



# UNIVERSIDAD AUTÓNOMA CHAPINGO

POSGRADO EN INGENIERÍA AGRÍCOLA  
Y USO INTEGRAL DEL AGUA

## REDES NEURONALES ARTIFICIALES PARA ESTIMAR Y PREDECIR VARIABLES CLIMATOLÓGICAS RELACIONADAS CON LA EVAPOTRANSPIRACIÓN DE REFERENCIA

### TESIS

QUE COMO REQUISITO PARCIAL  
PARA OBTENER EL GRADO DE:  
DOCTOR EN INGENIERÍA AGRÍCOLA  
Y USO INTEGRAL DEL AGUA

PRESENTA:

**ROCIO CERVANTES OSORNIO**



DIRECCIÓN GENERAL ACADÉMICA  
DIRECCIÓN DE SERVICIOS ESCOLARES  
OFICINA DE EXÁMENES PROFESIONALES

Chapingo, México, Diciembre de 2010



**REDES NEURONALES ARTIFICIALES PARA ESTIMAR Y  
PREDECIR VARIABLES CLIMATOLÓGICAS RELACIONADAS CON  
LA EVAPOTRANSPIRACIÓN DE REFERENCIA**

Tesis realizada por Rocio Cervantes Osornio bajo la dirección del  
Comité Asesor indicado, aprobada por el mismo y aceptada como  
requisito parcial para obtener el grado de:

**DOCTOR EN INGENIERÍA AGRÍCOLA  
Y USO INTEGRAL DEL AGUA**

**DIRECTOR**



**DR. RAMÓN ARTEAGA RAMÍREZ**

**ASESOR**



**DR. MARIO ALBERTO VÁZQUEZ PEÑA**

**ASESOR**



**DR. WALDO OJEDA BUSTAMANTE**

**LECTOR EXTERNO**



**DR. ABEL QUEVEDO NOLASCO**

The reason so few women get what they want is because they don't want it bad enough

You must do the thing you think you cannot do

In the battle of the sexes, the enemy is within ourselves

A woman who is loved will always be successful

There is more to be done than washing a dish

She who knows pain, knows it all

Go where you are appreciated more

If a boy can do it, a girl can do it

## ***A G R A D E C I M I E N T O S***

A la Universidad Autónoma Chapingo por darme la oportunidad de realizar mis estudios y ser parte de su comunidad estudiantil

Al programa de Postgrado en Ingeniería Agrícola y Uso Integral del Agua por permitirme ser parte de su proyecto académico

Al CONACYT por darme el apoyo económico que fue indispensable para llevar a cabo las actividades académicas durante mi estancia en el postgrado

Al Dr. Ramón Arteaga Ramírez por sus enseñanzas en el campo de la Agrometeorología, la dirección del presente trabajo, así como el apoyo brindado en el inicio, desarrollo y la buena conclusión del trabajo de tesis

Al Dr. Mario A. Vázquez Peña por sus enseñanzas con respecto al desarrollo de la tesis y la asesoría de este trabajo

Al Dr. Abel Quevedo Nolasco por sus enseñanzas con respecto al desarrollo de la tesis y la asesoría de este trabajo

Al Dr. Waldo Ojeda Bustamante por la asesoría brindada en este trabajo y en el de maestría, así como su apoyo en los momentos difíciles

Al Dr. Bulmaro Juárez Hernández por las enseñanzas brindadas durante los cursos tomados con él, un agradecimiento especial por su infinita paciencia, así como por los conocimientos que vertió en mi persona

Al profesor coordinador del Posgrado de Ingeniería Agrícola y Uso Integral del Agua: Dr. Eugenio Romanchik K. quien me dio todas las facilidades para culminar el postgrado

A los departamentos de Irrigación e Ingeniería Mecánica Agrícola por el apoyo logístico brindado en la estancia durante el doctorado

A mis amigos, colegas y compañeros: Paulino y su esposa Vianey, Lucia Carmona, Agustín Ruíz, Yam Tzec, Vicente López, Alejandro Mendieta, José Melchor, Abel, Esteban, Oziel, Edgar, Cuauhtémoc, Efrén y José Eduardo.

A todo el personal administrativo que contribuyó de alguna forma con este logro, en especial a las Sras. Rosa Ma. Mendoza y Lidia Ordaz.

**D E D I C A T O R I A**

**A mi madre:**

**Irene Osornio Zuñiga**

**A la memoria de mi padre (q.e.p.d):**

**Catalino Díaz Flores**

**A mis amadísimas hermanas:**

**Maria Sandra Díaz Osornio**

**Vianey Díaz Osornio (q.e.p.d)**

**Miriam Díaz Osornio**

**A mi hija:**

**Ma. de los Ángeles Cortes Cervantes**

**Y a quien cuida de ella**

**Con infinito amor**

**GRACIAS POR HABER ESTADO O TODAVIA ESTAR AHÍ**

## DATOS BIOGRÁFICOS DEL AUTOR

La autora de la presente tesis es originaria del Distrito Federal, nació el 11 de Junio de 1971, la educación básica y media la realizó en el mismo lugar de origen, en el año de 1996 concluyó la carrera quedando como pasante de la Licenciatura en Relaciones Comerciales en la Escuela Superior de Comercio y Administración. Ingresó en el año de 1997 a la Universidad Autónoma Chapingo, realizando el servicio social en el Centro Nacional de Estandarización de Maquinaria Agrícola (CENEMA) elaborando una base de datos, realizó una estancia en el área de diseño en la empresa Tecnomec Agrícola, fue incluida en un programa de entrenamiento en Iowa State University en el Departamento de “Agricultural Biosystems Engineering”, y fue en el año 2002 que egresó con el título de Ingeniero Mecánico Agrícola de dicha universidad. En julio de 2006 obtiene el grado de Maestra en Ciencias en el Programa de Cómputo Aplicado del Colegio de Postgraduados, Montecillo, México. Colaboró con la Secretaria de la Reforma Agraria por breve tiempo como evaluador de proyectos productivos. En agosto del 2007 ingresó en el Posgrado en Ingeniería Agrícola y Uso Integral del Agua para realizar estudios de Doctorado en la especialidad Uso Integral del Agua.

## CONTENIDO

|                                                                                                                                        | Pág. |
|----------------------------------------------------------------------------------------------------------------------------------------|------|
| <b>ÍNDICE DE CUADROS</b>                                                                                                               | iv   |
| <b>ÍNDICE DE FIGURAS</b>                                                                                                               | vi   |
| <b>RESUMEN</b>                                                                                                                         | viii |
| <b>ABSTRACT</b>                                                                                                                        | viii |
| <b>CAPÍTULO 1. INTRODUCCIÓN GENERAL</b>                                                                                                | 1    |
| 1.1 Objetivo general                                                                                                                   | 2    |
| 1.2 Objetivos específicos                                                                                                              | 3    |
| 1.3 Hipótesis                                                                                                                          | 4    |
| 1.4 Publicaciones realizadas                                                                                                           | 4    |
| <b>CAPÍTULO 2. REDES NEURONALES ARTIFICIALES Y LA PREDICCIÓN DE VARIABLES CLIMÁTICAS RELACIONADAS CON LA AGRICULTURA: UNA REVISIÓN</b> | 6    |
| 2.1 Introducción                                                                                                                       | 7    |
| 2.2 Redes neuronales artificiales. Teoría y fundamentos                                                                                | 9    |
| 2.2.1 RNA multicapa con el algoritmo <i>backpropagation</i>                                                                            | 9    |
| 2.2.2 RNA <i>radial basis function</i> (RBF)                                                                                           | 18   |
| 2.3 Similitudes y diferencias entre los modelos estadísticos tradicionales y las redes neuronales artificiales                         | 20   |
| 2.4 Áreas de aplicación de las redes neuronales artificiales                                                                           | 23   |
| 2.4.1 RNA en la predicción de variables climáticas relacionadas con la agricultura                                                     | 24   |
| 2.5 Perspectivas de las RNA en la predicción de variables agroclimáticas                                                               | 29   |
| 2.6 Conclusiones                                                                                                                       | 31   |
| 2.7 Literatura citada                                                                                                                  | 31   |
| <b>CAPÍTULO 3. COMPARACIÓN DE MODELOS PARA ESTIMAR LA PRESIÓN REAL DE VAPOR DE AGUA</b>                                                | 38   |
| 3.1 Introducción                                                                                                                       | 39   |

|       |                                                                                                                                                             |    |
|-------|-------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 3.1.1 | Marco teórico de la RNA multicapa <i>feedforward backpropagation</i>                                                                                        | 41 |
| 3.1.2 | Marco teórico de la red neuronal artificial multicapa <i>radial basis function</i> (RFB)                                                                    | 42 |
| 3.2   | Materiales y métodos                                                                                                                                        | 43 |
| 3.2.1 | Área de estudio y obtención de datos                                                                                                                        | 43 |
| 3.2.2 | Implementación de las redes neuronales artificiales <i>feedforward backpropagation</i> y <i>radial basis function</i>                                       | 45 |
| 3.2.3 | Modelos convencionales                                                                                                                                      | 45 |
| 3.2.4 | Modelos utilizados en la estimación de la presión real de vapor de agua                                                                                     | 47 |
| 3.2.5 | Datos observados                                                                                                                                            | 47 |
| 3.2.6 | Índices de evaluación estadística de los resultados de los modelos de estimación                                                                            | 48 |
| 3.3   | Resultados y discusión                                                                                                                                      | 49 |
| 3.3.1 | Validación de los modelos                                                                                                                                   | 59 |
| 3.4   | Conclusiones                                                                                                                                                | 63 |
| 3.5   | Literatura citada                                                                                                                                           | 63 |
|       | <b>CAPÍTULO 4. MODELOS CONVENCIONALES Y REDES NEURONALES ARTIFICIALES PARA ESTIMAR RADIACIÓN GLOBAL DIARIA EN EL DISTRITO DE RIEGO 075, SINALOA, MÉXICO</b> | 66 |
| 4.1   | Introducción                                                                                                                                                | 67 |
| 4.2   | Materiales y métodos                                                                                                                                        | 69 |
| 4.2.1 | Área de estudio y base de datos climática                                                                                                                   | 69 |
| 4.2.2 | Obtención de datos faltantes                                                                                                                                | 70 |
| 4.2.3 | Modelos utilizados en la estimación de la radiación global diaria                                                                                           | 70 |
| 4.2.4 | Método de Hargreaves                                                                                                                                        | 71 |
| 4.2.5 | Método de Prescott                                                                                                                                          | 72 |
| 4.2.6 | RNA multicapa con el algoritmo de retropropagación y función de base radial                                                                                 | 72 |
| 4.2.7 | Evaluación estadística de los resultados de los modelos de estimación                                                                                       | 73 |

|                                                                                                                                         |                                                                                               |     |
|-----------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------|-----|
| 4.3                                                                                                                                     | Resultados y discusión                                                                        | 74  |
| 4.4                                                                                                                                     | Conclusiones                                                                                  | 83  |
| 4.5                                                                                                                                     | Literatura citada                                                                             | 84  |
| <b>CAPÍTULO 5. HARGREAVES, PRIESTLEY-TAYLOR Y REDES NEURONALES ARTIFICIALES EN LA ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA</b> |                                                                                               | 87  |
| 5.1                                                                                                                                     | Introducción                                                                                  | 88  |
| 5.2                                                                                                                                     | Materiales y métodos                                                                          | 90  |
| 5.2.1                                                                                                                                   | Área de estudio y datos climatológicos                                                        | 90  |
| 5.2.2                                                                                                                                   | Penman-Monteith FAO 56                                                                        | 91  |
| 5.2.3                                                                                                                                   | Modelos utilizados en la estimación de la evapotranspiración de referencia (ET <sub>0</sub> ) | 91  |
| 5.2.4                                                                                                                                   | Implementación de la red neuronal función de base radial                                      | 94  |
| 5.2.5                                                                                                                                   | Índices estadísticos para evaluar los modelos                                                 | 94  |
| 5.3                                                                                                                                     | Resultados y discusión                                                                        | 95  |
| 5.3.1                                                                                                                                   | Validación de los modelos                                                                     | 98  |
| 5.4                                                                                                                                     | Conclusiones                                                                                  | 102 |
| 5.5                                                                                                                                     | Literatura citada                                                                             | 102 |
| <b>CAPÍTULO 6. CONCLUSIONES Y COMENTARIOS GENERALES</b>                                                                                 |                                                                                               | 105 |
| 6.1                                                                                                                                     | Conclusiones                                                                                  | 105 |
| 6.2                                                                                                                                     | Sugerencias                                                                                   | 106 |

## ÍNDICE DE CUADROS

|                   | Pág.                                                                                                                                                                                                                        |
|-------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>CAPÍTULO 2</b> |                                                                                                                                                                                                                             |
| Cuadro 1          | Topología de las RNA usadas para pronóstico de variables meteorológicas que tienen que ver con la agricultura 25                                                                                                            |
| <b>CAPÍTULO 3</b> |                                                                                                                                                                                                                             |
| Cuadro 1          | Estadísticos de prueba entre los datos observados de presión real de vapor y los datos estimados por los diferentes entrenamientos de RNA <i>feedforward backpropagation</i> 55                                             |
| Cuadro 2          | Estadísticos de prueba entre los datos observados de presión real de vapor y los datos estimados por los diferentes entrenamientos de RNA <i>radial basis function</i> 56                                                   |
| Cuadro 3          | Estadísticos de prueba entre los datos observados de presión real de vapor de agua y los estimados por los modelos convencionales para las diferentes estaciones 58                                                         |
| Cuadro 4          | RMSE obtenidos en la validación, de las diferentes estaciones y con los diferentes modelos 60                                                                                                                               |
| <b>CAPÍTULO 4</b> |                                                                                                                                                                                                                             |
| Cuadro 1          | Estadísticos de prueba entre la radiación medida y la estimada por los métodos de Hargreaves, Prescott calibrado y Prescott con las constantes propuestas por Allen <i>et al.</i> (1998), para las diferentes estaciones 76 |
| Cuadro 2          | Estadísticos de prueba de los escenarios entre los datos observados y los modelos estimados por el Modelo 4 de RNA multicapa con el algoritmo retropropagación, para las diferentes estaciones 77                           |
| Cuadro 3          | Estadísticos de prueba para diferentes escenarios de entrenamiento entre                                                                                                                                                    |

|                                                                                                                                               |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------|----|
| los datos medidos y los estimados por el Modelo 5 RNA de base radial para las estaciones Ruíz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2 | 78 |
|-----------------------------------------------------------------------------------------------------------------------------------------------|----|

