

## REDES NEURONALES ARTIFICIALES EN LA ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA\*

### ARTIFICIAL NEURAL NETWORKS IN THE ESTIMATION OF REFERENCE EVAPOTRANSPIRATION

Rocío Cervantes-Osornio<sup>1</sup>, Ramón Arteaga-Ramírez<sup>1</sup>, Mario Alberto Vázquez-Peña<sup>1</sup>, Waldo Ojeda-Bustamante<sup>2</sup> y Abel Quevedo-Nolasco<sup>3</sup>

<sup>1</sup>Posgrado en Ingeniería Agrícola y Uso Integral del Agua. Universidad Autónoma Chapingo. Carretera México-Texcoco, km 38.5. Chapingo, Texcoco, Estado de México. C. P. 56230. (rartegar@taurus.chapingo.mx), (mvazquezp@correo.chapingo.mx). <sup>2</sup>Instituto Mexicano de Tecnología del Agua. Paseo Cuauhnáhuac 8532, Col. Progreso, Jiutepec, Morelos. C. P. 62550. (wojeda@tlaloc.imta.mx). <sup>3</sup>Colegio de Posgraduados. Carretera México-Texcoco, km 36.5. Montecillo, Texcoco, Estado de México, C. P. 56230. (anolasco@colpos.mx). <sup>4</sup>Autora para correspondencia: rcervantes@colpos.mx.

#### RESUMEN

Las redes neuronales artificiales representan un vasto campo de investigación, puesto que han demostrado tener aplicación en varios campos de la ciencia, su capacidad de lidiar con no linealidades en diversos fenómenos, y los diferentes trabajos realizados en la estimación y/o pronóstico para predecir variables climáticas, que inciden directa e indirectamente en la evapotranspiración de referencia y la propia evapotranspiración ha originado el desarrollo de este trabajo. El objetivo fue presentar una revisión de literatura sobre redes neuronales artificiales, para la estimación de la evapotranspiración de referencia y variables relacionadas, que incluye: la teoría y fundamentos de las redes neuronales artificiales y el algoritmo backpropagation; algunas similitudes y diferencias entre los modelos estadísticos tradicionales y las redes neuronales artificiales; aplicaciones de las redes neuronales artificiales en la estimación de la evapotranspiración de referencia; y variables que se asocian con las perspectivas de las redes neuronales artificiales en la predicción de variables agroclimáticas. Las redes neuronales artificiales estáticas multicapa, son hasta ahora las más comunes en la estimación de evapotranspiración de referencia, y se vislumbra un cambio en la tendencia de aplicar redes neuronales artificiales de tipo dinámico.

#### ABSTRACT

Artificial neural networks represent a vast research field, since they have demonstrated application in various fields of science. Its ability to cope with nonlinearities in several different phenomena and work in the estimation or forecast meteorological variables, which act directly and indirectly in reference evapotranspiration and actual evapotranspiration, have led to this work development. The aim was to present a literature review on artificial neural networks for reference evapotranspiration estimating and related variables, including: theory and artificial neural networks foundations and backpropagation algorithm, some similarities and differences between traditional statistical models and artificial neural networks, applications of artificial neural networks in reference evapotranspiration estimating and variables associated with the prospects of artificial neural networks in agroclimatic variables prediction. Static neural multilayer networks, are so far the most common in reference evapotranspiration estimation and a change in applying artificial neural networks of dynamic type trend looms.

**Key words:** modeling, meteorological variables, prediction.

\* Recibido: diciembre de 2010  
Aceptado: abril de 2011

**Palabras clave:** modelos, predicción, variables meteorológicas.

## INTRODUCCIÓN

La evapotranspiración de referencia ( $ET_0$ ), se calcula con la ecuación dada por Penman-Monteith, modificada por la Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO), de acuerdo a los lineamientos del boletín 56 de la FAO (Allen *et al.*, 1998), para ello es necesario conocer la temperatura, la humedad relativa (variable dependiente de la presión real de vapor de agua), la radiación global diaria, y la velocidad del viento. Sobreestimar la  $ET_0$  resulta en pérdidas de grandes cantidades de agua que repercuten en los rendimientos de los cultivos, y subestimarla redundaría en estrés hídrico para las plantas, por tanto se necesita conocer cuánto regar. La idea central de calendarizar el riego es predecir cuánto y cuando aplicar riego a los cultivos a lo largo de su ciclo fenológico, de aquí la importancia de estimar la  $ET_0$  con anticipación para programar el agua que será distribuida en las zonas de riego.

El concepto de neurona artificial se introdujo en 1943, pero es hasta últimas fechas cuando ha florecido la investigación en diversas aplicaciones debido a la introducción del algoritmo backpropagation feedforward (McCulloch and Pitts, 1943; Rumelhart *et al.*, 1986; Maier y Dandy, 2000). El cerebro es una computadora, en el sentido de ser un sistema que procesa información, altamente compleja, no lineal y de procesamiento paralelo; este tiene la capacidad de organizar a las neuronas de tal forma para ejecutar ciertas tareas (reconocimiento de patrones, percepción, control motor) muchas veces más rápidamente que la computadora digital más veloz en existencia (Haykin, 1994).

Zhang *et al.* (1998) definen a las redes neuronales artificiales (RNA) como métodos manejadores de datos (cuando existen suficientes) adaptados por sí mismos, en el sentido de que existen pocas suposiciones a priori sobre el modelo del problema bajo estudio; las RNA aprenden de los ejemplos y capturan relaciones funcionales sutiles entre los datos, aun si las relaciones subyacentes no son conocidas o difíciles de describir, y añade que en este sentido las RNA se tratan como un método estadístico multivariado no lineal y no paramétrico. Estas características representan ventajas que colocan a las RNA como un método de expectativa

## INTRODUCTION

Reference evapotranspiration ( $ET_0$ ) is calculated with the Penman-Monteith equation, modified by the Food and Agriculture Organization of the United Nations (FAO), according to the 56<sup>th</sup> Bulletin guidelines of the FAO (Allen *et al.*, 1998), this requires knowing the temperature, relative humidity (dependent variable of actual vapor pressure of water), daily global radiation and wind speed.  $ET_0$  overestimated results in loss of large amounts of water impacting on crop yields and underestimate it results in water-stressed plants, so it is necessary to know how much to irrigate. The central idea of irrigation scheduling is to predict how and when to apply irrigation to crops throughout the phenological cycle, hence the importance of previously estimate  $ET_0$  to schedule the water that will be distributed in irrigation areas.

The artificial neuron concept was introduced in 1943, but research has flourished in various applications until today, due to the feed forward back propagation algorithm introduction (McCulloch and Pitts, 1943; Rumelhart *et al.*, 1986; Maier and Dandy, 2000). The brain is a computer, in the sense of being a highly complex information processing system, nonlinear and parallel processing, it has the ability to organize neurons to perform certain tasks (pattern recognition, perception, motor control), many times faster than the fastest digital computer in existence (Haykin, 1994).

Zhang *et al.* (1998), define artificial neural networks (ANN) as data handling methods (when there are sufficient) adapted by themselves, in the sense that there are few a priori assumptions about the problem under study model, ANNs learn examples and capture subtle functional relationships among data, even if the underlying relationships are unknown or difficult to describe and adds that in this sense, ANNs are treated as a multivariate statistical method non-linear and nonparametric. These features represent advantages that put ANN as an expectative method to predict agroclimatic variables. Among the works carried out to estimate reference evapotranspiration with ANN are: Wang *et al.* (2008) and González-Camacho *et al.* (2008), who estimate  $ET_0$  with a feedforward backpropagation ANN.

Some of the proposed objectives for this work development are: to present theory and foundations of multilayer ANN with backpropagation algorithm, to define similarities and

para predecir variables agroclimáticas. Entre los trabajos realizados para estimar evapotranspiración de referencia con RNA se encuentran a Wang *et al.* (2008) y González-Camacho *et al.* (2008) que estiman la  $ET_0$ , de igual forma, con una RNA feedforward backpropagation.

