}{n} - \bar{x} \bar{y} \right]^2}{\left[ \frac{\sum x_i^2}{n} - \bar{x}^2 \right] \left[ \frac{\sum y_i^2}{n} - \bar{y}^2 \right]} \quad (5)$$

El coeficiente de determinación es una medida de la bondad del ajuste de los datos a la recta, ya que a mayor  $r^2$  menor es el suma de cuadrados del error (Infante y Zárate, 2005).

## Resultados y discusión

El Cuadro 2, presenta los resultados de RMSE de los métodos de H y P-T para el periodo 2003-2008, se observa que al utilizar el método de H se obtiene una variación significativa de resultados que van de 0.5464 a 0.8732. El método de P-T tiende a arrojar resultados de RMSE uniformes, lo cual indica que los resultados son de mejor calidad, ajustándose a los datos de FAO-P-M, que es el método que se tiene como referencia, en comparación con los resultados del método de H.

En la Figura 3, A representa a FAO-P-M, B Hargreaves y C Priestley-Taylor, la Figura 3 a y b corresponde a los valores más pequeños de RMSE presentados en 2003 y 2005. El valor intermedio se observa en la Figura 3 c); y d) en 2005 y 2004 y por último los años 2007 y 2006 son los que tienen un valor alto de RMSE dándose una variación mayor de resultados con respecto de A y se muestra en la (Figura 3 e y f).

$$RMSE = \sqrt{\frac{1}{n} \sum (ET_{o_{P-M}} - ET_{o_i})^2} \quad (4)$$

Where  $n$  is the total number of observations,  $ET_{o_{P-M}}$  is the equation estimated by the FAO-Penman-Monteith and  $ET_{o_i}$  are calculated data with Hargreaves, Priestley-Taylor and ANN.

The coefficient of determination shows the percentage of data variability explained by the association between two variables and is calculated using equation 5.

$$r^2 = \frac{\left[ \frac{\sum x_i y_i}{n} - \bar{x} \bar{y} \right]^2}{\left[ \frac{\sum x_i^2}{n} - \bar{x}^2 \right] \left[ \frac{\sum y_i^2}{n} - \bar{y}^2 \right]} \quad (5)$$

The coefficient of determination is a measure of the goodness of fit of the data to the line, since the higher  $r^2$  less the sum of squared errors (Infante and Zárate, 2005).

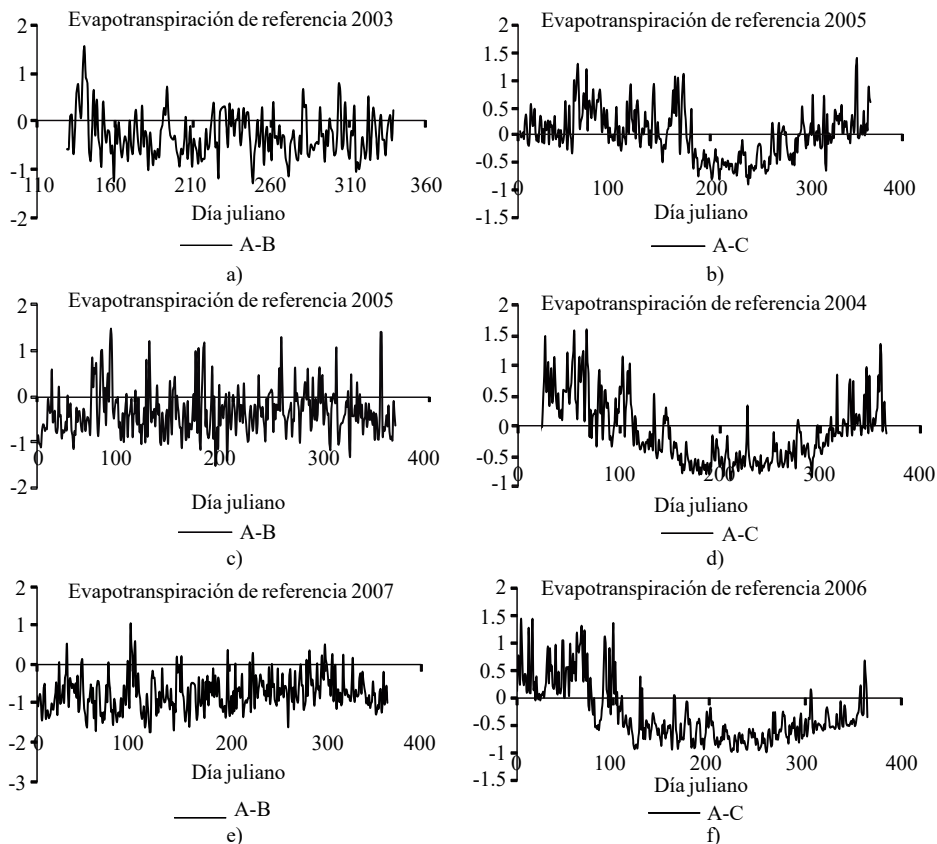
## Results and discussion

Table 2 presents the results of RMSE of the H and PT methods for the period 2003-2008, is observed that by using the H method is obtained a mean variation of results ranging from 0.5464 to 0.8732. The PT method tends to produce results of consistent RMSE, indicating that the results are of a better quality, adjusting with the data from FAO-PM, which is the method that is referenced, compared with the results of the H method.