## **CAPÍTULO 5**

|          |                                                                                                                                                                                 |    |
|----------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Cuadro 1 | Nombre, clave, longitud, latitud y altitud de las estaciones objeto de este estudio                                                                                             | 90 |
| Cuadro 2 | Diferentes estadísticos de prueba entre la radiación medida y la estimada por los modelos de Priestley-Taylor, Hargreaves y Hargreaves calibrado para las diferentes estaciones | 96 |
| Cuadro 3 | Estadísticos de prueba de las simulaciones entre los datos medidos y los estimados por el Modelo 4 de la RNA función de base radial, para las diferentes estaciones             | 96 |

## ÍNDICE DE FIGURAS

|                                                                                                                                                              | Pág. |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------|------|
| <b>CAPÍTULO 2</b>                                                                                                                                            |      |
| Figura 1                                                                                                                                                     | 10   |
| Grafo del flujo de señales destacando los detalles de salida de la neurona $j$                                                                               |      |
| Figura 2                                                                                                                                                     | 17   |
| Grafo del flujo de señales destacando los detalles de la neurona de salida $k$ conectando a la neurona oculta $j$                                            |      |
| Figura 3                                                                                                                                                     | 19   |
| Esquema de una red neuronal función de base radial                                                                                                           |      |
| Figura 4                                                                                                                                                     | 22   |
| Una RNA multicapa perceptrón con cuatro nodos de entrada, tres nodos ocultos y un nodo en la capa de salida                                                  |      |
| <b>CAPÍTULO 3</b>                                                                                                                                            |      |
| Figura 1                                                                                                                                                     | 44   |
| Región de estudio                                                                                                                                            |      |
| Figura 2                                                                                                                                                     | 50   |
| Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Ruíz Cortínez |      |
| Figura 3                                                                                                                                                     | 51   |
| Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Batequis      |      |
| Figura 4                                                                                                                                                     | 52   |
| Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Santa Rosa 1  |      |
| Figura 5                                                                                                                                                     | 53   |
| Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Santa Rosa 2  |      |
| Figura 6                                                                                                                                                     | 61   |
| Diferencias del Modelo 1 para nuevos conjuntos de datos                                                                                                      |      |
| Figura 7                                                                                                                                                     | 62   |
| Diferencias del Modelo 3 para nuevos conjuntos de datos                                                                                                      |      |
| Figura 8                                                                                                                                                     | 62   |
| Diferencias del Modelo 5 para nuevos conjuntos de datos                                                                                                      |      |

#### **CAPÍTULO 4**

|          |                                                                                             |    |
|----------|---------------------------------------------------------------------------------------------|----|
| Figura 1 | Predicción de la radiación global para la estación Ruiz Cortínez con tres modelos           | 80 |
| Figura 2 | Predicción de la radiación global para la estación Batequis con tres modelos                | 80 |
| Figura 3 | Predicción de la radiación global para la estación Santa Rosa 1 con tres diferentes modelos | 81 |
| Figura 4 | Predicción de la radiación global para la estación Santa Rosa 2 con tres diferentes modelos | 81 |

#### **CAPÍTULO 5**

|          |                                                                                                                     |     |
|----------|---------------------------------------------------------------------------------------------------------------------|-----|
| Figura 1 | Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Ruíz Cortínez | 99  |
| Figura 2 | Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Batequis      | 100 |
| Figura 3 | Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Santa Rosa 1  | 100 |
| Figura 4 | Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Santa Rosa 2  | 101 |

**Redes neuronales artificiales para estimar y predecir variables climatológicas relacionadas con la evapotranspiración de referencia**

Rocio Cervantes Osornio<sup>1</sup>

Ramón Arteaga Ramírez<sup>2</sup>

**RESUMEN**

El objetivo general del presente trabajo fue realizar una comparación de metodologías convencionales con modelos de RNA para estimar presión real de vapor de agua, radiación global diaria y evapotranspiración de referencia. Los datos usados para dicha comparación fueron de cuatro estaciones del DR075 Valle del Fuerte, estado de Sinaloa, México. También se llevo a cabo una revisión de literatura del uso de redes neuronales artificiales (RNA) en la estimación de variables climáticas relacionadas con la agricultura. La cantidad de agua requerida para compensar la pérdida por evapotranspiración del cultivo se define como necesidades hídricas del cultivo. Sobreestimar la evapotranspiración resulta en desperdicio de grandes cantidades de agua que repercuten en los rendimientos de los cultivos, por otro lado subestimar la evapotranspiración repercute en estrés hídrico para las plantas. Por tanto se necesita conocer con precisión cuanto regar anticipadamente. Los agentes meteorológicos que afectan a la  $ET_0$  son las variables temperatura, radiación global, humedad relativa y velocidad del viento, donde la  $ET_0$  se calcula a partir de estos. En el desarrollo de este trabajo de tesis se observó que las redes neuronales artificiales mostraron ser una excelente herramienta de estimación y/o predicción de las variables: presión real de vapor de agua, radiación global y evapotranspiración de referencia. Específicamente la red neuronal *radial basis function* mostró sistemáticamente mejor desempeño que la *feedforward backpropagation*. En la revisión de literatura se observó que se ha hecho bastante trabajo en estimación y/o predicción de las variables mencionadas previamente con las RNA *feedforward backpropagation* y *radial basis function*, pero durante el desarrollo de este trabajo, se observó también que existe carencia de investigación en la estimación de variables climáticas con redes neuronales dinámicas, y es ahí donde se vislumbra el futuro de la investigación, y la investigación se encamina también en la mejora de algoritmos para no desperdiciar espacio de almacenamiento en la terminal cuando se trabaja con redes neuronales artificiales.

**Palabras clave:** predicción, redes neuronales artificiales, variables climatológicas

**Artificial neural networks to estimate and to predict climatological variables related with reference evapotranspiration**

Rocio Cervantes Osornio<sup>1</sup>

Ramón Arteaga Ramírez<sup>2</sup>

**ABSTRACT**

The general aim of this work was to carry out a comparison of conventional methodologies with ANN models to estimate water vapor actual pressure, daily global radiation and reference evapotranspiration. Data used for this comparison were from four stations of DR075 “Valle del Fuerte”, Sinaloa state, México. In addition a literature review was conducted of the use of artificial neural networks (ANN) to estimate climatic variables related to agriculture. The quantity of water needed to compensate for the loss by crop evapotranspiration is defined as crop water needs. To overestimate the evapotranspiration results in the waste of large amounts of water, affecting crop yields. On the other hand to underestimate evapotranspiration impacts on plant water stress. Therefore it is necessary to know precisely how much water is needed beforehand. The meteorological agents which affect  $ET_0$  are the temperature, global radiation, relative humidity and wind speed variables, from which  $ET_0$  is calculated. In the development of this thesis paper, it was observed that artificial neural networks proved to be an excellent tool for estimating and/or predicting the variables: water vapor actual pressure, global radiation and reference evapotranspiration. Specifically the neural network radial basis function showed systematically better performance than the feedforward backpropagation one. In the literature review it was observed that enough work has been previously done in terms of the estimation and/or prediction of the above-mentioned variables with ANN feedforward backpropagation and radial basis function, but during the development of this work, it was also observed that there is a lack of research in the estimation of climatic variables with dynamic neural networks and there is where one can glimpse the future of research in this area, just as it is now aimed at improving algorithms in order not to waste storage space on the terminal when working with artificial neural networks.

**Key words:** forecasting, artificial neural networks, climatological variables.

<sup>1</sup> Autor de tesis

<sup>2</sup> Director de tesis

## CAPÍTULO 1

### INTRODUCCIÓN

Las redes neuronales artificiales (RNA) emulan ciertas características propias de los humanos, como la capacidad de memorizar y asociar hechos. Éstas son un modelo artificial simplificado del cerebro humano, el ejemplo más perfecto de un sistema capaz de adquirir conocimiento a través de la experiencia. Entre las ventajas de las RNA está la capacidad de modelar relaciones no-lineales que presentan los datos sin un conocimiento a priori de ellos. Además tienen formas funcionales más flexibles que los métodos de la estadística tradicional, cualquier modelo para pronosticar asume que existe una relación subyacente entre los valores de entrada y la salida y frecuentemente los modelos de pronóstico de la estadística tradicional presentan limitantes en estimar esta función subyacente debido a la complejidad (no-linealidad) del sistema real. Entonces las RNA resultan ser una buena alternativa para identificar esta función y para realizar una aproximación con bastante exactitud de los datos deseados (Zhang *et al.*, 1998).

La cantidad de agua requerida para compensar la pérdida por evapotranspiración ( $ET_0$ ) del cultivo se define como necesidades de agua del cultivo. Sobreestimar la  $ET_0$  resulta en pérdidas de grandes cantidades de agua que repercuten en los rendimientos de los cultivos, y subestimar la  $ET_0$  redundaría en estrés hídrico para las plantas, por tanto se necesita conocer cuanto regar. La idea central de calendarizar el riego es predecir cuanto 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 (Ojeda, 2004) para programar el agua que será distribuida en las zonas de riego.

Para estimar la evapotranspiración de referencia ( $ET_0$ ), el método de Penman-Monteith del boletín 56 de la FAO es el único recomendado como estándar, los factores que afectan a la  $ET_0$

son las variables climáticas tales como temperaturas, radiación global, humedad relativa y velocidad del viento, que se refleja en un balance de masas y energético donde la  $ET_0$  se calcula a partir de datos meteorológicos (Allen *et al.*, 1998).

Las redes neuronales artificiales (RNA), como una técnica de la inteligencia artificial, han mostrado ser una herramienta útil en la estimación de variables que son difíciles de manejar por la no-linealidad que subyace en ellas, en esta investigación se planteó emplear esta técnica para pronosticar la evapotranspiración de referencia y las variables que se le asocian: radiación global diaria, y presión real de vapor.

Este trabajo se organizó en seis capítulos: en el primero se encuentra la introducción general, objetivo general y específicos e hipótesis; en el segundo, se realizó la revisión literaria de las redes neuronales artificiales aplicadas en la estimación de variables climáticas relacionadas con la agricultura; en el tercero se encuentra la comparación de métodos convencionales con modelos de RNA para estimar la presión actual de vapor de agua; el cuarto es una comparación de métodos empíricos convencionales con RNA's en la estimación de la radiación global diaria; en el quinto se compara la RNA *radial basis function* con métodos convencionales para estimar la evapotranspiración de referencia y por último en el capítulo seis se presentan las conclusiones generales.

## **1.1 Objetivo general**

Realizar una comparación de métodos convencionales con modelos de RNA para estimar evapotranspiración de referencia ( $ET_0$ ) y variables climáticas relacionadas con ésta, estimaciones todas hechas para cuatro estaciones, que se ubican en el Distrito de Riego 075 Valle del Fuerte,

Los Mochis, Sinaloa, de igual forma llevar a cabo una revisión de literatura de RNA en la estimación de variables climáticas relacionadas con la agricultura.

## **1.2 Objetivos específicos**

Realizar una revisión de las aplicaciones de redes neuronales artificiales en la estimación y/o predicción de variables climáticas relacionadas con la agricultura, explorar algunas similitudes y diferencias entre la estadística tradicional con las RNA, así como revisar la estructura matemática de las RNA más comunes multicapa: *feedforward* y *radial basis function*, y presentar escenarios para el futuro de las RNA en aplicaciones de estimación de variables agroclimáticas.

Comparar los métodos convencionales, tales como Linsley, Bosen, Howell y Dusek, con un modelo de RNA *feedforward backpropagation* y uno *radial basis function* para estimar la presión real de vapor de agua.

Comparar los métodos convencionales Hargreaves, Prescott, y Prescott utilizando los coeficientes  $a$  y  $b$  que propone FAO-56, con los modelos de RNA *feedforward backpropagation* y *radial basis function* para estimar la radiación global diaria.

Realizar una comparación de los métodos convencionales Hargreaves, Hargreaves calibrado y Priestley y Taylor para estimar la evapotranspiración de referencia ( $ET_0$ ) con un modelo de RNA *radial basis function*.

### **1.3 Hipótesis**

Los modelos de redes neuronales artificiales son mejores estimadores de las variables agroclimáticas presión real de vapor de agua, radiación global diaria y evapotranspiración de referencia que los modelos convencionales.

### **1.4 Publicaciones realizadas**

Cervantes O. R. 2008. Aplicación de un modelo de red neuronal para estimar la evapotranspiración. *In: Congreso Internacional sobre Matemáticas y sus Aplicaciones*. Chapingo, México.

Cervantes O. R., Arteaga R. R., y Vázquez P. M. A. 2008. Predicción de la radiación global mediante redes neuronales artificiales. *In: XVIII Congreso Nacional de Ingeniería Agrícola*, Almengor S. R., Pérez S. L., y Romantchik K. E. (Editores). Universidad Autónoma Chapingo, Chapingo, Edo. de Mexico, p. 159-171.

Cervantes O. R., Arteaga R. R., Vázquez P. M. A. y Ojeda B. W. 2008. Red neuronal artificial para la predicción de la radiación global diaria. *In: III Foro de Avances de Investigación*, Universidad Autónoma Chapingo, Chapingo, Edo. de Mexico.

Cervantes O. R., Arteaga R. R., Vázquez P. M. A. y Ojeda B. W. 2008. Redes neuronales artificiales y series de tiempo en el pronóstico de la evapotranspiración de referencia. *In: IV Foro de Avances de Investigación*, Universidad Autónoma Chapingo, Chapingo, Edo. de México.

Cervantes O. R. y Juárez H. B. 2009. Modelo estadístico para la predicción de la evapotranspiración de referencia. *In: Segunda Semana Internacional de la Estadística y la Probabilidad*, Puebla, Pue.

Cervantes O. R., Arteaga R. R., Vázquez P. M. A. y Ojeda B. W. 2008. Redes neuronales artificiales, su comparación con modelos convencionales en la estimación de variables

climatológicas. *In:* V Foro de Avances de Investigación, Universidad Autónoma Chapingo, Chapingo, Edo. de México.