Entre los objetivos que se plantearon para el desarrollo del presente trabajo fueron: presentar la teoría y fundamentos de las RNA multicapa con el algoritmo backpropagation; definir algunas similitudes y diferencias entre los modelos de series de tiempo, regresión lineal y las RNA; realizar una revisión de literatura de las aplicaciones de las RNA en la estimación de la  $ET_0$  y variables asociadas a ésta y determinar algunas de las perspectivas al futuro de las RNA en la predicción de variables meteorológicas.

### Teoría y fundamentos de las redes neuronales artificiales

Existen ciertos criterios que hay que definir en el proceso de aplicación de un modelo de red neuronal artificial para estimar alguna variable climatológica. Dicho proceso empieza a especificar el problema, para redes supervisadas tal como la red feedforward entrenada con el algoritmo backpropagation, significa la elección de un conjunto de vectores de entrada y un conjunto de vectores deseados de salida (Demuth *et al.*, 2008). Antes de entrenar la red se inicializan los pesos y sesgos al utilizar algún algoritmo, una vez hecho esto se está listo para el entrenamiento; la red es entrenada por una función de aproximación (regresión no lineal), patrón de asociación o patrón de clasificación, durante el entrenamiento los pesos y sesgos de la red son iterativamente ajustados para minimizar la función de desempeño de la red. La función de desempeño de la red feedforward típica para el entrenamiento de la RNA es el error medio cuadrado (MSE) o suma media del cuadrado de los errores, que se obtiene entre la salida de la red  $a$  y el target o valores observados  $t$  descrita por la Ecuación (1):

$$mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad 1)$$

Existen diferentes algoritmos de entrenamiento para las redes feedforward, todos usan el gradiente de la función de desempeño para determinar cómo ajustar los pesos y minimizar el desempeño, el gradiente se determina con una técnica llamada backpropagation, la cual implica llevar a cabo cálculos hacia atrás a través de la red. De igual manera existen variaciones de este algoritmo, la implementación más simple del aprendizaje es actualizar

differences between time series models, linear regression and ANN, making a literature review of ANN applications in  $ET_0$  estimation and associated variables and to determine some of the future prospects of ANN in meteorological variables prediction.

### Theory and foundations of artificial neural networks

There are certain criteria to be defined in the process of implementing an artificial neural network model to estimate some weather variable. This process begins to specify the supervised networks problem, such as feedforward network trained with backpropagation algorithm, it means choosing a set of input vectors and a set of desired output vectors (Demuth *et al.*, 2008). Before network training, weights and biases are initialized using an algorithm, once this is done, it is ready for training, network is trained by an approximation function (nonlinear regression), association pattern or classification pattern, during the network's weights and biases training are iteratively adjusted to minimize the role of network performance. The performance for typical feedforward network in ANN training, is the root mean square error (RMSE) or mean square sum of errors, obtained from the output of "a" network and target or "t" observed values described by Equation (1):

$$mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad 1)$$

There are different training algorithms for feedforward networks all of them use the performance function gradient to determine how to adjust weights and minimize performance, gradient is determined by a technique called backpropagation, which involves carrying out calculations backwards through the network. Similarly there are variations of this algorithm, the simplest implementation of learning is to update the network weights and biases in the direction in which the performance function decreases more quickly, which is the gradient negative, one iteration of this algorithm is:

$$w_{k+1} = w_k - \alpha_k g_k \quad 2)$$

Where:  $w_k$  is the current weights and biases vector,  $g_k$  is the current gradient;  $\alpha_k$  is the learning rate and more complex algorithm such as conjugate gradient, are derived to increase convergence speed of this part (Demut *et al.*, 2008).

los pesos de la red y los sesgos en la dirección en la cual la función de desempeño decrece más rápidamente, que es el negativo del gradiente, una iteración de este algoritmo es:

$$w_{k+1} = w_k - \alpha_k g_k \quad 2)$$

Donde:  $w_k$  es el vector de pesos y sesgos actual;  $g_k$  es el gradiente actual;  $\alpha_k$  es la tasa de aprendizaje, y algoritmo más complejo como los de gradiente conjugado, se derivan para incrementar la velocidad de convergencia de esta parte (Demut *et al.*, 2008).

El entrenamiento de la red neuronal puede hacerse más eficiente, si se llevan a cabo ciertos pasos de preprocesamiento sobre las entradas y salidas de la red. Las funciones de preprocesamiento de entrada y salida de la red, transforman dichos datos en una forma más adecuada para el entrenamiento y uso de la red, y la función reversa regresa las salidas transformadas a las características de los datos observados originales. Una de estas funciones es el escalamiento de las entradas y salidas de tal forma que éstas siempre caigan dentro de un rango específico, por ejemplo de (-1, 1), llamada normalización de los datos (Demuth *et al.*, 2008). Otro preprocesamiento es hacer que caigan dentro de una distribución normal o algún otro tipo de distribución estadística como afirma Maier y Dandy (2000).

El normalizar los datos resulta un paso esencial para el funcionamiento de la RNA; en algunas situaciones, la dimensión del vector de entradas es muy grande, y los componentes de los vectores están altamente correlacionados (redundantes), es útil en esta situación reducir la dimensión del vector de entradas. Un procedimiento para llevar a cabo esta operación es el análisis de componentes principales, donde se eliminan aquellos componentes que contribuyen con menos a la variación del conjunto de datos.

### Algoritmo backpropagation

La arquitectura correspondiente para el aprendizaje backpropagation, incorporando ambas fases hacia delante y hacia atrás de la computación implicada en el proceso de aprendizaje, se presenta en la Figura 1.

La red multicapa en la parte de arriba de la Figura 1 representa la fase hacia delante. La notación usada en esta parte es como sigue:  $w^{(l)}$  = vector de pesos sináptico de una neurona en la capa  $l$ ;  $\theta^{(l)}$  = umbral de una neurona en la capa  $l$ ;  $v^{(l)}$  = vector de los niveles de actividad interna de la red de las neuronas en la capa  $l$ ;  $y^{(l)}$  = vector de señales función de las neuronas en la capa  $l$ .

Neural network training can be more efficient if we make certain preprocessing steps on network's inputs and outputs. Preprocessing network's input and output functions, transform those data into a more suitable form for training and use of the network and reverse function returns the processed output to the characteristics of original observed data. One of these functions is the inputs and outputs scaling, so that they always fall within a specific range, for example (-1, 1), called data normalization (Demuth *et al.*, 2008). Another preprocessing is to make them fall within a normal distribution or some other statistical distribution as stated by Maier and Dandy (2000).

Normalizing data is an essential step for ANN functioning, in some situations, the dimension of inputs vector is very large and the vectors components are highly correlated (redundant), in this situation it is useful to reduce vector of inputs size. A procedure for performing this operation is the principal component analysis, which removes components that contribute less to the data set variation.