### Cuadro 2. Resultados de RMSE con los métodos de H y P-T para el periodo 2003-2008.

Table 2. RMSE results with the methods of H and PT for the period 2003-2008.


Año	H	P-T
2003	0.5464	0.5265
2004	0.6000	0.5293
2005	0.6184	0.4247
2006	0.8202	0.6179
2007	0.8732	0.6012
2008	0.6060	0.4423



**Figura 3. Diferencias entre los valores de A y B, y A y C, para valores bajos, medios y altos de RMSE.**  
**Figure 3. Differences between the values of A and B, and A and C, for low, medium and high values of RMSE.**

Los resultados de entrenamiento, validación y evaluación del método de RNA se observan en la Figura 4; es importante mencionar, que sólo se esquematizará un escenario con cuatro variables climáticas que son:  $R_s$ ,  $T_{med}$ ,  $U_2$ ,  $(e_s - e_a)$  y seis neuronas en la capa oculta, identificado como E3406. Al observar la Figura 4, los datos indican que se ajustan a la ecuación propuesta en el entrenamiento, validación y evaluación.

In Figure 3, A represents FAO-PM, B Hargreaves and C Priestley-Taylor, Figure 3 a and b corresponds to the smallest values of RMSE presented in 2003 and 2005. The intermediate value is observed in Figure 3 c) and d) in 2005 and 2004 and finally the years 2007 and 2006 are those with a high value of RMSE giving a greater variation of results with respect to A and is shown in (Figure 3 e and f).



**Figura 4. a) entrenamiento; b) validación; y c) evaluación, del escenario E3406.**  
**Figure 4. a) training; b) validation; and c) evaluation of E3406 scenario.**



La Figura 5, presenta la diferencia de ETo de FAO-P-M vs los métodos de; Hargreaves, Priestley-Taylor y RNA, donde “A” representa a FAO-P-M, “B” Hargreaves, “C” Priestley-Taylor y “D” RNA.

La Figura 5 a) muestra la diferencia entre A y B, para el año 2009, la ETo calculada con B sobreestima el valor de A, esto es casi todo el año.

La Figura 5 b) es la diferencia del valor de A y C, para 2009, la ETo calculada con C subestima el valor de A, del mes de enero a marzo y de abril a diciembre es sobrestimado.

En la Figura 5 c) se observa la diferencia entre A y D, para 2009, la ETo estimada con D perteneciente al escenario tres con cuatro variables de entrada y seis neuronas en la capa oculta, identificada con E3406 tiene una tendencia uniforme y parecida al método de A, esto se observa en la mayoría del año, los meses en los que tuvo una desviación son de febrero a abril, pero no es grande.




Figura 5. Diferencias entre FAO-P-M vs a) Hargreaves; b) Priestley-Taylor; y c) RNA de 2009.

Figure 5. Differences between FAO-PM vs a) Hargreaves; b) Priestley-Taylor and; c) ANN 2009.

#### Diagrama de dispersión entre ETo FAO-Penman-Monteith con ETo calculada con Hargreaves, Priestley-Taylor y RNA.

En la Figura 6, se comparan los tres métodos (Hargreaves, Priestley-Taylor y RNA) con el de FAO-Penman-Monteith.

En c), d) y e) el número de variables de entrada son las mismas, la diferencia está en el número de neuronas en la capa oculta, disminuye de c) a e) y en este mismo sentido la dispersión de los puntos con respecto a la recta 1:1 aumenta.

En los escenarios de la Figura f), g) y h), los dos primeros presentan una dispersión de los valores casi semejante, en el último se observa una mayor dispersión (Barbosa da Silva, y Ramana, 2005).

The results of training, validation and evaluation of the ANN method are shown in Figure 4, it is important to note that only a scenario is going to be schematize with four climatic variables that are:  $R_s$ ,  $T_{med}$ ,  $U_2$ ,  $(e_s - e_a)$  and six neurons in the hidden layer, identified as E3406. By looking at Figure 4, indicates that the data fits to the equation proposed in the training, validation and evaluation.