## **CAPÍTULO 2**

### **REDES NEURONALES ARTIFICIALES Y LA PREDICCIÓN DE VARIABLES CLIMÁTICAS RELACIONADAS CON LA AGRICULTURA: UNA REVISIÓN<sup>1</sup>**

#### **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 agroclimatología y/o agrometeorología para predecir variables climáticas que inciden directa e indirectamente en la agricultura ha originado el desarrollo de este trabajo. El objetivo de este estudio fue presentar una revisión en la literatura de la investigación realizada de las redes neuronales artificiales en la predicción de las variables agroclimáticas.

**Palabras clave:** modelos, predicción, redes neuronales, variables climáticas.

#### **ARTIFICIAL NEURAL NETWORKS AND PREDICTION OF CLIMATOLOGICAL VARIABLES RELATED WITH AGRICULTURE: A REVIEW**

#### **ABSTRACT**

Artificial neural networks represent a research field since they have shown to have application in various fields of science, its ability to deal with various nonlinear phenomena and the different tasks performed in some phenomena and the agro-climatology and/or meteorology to predict climatic variables directly and indirectly affect agriculture have led to the development of this

---

<sup>1</sup> *Cervantes-Osornio R.; Arteaga-Ramírez R.; Vázquez-Peña M. A.; Ojeda-Bustamante W.; Quevedo-Nolasco A.*

work. The objective of this study is to present a literature review of the research of artificial neural networks in predicting the agro-climatic variables.

**Key words:** models, prediction, neural networks, climatological variables

## 2.1 Introducción

Los elementos meteorológicos se usan como elemento de juicio en la toma de decisiones y son importantes en la planeación de diversas actividades. Dentro de la agricultura se tienen: la previsión y combate de heladas; predicción de la aparición de plagas y enfermedades dado el estado del tiempo; calendarizar en base a las condiciones atmosféricas y biológicas los momentos oportunos de preparación de tierras, siembra, laboreo y aplicación de agroquímicos y cosecha; prevenir a los agricultores del peligro de granizadas, vientos huracanados, lluvias excesivas; avisar de incendios en los bosques; control de insectos y enfermedades, conocer el momento oportuno del riego y también para la recolección y operaciones poscosecha: almacenamiento y transporte de productos agrícolas (Romo y Arteaga, 1989; Elías y Castellví, 2001). Estas decisiones que se toman en cada unidad agrícola son a partir de la información sobre el tiempo en forma de análisis estadísticos de datos del estado del tiempo datos del tiempo pasado (históricos) que a su vez implica a datos de variables climáticas tales como temperaturas (máximas y mínimas), la radiación global, la humedad relativa, la velocidad y dirección del viento, la precipitación, si bien la resolución de muchos problemas requiere una predicción de los acontecimientos, aspecto que últimamente ha recibido una considerable atención. Una diferencia esencial entre las predicciones meteorológicas generales y las especiales para la agricultura reside en el hecho de que estas últimas deben ajustarse a ciertos elementos de importancia en el sector

agrario, así, por ejemplo, diferencias pequeñas en las temperaturas mínimas suponen grandes variaciones en sus efectos sobre los cultivos, (Elías y Castellví, 2001).

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). Ramón y Cajal (1911) introdujeron la idea de neuronas como estructuras constituyentes del cerebro. El cerebro es una computadora, en el sentido de ser un sistema que procesa información, altamente compleja, no lineal y de procesamiento paralelo; está tiene la capacidad de organizar a las neuronas de tal forma para ejecutar ciertas tareas (reconocimiento de patrones, percepción, control motor, etc.) muchas veces mas rápidamente que la computadora digital mas veloz en existencia hoy (Haykin, 1994). La red neuronal se asemeja al cerebro en dos aspectos: 1. El conocimiento es adquirido por la red a través de un proceso de aprendizaje. 2. Contempla fuerzas de conexión interneuronal conocidas como pesos sinápticos que se usan para almacenar conocimiento (Alexander and Morton, 1990). Zhang *et al.* (1998), definen a las RNA como métodos manejadores de datos (cuando existen suficientes datos) adaptados por si 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 Zhang *et al.* (1998) que es en este sentido que 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 mucha expectativa para predecir variables climáticas.

Los objetivos del presente trabajo fueron revisar la teoría y estructura matemática de las RNA mas comunes multicapa: *feedforward backpropagation* y base radial, así como explorar algunas

similitudes y diferencias entre la estadística tradicional con las RNA, realizar una revisión de las aplicaciones de redes neuronales artificiales en la estimación y/o predicción de variables climáticas relacionadas con la agricultura, y presentar escenarios para el futuro de las RNA.

Se organizó el trabajo de la siguiente forma: la sección dos es una revisión general de la teoría de las redes neuronales artificiales y a fondo del modelo más comúnmente usado, el multicapa perceptrón; en la sección tres se consideran diversos tópicos y paradigmas en este campo; la sección cuatro muestra las áreas en las cuales se han aplicado las redes neuronales artificiales, específicamente da un bosquejo de los trabajos realizados sobre RNA en la predicción de variables climáticas relacionadas con la agricultura, y la sección cinco es un vistazo al futuro que tienen las redes neuronales artificiales en la predicción de variables climatológicas, finalmente en la sección seis se dan las conclusiones.

## 2.2 Redes neuronales artificiales. Teoría y fundamentos

### 2.2.1 RNA multicapa con el algoritmo *backpropagation*

Considérese entonces la Figura 1 la cual representa a la neurona  $j$  siendo alimentada por un conjunto de señales función producidas por una capa de neuronas a su izquierda. El nivel de actividad interna de la red  $v_j(n)$  producida en la entrada de la no-linealidad asociada con la neurona  $j$  es por lo tanto

$$v_j(n) = \sum_{i=0}^p w_{ji}(n) y_i(n) \quad (6)$$

donde  $p$  es el número total de entradas (excluyendo el umbral) aplicado a la neurona  $j$ . El peso sináptico  $w_{j0}$  (correspondiente a la entrada fijada  $y_0 = -1$ ) igual al umbral  $\theta_j$  aplicado a la neurona  $j$ . De aquí la función señal  $y_j(n)$  apareciendo en la salida de la neurona  $j$  en la iteración  $n$  es

$$y_j(n) = \varphi_j(v_j(n)) \quad (7)$$




Figura 1. Grafo del flujo de señales destacando los detalles de salida de la neurona  $j$

En una manera similar al algoritmo de mínimos cuadrados, el algoritmo *backpropagation* aplica una corrección  $\Delta w_{ji}(n)$  al peso sináptico  $w_{ji}(n)$ , lo cual es proporcional al gradiente instantáneo  $\partial \xi(n) / \partial w_{ji}(n)$ . De acuerdo a la regla de la cadena, se puede expresar este gradiente como sigue:

$$\frac{\partial \xi(n)}{\partial w_{ji}(n)} = \frac{\partial \xi(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (8)$$

El gradiente  $\partial \xi(n) / \partial w_{ji}(n)$  representa un factor de sensibilidad, determinando la dirección de búsqueda en el espacio de pesos para el peso sináptico  $w_{ji}$

Diferenciando ambos lados de la Ec. (4) con respecto a  $e_j(n)$  se obtiene

$$\frac{\partial \xi(n)}{\partial e_j(n)} = e_j(n) \quad (9)$$

Diferenciando ambos lados de la Ec.(3) con respecto a  $y_j(n)$  se obtiene

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (10)$$

Después, diferenciando Ec. (7) con respecto a  $v_j(n)$  se obtiene

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \phi'_j(v_j(n)) \quad (11)$$

donde el uso de la prima (sobre el lado derecho) significa diferenciación con respecto al argumento. Finalmente, diferenciando la Ec. (6) con respecto a  $w_{ji}(n)$  produce

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (12)$$

De aquí, el uso de las Ecs. (9) a (12) en (8) produce

$$\frac{\partial \xi(n)}{\partial w_{ji}(n)} = -e_j(n) \phi'_j(v_j(n)) y_i(n) \quad (13)$$

La corrección  $\Delta w_{ji}(n)$  aplicada a  $w_{ji}(n)$  es definida por la regla delta

$$\Delta w_{ji}(n) = -\eta \frac{\partial \xi(n)}{\partial w_{ji}(n)} \quad (14)$$

donde  $\eta$  es una constante que determina la tasa de aprendizaje esta es llamado el parámetro tasa de aprendizaje del algoritmo *backpropagation*. El uso del signo menos en la Ec. (14) cuenta para gradientes descendientes en el espacio de vectores. Por consiguiente, el uso de la Ec. (13) en (14) produce

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (15)$$

donde el gradiente local  $\delta_j(n)$  esta en si mismo definido por

$$\delta_j(n) = -\frac{\partial \xi(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)}$$

$$\delta_j(n) = e_j(n) \phi_j'(v_j(n)) \quad (16)$$

El gradiente local apunta a cambios requeridos en pesos sinápticos. De acuerdo a la Ecuación (16), el gradiente local  $\delta_j(n)$  para la salida de la neurona  $j$  es igual al producto del correspondiente error  $e_j(n)$  y la derivada  $\phi_j'(v_j(n))$  de la función de activación asociada.

De las Ecuaciones (15) y (16) se nota que un factor clave implicado en el cálculo del ajuste de pesos  $\Delta w_{ji}(n)$  es la señal de error  $e_j(n)$  en la salida de la neurona  $j$ . En este contexto, se pueden identificar dos casos distintos, dependiendo sobre donde en la red la neurona  $j$  se localice. En el caso I, la neurona  $j$  es un nodo salida. Este caso es simple de manejar, debido a que cada nodo salida de la red es proveído con la respuesta deseada suya propia, haciendo de esto un problema sencillo para calcular el error asociado. En el caso II la neurona  $j$  es un nodo oculto. Aunque las neuronas no están directamente accesibles ellas comparten responsabilidad para cualquier error creado en la salida de la red. La cuestión, no obstante es conocer como penalizar o recompensar a las neuronas ocultas por el compartir la responsabilidad.

Caso I: La neurona  $j$  es un nodo de salida

Cuando la neurona  $j$  se localiza en la capa de salida de la red, ésta seria suministrada con la respuesta deseada de si misma. De aquí se pueden usar la Ec. (3) para calcular la señal de error  $e_j(n)$  asociada con esta neurona; ver Fig. 1. Habiendo determinado  $e_j(n)$ , es problema sencillo calcular el gradiente local  $\delta_j(n)$  usando la Ec. (16)

Caso II. La neurona  $j$  es un nodo oculto

Cuando la neurona  $j$  está localizada en una capa oculta de la red, no existe respuesta deseada específica para esa neurona. Por consiguiente, la señal de error para una neurona oculta tendría que ser determinada recursivamente en términos de las señales de error para todas las neuronas para las cuales esas neuronas ocultas están directamente conectadas; esto es en donde el desarrollo del algoritmo *backpropagation* se vuelve complicado. Considere la situación representada en la Fig. 2 la cual representa a la neurona  $j$  como un nodo oculto de la red. Según la Ec. (16) se pueden redefinir los gradiente locales  $\delta_j(n)$  para la neurona  $j$  oculta como

$$\begin{aligned}\delta_j(n) &= -\frac{\partial \xi(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \\ &= -\frac{\partial \xi(n)}{\partial y_j(n)} \phi'_j(v_j(n)), \text{ la neurona } j \text{ esta oculta}\end{aligned}\quad (17)$$

donde, en la segunda línea se ha hecho uso de la Ec. (11). Para calcular la derivada parcial  $\partial \xi(n) / \partial y_j(n)$  se procede como sigue. De la Fig. 2 se ve que

$$\xi(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n), \text{ la neurona } k \text{ es un nodo de salida} \quad (18)$$

el cual está reescrito de la Ec. (4) excepto para el uso del índice  $k$  en lugar del índice  $j$ . Se ha hecho así para evitar confusión con el uso del índice  $j$  que se refiere a la neurona oculta bajo el caso II. En algún evento, diferenciando la Ec. (18) con respecto a la función señal  $y_j(n)$ , se obtiene

$$\frac{\partial \xi(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} \quad (19)$$

Después, se usa la regla de la cadena para la derivada parcial  $\partial e_k(n)/\partial y_j(n)$ , y de esta forma se reescribe la Ec. (19) en la forma equivalente

$$\frac{\partial \xi(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (20)$$

Sin embargo, de la Fig. 2 se nota que

$$\begin{aligned} e_k(n) &= d_k(n) - y_k(n) \\ &= d_k(n) - \varphi_k(v_k(n)), \end{aligned} \quad (21)$$

donde la neurona  $k$  es un nodo de salida, y de aquí

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (22)$$

Se puede también notar de la Fig. 2 que para la neurona  $k$ , el nivel de actividad interno de la red es

$$v_k(n) = \sum_{j=0}^q w_{kj}(n) y_j(n) \quad (23)$$

donde  $q$  es el número de entradas (excluyendo el umbral) aplicado a la neurona  $k$ . De aquí de nuevo, el peso sináptico  $w_{k0}(n)$  es igual al umbral  $\theta_k(n)$  aplicado a la neurona  $k$ , y la correspondiente entrada  $y_0$  se fija en el valor -1. En algún evento, diferenciando la Ec. (23) con respecto a  $y_j(n)$  da

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (24)$$

De esta forma, usando la Ec. (22) y (24) en la (20), se obtiene la derivada parcial deseada:

$$\frac{\partial \xi(n)}{\partial y_j(n)} = -\sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n)$$

$$= - \sum_k \delta_k(n) w_{kj}(n) \quad (25)$$

donde, en la segunda línea, se ha usado la definición del gradiente local  $\delta_k(n)$  dado en la Ec. (16) con el índice  $k$  sustituido para  $j$ .

Finalmente, usando la Ec. (25) en (17), se obtiene el gradiente local  $\delta_j(n)$  para la neurona escondida  $j$ , después reacomodando términos, como sigue:

$$\delta_j(n) = \varphi_j'(v_j(n)) \sum_k \delta_k(n) w_{kj}(n), \text{ la neurona } j \text{ está escondida.} \quad (26)$$

El factor  $\varphi_j'(v_j(n))$  implicado en el cálculo del gradiente local  $\delta_j(n)$  en la Ec. (26) depende únicamente sobre la función de activación asociada con la neurona escondida  $j$ . El factor restante envuelto en este cálculo, llamado, la sumatoria sobre  $k$ , depende de dos conjuntos de términos. El primer conjunto de términos, el  $\delta_k(n)$ , requiere conocimiento de las señales de error  $e_k(n)$ , para todas estas neuronas que se ligan en una capa a la derecha inmediata de la neurona oculta  $j$ , y que están directamente conectadas a la neurona  $j$ ; ver Fig. 2. El segundo conjunto de términos, el  $w_{kj}(n)$ , consiste de los pesos sinápticos asociados con estas conexiones.