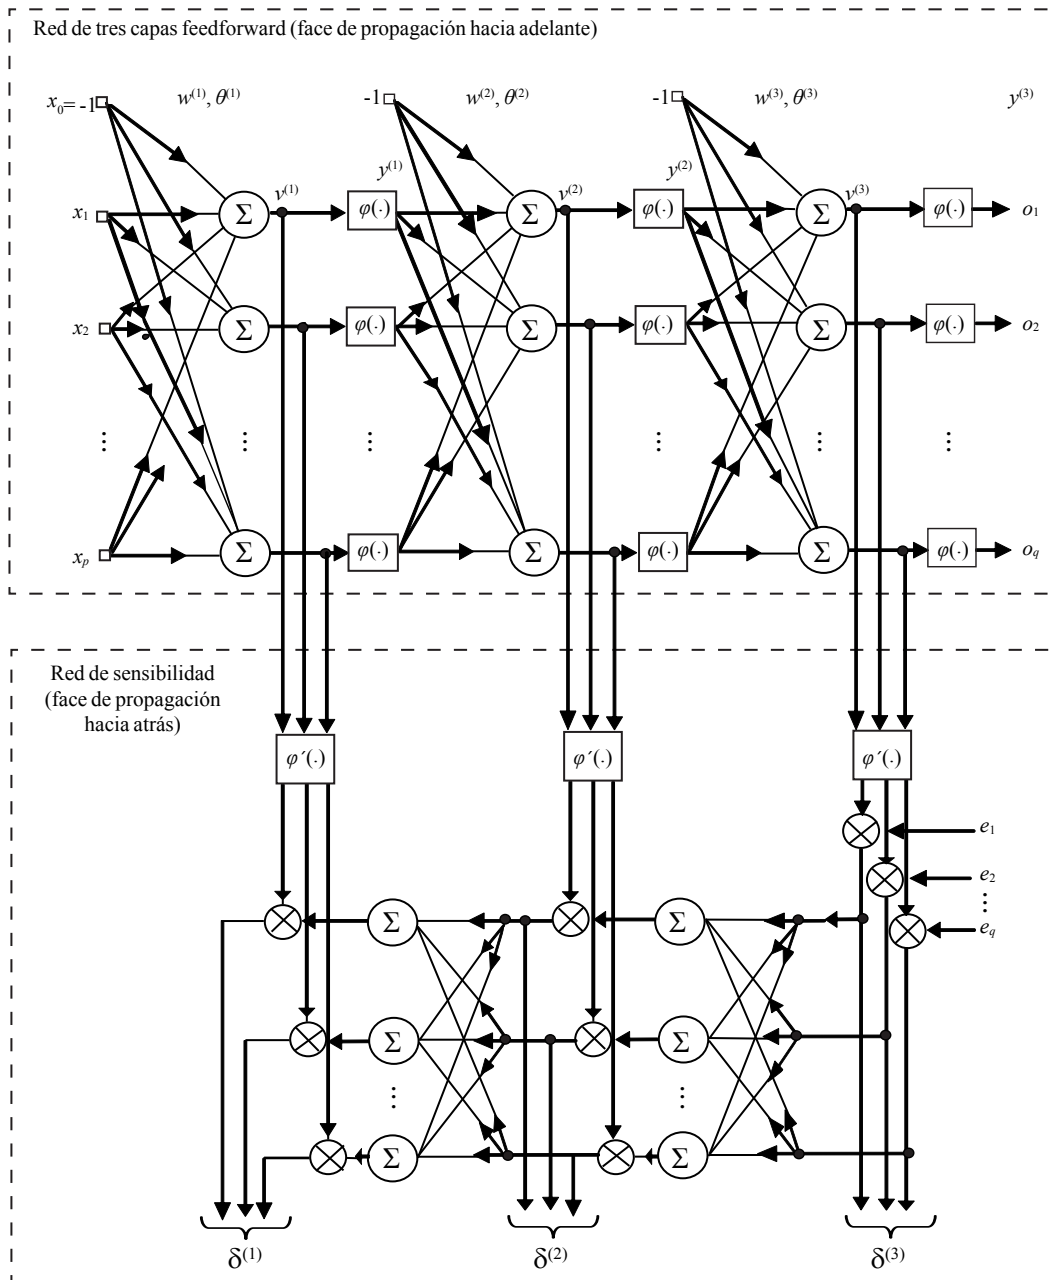
### Backpropagation algorithm

Architecture for backpropagation learning, incorporating both phases, forward and backward of involved computation in learning process is presented in Figure 1.

The multi-layered network in the top of Figure 1 represents the forward phase. Notation used in this part is as follows:  $w^{(l)}$  = synaptic weights vector of  $l$  layer neuron;  $\theta^{(l)}$  =  $l$  layer neuron threshold,  $v^{(l)}$  = activity levels within the  $l$  layer neural network vector,  $y^{(l)}$  = function signal of  $l$  layer neurons vector.

The  $l$  layer index, ranges from the input layer ( $l=0$ ) to the output layer ( $l=L$ ), in Figure 1 there is  $L=3$ , where  $L$  is the network depth. Lower part of Figure 1 represents backward phase, which is referred to as sensitivity network to calculate local gradients in backpropagation algorithm. Used notation in this second part is as follows:  $\delta^{(l)}$  = vector of local gradients of layer neurons  $l$ ,  $e$  = error vector represented by  $e_1, e_2, \dots, e_q$  as elements  $x_1, x_2, \dots, x_p$  = input variables;  $\phi(\cdot)$  = activation function.

While Figure 1 network is merely a layer of backpropagation algorithm architecture, it has substantial advantages in dynamic situations, where algorithmic representation begins to be bulky (Narendra and Parthasarathy, 1990). The updating of weights, pattern by pattern is the preferred



**Figura 1. Arquitectura de una red de tres capas feedforward y red de sensibilidad asociada (señales de error de propagación hacia atrás).**

**Figure 1. Architecture of a three-layer feedforward network and associated sensitivity network (error signals of backward propagation).**

El índice de la capa  $l$  incluye desde la capa de entrada ( $l=0$ ) a la capa de salida ( $l=L$ ); en la Figura 1 se tiene  $L=3$ ; donde  $L$  es la profundidad de la red. La parte baja de la Figura 1 representa la fase hacia atrás, la cual es referida como red de sensibilidad para calcular los gradientes locales en el algoritmo backpropagation. La notación usada en esta segunda parte es como sigue:  $\delta^{(l)}$ = vector de

method for online implementing of backpropagation algorithm. For this mode, the algorithm cycles through the training data  $\{[x(n),d(n)]; n = 1, 2, \dots, N\}$  as follows:

**Initialization.** Starts with a reasonable network configuration, place all synaptic weights and network's threshold levels for small random numbers that are evenly distributed.

gradientes locales de neuronas en la capa  $l$ ;  $e$ = el vector error representado por  $e_1, e_2, \dots, e_q$  como elementos  $x_1, x_2, \dots, x_p$ = variables de entrada;  $\phi(\cdot)$ = función de activación.

Mientras que la red de la Figura 1 es meramente una capa de la arquitectura del algoritmo backpropagation, se encuentra que tiene ventajas substanciales en situaciones dinámicas, donde la representación algorítmica comienza a ser voluminosa (Narendra and Parthasarathy, 1990). La actualización de pesos patrón por patrón es el método preferido para la implementación en línea del algoritmo backpropagation. Para este modo de operación, el algoritmo cicla a través de los datos de entrenamiento  $\{[x(n), d(n)]; n = 1, 2, \dots, N\}$  como sigue:

**Inicialización.** Empieza con una configuración de red razonable, y coloca todos los pesos sinápticos y niveles de umbral de la red, para pequeños números aleatorios que están uniformemente distribuidos.

**Presentación de ejemplos de entrenamiento.** Presenta la red con una época de ejemplos de entrenamiento. Para cada ejemplo en el conjunto ordenado en alguna forma, ejecutan la siguiente secuencia de cálculos hacia delante y hacia atrás bajo los puntos c y d, respectivamente.