Figure 5 shows the difference of ETo FAO-PM vs. methods; Hargreaves, Priestley-Taylor and ANN, where “A” represents FAO-PM, “B” Hargreaves, “C” Priestley-Taylor and “D” ANN.

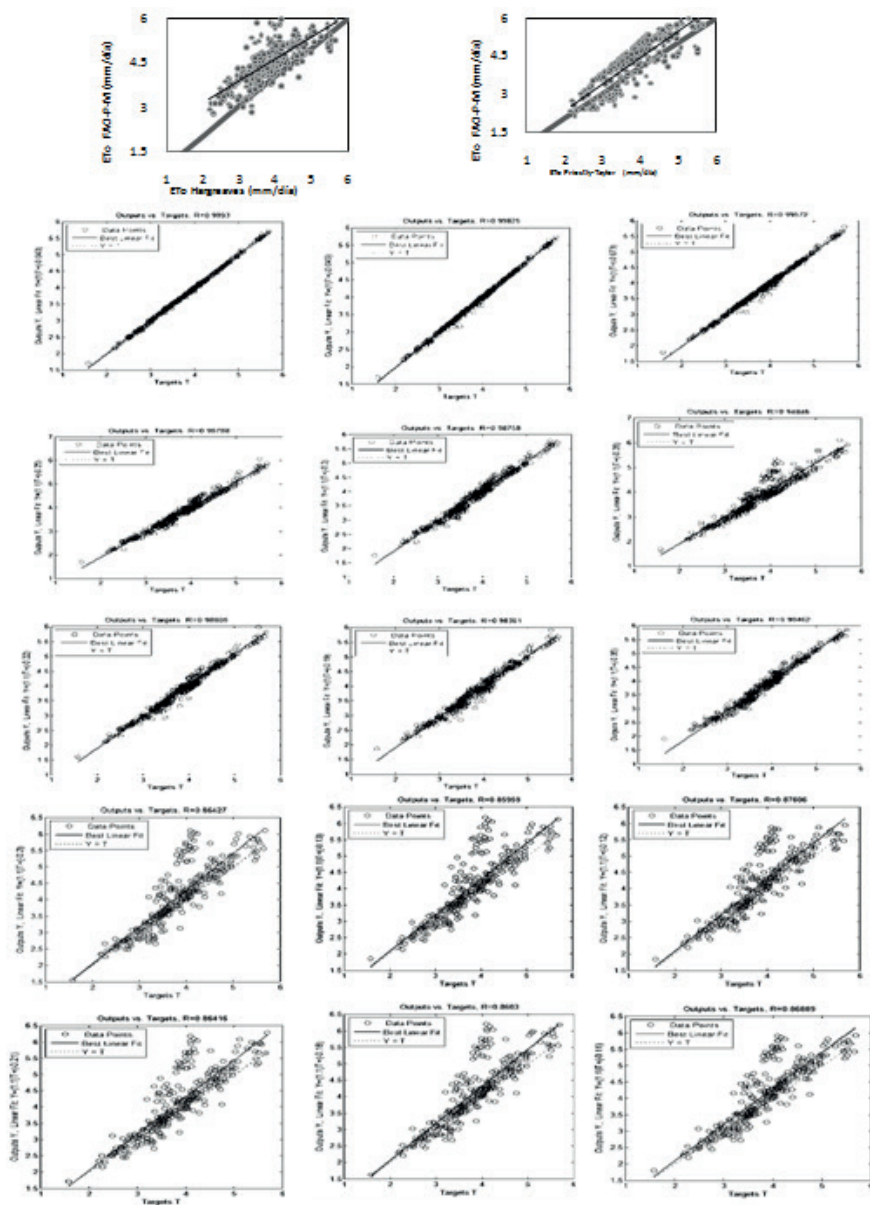
Figure 5 a) shows the difference between A and B, for the year 2009, the calculated ETo with B overestimates the value of A, this is almost all year.

Figure 5 b) is the difference of the value of A and C, for 2009, the calculated ETo with C underestimates the value of A, from January to March and April to December is overestimated.

Figure 5 c) shows the difference between A and D, for 2009, the estimated ETo with D belonging to the scenario three with four input variables and six neurons in the hidden layer, identified with E3406 has a uniform trend and similar to method A, as seen in most of the year, the months that had a deviation are from February to April, but it is not great.

#### Scatterplot between ETo FAO-Penman-Monteith with a calculated ETo by Hargreaves, Priestley-Taylor and ANN.

In Figure 6, are compared the three methods (Hargreaves, Priestley-Taylor and ANN) with the FAO-Penman-Monteith.