Ahora se puede resumir las relaciones que se han derivados para el algoritmo *backpropagation*. Primero las correcciones  $\Delta w_{ji}(n)$  aplicadas al peso sináptico que conecta a la neurona  $i$  con la neurona  $j$  definido por la regla delta:

$$\begin{pmatrix} \text{Correccion} \\ \text{de peso} \\ \Delta w_{ji}(n) \end{pmatrix} = \begin{pmatrix} \text{parametro} \\ \text{tasa de} \\ \text{aprendizaje} \\ \eta \end{pmatrix} \cdot \begin{pmatrix} \text{gradiente} \\ \text{local} \\ \delta_j(n) \end{pmatrix} \cdot \begin{pmatrix} \text{señal} \\ \text{de entrada} \\ \text{de neurona} \\ y_i(n) \end{pmatrix} \quad (27)$$

Segundo, el gradiente local  $\delta_j(n)$  depende de si la neurona  $j$  es un nodo de salida o un nodo oculto:

1. Si la neurona  $j$  es un nodo de salida,  $\delta_j(n)$  iguala al producto de la derivada  $\varphi_j'(v_j(n))$  y la señal de error  $e_j(n)$ , ambos de los cuales están asociados con la neurona  $j$ ; ver Ec. (16).
2. Si la neurona  $j$  es un nodo oculto,  $\delta_j(n)$  es igual al producto de la derivada asociada  $\varphi_j'(v_j(n))$  y la suma ponderada de las  $\delta$ 's calculadas para las neuronas en la siguiente capa oculta o en la capa de salida que están conectadas a la neurona  $j$ ; ver la Ec. (26).

Los dos pasos de cálculo

En la aplicación del algoritmo *backpropagation*, dos pasos distintos de cálculo pueden distinguirse. El primer paso se refiere como el paso hacia delante, y el segundo como el paso hacia atrás.

En el paso hacia delante el peso sináptico permanece inalterado a través de la red, y la función señal de la red se calcula sobre la base de neurona por neurona. Específicamente, la función señal que aparece en la salida de la neurona  $j$  se calcula como

$$y_j(n) = \varphi(v_j(n)) \quad (28)$$

donde  $v_j(n)$  es el nivel de actividad interno de la red de la neurona  $j$ , definido por

$$v_j(n) = \sum_{i=0}^p w_{ji}(n) y_i(n) \quad (29)$$

donde  $p$  es el número total de entradas (excluyendo al umbral) aplicado a la neurona  $j$ , y  $w_{ji}(n)$  es el peso sináptico que conecta a la neurona  $i$  con la neurona  $j$ , y  $y_i(n)$  es la señal de entrada de la neurona  $j$  o equivalentemente, la función señal que aparece en la salida de la neurona  $i$ . Si la

neurona  $j$  está en la primera capa oculta de la red, entonces el índice  $i$  se refiere a la  $i$ -ésima entrada terminal de la red, para la cual se escribe

$$y_i(n) = x_i(n) \quad (30)$$

donde  $x_i(n)$  es el  $i$ -ésimo elemento del vector de entradas (patrón). Si, por el otro lado, la neurona  $j$  está en la capa de salida de la red, el índice  $j$  se refiere a la  $j$ -ésima salida terminal de la red, para la cual se escribe

$$y_j(n) = o_j(n) \quad (31)$$

donde  $o_j(n)$  es el  $j$ -ésimo elemento del vector salida (patrón). Esta salida se compara con la respuesta deseada  $d_j(n)$ , obteniendo la señal de error  $e_j(n)$  para la  $j$ -ésima neurona. De esta forma la fase hacia delante de cálculo empieza en la primera capa oculta presentándole el vector de entradas, y termina en la capa de salida calculando la señal de error para cada neurona de esta capa.




Figura 2. Grafo del flujo de señales destacando los detalles de la neurona de salida  $k$  conectado a la neurona oculta  $j$ .

El paso hacia atrás, por el otro lado, empieza en la capa de salida pasando las señales de error a través de la red, capa por capa, y recursivamente, calculando los  $\delta$ 's (esto es los gradientes locales) para cada neurona. Este proceso recursivo permite a los pesos sinápticos de la red recibir los cambios de acuerdo con la regla delta de la Ec. (27). Para una neurona localizada en la capa de salida, la  $\delta$  es simplemente igual a la señal de error de esa neurona multiplicada por la primera derivada de su no-linealidad. De aquí, se usa la Ec. (27) para calcular los cambios a los pesos de todas las conexiones alimentantes en la capa de salida. Dadas las  $\delta$ 's para las neuronas de la capa de salida, después se usa la Ec. (26) para calcular las  $\delta$ 's para todas las neuronas en la penúltima capa y por lo tanto los cambios para los pesos de todas las conexiones alimentantes de ésta. El cálculo recursivo se continúa capa por capa, propagando los cambios a todos los pesos sinápticos hechos.

Note que para la presentación de cada ejemplo de entrenamiento, el patrón de entrada se fija (se ‘ancla’) a través del proceso de viaje redondo, implicando el paso hacia delante seguido por el paso hacia atrás (Haykin, 1994).

### 2.2.2 RNA *radial basis function* (RBF)

Una red esquemática de la función de base radial con  $n$  entradas y un escalar como salida se representa en la Figura 3, tal red implementa un mapeo  $f_r : R^n \rightarrow R$  de acuerdo con

$$f_r(x) = \lambda_0 + \sum_{i=1}^{n_r} \lambda_i \phi(\|\mathbf{x} - \mathbf{c}_i\|) \quad (32)$$

donde  $x \in R^n$  es el vector de entrada,  $\phi(\cdot)$  es una función dada de  $R^+$  a  $R$ ,  $\|\cdot\|$  denota la norma euclidiana,  $\lambda_i$ ,  $0 \leq i \leq n_r$ , son los pesos o parámetros,  $c_i \in R^n$ ,  $1 \leq i \leq n_r$  conocidas como los

centros RBF, y  $n_r$  es el número de centros. Aunque el caso de salida escalar es el que se considera aquí por simplicidad rotacional. De hecho, una red RBF multisalida puede siempre separarse en un grupo de una red RBF de una sola salida. En la red RBF la forma funcional  $\phi(\cdot)$  y los centros  $c_i$  se asumen estén fijos. Suministrando un conjunto de la entrada  $x(t)$  y la salida deseada correspondiente  $d(t)$  para  $t = 1$  hasta  $N$ , los valores de los pesos  $\lambda_i$  se determinan usando el método lineal de mínimos cuadrados. Sin embargo las elecciones de  $\phi(\cdot)$  y  $c_i$  deben ser cuidadosamente consideradas para que la red RBF sea capaz de corresponder lo mas posible a la representación de la red neuronal de dos capas.

Resultados teóricos de investigación y práctica, sugieren que la elección de la función de no-linealidad  $\phi(\cdot)$  no es crucial para la realización de la red RBF. Por ejemplo, la función Gaussiana es:

$$\phi(v) = \exp(-v^2 / \beta^2) \quad (33)$$

donde  $\beta$  es una constante real. Para la no linealidad  $\phi(v) \rightarrow 0$  así como  $v \rightarrow \infty$ .




Figura 3. Esquema de una red neuronal función de base radial

En la práctica los centros son normalmente elegidos de los datos  $\{x(t)\}_{t=1}^N$ , eligiéndolos arbitrariamente, aunque no garantiza un adecuado desempeño, (Chen *et al.*, 1991).

### 2.3 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. En los círculos de IA la herramienta canónica para resolver tales problemas son las redes neuronales, o más específicamente el perceptrón multicapa (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/o actividades. Por ejemplo el muy conocido evento *M-competition* donde compitieron eventos de series de tiempo y redes neuronales artificiales, las RNA obtuvieron buen desempeño (Hill *et al.*, 1994), así también lo mencionan Hsieh y Tang (1998) para el evento patrocinado por el Santa Fe Institute.

Las redes neuronales son únicamente 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  $y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p = \alpha + \sum_{i=1}^p \beta_i x_i$ . Los términos  $\theta$  y  $\omega$  (Ec. 34) son análogos a  $\alpha$  y  $\beta$  en la ecuación de regresión, siendo los parámetros de la red (Marzban 2009).

$$y(x, \omega, H) = g \left( \sum_{i=1}^H \omega_i f \left( \sum_{j=1}^{N_{in}} \omega_{ij} x_j - \theta_i \right) - \theta \right) \quad (34)$$

La representación que es análoga a la Ec. (34) se muestra en la Figura 4, esta red es referida como multicapa perceptrón, con  $N_{in}$  nodos de entrada, un nodo de salida ( $N_{out}$ ) y dos capas ocultas 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;  $f(x)$  y  $g(x)$ , llamadas funciones de activación, son funciones preespecificadas, su trabajo es transformar los predictores  $x_j$  y dos elecciones comunes de estas funciones son  $\tanh(x)$  y  $1/(1+e^{-x})$ . Contando los parámetros o pesos en la Figura 4 se tiene: cada línea que conecta a algún nodo con otro nodo es un peso, y existen  $N_{in}H + HN_{out}$  de éstos (Marzban, 2009).

Sin ir en detalle, se puede ver porque la red multicapa perceptrón puede ajustar cualquier dato (la mayoría de las veces). Justo pensando en  $f(x)$  como una función base; la Ec. (34) entonces está indicando que cualquier función que relaciona a  $y$  con las  $x_i$ 's puede ser aproximada con la función dada por la Ec. (34), dando algunos valores para los parámetros, y dado un valor suficientemente grande de  $H$ . Marzban (2009) continúa diciendo que también es análogo 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 puede ser escrita como una combinación lineal de un conjunto de funciones sigmoideas (Marzban, 2009).

$$y_t = \alpha_0 + \sum_{j=1}^n \alpha_j f \left( \sum_{i=1}^m \beta_{ij} y_{t-i} + \beta_{0j} \right) + \varepsilon_t \quad (35)$$

Con respecto a el preprocesamiento de los datos que se realiza en la estadística tradicional y comparándolo con las RNA, la mayoría de las series de tiempo exhiben variaciones de tendencia y estacionalidad, la estacionalidad es un patrón periódico y recurrente causado por diversos factores, es decir se exhibe cierto cambio en determinado periodo de tiempo (Zhang y Qi, 2005). No obstante las variaciones estacionales son quizás el componente mas significativo en una serie

de tiempo estacional, una tendencia estocástica frecuentemente es acompañada con variaciones estacionales y puede tener impacto significativo sobre los métodos de pronóstico o predicción. Una serie de tiempo con tendencia se considera que es no estacionaria y necesita ser estacionaria antes que se lleve a cabo el proceso de modelación y predicción, así también la estacionariedad es usualmente una suposición deseable en el análisis y predicción de series de tiempo, en particular para que la predicción sea posible (Zhang y Qi, 2005; Kim *et al.*, 2004).




Figura 4. Una RNA multicapa perceptrón con cuatro nodos de entrada, tres nodos ocultos y un nodo en la capa de salida.

De esta manera existen planteamientos tradicionales para modelar series de tiempo removiendo 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 dicho componente, así como se realizan ciertas actividades en una serie de datos para aplicar el modelo de series de tiempo, esto genera discusión, para que antes de aplicar el modelo de RNA, se quite estacionalidad y tendencia a los datos, priori al entrenamiento para realizar un

pronóstico de mejor ajuste, como afirman Zhang y Qi, (2005) que los resultados que ellos encontraron demuestran que las RNA no son capaces directamente de modelar la estacionalidad, siendo deseable remover este componente de los datos antes del entrenamiento para obtener mejor desempeño.

Ahora bien el pronóstico basado sobre las redes neuronales es actualmente un método de caja-negra, es incapaz de describir y analizar las relaciones entre el sistema entrada-salida de pronóstico, de igual forma es difícil realizar alguna explicación a los resultados obtenidos o hacer una prueba estadística sobre los datos; no existe un método estándar para elegir una estructura apropiada de red neuronal cuando se usan éstas para pronóstico, la única forma que se puede tomar es invertir bastante tiempo para probar, descubrir la red “más apropiada” de muchos experimentos, y esto puede tomar demasiado tiempo horas-máquina el usar redes neuronales para pronóstico (Ding *et al.*, 2008).

## **2.4 Áreas de aplicación de las redes neuronales artificiales**

Las redes neuronales se han aplicado en diferentes áreas del conocimiento, uno de ellos es en la manufactura tal como lo muestra Zhang y Huang (1995) en su trabajo. Las redes neuronales también han sido usadas para predecir en el área de finanzas tal como el trabajo hecho por Pérez (2006) en su estado del arte y las redes neuronales para pronosticar la quiebra en empresas; de igual forma existen trabajos realizados para la identificación y predicción de series de tiempo tal como lo muestra González *et al.* (2000); en reconocimiento del habla se encuentra el trabajo de Milone (2005); en la teoría de control inteligente se han utilizado las RNA, muestra de ello es el trabajo de Galán *et al.* (2000), Zhang and Stanley (1999), Neelakantan and Pundarikanthan

(2000), Ray and Klindworth (2000), citados por Trajnovic *et al.* (2003) que reportan aplicaciones de modelación de RNA en el vasto campo de la hidrología; en la ecología se reporta el trabajo de Lek *et al.* (1996) que modela las relaciones no lineales en esta área con una red neuronal artificial, y una investigación en agroecología basado en RNA lo representa el trabajo de Jiménez *et al.* (2008); una revisión de las aplicaciones en la predicción de variables que tienen que ver con el recurso agua es el trabajo de Maier and Dandy, (2001).