**Cálculos hacia delante.** Sea un ejemplo de entrenamiento en la época denotado por  $[x(n), d(n)]$ , con el vector de entrada  $x(n)$  aplicados a la capa de entrada de los nodos sensores y el vector de respuestas deseado  $d(n)$ , presentado a la capa de salida de los nodos computados. Calcule los potenciales de activación y las señales función de la red procediendo hacia delante a través de la red, capa por capa. El nivel de actividad interno de la red  $v_j^{(l)}(n)$  para la neurona  $j$  en la capa  $l$  es:

$$v_j^{(l)}(n) = \sum_{i=0}^p w_{ij}^{(l)}(n) y_i^{(l-1)}(n) \quad (3)$$

Donde:  $y_i^{(l-1)}(n)$  = señal función de la neurona  $i$  en la capa previa  $l - 1$  en la iteración  $n$ ;  $w_{ji}^{(l)}(n)$  = peso sináptico de la neurona  $j$  en la capa  $l$  que es alimentado de la neurona  $i$  en la capa  $l - 1$ . Para  $i = 0$ , se tiene  $y_0^{(l-1)}(n) = -1$  y  $w_{j0}^{(l)}(n) = \theta_j^{(l)}(n)$ ; donde:  $\theta_j^{(l)}(n)$  = umbral aplicado a la neurona  $j$  en la capa  $l$ . Suponiendo el uso de una función logística para la no linealidad sigmoidea, la función señal (salida) de la neurona  $j$  en la capa  $l$  es:

$$y_j^{(l)}(n) = \frac{1}{1 + \exp(-v_j^{(l)}(n))} \quad (4)$$

**Presentation of training examples.** Present network with a time of training examples. For each example in the ordered set, perform the following calculations sequence forwards and backwards under c and d points, respectively.

**Forward calculations.** An example of training at denoted time by  $[x(n), d(n)]$ , with the input vector  $x(n)$  applied to input layer of sensor nodes and desired response vector  $d(n)$ , presenting to output layer of computed nodes. Calculate activation potentials and network's function signals proceeding forward through the network, layer by layer. The  $v_j^{(l)}$  network's internal activity level for  $j$  neuron in  $l$  layer is:

$$v_j^{(l)}(n) = \sum_{i=0}^p w_{ij}^{(l)}(n) y_i^{(l-1)}(n) \quad (3)$$

Where:  $y_i^{(l-1)}(n)$  = function signal of  $i$  neuron in previous layer  $l - 1$  at  $n$  iteration;  $w_{ji}^{(l)}(n)$  = synaptic weight of  $j$  neuron in  $l$  layer  $l$  that is fed from  $i$  neuron in layer  $l - 1$ . For  $i = 0$ , we have  $y_0^{(l-1)}(n) = -1$  and  $w_{j0}^{(l)}(n) = \theta_j^{(l)}(n)$  where:  $\theta_j^{(l)}(n)$  = threshold applied to  $j$  neuron in  $l$  layer. Assuming the use of a logistic function for nonlinearity sigmoid, the signal function (output) of  $j$  neuron in  $l$  layer is:

$$y_j^{(l)}(n) = \frac{1}{1 + \exp(-v_j^{(l)}(n))} \quad (4)$$

If  $j$  neuron is on the first hidden layer ( $l = 1$ ), we put:

$$y_j^{(0)}(n) = x_j(n) \quad (5)$$

Where:  $x_j(n)$  =  $j$ -th element of input vector  $x(n)$ . If  $j$  neuron is in the output layer ( $l = L$ ), we put:

$$y_j^{(L)}(n) = o_j(n) \quad (6)$$

Hence, we calculate error signal:

$$e_j(n) = d_j(n) - o_j(n) \quad (7)$$

Where:  $d_j(n)$  =  $j$ -th element of desired response vector  $d(n)$ ,  $o_j(n)$  is the  $j$ -th network output.

**Backwards computing.** To calculate  $\delta$ 's (local gradients) of the network by proceeding backward, layer by layer, to  $j$  neuron in  $L$  output layer, we have:

$$\delta^{(L)}(n) = e_j^{(L)}(n) o_j(n) [1 - o_j(n)] \quad (8)$$

For  $j$  neuron in  $l$  hidden layer:

$$\delta_j^{(l)}(n) = y_j^{(l)}(n) [1 - y_j^{(l)}(n)] \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad (9)$$

Si la neurona  $j$  está en la primera capa oculta (esto es,  $l = 1$ ), se coloca:

$$y_j^{(0)}(n) = x_j(n) \quad (5)$$

Donde:  $x_j(n)$  =  $j$ -ésimo elemento del vector de entradas  $x(n)$ . Si la neurona  $j$  está en la capa de salida (esto es  $l = L$ ), se coloca:

$$y_j^{(L)}(n) = o_j(n) \quad (6)$$

De aquí, se calcula la señal de error:

$$e_j(n) = d_j(n) - o_j(n) \quad (7)$$

Donde:  $d_j(n)$  =  $j$ -ésimo elemento de el vector de respuestas deseado  $d(n)$ ,  $o_j(n)$  es la  $j$ -ésima salida de la red.

**Computo hacia atrás.** Calcular los  $\delta$ 's (gradientes locales) de la red procediendo hacia atrás, capa por capa; para la neurona  $j$  en la capa de salida  $L$  se tiene:

$$\delta_j^{(L)}(n) = e_j^{(L)}(n) o_j(n) [1 - o_j(n)] \quad (8)$$

Para la neurona  $j$  en la capa oculta  $l$ :

$$\delta_j^{(l)}(n) = y_j^{(l)}(n) [1 - y_j^{(l)}(n)] \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad (9)$$

De aquí, se ajustan los pesos sinápticos de la red en la capa  $l$  de acuerdo a la regla delta generalizada:

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n) - w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (10)$$

Donde:  $\eta$  = parámetro tasa de aprendizaje y  $\alpha$  es la constante momento.

**Iteración.** Iteración de la computación presentando nuevas épocas de entrenamiento a la red, hasta que los parámetros libres de la red estabilicen sus valores y el error medio cuadrado  $\varepsilon_{av}$  calculado sobre el conjunto entero de entrenamiento esté en el mínimo o un valor pequeño aceptable. El orden de presentación de los ejemplos de entrenamiento debería aleatorizarse de época en época. El momento y el parámetro tasa de aprendizaje son ajustados típicamente (usualmente decrecen) tanto como el número de iteraciones de entrenamiento se incrementan (Haykin, 1994).

From here, we adjust synaptic weights of network in  $l$  layer according to generalized delta rule:

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n) - w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (10)$$

Where:  $\eta$  = learning rate parameter and  $\alpha$  is the moment constant.

**Iteration.** Iteration computing, presenting new times of network training until network's free parameters stabilize their values and mean square error  $\varepsilon_{av}$ , calculated on the entire training set, is the minimum or a small acceptable value. The presentation order of training examples should be randomized from time to time. The time and learning rate parameters are typically adjusted (usually decreased) as well as the number of training iterations increased (Haykin, 1994).

### Similarities and differences between traditional statistical models and artificial neural networks

Difference between artificial intelligence techniques (AI) and traditional statistics, it is not from class but grade, says Marzban (2009). Is said that most of the techniques belonging to a continuum and different techniques have different belonging degrees, either artificial intelligence or statistics (Marzban, 2009).

Comparison of artificial neural networks with statistical part and specifically with time series has led to various studies and activities (Hill *et al.*, 1994; Hsieh and Tang, 1998). Marzban (2009), states that neural networks are just another regression and classification tool. On perceptron multilayer model, in equation terms, is just a generalization of regression equation:  $y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p = \alpha + \sum_{i=1}^p \beta_i x_i$ . Terms  $\theta$  and  $\omega$  (Equation 11) are analogous to  $\alpha$  and  $\beta$  in the regression equation, with the network parameters:

$$y(x, \omega, H) = g \left( \sum_{i=1}^H \omega_i f \left( \sum_{j=1}^{N_{in}} \omega_{ij} x_j - \theta \right) \right) \quad (11)$$

Analogous representation of Equation 11, is shown in Figure 2, this network is referred as multilayer perceptron, with  $N_{in}$  input nodes ( $x_i$ ), an output node ( $y$ ) and a hidden layer of weights or equivalently a hidden layer of nodes ( $hi$ ), where  $H$  is the hidden number of nodes and plays the role of polynomial regression order. In equation 11  $f(x)$  and  $g(x)$  are called activation functions, pre-specified functions; its job is to transform the  $x_j$  predictors.