**Figura 6. Diagramas de dispersión para los datos de 2009, (FAO-P-M vs a) H b) P-T, c), d), e) escenario 1 RNA, f), g), h) escenario 2 RNA, i), j), k) escenario 3 RNA, l), m), n) escenario 4 RNA; y ñ), o), y p) escenario 5).**

**Figure 6. Scatterplots for the 2009 data (FAO-PM vs a) H b) PT; c); d); e) Scenario 1 ANN, f); g); h) Scenario 2 ANN, i); j); k) scenario 3 ANN; l); m); n) scenario 4 ANN, and ñ); o); and p) Scenario 5).**

En las Figuras i), j) y k), se observa un comportamiento semejante a las Figuras a), b) y c). En las Figuras l), m) y n), en los dos primeros se observa una dispersión de puntos

un poco mayor que la última. En los tres últimos escenarios (Figura o), p) y q) el comportamiento es semejante al que se acaba de explicar.

In a) shows that the data presents a wide dispersion with respect to the line 1:1, in b) the data have less scatter and are aligned to this.

In c), d) and e) the number of input variables are the same, the difference is in the number of neurons in the hidden layer, decreases from c) to e) and in this sense the dispersion of the points with respect to the line 1:1 increases.

## Estadísticos

En el Cuadro 3 se muestran los resultados de los estadísticos que ayudaron a definir cuál de los métodos de Hargreaves, Priestley-Taylor y RNA estimó la ETo, con un valor aproximado al de FAO-P-M, los cuales son:  $r$  coeficiente de correlación,  $r^2$  coeficiente de determinación, RMSE, raíz cuadrada del cuadrado medio del error,  $m$  pendiente y  $b$  ordenada al origen.

The scenarios in Figure f), g) and h), the first two have a dispersion of values almost similar; in the last is shown a greater dispersion (Barbosa da Silva, and Ramana, 2005).

Figures i), j) and k) show a similar behavior to Figures a), b) and c). In Figures l) m) n), in the first two is observed a dispersion of points a little larger than the latter. In the last three scenarios (Figure o), p) and q) the behavior is similar to that explained above.

**Cuadro 3. Estadísticos de cada uno de los métodos para la estimación de ETo.**

**Table 3. Statistical of each of the methods for estimating ETo.**

Hargreaves ETo					
H	$r$	$r^2$	RMSE	$m$	$b$
	0.7333	0.5378	0.8553	1.6586	0.7413
Priestley-Taylor ETo					
P-T	$r$	$r^2$	RMSE	$m$	$b$
	0.8352	0.6977	0.6501	1.0339	0.2864
RNA pronóstico ETo					
E1810	$r$	$r^2$	RMSE	$m$	$b$
	0.9993	0.9986	0.0297	1.0096	-0.0425
E1808	0.9982	0.9964	0.0457	1.0100	-0.0426
E1806	0.9957	0.9914	0.0733	1.0146	-0.0726
RNA pronóstico ETo					
E2406	$r$	$r^2$	RMSE	$m$	$b$
	0.9879	0.9759	0.1373	1.0701	-0.2539
E2404	0.9876	0.9753	0.1328	1.0554	-0.2046
E2402	0.9485	0.8996	0.2946	1.0945	-0.2807
RNA pronóstico ETo					
E3406	$r$	$r^2$	RMSE	$m$	$b$
	0.9881	0.9763	0.1319	1.0593	-0.2190
E3404	0.9836	0.9674	0.1485	1.0455	-0.1899
E3402	0.9846	0.9694	0.1608	1.0919	-0.3510
RNA pronóstico ETo					
E4304	$r$	$r^2$	RMSE	$m$	$b$
	0.8643	0.7470	0.5659	1.1222	-0.1997
E4303	0.8596	0.7389	0.5694	1.1047	-0.1262
E4302	0.8761	0.7675	0.5379	1.1039	-0.1228
RNA pronóstico ETo					
E5304	$r$	$r^2$	RMSE	$m$	$b$
	0.8642	0.7468	0.5802	1.1301	-0.2091
E5303	0.8603	0.7401	0.5874	1.1231	-0.1761
E5302	0.8689	0.7549	0.5555	1.1028	-0.1097

Los resultados de RMSE muestran que el método que mejor resultados tuvo fue el de RNA, en este método se emplearon 5 escenarios en los cuales se abordó diversos números de variables de entrada y neuronas en la capa oculta.

## Statistical

Table 3 shows the statistical results that helped to define which method of Hargreaves, Priestley-Taylor and ANN estimated ETo, with an approximate value to the FAO-

Es interesante analizar los resultados de cada uno de los métodos, ya que en H se observa que los datos fueron dispersos, dando errores mayores lo que se comprueba con el valor de RMSE de 0.8553, para P-T se tiene un RMSE de 0.6501, lo cual indica que tiene una menor dispersión. Con respecto a RNA los resultados de los escenarios son: 1) En el escenario E1810 donde se consideraron el mayor número de variables y neuronas se tiene un RMSE de 0.0297, con 10 neuronas, observe conforme disminuyen el valor de RMSE aumenta, este comportamiento también se esquematiza en el escenario 3.