#### **2.4.1 RNA en la predicción de variables climáticas relacionadas con la agricultura**

Los pronósticos de tiempo general proporcionados al público por los servicios meteorológicos, frecuentemente proporcionan un rango de productos más especializados para diferentes usuarios o aplicaciones. Entre estos están los pronósticos de corto periodo de lluvias para pronóstico de inundaciones y operaciones de suministro de agua, pronósticos estacionales para sequía y aplicaciones en la agricultura, esto es temperatura de aire y otras entradas, estos 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 es el de las redes neuronales artificiales que es el 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 y la oceanografía con redes neuronales, por ejemplo se ha aplicado RNA para pronosticar al fenómeno de El niño y los fenómenos que se encuentran más directamente relacionados con la agricultura se encuentran descritos, a grandes rasgos, en el Cuadro 1

Cuadro 1. Topología de las RNA usadas para pronóstico de variables meteorológicas relacionadas con la agricultura

| Ref | Autor(es)                       | Estructura de RNA                                                                                                                             | Función de transferencia                                 | Variable estimada                           | Tipo dato | Índices estadísticos                      |
|-----|---------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------|---------------------------------------------|-----------|-------------------------------------------|
| 1   | López <i>et al.</i> (2001)      | Multicapa perceptrón <i>feedforward</i>                                                                                                       | Función sigmoidea                                        | Radiación fotosintéticamente activa (PAR)   | hora      | R <sup>2</sup> , RMSE, MBE                |
| 2   | Elminir <i>et al.</i> (2005)    | Multicapa con el algoritmo <i>backpropagation</i>                                                                                             | Sigmoidea                                                | insolación en diferentes bandas espectrales | diaria    | RMSE, MBE, r                              |
| 3   | Elizondo <i>et al.</i> (1994)   | Multicapa <i>feedforward</i> con el algoritmo <i>backpropagation</i>                                                                          | -                                                        | Radiación solar                             | diaria    | RMSE, R <sup>2</sup> , CV, Error absoluto |
| 4   | Rehman y Mohandes (2008)        | Red <i>feedforward</i> de tres capas, con el algoritmo <i>backpropagation</i>                                                                 | Función logística                                        | Radiación solar global                      | diaria    | RMSE, MAPE                                |
| 5   | Benghanem, <i>et al.</i> (2009) | <i>Feedforward</i> con el algoritmo de entrenamiento <i>backpropagation</i>                                                                   | -                                                        | Radiación solar global                      | diaria    | MPE, RMSE, MBE, r                         |
| 6   | Alawi y Hinai, (1998)           | Multicapa <i>feedforward</i> con el algoritmo <i>backpropagation</i>                                                                          | -                                                        | Radiación global                            | mensual   | R <sup>2</sup> , MAPE                     |
| 7   | Sfetsos y Coonick, (2000)       | <i>Feedforward</i> con algoritmo de entrenamiento <i>backpropagation</i> 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 <i>feedforward backpropagation</i>                                                                                       | Función logística sigmoidea                              | Radiación solar global                      | diario    | RMSE, MBE                                 |

| Ref | Autor(es)                      | Estructura de RNA                                                       | Función de transferencia               | Variable estimada                | Tipo dato | Índices estadísticos |
|-----|--------------------------------|-------------------------------------------------------------------------|----------------------------------------|----------------------------------|-----------|----------------------|
| 9   | Mohandes <i>et al.</i> (1998)  | <i>Feedforward</i> de dos capas con el algoritmo <i>backpropagation</i> | Función sigmoidea                      | Radiación solar global           | mensual   | MAPE                 |
| 10  | Mohandes <i>et al.</i> (2000)  | Multicapa perceptrón y función de base radial                           | Función sigmoidea<br>Función gaussiana | Radiación solar                  | mensual   | MAPE                 |
| 11  | Khoob (2008)                   | Perceptrón multicapa con algoritmo <i>backpropagation</i> .             | Logística sigmoidea                    | Evapotranspiración de referencia | mensual   | $R^2$ , RMSE, R      |
| 12  | Chauhan y Shrivastava (2009).  | <i>Feedforward</i> multicapa con algoritmo <i>backpropagation</i> .     | -                                      | Evapotranspiración de referencia | mensual   | SEE, E, RSEE         |
| 13  | Kumar <i>et al.</i> (2002)     | Multicapa con algoritmo <i>backpropagation</i>                          | Sigmoidea                              | Evapotranspiración de referencia | diario    | WSEE, SEE            |
| 14  | Trajnovic <i>et al.</i> (2003) | Radial basis function usando un filtro de Kalman                        | Función gaussiana                      | Evapotranspiración de referencia | mensual   | MAE, MSE             |
| 15  | Kumar <i>et al.</i> (2008)     | Multicapa con algoritmo <i>backpropagation</i>                          | Función sigmoidea                      | Evapotranspiración de referencia | diario    | WSEE, SEE, r         |
| 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 <i>backpropagation</i>            | -                                      | Evapotranspiración de referencia | diario    | MBE, MAE, RMSE       |
| 18  | Gonzalo-Camacho et al. (2008)  | <i>Feedforward backpropagation</i>                                      | Logsigmoidea,<br>tangente hiperbólica  | Evapotranspiración de referencia | diario    | MSE, r, $R^2$        |

| Ref | Autor(es)                                                 | Estructura de RNA                                                             | Función de transferencia                                          | Variable estimada                                                                                                              | Tipo dato      | Índices estadísticos           |
|-----|-----------------------------------------------------------|-------------------------------------------------------------------------------|-------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------|----------------|--------------------------------|
| 19  | Kim y Kim (2008)                                          | RNA de regresión generalizada, forma modificada de la RBF                     | Función de Kernel Gaussiana                                       | Evaporación y Evapotranspiración                                                                                               | diario         | RMSE, r, E                     |
| 20  | Maqsood <i>et al.</i> (2004)                              | Multicapa perceptrón, Elman recurrente, radial basis function, modelo Hopfiel | -                                                                 | Temperatura, velocidad del viento y humedad relativa                                                                           | horaria        | MSE, RMSE, r, MAPE             |
| 21  | Shank <i>et al.</i> (2008a, b)                            | Multicapa con el algoritmo <i>backpropagation</i>                             | Gaussiana, Gaussiana complemento, tangente hiperbólica, logística | Temperatura del punto de rocío                                                                                                 | horaria        | R <sup>2</sup> , MAE           |
| 22  | Mittal y Zhang, 2003                                      | Multicapa                                                                     | Función gaussiana, Gaussiana complemento, tangente hiperbólica    | Temperatura del punto de rocío, temperatura de bulbo húmedo, entalpía, radio de humedad, volumen específico y humedad relativa |                | Error relativo, Error absoluto |
| 23  | Schoof y Pryor, 2001                                      | Multicapa, algoritmo <i>backpropagation</i>                                   | Sigmoidea                                                         | Temperatura y precipitación                                                                                                    | diario mensual | MSE, MAE                       |
| 24  | Chevalier <i>et al.</i> (2010) (Smith <i>et al.</i> 2009) | Red aprendizaje supervisada, maquina de vector soporte                        | Logística                                                         | Temperatura del aire                                                                                                           | horaria        | MAE                            |

| Ref | Autor(es)                    | Estructura de RNA | Función de transferencia | Variable estimada             | Tipo dato            | Índices estadísticos |
|-----|------------------------------|-------------------|--------------------------|-------------------------------|----------------------|----------------------|
| 25  | Salazar <i>et al.</i> (2010) | Multicapa         | -                        | CO <sub>2</sub> , Temperatura | Cinco y diez minutos | MSE                  |

$R^2$ , 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, mean absolute error; MPE, mean percentage error; R, razón entre las medias estimadas de  $ET_0$  y las observadas; MAPE, mean absolute percentage error.

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

En el presente la red neuronal multicapa estática es todavía el sistema de modelado y método de predicción popular en las aplicaciones; más allá de la investigación de las redes neuronales multicapa *forward*, que es comparativamente minucioso. 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 habilidad propuesta de la red. La red neuronal multicapa *forward* puede obtener buenos resultados en la predicción de la modelación de sistemas estáticos. Pero 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, usando una red neuronal multicapa *forward* debería poder determinarse la categoría del modelo del sistema por adelantado, pero esto es difícil de lograr. Usar la red dinámica *feedback* para continuar el modelado y predicción del sistema puede resolver los problemas difíciles citados arriba, y es tomado en serio en la aplicación práctica, representando la tendencia en la modelación de redes neuronales y predicción. Esto es principalmente debido a que la red dinámica en si 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. Pero el estudio basado en el modelado y predicción de red dinámico está lejos todavía de la investigación de redes neuronales multicapa *forward* (Ding *et al.*, 2008).

Se espera por un nuevo progreso sobre la realización física en circuitos electrónicos una explicación del complejo comportamiento del cerebro humano. Los desarrollos del dominio de

las matemáticas relacionadas, la investigación de los modelos dinámicos no lineales y así sobre lo que está afectando el desarrollo adicional de las redes neuronales. También las reglas de aprendizaje que las redes presentes usan son en su mayoría de aprendizaje supervisado y aprendizaje no supervisado. El aprendizaje semi-supervisado es la cuestión de primer plano de las reglas de aprendizaje de máquina, que ha sido aplicado en el dominio de la minería de datos, reconocimiento de patrones y demás, pero éste es también una nueva tentativa para las redes neuronales (Ding *et al.*, 2008).

La investigación de las redes neuronales tiene un muy amplio prospecto de desarrollo y 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 del mismo modo irán extendiéndose cada vez más. Existirá un auge en el campo del pronóstico basado sobre la superioridad especial de las redes neuronales en el procesamiento de problemas no lineales, especialmente en la agricultura en donde varios fenómenos entran en este campo de la no-linealidad (Ding *et al.*, 2008).

En el presente la investigación en RNA principalmente se hace en mejoramientos sobre la base de los modelos, estos mejoramientos se engloban en cuatro aspectos los cuales son: selección de parámetros, algoritmos, función de activación, 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, y una combinación de algoritmos avanzados como el algoritmo máquina de vector soporte, y entonces la investigación también estará encaminada a la mejora de los algoritmo para no desperdiciar espacio de almacenamiento (Ding *et al.*, 2008).

## **2.6 Conclusiones**

Existen muchos trabajos en pronóstico de RNA en el campo de la agrometeorología, pero todavía falta realizar investigación en algunos campos, por ejemplo en la precipitación, o en el pronóstico de la tensión real de vapor de agua.

Falta todavía investigación en aplicaciones específicas para las redes neuronales artificiales del tipo dinámico y por tanto en el de estudio de las variables climáticas aplicadas en la agricultura, por tanto ahí está el futuro donde se vislumbra seguirá la investigación dirigida hacia aplicaciones de redes neuronales artificiales pero de manera dinámica.

La comparación de los procesos para pronóstico con RNA y con modelos de serie de tiempo es que ambos necesitan previamente procesar los datos, ya sea para el modelo de serie de tiempo que requiere quitar componentes de estacionalidad y tendencia a la serie de datos, como para entrenar esos mismos datos con una red neuronal, ya que también requieren que se remuevan esos mismos componentes para que mejore la exactitud del pronóstico. Por último la investigación también esta encaminada en el mejoramiento de los algoritmos para no desperdiciar espacio de almacenamiento en una computadora cuando se trabaja con RNA.

## **2.7 Literatura citada**

Aksoy H. and Dahamsheh A. 2009. Artificial neural network models for forecasting monthly precipitation in Jordan. *Stoch Environ Res Risk Assess*, 23:917-931.

Alawi, S., M., and H.A. Hinai. 1998. An ANN-based approach for predicting global radiation in locations with no direct measurements instrumentation. *Renewable Energy* 14:199-204.

Aleksander I., and Morton H. 1990. *An introduction to neural computing*. London: Chapman & Hall.

- Benghanem, M., A. Mellit, and S. N. Alamri. 2009. ANN-based modeling and estimation of daily global solar radiation data: A case study. *Energy Conversion Manage.* 50:1644-1655.
- Chauhan S. y Shrivastava R.K. 2009. Performance evaluation of reference evapotranspiration estimation using climate based methods and artificial neural networks. *Water. Resour. Manage.*, 23:825-837.
- Chen S., C.F. Cowan N., and P. Grant M. 1991. Orthogonal least squares learning algorithm for Radial Basis Functions networks. *IEEE Transactions on neural networks*, 2:302-309.
- Chevalier R. F., G. Hoogenboom, R.W. McClendon, and J.A. Paz. Support vector regression with reduced training sets for air temperature prediction: a comparison with artificial neural networks. *Neural computing & applications*
- Demuth H., Beale M. and Hagan M. 2008. *Neural network toolbox™ 6. User's guide.* 907 pp.
- 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.* pp:783-793.
- Elías C.F. y Castellví S. F. 2001. *Agrometeorología.* Ed. Grupo Mundi-Prensa, 2a. ed., 515 p.
- Elizondo, D., G. Hoogenboom, and R.W. McClendon. 1994. Development of a neural network model to predict daily solar radiation. *Agric. For. Meteorol.* 71:115-132.
- Elminir H. K., F.F. Areed and T.S. Elsayed. 2005. Estimation of solar radiation components incident on Helwan site using neural networks. *Sol. Energy* 79: 270-279.
- Galán R., Jiménez A., Sanz R. y Matia F. 2000. Control inteligente. *Inteligencia artificial, Revista Iberoamericana de Inteligencia Artificial, Valencia España,* 4:43-48.
- González-Camacho J.M., Cervantes-Osornio R., Bustamante-Ojeda W. y López-Cruz I. 2008. Predicción de la evapotranspiración de referencia mediante redes neuronales artificiales. *Ingeniería hidráulica en México*, 23:127-138.

- González Y. A., Ávila A. M. A., Gómez R. E., Vilasis C.X., Mulet O. y Mazzanti F. 2000. Redes neuronales para identificación y predicción de series de tiempo. *Revista del Centro de Investigación, Universidad La Salle, México*, 4:45-65.
- 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., Remus W. 1994. Artificial neural network models for forecasting and decision making. *International Journal of forecasting* 10:5-15
- Howell A., T., and D. Dusek A. 1995. Comparison of vapor-pressure-deficit calculation methods- southern high plains. *Journal of Irrigation and Drainage Engineering*, 121:191-198 March/April.
- Hsieh W. W and B. Tang. 1998. Applying neural network models to prediction and data analysis in meteorology and oceanography. *Bulletin of the American Meteorological Society*.
- Jain A., McClendon W.R., and Hoogenboom G. 2006. Freeze prediction for specific locations using artificial neural networks. *American society of agricultural and biological engineers; Transactions of ASABE*, 49:1955-1962.
- Jimenez D., Perez-Urbe A., Satizabal H., Barreto M., Van Damme P., and Tomassini M. 2008. A survey of artificial neural network-based modeling in agroecology. *In: Prasad B. (ed.), Soft Computing Applications in Industry*, Springer-Verlag Berlin Heidelberg pp. 247-269.
- 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. y Kim H.S. 2008. Neural networks and genetic algorithm approach for nonlinear evaporation and evapotranspiration modeling. *Journal of hydrology*, 351:299-317.
- Kim T. Y., Oh K. J. Kim C., and Do J.D. 2004. Artificial neural networks for non-stationary time series. *Neurocomputing* 61: 439-447.