**Similitudes y diferencias entre los modelos estadísticos tradicionales y las redes neuronales artificiales**

La diferencia entre las técnicas de inteligencia artificial (IA) y la estadística tradicional no es de clase pero si de grado afirma Marzban (2009). Se dice que la mayoría de las técnicas pertenecen a un continuo, y diferentes técnicas tienen diferentes grados de pertenencia ya sea a la inteligencia artificial o a la estadística (Marzban, 2009).

La comparación de las redes neuronales artificiales con la parte estadística y específicamente con las series de tiempo ha originado diversos estudios y actividades (Hill *et al.*, 1994; Hsieh y Tang, 1998). Marzban (2009) afirma que las redes neuronales son otra herramienta de regresión y clasificación, y acerca del modelo multicapa perceptrón, en términos de una ecuación, este es simplemente una generalización de la ecuación de regresión:  $y = \alpha + \beta_1x_1 + \beta_2x_2 + \dots + \beta_px_p = \alpha + \sum_{i=1}^p \beta_i x_i$ . Los términos  $\theta$  y  $\omega$  (ecuación 11) son análogos a  $\alpha$  y  $\beta$  en la ecuación de regresión, siendo los parámetros de la red:

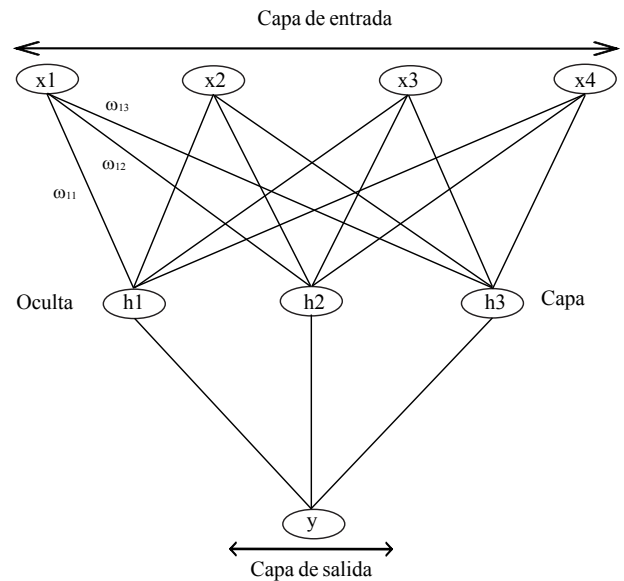
$$y(x, \omega, H) = g \left( \sum_{i=1}^H \omega_i f \left( \sum_{j=1}^{N_m} \omega_{ij} x_j - \theta_i \right) \right) \tag{11}$$

La representación que es análoga a la Ecuación 11 se muestra en la Figura 2, esta red es referida como multicapa perceptrón, con  $N_{in}$  nodos de entrada ( $x_i$ ), un nodo de salida ( $y$ ) y una capa oculta de pesos o equivalentemente una capa oculta de nodos ( $h_i$ ) donde  $H$  es el número de nodos ocultos y éste juega el rol del orden de la regresión polinomial. En la ecuación 11  $f(x)$  y  $g(x)$  son las llamadas funciones de activación, funciones preespecificadas, su trabajo es transformar los predictores  $x_j$ .

Demuth *et al.* (2008) indican que dos elecciones comunes de estas funciones son  $\tanh(x) = 2/(1+e^{-2*x})-1$  y  $\text{logsig}(x) = 1/(1+e^{-x})$ . Marzban (2009) indican también que es análoga a una serie de Fourier; es decir, una serie de tiempo puede ser escrita como una suma de un conjunto de senos y cosenos (serie de Fourier). La analogía con el perceptrón multicapa es que cualquier función es escrita como una combinación lineal de un conjunto de funciones sigmoideas (Marzban, 2009):

$$y_i = \alpha_0 + \sum_{j=1}^n \alpha_j f \left( \sum_{i=1}^m \beta_{ij} y_{i-1} + \beta_{0j} + \epsilon_i \right) \tag{12}$$

Con respecto al preprocesamiento de los datos que se realiza en la estadística tradicional, específicamente con las series de tiempo y comparándolo con las RNA, la mayoría de



**Figura 2. Una RNA multicapa perceptrón con cuatro nodos de entrada, tres nodos ocultos y un nodo en la capa de salida.**

**Figure 2. A multilayer perceptron ANN with four input nodes, three hidden nodes and a node in the output layer.**

Demuth *et al.* (2008), indicate that two common choices of these functions are  $\tanh(x) = 2/(1+e^{-2*x})-1$  and  $\text{logsig}(x) = 1/(1+e^{-x})$ . Marzban (2009) also indicates that is analogous to a Fourier series, i.e., a time series can be written as a sum of sines and cosines set (Fourier series). Analogy with multilayer perceptron, is that any function is written as a linear combination of a sigmoid functions set (Marzban, 2009):

$$y_i = \alpha_0 + \sum_{j=1}^n \alpha_j f \left( \sum_{i=1}^m \beta_{ij} y_{i-1} + \beta_{0j} + \epsilon_i \right) \tag{12}$$

Respect to data preprocessing used in traditional statistics, specifically time series and comparing with ANN, most of time series exhibit trend and seasonal variations, seasonality is a regular and recurring pattern caused by various factors (Zhang and Qi, 2005). Traditional approaches for modeling time series, remove seasonal variations as it does by the classic decomposition method, which first decomposes time series into trend, seasonality, cycle and irregular components and remove those components, as well as certain activities are performed in data series to apply the time series model. There is a discussion about whether before applying ANN model; there must be removed seasonality and data trend, prior to training to make a best fit forecast. Zhang and Qi (2005),



las series de tiempo exhiben variaciones de tendencia y estacionalidad, la estacionalidad es un patrón periódico y recurrente causado por diversos factores, (Zhang y Qi, 2005). Los planteamientos tradicionales para modelar series de tiempo remueven las variaciones estacionales como lo realiza el método clásico de descomposición que primero, descompone la serie de tiempo en tendencia, estacionalidad, componentes ciclos e irregulares y remueve dichos componentes, así como se realizan ciertas actividades en una serie de datos para aplicar el modelo de series de tiempo, existe discusión, sobre si antes de aplicar el modelo de RNA, se debe quitar estacionalidad y tendencia a los datos, priori al entrenamiento para realizar un pronóstico de mejor ajuste. Zhang y Qi, (2005) afirman con sus resultados que las RNA no son capaces directamente de modelar la estacionalidad, y es deseable remover este componente de los datos antes del entrenamiento para obtener mejor desempeño.

### **Aplicaciones de las RNA en la estimación de la evapotranspiración de referencia y variables meteorológicas relacionadas**

Entre los servicios que proporciona una estación meteorológica están las predicciones de corto periodo de lluvias para pronóstico de inundaciones y operaciones de suministro de agua, pronósticos estacionales para sequía y aplicaciones en la agricultura, éstos se han hecho con modelos numéricos, que típicamente resuelven ecuaciones tridimensionales para conservación de masa, momento y energía en la atmósfera y como Schoof and Prior (2001) afirman el pronóstico de rendimientos futuros en la agricultura requiere explícita atención a la variabilidad climática.

Otro tipo de modelo para pronóstico es las redes neuronales artificiales, objeto de estudio de este trabajo. Entre los diversos trabajos de investigación que se han hecho para resolver problemas que tienen que ver con la meteorología en el campo de la agricultura con redes neuronales, existen los trabajos para pronóstico y estimación de temperaturas, radiación global, humedad relativa, presión real de vapor de agua y evapotranspiración de referencia.

Conocer la humedad relativa resulta importante para el control de enfermedades en los cultivos, en las operaciones poscosecha en almacenamiento y en el transporte de los productos agrícolas; por ejemplo, en las cámaras de atmósferas controladas se supone que la humedad relativa sea alta (Corrales *et al.*, 1991), esta variable se encuentra ligada a la presión real de vapor de agua, importante como

argue with their results that ANNs can not directly model seasonality and it is desirable to remove this data component before improved performance training.