En los escenarios 4 y 5 se observa que los RMSE menores son: 0.5379 y 0.555 respectivamente, se obtienen al utilizar 2 neuronas en la capa oculta, con variables de entrada:  $R_s$ ,  $T_{med}$ ,  $(e_s - e_a)$ ; y  $R_s$ ,  $T_{med}$ ,  $H_{med}$  para cada uno, el comportamiento se debe a que el modelo generado para el pronóstico se ajusto mejor a los datos, lo que se observa en su  $r^2$ . En el escenario 2 el RMSE pequeño de 0.1328 se tiene al usar cuatro neuronas en la capa oculta con las siguientes variables:  $R_s$ ,  $T_{med}$ ,  $H_{max}$ ,  $U_2$ , los resultados al variar las neuronas en la capa oculta son muy semejantes, por lo que no existe mucha variación en sus  $r^2$  y sus RMSE, la diferencia se presenta en la tercera cifra. Es importante indicar que el RMSE conserva las unidades de ETo en  $\text{mm día}^{-1}$ . Con respecto a la pendiente (m) y a la ordenada al origen (b), éstas deben tener un valor próximo a uno y cero lo que indica un buen ajuste del modelo. Como se observa en todos los escenarios sus valores son muy próximos a uno (m) y a cero (b), en relación a los métodos convencionales, H presenta los valores más grandes de m, b y los de P-T tiene valores que generan un mejor ajuste y m es mejor que la de algunos escenarios.

Los resultados obtenidos y el buen ajuste logrado, demuestra la versatilidad que ofrece la modelación en redes neuronales, al considerar además que el éxito de la modelación depende en gran medida de la calidad y cantidad de datos disponibles para los procesos de entrenamiento, validación y evaluación.

Es importante mencionar que los métodos de H, P-T y FAO-P-M, son métodos no tan laboriosos y para aplicarlos no se requiere un conocimiento minucioso en algún software, además dan resultados muy buenos para la estimación de ETo en la práctica diaria.

Para aplicar el método de RNA se necesita tener un conocimiento en la aplicación del software (Matlab), por lo que es una herramienta muy útil para la estimación de ETo, este método se recomienda aplicarlo en cuestiones de

PM, which are:  $r$  correlation coefficient,  $r^2$  coefficient of determination, RMSE, root mean square error,  $m$  slope and  $b$  intercept.

RMSE results show that the method that had better results was the ANN; in this method were used 5 scenarios in which addressed various numbers of inputs and neurons in the hidden layer.

It is interesting to analyze the results of each of the methods, since in H is observed that the data were scatter, giving major errors which can be proved with the RMSE value of 0.8553, for PT has a RMSE of 0.6501, which indicates that has a lower dispersion. With respect to ANN the results of the scenarios are: 1) In the scenario E1810 were considered the highest number of variables and neurons have a RMSE of 0.0297, with 10 neurons, observe as decreasing the value of RMSE increases, this behavior also is outlined in Scenario 3.

Scenarios 4 and 5 shows that the lower RMSE are 0.5379 and 0.555 respectively, are obtained by using 2 neurons in the hidden layer, with input variables:  $R_s$ ,  $T_{med}$ ,  $(e_s - e_a)$ ; and  $R_s$ ,  $T_{med}$ ,  $H_{med}$  for each, the behavior is due to the model generated for the forecast was adjusted better to the data, which is observed in its  $r^2$ . In Scenario 2, the smallest RMSE of 0.1328 is obtained by using four neurons in the hidden layer with the following variables:  $R_s$ ,  $T_{med}$ ,  $H_{max}$ ,  $U_2$ , the results by varying neurons in the hidden layer are very similar, so there is no much variation in their  $r^2$  and RMSE, the difference is in the third digit. It is important to note that the RMSE conserves the units of ETo in  $\text{mm day}^{-1}$ . With respect to the slope (m) and the intercept (b), these must have a value close to one and zero indicating a good fit of the model. As seen in all scenarios their values are very close to one (m) and zero (b) in relation to conventional methods, H has the largest values of m, b and the PT has values that generate a better fit and m is better than some scenarios.

The results obtained and the good fit achieved, shows the versatility that neural network modeling offers, considering that the success of modeling depends heavily on the quality and quantity of data available for the processes of training, validation and evaluation.

It is noteworthy that the methods of H, PT and FAO-PM, are methods not so laborious and to apply them is not required a thorough knowledge in some software, besides they give very good results for the estimation of ETo in daily practice. To apply the method of ANN is necessary to have knowledge

investigación, automatización de invernaderos y modelación de cultivos donde se requiere una precisión en tiempo y cantidad de agua a aplicar a los cultivo.