- Kumar M., Bandyopadhyay A., Raghuwanshi N.S. y Singh R. 2007. Comparative study of conventional and artificial neural network-based ETo estimation models. *Irrig. Sci.*, 26:531-545.
- Kumar M., Raghuwanshi N.S., Singh R., Wallender W.W. y Pruitt W.O. 2002. Estimating evapotranspiration using artificial neural network. *Journal of irrigation and drainage engineering*, 128:224-233.
- Lam J., C., K. Wan K.W., and L.Yang. 2008. Solar radiation modeling using ANNs for different climates in China. *Energy conversion and management*, 49:1080-1090.
- Landeras G., Ortiz-Barredo A. y 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). *Agricultural water management*, 95:553-565.
- Lek S., Delacoste M., Baran P., Dimopoulos I., Lauga J. and Aulagnier S. 1996. Application of neural networks to modelling nonlinear relationships in ecology. *Ecological Modelling*, 90:39-52.
- Lopez G., Rubio M.A., Martinez M., and Batles F.J. 2001. Estimation of hourly global photosynthetically active radiation using artificial neural network models. *Agricultural and forest Meteorology* 107:279-291.
- Maier H. R. M., 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.
- Maier H. R., Dandy C.G. 2001. Neural network based modelling of environmental variables: A systematic approach. *Mathematical and Computer Modelling*, 33:669-682.
- 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. *In: Haupt S.E. et al., (eds.), Artificial Intelligence Methods in the Environmental Sciences. Springer-Verlag Berlin Heidelberg*, pp. 15-47.
- McCulloch, W.S., 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. *Agricultural and Forest Meteorology* 100:231-241.
- Milone D. H. 2005. Reconocimiento automático del habla con redes neuronales artificiales *Ciencia docencia y tecnología, Universidad Nacional de entre Ríos, Concepción de Uruguay, Argentina*; 16(31):261-322.
- Mittal G.S. and Zhang J. 2003 Artificial neural network-based psychrometric predictor. *Biosystems Engineering* 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.
- Neelakantan T.R., and Pundarikanthan N.V. 2000. Neural network-based simulation-optimization model for reservoir operation. *J. Water Resour. Plan. Manage.*, 126:57-64.
- Ovando G., Bocco M. y Sayago S. 2005. Redes neuronales para modelar predicción de heladas. *Agricultura técnica, Chile*, 65:65-73.
- Pérez M. 2006. Artificial neural networks and bankruptcy forecasting: a state of the art. *Neural Comput. & Applic.* 15:154-163.
- Podestá G. P.; Nuñez L.; Villanueva C. A.; and Skansi M.A. 2004. Estimating daily solar radiation in the Argentine Pampas. *Agricultural and Forest Meteorology* 123:41 -53.

Ramón y Cajal., S. 1911. Histologie du systeme nerveux de l'homme et des vertébrés. Paris: Maline; Edition Francaise Revue: Tome I, 1952; Tome II, 1955; Madrid: Consejo superior de investigaciones científicas.

Ray C., and Klindworth K.K. 2000. Neural network for agrichemical vulnerability assessment of rural private wells. J. Hydrologic Eng., 5:162-171.

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.

Romo G. J.R.y Arteaga R. R. 1989. Meteorología agrícola. Universidad autónoma chapingo, México, 441 p.

Rumelhart, D.E., Hinton, G.E., Williams, R.J. 1986. Learning internal representations by error propagation. In: Rumelhart D.E., McClelland J.L. (Eds.) Parallel Distributed Processing. MIT Press, Cambridge.

Salazar R., Schmidt U., Huber C., Rojano A., and Lopez I. 2010. Neural networks models for temperature and CO<sub>2</sub> control. International journal of agricultural research

Salini C. G. y Pérez J. P. 2006. Estudio de series temporales de contaminación ambiental mediante técnicas de redes neuronales artificiales. Ingeniare, Revista chilena de ingeniería, Universidad de Tarapacá, Chile, 14(3):284-290.

Sfetsos, A., and A.H. Coonick. 2000. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. Sol. Energy 68: 169-178.

Sanchez C.E.N. y Alanis G.A.Y. 2006. Redes Neuronales. Conceptos fundamentales y aplicaciones a control automático. Pearson Prentice Hall, 210 pp.

Schoof J.T. and Pryor S.C. 2001. Downscaling temperature and precipitation: A comparison of regression-based methods and artificial neural networks. International Journal of climatology 21:773-790

- Shank D.B., Hoogenboom G., and McClendon R.W. 2008a. Dew point temperature prediction using artificial neural networks. *Journal of applied meteorology and climatology* 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. *Applied artificial intelligence* 22:523-542.
- Sudheer K.P., Gosain A.K. y Ramasastri K.S. 2003. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of irrigation and drainage engineering*, 129:214-218.
- Trajnovic S., Todorovic B., and Stankovic M. 2003. Forecasting of reference evapotranspiration by artificial neural networks. *Journal of irrigation and drainage engineering, ASCE*, 129:454-457.
- Torres R. E. 2006. *Agrometeorología*. Trillas, Universidad Autónoma Agraria Antonio Narro.
- Wang Y., Traore S., y Kerh T. 2008. Neural network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso. *Wseas transactions on computers*, 7:704-713.
- Zanetti S. S.; E. F. Sousa; V.P.S. Oliveira; F.T. Almeida and S. Bernardo. 2007. Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of irrigation and drainage engineering, ASCE*, 133(2):83-89.
- Zhang G., Patuwo E. B., and Hu Y. M. 1998. Forecasting with artificial neural networks: The state of the art. *International Journal of forecasting*, 14:35-62.
- Zhang G. P., and Qi M. 2005. Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research* 160:501-514.
- Zhang H. C. and Huang S.H. 1995 Applications of neural networks in manufacturing: a state of the art survey. *Int. J. Prod. Res.* 33(3):705-728.
- Zhang Q., and Stanley S.J. 1999. Real-time treatment process control with artificial neural networks. *J. Environ. Eng.*, 125(2):153-160.

## CAPÍTULO 3

### COMPARACIÓN DE MODELOS PARA ESTIMAR LA PRESIÓN REAL DE VAPOR DE AGUA<sup>1</sup>

#### RESUMEN

La presión real de vapor de agua es una variable básica para estimar la evapotranspiración de los cultivos, uno de los componentes del ciclo hidrológico, sin embargo es difícil y cara de medirla directamente, por lo que se recurre en la práctica a estimaciones basadas en la temperatura y relaciones sicrométricas. El objetivo del presente trabajo fue realizar una comparación de diferentes métodos convencionales para el cálculo de la presión real de vapor y compararlos con las estimaciones hechas por los dos tipos de redes neuronales artificiales: *feedforward backpropagation* y *radial basis function*. Se usaron datos meteorológicos de cuatro estaciones del Distrito 075, localizado en el Valle del Fuerte al norte del estado de Sinaloa, México. Los resultados indican que la red neuronal artificial tipo *radial basis function* mostró ser el mejor método en la estimación de la presión actual de vapor de agua.

**Palabras clave:** Humedad atmosférica, déficit de presión de vapor, redes neuronales artificiales.

#### MODELS COMPARISON FOR CALCULATION OF ACTUAL VAPOR PRESSURE

#### ABSTRACT

Actual vapor pressure is a basic data in the estimation of evapotranspiration, an hydrological cycle component, however, the direct measurement of actual vapor pressure is difficult and expensive, consequently its indirect determination makes use of temperature data and

---

<sup>1</sup> Cervantes-Osornio R.; Ramírez-Arteaga R.; Vázquez-Peña M. A.; Ojeda-Bustamante W.; Quevedo-Nolasco A. 2010. Enviado a la revista *Tecnología y Ciencias del Agua*.

psychometric relationships. A comparison of conventional methods with artificial neural networks, feedforward backpropagation and radial basis function was realized to calculate the actual vapor pressure. Meteorological data were used from four weather stations of the Irrigation district 075, located at the “Valle del Fuerte”, at northern part of the Sinaloa State, Mexico. The results indicate that artificial neural network radial basis function was the best method for estimating the actual vapor pressure.

**Key words:** Atmospheric humidity, vapor pressure deficit, artificial neural network.

### 3.1 Introducción

La presión real de vapor de agua es un elemento importante en la existencia de la humedad circundante en la atmósfera y por tanto para determinar el déficit de presión de vapor, resulta necesario conocerlo en el cálculo de la evapotranspiración (Allen *et al.*, 1998), variable esta última relacionada con los requerimientos de agua de los cultivos (Jensen *et al.*, 1990), y que influye finalmente en la lamina de riego; de igual manera la presión real de vapor de agua representa un elemento básico como variable en la modelación de crecimiento de cultivos; y como lo indica Baker (2005), no existen muchos métodos directos para medir la presión o densidad de vapor. La presión de vapor solo puede ser medida directamente por medios ópticos que son caros para la mayoría de las aplicaciones agrícolas, en consecuencia, su estimación practica se realiza a partir de la temperatura y relaciones psicrométricas; se han propuesto diversos modelos para estimar la presión real de vapor, tales como los expuestos por Allen *et al.* (1998), unos modelos plantean el uso de la temperatura de punto de rocío y para su cálculo también se han propuesto diversos métodos como la ecuación de Murray (Howell y Dusek, 1995), ó la que propone Linsley *et al.* (1998) y para la propia presión de vapor actual Allen *et al.*,

(1998) presentan una ecuación que requiere la temperatura mínima y la humedad relativa máxima. Sadler y Evans (1989) demostraron que el uso de 15 métodos diferentes de cálculo del déficit de presión de vapor podrían causar error de hasta el 80% en subestimación y del 100% en la sobreestimación de la evapotranspiración comparadas con el mejor método para estimar el déficit de presión de vapor de agua.

Las redes neuronales artificiales (RNA) son un modelo que aprende por medio del entrenamiento y captura relaciones funcionales entre los datos aun si las relaciones subyacentes no son conocidas o difíciles de describir, y es en este sentido que las RNA pueden ser tratadas como un método estadístico multivariado no lineal y no paramétrico (Zhang *et al.*, 1998). Estas características representan ventajas que colocan a las RNA como un excelente método para predecir y/o estimar variables climáticas.

En el mejor conocimiento de los autores no se encontraron investigaciones para estimar la presión de vapor real de agua usando redes neuronales artificiales (RNA), pero se han realizado diversos trabajos para estimar el déficit de presión de vapor, la humedad relativa y la temperatura de punto de rocío con RNA (Mittal y Zhang, 2003; Shank *et al.*, 2008a, b). Bialobrzewski (2008) estima la humedad relativa en el aire entrenando una RNA *feedforward* multicapa con retraso en el tiempo, con el algoritmo *backpropagation* para estimar 16 datos en intervalos de 3 h, es decir una predicción de la humedad relativa en las próximas 48 h; ó el trabajo realizado por He *et al.* (2007) donde predicen por medio de una red neuronal la humedad relativa y la temperatura del aire en un invernadero, o Shank *et al.* (2008a, b,) que estimaron la temperatura de punto de rocío, paso previo en el cálculo de la presión real de vapor de agua, por medio de una RNA tipo *backpropagation* de forma horaria.

El objetivo de la presente investigación fue realizar una comparación de la presión real de vapor de agua estimada con los métodos convencionales de Linsley, Murray y Bosen contra las

estimaciones realizadas con un modelo de red neuronal artificial multicapa tipo *feedforward backpropagation* y otro *radial basis function* y la validación de todos éstos modelos.

### 3.1.1 Marco teórico de la RNA multicapa *feedforward backpropagation*

Las redes neuronales artificiales recientemente han probado ser excelentes herramientas para aproximar sistemas no lineales. El algoritmo usado en el modelo *feedforward* multicapa de red neuronal artificial fue el *backpropagation*. Este algoritmo empieza con la inicialización, la presentación de ejemplos para el entrenamiento y para cada ejemplo se ejecutan los dos pasos siguientes de acuerdo con Haykin (1994):

Paso 1. El cálculo hacia delante. Sea un ejemplo de entrenamiento en la época denotado por  $[\mathbf{x}(n), \mathbf{d}(n)]$ , con el vector de entradas  $\mathbf{x}(n)$  aplicado a los nodos de la capa de entradas y el vector de respuestas deseado  $\mathbf{d}(n)$  presentado al nodo de la capa de salida. El nivel de actividad interno de la red  $v_j^{(l)}(n)$  para la neurona  $j$  en la capa  $l$  es:

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

donde  $y_i^{(l-1)}(n)$  es la función señal de la neurona  $i$  en la capa previa  $l - 1$  en la iteración  $n$ ,  $w_{ji}^{(l)}(n)$  es el peso sináptico de la neurona  $j$  en la capa  $l$  que es alimentada 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  $\theta_j^{(l)}(n)$  es un umbral aplicado para la neurona  $j$  en la capa  $l$ . Asumiendo el uso de la función logística para la no linealidad sigmoidea, la función señal (de salida) de la neurona  $j$  en la capa  $l$  es:

$$y_j^{(l)}(n) = \frac{1}{1 + \exp(-v_j^{(l)}(n))} \quad (2)$$

Si la neurona  $j$  está en la primera capa escondida (esto quiere decir  $l = 1$ ), se tiene

$$y_j^{(0)}(n) = x_j(n) \quad (3)$$

donde  $x_j(n)$  es el  $j$ -ésimo elemento del vector de entrada  $x(n)$ . Si la neurona  $j$  está en la capa de salida ( $l = L$ ), se tiene:

$$y_j^{(L)}(n) = o_j(n) \quad (4)$$

de aquí, se calcula el error de la señal

$$e_j(n) = d_j(n) - o_j(n) \quad (5)$$

donde  $d_j(n)$  es el  $j$ -ésimo elemento del vector de respuestas deseado  $\mathbf{d}(n)$ .

Paso 2. Cálculo hacia atrás. Calcula los  $\delta$ 's (gradientes locales) de la red por el procedimiento hacia atrás, capa por capa:

$$\delta_j^{(L)}(n) = e_j^{(L)}(n) o_j(n) [1 - o_j(n)] \quad (6)$$

para la neurona  $j$  en la salida de la capa  $L$

$$\delta_j^{(l)}(n) = y_j^{(l)}(n) [1 - y_j^{(l)}(n)] \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) \quad (7)$$

para la neurona  $j$  en la salida de la capa  $l$ .