### **Applications of ANN in reference evapotranspiration estimating and related meteorological variables**

Among the services provided by a weather station, there are the predictions of short period rains to flood forecasting and water supply operations, seasonal forecasts for drought and agricultural applications, these have been made with numerical models that typically resolve three-dimensional equations for mass conservation, momentum and atmosphere's energy as Schoof and Pryor (2001) declare, the forecast of future returns in agriculture requires explicit attention to climate variability.

Another type of forecasting model is the artificial neural networks which are the object of this study. Among various research papers that have been made to solve problems about the weather of agriculture field with neural networks, there are jobs for forecasting and temperatures estimating, global radiation, relative humidity, actual pressure of water vapor and reference evapotranspiration.

Knowing the relative humidity is important for disease control in crops, post-harvest operations, storage and agricultural products transportation, for example, in controlled atmosphere chambers is assumed that relative humidity is high (Corrales *et al.*, 1991), this variable is linked to the actual pressure of water vapor, important as input parameter in crops modeling. Global radiation is the main energy source in many physical and biochemical processes (one of them is evapotranspiration) that are carried out on land (Meza and Varas, 2000; Podesta *et al.*, 2004).

During this work development, we found various studies with ANN for  $ET_0$  estimating, as well as necessary variables for its calculation in accordance with FAO's 56<sup>th</sup> bulletin (Allen *et al.*, 1998), only some of these work are shown in Table 1. It is noted that one of the most commonly used ANN architectures is multilayer feedforward backpropagation, even more than the recurrent or Hopfield. Transfer functions that were used due to their successful estimation of  $ET_0$  are the sigmoid function, the logistic sigmoid and radial basis function, that have also given successful results in global radiation

parámetro de entrada en la modelación de cultivos. La radiación global es fuente de energía principal en muchos procesos físicos y bioquímicos (uno de estos procesos es la evapotranspiración) que se llevan a cabo sobre la tierra (Meza and Varas, 2000; Podestá *et al.*, 2004).

En el desarrollo del presente trabajo se encontraron diversos trabajos con RNA para estimar la  $ET_0$ , así también como las variables necesarias para su cálculo, de acuerdo con el boletín 56 de FAO (Allen *et al.*, 1998), sólo algunos de estos trabajos se muestran en el Cuadro 1; se puede observar que una de las arquitecturas de RNA más comúnmente usada es la multicapa feedforward backpropagation, más usada aun que la recurrente o Hopfield; las funciones de transferencia que se han usado, porque han dado buenos resultados en la estimación de la  $ET_0$ , es la función sigmoidea, la logística sigmoidea y la radial basis function; en la estimación de la radiación global ha dado buenos resultados estas mismas funciones de transferencia, y en la estimación de la temperatura ha funcionado la sigmoidea y la función gaussiana, hay que destacar que algunos autores no reportan la función que usaron.

La estimación que se ha hecho para las diferentes variables ha sido a nivel mensual, diario, horario y a 5 y 10 min probando la capacidad de pronóstico de las RNA. Finalmente entre los índices estadísticos que se han usado para evaluar el desempeño de las RNA, se encontraron que las más comunes son la raíz cuadrada del cuadrado medio del error o error promedio (RMSE) y el coeficiente de determinación ( $R^2$ ), siguen en orden de importancia, el error medio sesgado (MBE), el porcentaje de error medio absoluto (MAPE) y el error cuadrado medio (MSE); los menos comunes son el error relativo, error absoluto y coeficiente de variación. Se observa que por ejemplo, en el campo de la humedad relativa no existen muchos trabajos para estimarla con RNA, de igual forma sucede con la presión real de vapor de agua, y con la velocidad del viento.

### **Perspectivas de las RNA en la predicción de variables agroclimáticas**

En el presente la red neuronal multicapa estática todavía es el sistema de modelado y método de predicción popular en las aplicaciones para estimar variables agrometeorológicas y otras. Usar la red neuronal multicapa forward estática para establecer un modelo entrada/salida, esencialmente es conocer la posición de la función no lineal en el sistema de ecuaciones diferenciales basado en el aprendizaje de la

estimación and for temperature estimate it has worked the sigmoid and the Gaussian function, it is noteworthy that some authors do not report the function they used.

The estimate that has been done for different variables has been monthly, daily, per hour and 5 and 10 minutes, testing the predictive capacity of ANNs. Finally among statistical indices that have been used to evaluate the performance of ANNs, it has been found that the most common are the square root of the mean square error or mean error (RMSE) and determination coefficient ( $R^2$ ), followed by: the mean bias error (MBE), the mean absolute percentage error (MAPE) and mean square error (MSE), less common are the relative error, absolute error and coefficient of variation. It is noted that for example in terms of relative humidity there are not many papers to estimate it with ANN, just as happens with the actual pressure of water vapor and wind speed.

### **Prospects of ANNs in the prediction of agroclimatic variables**

In the present, the static multilayer neural network is still the popular modeling and prediction method system in applications to estimate agrometeorological variables and others. Using the static forward multilayer neural network to establish an input/output model, is essentially to know the position of nonlinear function in the system of differential equations based on the learning of the proposed ability of the network. Forward multilayer neural network can obtain good results in predicting the modeling of static systems.

In practice the system that needs to be modeled and predicted, most of the time is a nonlinear dynamic time-varying system, where no one knows the position of nonlinear function, then to use the feedback dynamic network to continue the system modeling and prediction, can be the solution and it is important in practical application. This represents the trend in neural network modeling and prediction. Mainly due to the dynamic network itself is a dynamic time-varying system, concerning to the modeling of dynamic system, it has the natural ability to reflect the change in system dynamics and it does not need to locate the type and order of system model previously (Ding *et al.*, 2008).

Current research in ANN, focus mainly on improvements on the model basis, they fall into four areas: parameters selection, algorithms, activation function

**Cuadro 1. Topología de las RNA usadas para pronóstico de variables meteorológicas relacionadas con la agricultura.**  
**Table 1. Topology of ANNs used to forecast meteorological variables related to agriculture.**

Núm.	Autor(es)	Estructura de RNA	Función de transferencia	Variable estimada	Tipo de dato	Índices estadísticos
1	López <i>et al.</i> (2001)	Multicapa perceptrón feedforward	Función sigmoidea	Radiación fotosintéticamente activa (PAR)	Hora	R <sup>2</sup> , RMSE, MBE
2	Elminir <i>et al.</i> (2005)	Multicapa con el algoritmo backpropagation	Sigmoidea	Insolación en diferentes bandas espectrales	Diaria	RMSE, MBE, r
3	Elizondo <i>et al.</i> (1994)	Multicapa feedforward con el algoritmo backpropagation	-	Radiación solar	Diaria	RMSE, R <sup>2</sup> , CV, Error absoluto
4	Rehman y Mohandes (2008)	Red feedforward de tres capas, con el algoritmo backpropagation	Función logística	Radiación solar global	Diaria	RMSE, MAPE
5	Benghanem <i>et al.</i> (2009)	Feedforward con el algoritmo de entrenamiento backpropagation	-	Radiación solar global	Diaria	MPE, RMSE, MBE, r
6	Alawi y Hinai (1998)	Multicapa feedforward con el algoritmo backpropagation	-	Radiación global	Mensual	R <sup>2</sup> , MAPE
7	Sfetsos y Coonick (2000)	Feedforward con algoritmo de entrenamiento backpropagation y Leveberg Marquardt. <i>Basis radial fuction</i> y Elman recurrente	Logística o tangente hiperbólica Función de base radial	Radiación solar	Horario	RMSE, MBE
8	Lam <i>et al.</i> (2008)	Perceptrón multicapa feedforward backpropagation	Función logística sigmoidea	Radiación solar global	Diario	RMSE, MBE
9	Mohandes <i>et al.</i> (1998)	Feedforward de dos capas con el algoritmo backpropagation	Sigmoidea	Radiación solar global	Mensual	MAPE
10	Mohandes <i>et al.</i> (2000)	Multicapa perceptrón y función de base radial	Sigmoidea, gaussiana	Radiación solar	Mensual	MAPE
11	Khoob (2008)	Perceptrón multicapa con algoritmo backpropagation.	Logística sigmoidea	Evapotranspiración de referencia	Mensual	R <sup>2</sup> , RMSE, R
12	Chauhan y Shrivastava (2009)	Feedforward multicapa con algoritmo backpropagation.	-	Evapotranspiración de referencia	Mensual	SEE, E, RSEE
13	Kumar <i>et al.</i> (2002)	Multicapa con algoritmo backpropagation	Sigmoidea	Evapotranspiración de referencia	Diario	WSEE, SEE
14	Trajnovic <i>et al.</i> (2003)	Radial basis function usando un filtro de Kalman	Gaussiana	Evapotranspiración de referencia	Mensual	MAE, MSE
15	Kumar <i>et al.</i> (2008)	Multicapa con algoritmo backpropagation	Sigmoidea	Evapotranspiración de referencia	Diario	WSEE, SEE, r