En investigaciones realizadas por (Pérez y Castellví, 2002) se observó que la ecuación de H presenta una mayor dispersión en relación a P-T, también (Lu *et al.*, 2005), encontró que al comparar seis métodos en el sureste de Estados Unidos de American (Thornthwaite, Hamon, Turc, Priestley-Taylor, Makkink y Hargreaves-Samani) obtienen valores del coeficiente de correlación de (0.63, 0.63, 0.64, 0.65, 0.60 y 0.57) respectivamente, demostrando una vez más que el método de P-T logra un mejor ajuste en relación a los demás, un comportamiento semejante se encontró para los datos de este trabajo. En relación al método de RNA y H (Seydou *et al.*, 2010, observaron que RNA tiene un mejor desempeño en comparación de H, además encontraron que las variables clave para el cálculo de ETo con RNA son:  $U_2$ ,  $Rs$ ,  $T_{med}$ , resultados semejantes a los obtenidos aquí.

## Conclusiones

Se calculó la ETo, con los métodos de FAO-P-M, H, P-T y RNA con sus respectivas variables, en el caso del RNA fue con diferentes variables de entrada y cantidad de neuronas en la capa oculta.

Con los métodos de H y P-T se tiene que este último estimó mejor la ETo en el periodo 2003-2008 y en 2009, logrando mejores ajustes que H. Los métodos de H y P-T son métodos accesibles y sobre todo aplicables en la planeación de diversas actividades donde se involucra esta variable.

Se encontró que el método de RNA tiene un mejor desempeño ya que se entrena, valida y evalúa, en relación a los métodos de H y P-T que solo utiliza los coeficientes propuestos por sus autores. Además se observó que si se cuenta con todas las variables climáticas es mejor utilizar RNA debido a que los resultados de RMSE son cercanos a cero y su  $r^2$  se aproxima a uno. Otro punto importante presentado por RNA es que si se decrece el número de neuronas en la capa oculta, los resultados tienden a alejarse del modelo, dando un mayor error en la estimación de ETo, pero menor a los obtenidos por H y P-T.

Aunado a los resultados obtenidos se abre un panorama de aplicaciones de las redes neuronales en el pronóstico de ETo, debido a su capacidad para su uso en investigaciones.

in the application of software (Mathlab), making it a useful tool for estimating ETo, this method is recommended to apply in matters of research, greenhouse automation and modeling cultures where accuracy is required in time and amount of water to apply to the crop.

Research by (Pérez and Castellví, 2002) noted that the equation of H has a higher dispersion in relation to PT, as well (Lu *et al.*, 2005) found that when comparing six methods in the southeastern of USA (Thornthwaite, Hamon, Turc, Priestley-Taylor, Makkink and Hargreaves-Samani) obtained values of correlation coefficient of (0.63, 0.63, 0.64, 0.65, 0.60 and 0.57) respectively, demonstrating once again that the PT method achieves a better fit in relation to others, a similar behavior was found for the data in this work. Regarding the method of ANN and H (Seydou *et al.*, 2010, found that ANN has a better performance compared to H, also found that the key variables for the calculation of ETo with ANN are:  $U_2$ ,  $Rs$ ,  $T_{med}$ , similar results to those obtained here.

## Conclusions

ETo was calculated, using the methods of FAO-PM, H, PT and ANN with their respective variables, in the case of ANN was with different input variables and number of neurons in the hidden layer.

With the H and PT methods has that latter estimated ETo better in the period 2003-2008 and in 2009, making better adjustments H. The H and PT methods are accessible methods and mostly applicable in planning various activities which involve this variable.

It was found that the ANN method has better performance because it trains, validates and evaluates, in relation to the H and PT methods only using the coefficients proposed by the authors. Although it was observed that if you have all the climate variables is better to use ANN because the RMSE results are close to zero and its  $r^2$  is close to one. Another important point presented by ANN is that if it decreases the number of neurons in the hidden layer, the results tend to move away from the model, giving a greater error in estimating ETo, but lower than those obtained by H and PT.

In addition to the results obtained, opens a panorama of applications of neural networks in the prognosis of ETo, due to its capacity to be use in research.



La selección óptima de un método en especial depende de muchos factores, lo más importante es que la aproximación de este satisfaga el uso de los resultados, sea en investigación o simplemente para planeación en campo, así como de la disponibilidad de las variables climáticas con que se cuente.