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

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha [w_{ji}^{(l)}(n) - w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (8)$$

donde  $\eta$  es el parámetro tasa de aprendizaje y  $\alpha$  es la constante de momento; y el último componente del algoritmo *backpropagation* es la iteración donde se presentan nuevas épocas de ejemplos de entrenamiento a la red hasta que los parámetros libres de la red estabilicen sus valores y el error medio cuadrado ( $\xi_{av}$ ) calculado sobre el conjunto entero de entrenamiento tenga un valor mínimo o pequeño aceptable (Haykin, 1994).

### 3.1.2 Marco teórico de la red neuronal artificial multicapa *radial basis function* (RBF)

Una alternativa viable a la alta no linealidad en los parámetros de la red neuronal es la red *radial basis function*. Una red RBF puede ser considerada como un caso especial de una red de dos capas la cual es lineal en los parámetros debido al fijamiento de todos los centros RBF y no linealidades en la capa oculta. De esta forma la capa oculta ejecuta una transformación no lineal fija con parámetros no ajustables y mapeo al espacio de entradas en un nuevo espacio. La capa de salida entonces implementa una combinación lineal sobre este nuevo espacio y los únicos parámetros ajustables son los pesos de esta combinación lineal. Estos parámetros pueden por lo tanto ser determinados usando el método lineal de mínimos cuadrados. En la práctica los centros son frecuentemente elegidos como un subconjunto de los datos. La mayoría de los trabajos publicados simplemente asumen que los centros sean arbitrariamente seleccionados de los datos (Chen *et al.*, 1991).

## **3.2 Materiales y métodos**

### **3.2.1 Área de estudio y obtención de datos**

Se utilizaron datos climatológicos de humedad relativa en porcentaje (%), temperaturas máximas y mínimas (°C), obtenidos de la base datos de la red agroclimática automatizada Valle del Fuerte localizada en el Distrito de Riego 075, ubicada en la vecindad de la ciudad de Los Mochis, Sinaloa. Tales datos fueron de cuatro estaciones meteorológicas (Figura 1): 3843 II-2 Ruiz Cortínez, 3546 II-3 Batequis, 3765 III-1 AC Santa Rosa 1 y 9610 III-1 AC Santa Rosa 2, cuyas coordenadas geográficas (latitud, longitud y altitud en metros) respectivamente son 25° 39' 15", 108° 45' 20", 31; 25° 45' 49", 108° 48' 41", 32; 25° 45' 03", 108° 57' 21", 40 y 25° 51' 16", 108° 52' 03", 61. Estos datos se preprocesaron a nivel diario, comprendieron del periodo abril de 1997 a mayo de 2001, generando vectores de 1484 datos diarios, los cuales se utilizaron para el

ajuste de los modelos convencionales, y para el entrenamiento, validación y prueba de las RNA. Otro conjunto de datos del periodo de junio a diciembre de 2001 (229 días) se utilizaron para realizar, con los diferentes modelos, una predicción (validación) de la presión real de vapor de agua. Los datos se preprocesaron en hojas de cálculo de Excel de Microsoft Office 2007 y el software usado para el entrenamiento de las RNA fue el Matlab 7.0 con sus utilerías (toolbox) para redes neuronales.




Figura 1. Región de estudio

### 3.2.2 Implementación de la redes neuronales artificiales *feedforward backpropagation* y *radial basis function*

En el entrenamiento de la RNA *feedforward backpropagation* se consideraron diferentes conjuntos de variables de entrada con una sola capa oculta y una sola neurona en la capa de salida, el algoritmo de entrenamiento fue el Levenberg-Marquardt, se utilizó la función de transferencia tangente-sigmoidea (tansig) en la capa oculta y en la capa de salida, todos los entrenamientos convergieron en menos de 100 épocas, de los datos se ocuparon: la mitad para el entrenamiento, una cuarta parte para la validación y a otra parte para la prueba de la red neuronal artificial. Como parte de la propia arquitectura de la red, se consideraron combinaciones de las variables de entrada, de la temperatura máxima, temperatura mínima, humedad relativa máxima y humedad relativa mínima, con 4 neuronas en la capa oculta y como salida la presión real o actual de vapor de agua y previo a los entrenamiento se escalaron las entradas y salida a un rango de [-1, 1].

En la RNA *radial basis function* el extendido o *spread* elegido fue de 100 en todos los entrenamientos, el código en matlab para esta función es “*net=newrbe(P,T,spread)*” donde se crean tantas neuronas *radbas* como vectores de entradas existen, y donde *P* son los vectores de entrada y *T* es el *target* o vector de salida.

### 3.2.3 Modelos convencionales

Uno de los modelos utilizados para estimar la temperatura del punto de rocío es con la expresión de Murray (1967) y está expresada:

$$T_{rocio} = \frac{237.3}{\left\{ \frac{1}{\left[ \frac{\ln\left(\frac{HR_i}{100}\right)}{17.27} \right] + \left[ \frac{T_i}{237.3 + T_i} \right]} - 1 \right\}} \quad (9)$$

Otra forma alterna de estimar la temperatura del punto de rocío está dado por la expresión mencionada por Linsley *et al.* (1998), y es:

$$T_{rocio} = T - \left[ (14.55 + 0.114 * T) * X + \left[ (2.5 + 0.007 * T) * X \right]^3 + (15.9 + 0.117 * T) * X^{14} \right] \quad (10)$$

donde

$$X = 1 - \frac{HR}{100}$$

Otra ecuación para estimar la temperatura de punto de rocío esta dada por la expresión de Bosen (1958)

$$T_{rocio} = \left( \frac{HR}{100} \right)^{1/8} * [112 + 0.9 * T] + (0.1 * T) - 112 \quad (11)$$

el valor  $T_{rocio}$  se sustituye en lugar de la temperatura mínima ( $T_{min}$ ) en °C en la ecuación siguiente (Allen *et al.*, 1998):

$$e_a = e^*(T_{min}) = 0.611 \exp \left[ \frac{17.27 T_{min}}{(T_{min} + 237.3)} \right] \quad (12)$$

Allen *et al.* (1998) indica que cuando no se tiene el valor de  $T_{rocio}$  se puede utilizar la  $T_{min}$  ya que la relación  $T_{rocio} \approx T_{min}$  se mantiene para localidades en donde un cultivo bien regado cubre el suelo de la estación. Sin embargo mencionan Allen *et al.* (1998), en regiones áridas, donde el aire no está saturado cuando se presenta la temperatura mínima, es posible  $T_{min}$  pueda ser mayor que

$T_{rocio}$ , y se necesita una calibración local para estimar la temperatura del punto de rocío. En estas situaciones  $T_{min}$  en la Ecuación (12) puede aproximarse más adecuadamente restándole de 2 a 3 °C;  $T_{min}$  es la temperatura mínima del aire en °C;  $HR$  es la humedad relativa del aire en %; y  $e^*(T_{min})$  es la presión de vapor saturada en kPa para temperatura  $T_{min}$  en °C de cada día. Se realizaron las estimaciones de la presión real de vapor de agua real ( $e_a$ ) de acuerdo a este procedimiento.

### 3.2.4 Modelos utilizados en la estimación de la presión real de vapor de agua

Se estimó la presión real de vapor por diferentes métodos, cada método se consideró como un modelo, para el Modelo 1 se consideraron los entrenamientos por medio de la red neuronal artificial (RNA) multicapa *feedforward backpropagation*, y para el Modelo 2 la RNA *radial basis function* con la metodología teórica propia indicada para redes neuronales artificiales (Park y Sandberg, 1991; Chen *et al.*, 1991).

Con la Ecuación 12 se estimó la presión real de vapor para los Modelos del 3 al 8 (convencionales), lo único que cambia es el valor que se sustituye en lugar de la temperatura mínima. Los Modelos 3, 4 y 5 utilizan:  $T_{min} - 2$ ,  $T_{min} - 3$  y  $T_{min}$  respectivamente. Los Modelos 6, 7 y 8 calculan primero la  $T_{rocio}$  con las ecuaciones de: Murray (ec. 9), Linsley (ec. 10) y Bosen (ec. 11), respectivamente, y por ultimo cada uno de estos valores se sustituye por la  $T_{min}$ .

### 3.2.5 Datos observados

Según Allen *et al.* (1998) la presión real de vapor ( $e_a$ ) se deriva de la humedad relativa, y se tiene la ecuación siguiente:

$$e_a = \frac{e^o(T_{\min}) \frac{HR_{\max}}{100} + e^o(T_{\max}) \frac{HR_{\min}}{100}}{2} \quad (13)$$

la Ecuación (13) es la expresión que de acuerdo con Allen *et al.* (1998) es la que mejor se aproxima al valor deseado (observado) de la presión real de vapor de agua, como se careció de datos directos de la presión real de vapor, se asumieron como exactos los calculados por la Ecuación (13) y contra estos datos se compararon los datos de presión real de vapor estimados con los métodos citados previamente.

### 3.2.6 Índices de evaluación estadística de los resultados de los modelos de estimación

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

$$RMSE = \left( \frac{\sum_{i=1}^N (a_i - t_i)^2}{N} \right)^{1/2} \quad (14)$$

el error medio (MBE) llamado también sesgo o desviación, calculado con el fin de caracterizar la bondad de cada uno de los modelos, dado por la ecuación siguiente

$$MBE = \frac{\sum_{i=1}^N (a_i - t_i)}{N} \quad (15)$$

el coeficiente de correlación, R, dado por

$$R = \frac{\sum_{i=1}^N (a_i - \bar{a})(t_i - \bar{t})}{\left\{ \left[ \sum_{i=1}^N (a_i - \bar{a})^2 \right] \left[ \sum_{i=1}^N (t_i - \bar{t})^2 \right] \right\}^{1/2}} \quad (16)$$

donde el coeficiente de determinación está dado por  $R^2$ ,  $a$  es el dato estimado por el modelo,  $t$  es el dato que se asume como exacto,  $N$  es el número de observaciones o estimaciones,  $\bar{a}$  es el

promedio de los datos estimados por el modelo,  $\bar{t}$  es el promedio de los datos del modelo que se asume como exacto (observados), (Cai *et al.*, 2007; Pereira, 2004).

### 3.3 Resultados y discusión

Al analizar las Figuras 2, 3, 4 y 5 se observa que los datos estimados con el Modelo 1 al compararlos con los datos observados se alinean en la recta 1:1, lo que indica una dispersión mínima en los datos de las cuatro estaciones utilizados. El ajuste del Modelo 2 es casi perfecto en todas las estaciones. El Modelo 3 ( $T_{min} - 2$ ) y el 4 ( $T_{min} - 3$ ) subestiman los valores observados en Ruiz Cortínez y Santa Rosa 1 y en las otras dos estaciones los puntos se distribuyen mejor alrededor de la recta a 45°, pero es mejor el ajuste del Modelo 3. El Modelo 5 ( $T_{min}$ ) presenta una mejor dispersión de sus puntos en las estaciones Ruiz Cortínez y Santa Rosa 1 y en las otras dos se observa una sobreestimación entre los valores de tres a cuatro (kPa) en el eje x. Los Modelos 6, 7 y 8 que utilizan la temperatura del punto de rocío, presentan una sobreestimación en todas las estaciones (esta más acentuada en la estación Santa Rosa 2), aunque sus puntos son menos dispersos, comparados con los Modelos 3, 4 y 5.

Los resultados de las Figuras (2, 3, 4 y 5) reafirman lo encontrado por Allen *et al.* (1998) y Cai *et al.* (2007), que según la zona climática se espera que en zonas húmedas o en localidades donde el cultivo esta bien regado la  $T_{rocio}$  es aproximadamente igual a la  $T_{min}$  o si la región es árida la  $T_{rocio} \approx T_{min} - (2 \text{ y } 3^\circ \text{ C})$ . En este estudio en dos estaciones (Ruiz Cortínez y Santa Rosa 1) resultó ser mejor el Modelo 5 que utilizo la  $T_{min}$  y en las otras dos (Batequis y Santa Rosa 2) fue el Modelo 3 que considero la  $T_{min} - 2$ . La anterior diferencia se puede deber a que el lugar donde están las estaciones instaladas no tengan las mismas características físicas. Otro aspecto indicativo de que




Figura 2. Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Ruíz Cortínez




Figura 3. Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Batequis




Figura 4. Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Santa Rosa 1




Figura 5. Comparación entre los valores estimados y los observados (kPa) por los diferentes modelos de la presión real de vapor de agua para la estación Santa Rosa 2.

lo que pudiera estar ocasionando que no sea el mismo modelo el que estime mejor es la lejanía o cercanía a la costa, puesto que observando la Figura 1 las estaciones en las cuales  $T_{min}$  (Modelo 5) fue utilizada para calcular la presión de vapor actual y fue el método que mejor aproximó a los datos observados, fue justamente en las estaciones mas cercanas a la costa que son Ruíz Cortínez y Santa Rosa 1 (aire mas saturado de vapor de agua), a diferencia de las estaciones mas alejadas de la costa que son Batequis y Santa Rosa 2 en la cuales el Modelo 3 fue el que mejor aproximó a los datos observados. Los Modelos 6, 7 y 8 no estiman bien a la  $T_{rocio}$ , por eso presentan la sobreestimación en todas las estaciones.

A partir de este análisis previo se obtuvieron los estadísticos de prueba: raíz cuadrada del cuadrado medio del error (RMSE), el error medio sesgado (MBE), así como el coeficiente de determinación ( $R^2$ ), la pendiente ( $m$ ) y el intercepto ( $b$ ) de la relación entre los datos observados y los estimados de la presión real de vapor para las diferentes estaciones para los Modelos 1,2, 3, 5, 6, 7 y 8, y debido a que el desempeño del Modelo 4 es mucho menor que los Modelos 3 y 5 en cuanto a la estimación de la presión de vapor real de agua, se omiten los estadísticos de prueba para dicho Modelo.

En el Cuadro 1 y 2 se presentan los parámetros ( $m$  y  $b$ ) de los Modelos 1 y 2 así como, los estadísticos de su ajuste, en cuatro Escenarios E1, E2, E3 y E4 respectivamente, se observan en ambos casos que el ajuste de los cuatro Escenarios es bueno y mejora conforme aumenta el número de variables de entrada. En el Cuadro 1 la nomenclatura del Escenario E4{ $T_{min}$ ,  $T_{max}$ ,  $HR_{min}$ ,  $HR_{max}$ }(4x4x1), significa que se utilizaron las variables indicadas dentro de las llaves (temperatura mínima, máxima, humedad relativa mínima y máxima), que son cuatro variables de

entradas, cuatro neuronas en la capa oculta y una salida; y es en este Escenario E4 en donde se presenta un ajuste muy bueno, como se había observado en las Figuras (2 a 5).