R<sup>2</sup>= coeficiente de determinación; RMSE= raíz cuadrada del cuadrado medio del error; MBE= error medio sesgado; r= coeficiente de correlación; CV= coeficiente de variación; MAPE= mean absolute percentage error; MSE= error cuadrado medio; SEE= error estándar estimado; E= eficiencia del modelo; RSEE= raw standard error estimated; WSEE= error estándar ponderados de la estimación; MAE= error medio absoluto; MPE= porcentaje de error medio; R= razón entre las medias estimadas de ET<sub>0</sub> y las observadas.

**Cuadro 1. Topología de las RNA usadas para pronóstico de variables meteorológicas relacionadas con la agricultura (Continuación).****Table 1. Topology of ANNs used to forecast meteorological variables related to agriculture (Continuation).**

Núm.	Autor(es)	Estructura de RNA	Función de transferencia	Variable estimada	Tipo de dato	Índices estadísticos
16	Sudheer <i>et al.</i> (2003)	Radial basis function (RBF)	RBF	Evapotranspiración de referencia	Diario	r, SEE, E
17	Landeras <i>et al.</i> (2008)	Multicapa perceptrón con el algoritmo backpropagation	-	Evapotranspiración de referencia	Diario	MBE, MAE, RMSE
18	Kim y Kim (2008)	RNA de regresión generalizada, forma modificada de la RBF	Kernel Gaussiana	Evaporación y evapotranspiración	Diario	RMSE, r, E
19	Chevalier <i>et al.</i> (2010)	Red aprendizaje supervisada, maquina de vector soporte	Logística	Temperatura del aire	Horaria	MAE
20	Maqsood <i>et al.</i> (2004)	Multicapa perceptrón, Elman recurrente, <i>radial basis function</i> , modelo Hopfield	-	Temperatura, velocidad del viento y humedad relativa	Horaria	MSE, RMSE, r, MAPE
21	Shank <i>et al.</i> (2008a, b)	Multicapa con el algoritmo backpropagation	Gaussiana, gaussiana complemento, tangente hiperbólica, logística	Temperatura del punto de rocío	Horaria	R <sup>2</sup> , MAE
22	Mittal y Zhang (2003)	Multicapa	Gaussiana, gaussiana complemento, tangente hiperbólica	Temperatura del punto de rocío, temperatura de bulbo húmedo, entalpía, radio de humedad, volumen específico y humedad relativa	Diario	Error relativo, Error absoluto
23	Schoof y Pryor (2001)	Multicapa, algoritmo backpropagation	Sigmoidea	Temperatura y precipitación	Mensual	MSE, MAE
24	Salazar <i>et al.</i> (2010)	Multicapa	-	Temperatura, CO <sub>2</sub>	5 y 10 minutos	MSE

R<sup>2</sup>= coeficiente de determinación; RMSE= raíz cuadrada del cuadrado medio del error; MBE= error medio sesgado; r= coeficiente de correlación; CV= coeficiente de variación; MAPE= mean absolute percentage error; MSE= error cuadrado medio; SEE= error estándar estimado; E= eficiencia del modelo; RSEE= raw standard error estimated; WSEE= error estándar ponderados de la estimación; MAE= error medio absoluto; MPE= porcentaje de error medio; R= razón entre las medias estimadas de ET<sub>o</sub> y las observadas.

habilidad propuesta de la red. La red neuronal multicapa forward puede obtener buenos resultados en la predicción de la modelación de sistemas estáticos.

En la práctica el sistema que necesita ser modelado y predicho, la mayoría de las veces es un sistema dinámico no lineal variable en el tiempo, y donde no se conoce la posición de la

and network's structure. Optimization algorithms can be of conjugate gradient, Quasi-Newton, Levenberg-Marquardt, among others, these algorithms improve the convergence speed of the network and waste storage space, then research is also aimed to algorithms improving to avoid waste of storage space (Ding *et al.*, 2008).

función no lineal entonces usar la red dinámica feedback, para continuar el modelado y predicción del sistema puede ser la solución, y se toma en serio en la aplicación práctica, esto representa la tendencia en la modelación de redes neuronales y predicción. Esto es principalmente debido a que la red dinámica en sí misma, es un sistema dinámico variante en el tiempo, referente al modelado del sistema dinámico, éste tiene la habilidad natural para reflejar el cambio en la dinámica del sistema, y éste no necesita ubicar el tipo y el orden del modelo del sistema por adelantado (Ding *et al.*, 2008).

La investigación actualmente en RNA principalmente se hace en mejoramientos sobre la base del modelo, éstos se engloban en cuatro aspectos: selección de parámetros, algoritmos, función de activación y estructura de la red. Los algoritmos de optimización pueden ser de gradiente conjugado, Quasi-Newton, Levenberg-Marquardt, entre otros; no obstante, estos algoritmos mejoran la velocidad de convergencia de la red, ellos desperdician espacio de almacenamiento, entonces la investigación también está encaminada a la mejora de los algoritmos para no desperdiciar dicho espacio de almacenamiento (Ding *et al.*, 2008).

## CONCLUSIONES

Las redes neuronales tienen un amplio prospecto de desarrollo junto con el progreso de la teoría básica y la madurez, tanto de la tecnología informática como el desarrollo teórico de las redes neuronales. Las aplicaciones con RNA, irán extendiéndose cada vez más en el campo de la agrometeorología. Se espera un auge en el campo basado sobre la superioridad especial de las redes neuronales, específicamente del tipo dinámico en el procesamiento de problemas no lineales, como la  $ET_0$  y variables asociadas.

La comparación del preprocesamiento de los datos para pronóstico con RNA y con modelos de serie de tiempo, muestra que ambos tipos de pronóstico necesitan previamente procesar los datos, y al modelar con una red neuronal artificial, se requiere renovar el componente de estacionalidad y tendencia, para la exactitud del pronóstico.

En el campo de las variables climáticas aplicadas a la agricultura, es donde se vislumbra el futuro que seguirá la investigación, con aplicaciones de redes neuronales artificiales en forma dinámica.

## CONCLUSIONS

Neural networks have a broad prospect of development with the progress of basic theory and maturity of both information technology and theoretical development of neural networks. Applications with ANN, will cover more in the agrometeorology field. It is expected a boom in field, based on the especial superiority of neural networks, specifically the dynamic type in the processing of nonlinear problems, as the  $ET_0$  and associated variables.

Comparison of data preprocessing to forecast with ANN and time series models, shows that both forecast types previously need to process the data and modeling with an artificial neural network requires to renew the seasonal and tendency component to forecast accuracy.

In the field of climatic variables applied to agriculture, is where the future of investigation will be, with applications artificial neural network dynamically.