## Nomenclatura

$ET_o$  evapotranspiración de referencia, mm día<sup>-1</sup>;  $R_n$ = radiación neta en la superficie del cultivo, MJ m<sup>-2</sup> día<sup>-1</sup>;  $G$ = flujo del calor de suelo, MJ m<sup>-2</sup> día<sup>-1</sup>;  $T$ = temperatura media del aire a 2 m de altura, °C;  $u_2$ = velocidad del viento a 2 m de altura, m s<sup>-1</sup>;  $e_s$ = presión de vapor de saturación, kPa;  $e_a$ = presión real de vapor, kPa;  $(e_s - e_a)$ = déficit de presión de vapor, kPa;  $\Delta$ = pendiente de la curva de presión de vapor, kPa °C<sup>-1</sup>;  $\gamma$ = constante psicrométrica, kPa °C<sup>-1</sup>;  $T_{med}$  temperatura media diaria, °C;  $R_a$ = radiación solar extraterrestre, en mm/día;  $\alpha$ = parámetro ecuación de Priestley-Taylor, adim;  $\lambda$ = Calor latente de vaporización a 20°C, 2.45MJ/kg;  $J$ = día Juliano, entre el día primero del año hasta el 31 de diciembre, numerando los días consecutivamente;  $R_s$ = radiación solar o de onda corta, MJ m<sup>-2</sup>día<sup>-1</sup>;  $T_{max}$ = temperatura máxima diaria del aire °C;  $T_{min}$ = temperatura mínima diaria del aire °C;  $HR_{max}$ = humedad relativa máxima, %;  $HR_{min}$ = humedad relativa mínima, %;  $HR_{med}$ = humedad relativa mínima, %;  $r^2$ = coeficiente de determinación;  $r$ = coeficiente de correlación; RMSE= raíz cuadrada del cuadrado medio del error;  $m$ = pendiente;  $b$ = ordenada al origen.

## Literatura citada

- Ajayi, A. E. and Olufayo, A. A. 2004. Evaluation of two temperature stress indices to estimate grain sorghum yield and evapotranspiration. *Agron. J.* 96:1282-1287.
- Allen, R. G.; Pereira, L. S.; Raes, D. y Smith, M. 2006. Evapotranspiración del cultivo. Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO). Roma, Italia. 56:1-79.
- Barbosa da Silva, B. y Ramana, R. T. A. 2005. The CWSI variations of a cotton crop in a semi-arid region of Northeast Brazil. *J. Arid Environ.* 62:649-659.
- Buendía, E.; Vargas, E.; Leyva, A. y Terrazas S. 2002. Aplicación de redes neuronales artificiales y técnicas SIG para la predicción de coberturas forestales. *Revista Chapingo. Series Forestales y del Ambiente.* 08:31-37.

The optimal choice of a particular method depends on many factors, most importantly; the approach of this satisfies the use of the results, either in research or simply for planning in field, as well as the availability of climate variables that are counted with.

## Nomenclature

$ET_o$ = reference evapotranspiration, mm day<sup>-1</sup>;  $R_n$ = net radiation at the crop surface, MJ m<sup>-2</sup> day<sup>-1</sup>;  $G$ = soil heat flux, MJ m<sup>-2</sup> day<sup>-1</sup>;  $T$ = mean air temperature at 2 m height, °C;  $u_2$ = wind speed at 2 m, m s<sup>-1</sup>;  $e_s$ = saturation vapor pressure, kPa;  $e_a$ = actual vapor pressure, kPa;  $(e_s - e_a)$ = vapor pressure deficit, kPa;  $\Delta$ = slope of the vapor pressure curve, kPa °C<sup>-1</sup>;  $\gamma$ = psychrometric constant, kPa °C<sup>-1</sup>;  $T_{med}$ = average daily temperature, °C;  $R_a$ = extraterrestrial solar radiation in mm/day;  $\alpha$ = parameter Priestley-Taylor equation, dimensionless;  $\lambda$ = latent heat of vaporization at 20 °C, 2.45MJ/kg;  $J$ = Julian day, among the first of the year to December 31, numbering the days consecutively;  $R_s$ = solar or shortwave radiation, MJ m<sup>-2</sup>day<sup>-1</sup>;  $T_{max}$ = maximum daily air temperature °C;  $T_{min}$ = daily minimum air temperature °C;  $HR_{max}$ = maximum relative humidity,%;  $HR_{min}$ = minimum relative humidity,%;  $HR_{med}$ = minimum relative humidity,%;  $r^2$ = coefficient of determination;  $r$ = correlation coefficient; RMSE= root mean square error;  $m$ = slope;  $b$ = ordinate to the origin.