*End of the English version*



## LITERATURA CITADA

- Alawi, S. M. and Hinai, H. A. 1998. An ANN-based approach for predicting global radiation in locations with no direct measurements instrumentation. *Renewable Energy*. (14):199-204.
- Allen, R. G.; Pereira, S. L.; Raes, D. and Smith, M. 1998. Crop evapotranspiration guidelines for computing crop water requirements. FAO Irrigation and drainage paper 56. Roma. 29-86 pp.
- Benghanem, M.; Mellit, A. and Alamri, S. N. 2009. ANN-based modeling and estimation of daily global solar radiation data: A case study. *Energy Conversion Manage.* (50):1644-1655.
- Chauhan, S. and Shrivastava, R. K. 2009. Performance evaluation of reference evapotranspiration estimation using climate based methods and artificial neural networks. *Water Resour. Manage.* (23):825-837.

- Chevalier, R. F.; Hoogenboom, G.; McClendon, R. W. and Paz, J. A. 2010. Support vector regression with reduced training sets for air temperature prediction: a comparison with artificial neural networks. *Neural computing & applications*.
- Corrales, G. J. E.; Hernández, M. J. y Gómez, V. R. 1991. *Uso comercial de las atmósferas controladas en México*. Universidad Autónoma Chapingo. FIRA-Banco de México. 51 p.
- Demuth, H.; Beale, M. and Hagan, M. 2008. *Neural network toolbox™ 6. User's guide*. 907 p.
- Ding, S.; Jia, W.; Su, Ch.; Zhang, L. and Shi, Z. 2008. Neural network research progress and applications in forecast. *In: Sun et al.*, (eds.). Springer -Verlag Berlin Heidelberg. 783-793 pp.
- Elizondo, D.; Hoogenboom, G. and McClendon, R. W. 1994. Development of a neural network model to predict daily solar radiation. *Agric. For. Meteorol.* (71):115-132.
- Elminir, H. K.; Areed, F. F. and Elsayed, T. S. 2005. Estimation of solar radiation components incident on Helwan site using neural networks. *Sol. Energy.* (79):270-279.
- González-Camacho, J. M.; Cervantes-Osornio, R.; Bustamante-Ojeda, W. y López-Cruz, I. L. 2008. Predicción de la evapotranspiración de referencia mediante redes neuronales artificiales. *Ingeniería hidráulica en México*. (23):127-138.
- Haykin, S. S. 1994. *Neural Networks. A comprehensive foundation*. MacMaster MacMillan Publishing Company, University, Hamilton, Ontario Canada. 696 p.
- Hill, T.; Marquez, L.; O'Connor, M. and Remus, W. 1994. Artificial neural network models for forecasting and decision making. *Int. J. forecasting.* (10):5-15
- Hsieh, W. W. and Tang, B. 1998. Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin of the American Meteorological Society.* 9(79):1855-1870.
- Khoob, A. R. 2008. Comparative study of Hargreave's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. *Irrig. Sci.* (26):253-259.
- Kim, S. and Kim, H. S. 2008. Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling. *J. hydrol.* (351):299-317.
- Kumar, M.; Raghuwanshi, N. S.; Singh, R.; Wallender, W. W. and Pruitt, W. O. 2002. Estimating evapotranspiration using artificial neural network. *J. Irrig. drainage eng.* (128):224-233.
- Kumar, M.; Bandyopadhyay, A.; Raghuwanshi, N. S. and Singh, R. 2008. Comparative study of conventional and artificial neural network-based ET<sub>0</sub> estimation models. *Irrig. Sci.*, (26):531:545.
- Lam, J. C. K.; Wan, K. W. and Yang, L. 2008. Solar radiation modeling using ANNs for different climates in China. *Energy conversion and management.* (49):1080-1090.
- Landeras, G.; Ortiz-Barredo, A. and Lopez, J. J. 2008. Comparison of artificial neural network models and empirical and semi-empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). *Agric. Water Manage.* (95):553-565.
- Lopez, G.; Rubio, M. A.; Martinez, M. and Batles, F. J. 2001. Estimation of hourly global photosynthetically active radiation using artificial neural network models. *Agric. For. Meteorol.* (107):279-291.
- Maier, H. R. M. and Dandy, C. G. 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. *Environmental Modelling & Software.* (15):101-124.
- Maqsood, I.; Khan, M. R. and Abraham, A. 2004. An ensemble of neural networks for weather forecasting. *Neural Comput & Applic.* (13):112-122
- Marzban, C. 2009. Basic statistics and basic AI: Neural networks. *Artificial Intelligence methods in the environmental sciences. In: Haupt S. E. et al.* (eds.). Springer-Verlag Berlin Heidelberg. 15-47 pp.
- McCulloch, W. S. and Pitts, W. 1943. A logical calculus of the ideas imminent in nervous activity. *Bulletin and Mathematical Biophysics.* (5):115-133.
- Meza, F. and Varas, E. 2000. Estimation of mean monthly solar global radiation as a function of temperature. *Agric. For. Meteorol.* (100):231-241.
- Mittal, G. S. and Zhang, J. 2003. Artificial neural network-based psychrometric predictor. *Biosystems Eng.* (85):283-289.
- Mohandes, M.; Balghonaim, A.; Kassas, M.; Rehman, S. and Halawani, T. O. 2000. Use of radial basis functions for estimating monthly mean daily solar radiation. *Solar Energy.* (68):161-168.
- Mohandes, M.; Rehman, S. and Halawani, T. O. 1998. Estimation of global solar radiation using artificial neural networks. *Renewable energy.* (14):179-184.

- Narendra, K. S. and Parthasarathy, K. 1990. Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks*. (1):4-27.
- Podestá, G. P.; Nuñez, L.; Villanueva, C. A. and Skansi, M. A. 2004. Estimating daily solar radiation in the Argentine Pampas. *Agric. For. Meteorol.* (123):41-53.
- Rehman, S. and Mohandes, M. 2008. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energy Policy*. (36):571-576.
- Rumelhart, D. E.; Hinton, G. E. and Williams, R. J. 1986. Learning internal representations by error propagation. *In*: Rumelhart D. E. and McClelland J. L. (eds.). *Parallel Distributed Processing*. MIT Press, Cambridge. 1-33 pp.
- Salazar, R.; Schmidt, U.; Huber, C.; Rojano, A. and Lopez, I. 2010. Neural networks models for temperature and CO<sub>2</sub> control. *Int. J. Agric. Res.* 4(5):191-200.
- Schoof, J. T. and Pryor, S. C. 2001. Downscaling temperature and precipitation: a comparison of regression-based methods and artificial neural networks. *Int. J. Clim.* (21):773-790
- Sfetsos, A. and Coonick, A. H. 2000. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. *Sol Energy*. (68):169-178.
- Shank, D. B.; Hoogenboom, G. and McClendon, R. W. 2008a. Dew point temperature prediction using artificial neural networks. *J. Appl. Meteorol. Clim.* (47):1757-1769.
- Shank, D. B.; McClendon, R. W.; Paz, J. and Hoogenboom, G. 2008b. Ensemble artificial neural networks for prediction of dew point temperature. *Appl. Artificial Intelligence*. (22):523-542.
- Sudheer, K. P.; Gosain, A. K. and Ramasastri, K. S. 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *J. Irrig. Drainage Eng.* (129):214-218.
- Trajinovic, S.; Todorovic, B. and Stankovic, M. 2003. Forecasting of reference evapotranspiration by artificial neural networks. *J. Irrig. Drainage Eng. ASCE*. (129):454-457.
- Wang, Y.; Traore, S. and Kerh, T. 2008. Neural network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso. *Wseas Transactions on Computers*. (7):704-713.
- Zhang, G.; Patuwo, E. B. and Hu, Y. M. 1998. Forecasting with artificial neural networks: the state of the art. *Int. J. Forecasting*. (14):35-62.
- Zhang, G. P. and Qi, M. 2005. Neural network forecasting for seasonal and trend time series. *European J. Operational Res.* (160):501-514.