*End of the English version*



- Cardona, J. E.; Hoyos, J. G. y Zapata, J. H. 2007. Control de un evaporador de doble efecto por linealización instantánea usando redes neuronales artificiales. *Scientia et Technica.* XIII-37:97-102.
- Demuth, H. and Beale, M. 2008. Neural network toolbox™ 6. User's Guide. The Math Works, Inc. U. S. 1-3 p.
- Demuth, H.; Beale, M. and Hagan, M. 2009. Neural Network Toolbox™ 6. User's Guide. The Math Works, Inc. Natick, MA. 321 pp.
- Donatelli, M.; Bellocchi, G. and Carlini, L. 2006. Sharing knowledge via software components: models on reference evapotranspiration. *Europ. J. Agron.* 24:186-192.
- Freeman, J. A. and Skapura, D. M. 1991. Neural networks: algorithms, applications and programming techniques (Computation and Neural Systems Series). Addison-Wesley Pub. Co. Reading, Massachusetts, USA. 401 p.

- Hargreaves, G. H. and Sumani, Z. A. 1985. Reference crop evapotranspiration from temperatura. *Applied Eng. Agric.* 8:96-99.
- Hargreaves, G. H. and Allen, R. G. 2003. History and evaluation of Hargreaves equation. *J. Irrigation Drainage Engineering*.-ASCE. 129:53-63.
- Haykin, S. 1995. *Neural networks: a comprehensive foundation*, Pearson. Canada. 823 p.
- Heuvelink, E.; Bakker, M. and Marcelis, L. F. M. and Raaphorst, M. 2008. Climate and yield in a closed greenhouse. *Acta Hort.* 801:1083-1092.
- Infante, G. S. y Zárate, de L. G. P. 2005. *Métodos estadísticos*. México D. F. Ed. Trillas. 643 p.
- Ljung, L. 2008. Perspectives on system identification. 17<sup>th</sup> IFAC World Congress in Seoul, Korea. 174 pp.
- López-Cruz, I. L. y Hernández-Larragoiti, L. 2010. Modelos Neurodifusos para temperatura y humedad del aire en invernaderos tipo cenital y capilla en el centro de México. *Agrociencia.* 44:791-805.
- Lu, J.; Sun, G.; McNulty, S. and Amatya, D. A. comparison of six potential evapotranspiration methods for regional use in the southeastern United States. *J. Am. Water Res. Association.* (JAWRA). 03175:621-633.
- Marcelis, L. F. M.; Elings, P. A.; de Visser, H. B. and Heuvelink, E. 2009. Simulating growth and development of tomato crop. *Acta Hort.* 821:101-110.
- Martínez, R.; Boueri, M. y Escalona, P. 2005. Correlación entre la evaporación de tina y la evapotranspiración de referencia en cinco estaciones climatológicas de Venezuela. *Bioagro.* 17(02):79-83.
- Orta, A. H.; Erdem, Y. and Erdem, T. 2003. Crop water stress index for watermelon. *Sci. Hort.* 98:121-135.
- Ovando, G.; Bocco, M. y Sayago, S. 2005. Redes neuronales para modelar predicción de heladas. *Agric. Téc. Méx.* 65(01)65-73.
- Pérez, P. y Castellví, F. 2002. Análisis de la evapotranspiración a escala local y regional en Cataluña. *Ingeniería del Agua.* 9(1)59-72.
- Priestley, C. H. and Taylor, R. H. 1972. On the assessment of surface heat flux and Evaporation using large scale parameters. *Monthly Weather Review.* 100(2)81-92.
- Rivas-Martínez, S. 2008. Otros índices bioclimáticos. Worldwide bioclimatic classification systems. Centro de Investigaciones Fitosociológicas. Web <http://www.globalbioclimatics.org>.
- Seydou, T.; Yu-Min, W. and Tienfuan, K. 2010. Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone. *Agric. Water Manag.* 97.707-714.
- Trezza, R. 2008. Estimación de la evapotranspiración de referencia a nivel mensual en Venezuela. *Bioagro.* 2:89-95.
- Venturini, V.; Rodríguez, L. e Islam, S. 2007. Metodología para la estimación de la fracción evaporable y la evapotranspiración con productos MODIS. *Rev. Teledetección.* 44-52 pp.
- Walter, I. A.; Allen, R. G.; Elliot, R.; Itenfisu, D.; Brown, P.; Jensen, M. E.; Mecham, B.; Howell, T. A.; Snyder, R.; Eching, S.; Spofford, T.; Hattendorf, M.; Martin, D.; Cuenca, R. H. and Wright, J. L. 2005. The ASCE standardized reference evapotranspiration equation. ASCE and EWRI. 70 p.
- Zaho, W. Z.; Ji, X. B.; Kang, E. S.; Zhang, Z. H. and Jin, B. W. 2010. Evaluation of Penman-Monteith model applied to a maize field in the arid area of northwest China. *Hydrol. Earth Syst. Sci.* 14:1353-1364.