Cuadro 1. Estadísticos de prueba de ajuste entre los datos observados de presión real de vapor y los datos estimados por los diferentes entrenamientos de RNA *feedforward backpropagation*.

| Modelo 1. Arquitectura (Multilayer Perceptrón) | m      | b      | R <sup>2</sup> | RMSE   | MBE       |
|------------------------------------------------|--------|--------|----------------|--------|-----------|
| E1{Tmin}                                       |        |        |                |        |           |
| Ruiz Cortínez (1x4x1)                          | 0.9455 | 0.1095 | 0.9409         | 0.1906 | 0.0022    |
| Batequis (1x4x1)                               | 0.9293 | 0.1324 | 0.9291         | 0.2081 | 0.0012    |
| Santa Rosa 1 (1x4x1)                           | 0.9303 | 0.1397 | 0.9318         | 0.2102 | 0.0009    |
| Santa Rosa 2 (1x4x1)                           | 0.9226 | 0.1450 | 0.9193         | 0.2092 | 0.0005    |
| E2{Tmin, Tmax}                                 |        |        |                |        |           |
| Ruiz Cortínez (2x4x1)                          | 0.9534 | 0.0914 | 0.9487         | 0.1776 | -0.0002   |
| Batequis (2x4x1)                               | 0.9370 | 0.1217 | 0.9403         | 0.1912 | 0.0048    |
| Santa Rosa 1 (2x4x1)                           | 0.9366 | 0.1253 | 0.9391         | 0.1985 | -0.0009   |
| Santa Rosa 2 (2x4x1)                           | 0.9356 | 0.1215 | 0.9364         | 0.1854 | 0.0011    |
| E3{Tmin, HRmax}                                |        |        |                |        |           |
| Ruiz Cortínez (2x4x1)                          | 0.9623 | 0.0717 | 0.9553         | 0.1659 | -0.0025   |
| Batequis (2x4x1)                               | 0.9627 | 0.0713 | 0.9641         | 0.1481 | 0.0022    |
| Santa Rosa 1 (2x4x1)                           | 0.9514 | 0.0967 | 0.9533         | 0.1738 | -1.85E-05 |
| Santa Rosa 2 (2x4x1)                           | 0.9612 | 0.0728 | 0.9616         | 0.1444 | 0.0004    |
| E4{Tmin, Tmax, HRmin, HRmax}                   |        |        |                |        |           |
| Ruiz Cortínez (4x4x1)                          | 0.9983 | 0.0032 | 0.9960         | 0.0152 | -0.0002   |
| Batequis (4x4x1)                               | 0.9991 | 0.0015 | 0.9996         | 0.0142 | -0.0002   |
| Santa Rosa 1 (4x4x1)                           | 0.9989 | 0.0018 | 0.9996         | 0.0157 | -0.0004   |
| Santa Rosa 2 (4x4x1)                           | 0.9989 | 0.0021 | 0.9992         | 0.0206 | -4.35E-05 |

R<sup>2</sup>: Coeficiente de determinación; RMSE: Raíz cuadrada del cuadrado medio del error; MBE: Error medio sesgado; m: pendiente; b: intercepto; Tmin: Temperatura mínima; Tmax: Temperatura máxima; HRmin: Humedad relativa mínima; HRmax: Humedad relativa máxima; E: Escenario *i*-ésimo.

Cuadro 2. Estadísticos de prueba de ajuste entre los datos observados de presión real de vapor y los datos estimados por los diferentes entrenamientos de RNA *radial basis function*.

| Modelo 2. RNA <i>Radial basis function</i> | m      | b          | R <sup>2</sup> | RMSE     | MBE       |
|--------------------------------------------|--------|------------|----------------|----------|-----------|
| E1{Tmin}                                   |        |            |                |          |           |
| Ruiz Cortinez                              | 0.9393 | 0.1194     | 0.9393         | 0.1931   | 6.47E-06  |
| Batequis                                   | 0.9254 | 0.1384     | 0.9254         | 0.2136   | 2.76E-06  |
| Santa Rosa 1                               | 0.9302 | 0.1391     | 0.9301         | 0.2127   | 7.08E-06  |
| Santa Rosa 2                               | 0.9224 | 0.1450     | 0.9224         | 0.2050   | -1.3E-06  |
| E2{Tmin, Tmax}                             |        |            |                |          |           |
| Ruiz Cortínez                              | 0.9461 | 0.1061     | 0.9461         | 0.1819   | -1.27E-07 |
| Batequis                                   | 0.9344 | 0.1217     | 0.9343         | 0.2002   | 5.77E-07  |
| Santa Rosa 1                               | 0.9389 | 0.1217     | 0.9389         | 0.1989   | -2.94E-07 |
| Santa Rosa 2                               | 0.9282 | 0.1342     | 0.9281         | 0.1972   | 1.18E-06  |
| E3{Tmin, HRmax}                            |        |            |                |          |           |
| Ruiz Cortínez                              | 0.9538 | 0.0907     | 0.9539         | 0.1683   | -4.61E-06 |
| Batequis                                   | 0.9633 | 0.0680     | 0.9633         | 0.1497   | -1.23E-06 |
| Santa Rosa 1                               | 0.9522 | 0.0952     | 0.9522         | 0.1759   | -1.12E-06 |
| Santa Rosa 2                               | 0.9590 | 0.0767     | 0.9590         | 0.1491   | 1.84E-06  |
| E4{Tmin, Tmax, HRmin, HRmax}               |        |            |                |          |           |
| Ruiz Cortínez                              | 1.0000 | 2.67E-006  | 1.0000         | 0.0009   | 7.76E-07  |
| Batequis                                   | 1.0000 | 1.80E-008  | 1.0000         | 6.36E-05 | 7.25E-07  |
| Santa Rosa 1                               | 1.0000 | -4.01E-009 | 1.0000         | 7.49E-05 | -8.33E-07 |
| Santa Rosa 2                               | 1.0000 | -2.87E-008 | 1.0000         | 8.45E-05 | -7.88E-07 |

R<sup>2</sup>: Coeficiente de determinación; RMSE: Raíz cuadrada del cuadrado medio del error; MBE: Error medio sesgado; m: pendiente; b: intercepto; Tmin: Temperatura mínima; Tmax: Temperatura máxima; HRmin: Humedad relativa mínima; HRmax: Humedad relativa máxima; Ei: Escenario *i*-ésimo.

Al comparar los estadísticos,  $R^2$  y RMSE, del Cuadro 1 versus el Cuadro 2 se tiene que: en el E1 el Modelo 1 es ligeramente superior en las tres primeras estaciones. De igual manera, los Escenarios E2 y E3 del Modelo 1 son ligeramente mejores que los del Modelo 2 y en el último Escenario (E4) fue el Modelo 2 quien presentó mejor ajuste estadístico. En el Cuadro 3 se observa que los Modelos 3 y 5 tienen similares valores de  $R^2$ , los Modelos 6, 7 y 8 presentan  $R^2$  muy cercanos, y estos últimos tienen valores de  $R^2$  más altos que los Modelos 3 y 5 indicando que son modelos con mejor ajuste a los datos observados.

Comparando los RMSE del Modelo 3 ( $T_{min} - 2$ ) contra los Modelos del 5 al 8, el Modelo 3 es mejor en todos los casos en Batequis y Santa Rosa 2 (estaciones mas alejadas de la costa), esto confirma lo que se discutió previamente en las Figuras, además al contrastar el Modelo 7 con los Modelos 5, 6 y 8, estos últimos resultan ser mejores en las cuatro estaciones. Generalizando, de los modelos convencionales, el mejor modelo es el 5 al considerar los estadísticos de ajuste, le seguirían el Modelo 3, 6 y 8, y por último el Modelo 7, pero en la práctica todos ofrecen una buena alternativa y su selección esta en función de la información disponible.

Se puede decir que los RMSE y los MBE de los dos modelos de RNA tienden a estar mas cerca del cero que los RMSE y los MBE de los modelos convencionales; en particular el Modelo 5 de los convencionales muestra ser también un buen modelo de ajuste de la presión real de vapor de agua. Sin embargo las  $R^2$  para modelos convencionales y modelos de RNA mostraron tener valores mas o menos similares para todos los modelos, excepto para los modelos de RNA *feedforward backpropagation* y *radial basis function* con el mayor número de variables de entrada, que obtuvieron las  $R^2$  mas altas. Comparando de manera paralela al modelo RNA

Cuadro 3. Estadísticos de prueba de ajuste entre los datos observados de presión real de vapor de agua y los estimados por los modelos convencionales para las diferentes estaciones.

| Mejores modelos convencionales | m      | b       | R <sup>2</sup> | RMSE    | MBE     |
|--------------------------------|--------|---------|----------------|---------|---------|
| Modelo 3                       |        |         |                |         |         |
| Ruiz Cortínez                  | 0.9239 | -0.0857 | 0.9349         | 0.3088  | -0.2352 |
| Batequis                       | 0.9307 | 0.0030  | 0.9153         | 0.2600  | -0.1255 |
| Santa Rosa 1                   | 0.9405 | -0.1203 | 0.9203         | 0.3300  | -0.2388 |
| Santa Rosa 2                   | 0.9816 | -0.0532 | 0.9124         | 0.2408  | -0.0876 |
| Modelo 5                       |        |         |                |         |         |
| Ruiz Cortínez                  | 1.0325 | -0.0664 | 0.9349         | 0.2150  | -0.0024 |
| Batequis                       | 1.0402 | 0.0324  | 0.9153         | 0.2712  | 0.1069  |
| Santa Rosa 1                   | 1.0508 | -0.1048 | 0.9204         | 0.2521  | -0.0036 |
| Santa Rosa 2                   | 1.0966 | -0.0293 | 0.9124         | 0.3007  | 0.1511  |
| Modelo 6                       |        |         |                |         |         |
| Ruiz Cortínez                  | 0.9748 | 0.2772  | 0.9769         | 0.2569  | 0.2276  |
| Batequis                       | 0.9551 | 0.3219  | 0.9793         | 0.2646  | 0.2386  |
| Santa Rosa 1                   | 0.9738 | 0.2670  | 0.9751         | 0.2494  | 0.2149  |
| Santa Rosa 2                   | 0.9791 | 0.3262  | 0.9663         | 0.3176  | 0.2873  |
| Modelo 7                       |        |         |                |         |         |
| Ruiz Cortínez                  | 0.9827 | 0.2762  | 0.9755         | 0.27139 | 0.2422  |
| Batequis                       | 0.9640 | 0.3198  | 0.9785         | 0.2781  | 0.2531  |
| Santa Rosa 1                   | 0.9816 | 0.2659  | 0.9739         | 0.2636  | 0.2293  |
| Santa Rosa 2                   | 0.9904 | 0.3215  | 0.9653         | 0.3336  | 0.3036  |
| Modelo 8                       |        |         |                |         |         |
| Ruiz Cortínez                  | 0.9786 | 0.2689  | 0.9767         | 0.2563  | 0.2267  |
| Batequis                       | 0.9590 | 0.3136  | 0.9791         | 0.2637  | 0.2377  |
| Santa Rosa 1                   | 0.9775 | 0.2588  | 0.9752         | 0.2489  | 0.2141  |
| Santa Rosa 2                   | 0.9839 | 0.3171  | 0.9659         | 0.3178  | 0.2869  |

R<sup>2</sup>: Coeficiente de determinación; RMSE: Raíz cuadrada del cuadrado medio del error; MBE: Error medio sesgado; m: pendiente; b: intercepto.

*feedforward backpropagation* y al modelo *radial basis function*, este último muestra ligeramente mejor ajuste a los datos observados de acuerdo con los resultados de MBE presentados en los Cuadros 1 y 2.

### 3.3.1 Validación de los modelos

Se obtuvieron los índices estadísticos RMSE y el MBE (Cuadro 4) para un periodo de validación de 229 días, en las Figura 6, 7 y 8 se muestran únicamente las diferencias entre las estimaciones hechas con los Modelos 1, 3 y 5 y los datos observados de presión actual de vapor para las respectivas estaciones.

Al observar los RMSE y MBE del Cuadro 4 y las Figuras de la 6 a la 8, se define que de todos los modelos el que mejor pronostica a la presión actual de vapor de agua en todas las estaciones es el 2, E4; le sigue el 1, E4; y luego el 2 E3. De los modelos restantes el Modelo 3, es el que mayor error presentó en la validación, de todos los demás modelos convencionales se tienen errores equivalentes, por lo que por su simplicidad se recomendarían, principalmente el Modelo 5, que mostró consistencia en los dos conjuntos de datos (ajuste y validación), así como los Modelos 6, 7 y 8.

Con respecto a los modelos de RNA, se puede afirmar que entre mayor sea el número de variables de entrada es mejor la estimación de la presión real de vapor de agua, ya que el Modelo 2 E4 fue el que mejor aproximó a los datos observados; sin embargo los entrenamientos que contaron con una sola variable de entrada también presentaron un buen ajuste de los datos observados, lo cual indica simplicidad y mayor interés práctico. No hay que descartar los


Cuadro 4. RMSE y MBE obtenidos en la validación, de las diferentes estaciones y con los diferentes modelos

| Modelos | Estaciones    |         |          |           |              |           |              |         |
|---------|---------------|---------|----------|-----------|--------------|-----------|--------------|---------|
|         | Ruiz Cortínez |         | Batequis |           | Santa Rosa 1 |           | Santa Rosa 2 |         |
|         | RMSE          | MBE     | RMSE     | MBE       | RMSE         | MBE       | RMSE         | MBE     |
| 1, E1   | 0.2426        | -0.1480 | 0.2542   | -0.1247   | 0.2716       | -0.1569   | 0.3557       | -0.2712 |
| 1, E2   | 0.2291        | -0.1567 | 0.2487   | -0.1355   | 0.2553       | -0.1618   | 0.3924       | -0.3127 |
| 1, E3   | 0.2139        | -0.0956 | 0.1728   | -0.0402   | 0.2307       | -0.1169   | 0.2629       | -0.1705 |
| 1 E4    | 0.0212        | -0.0034 | 0.0253   | -0.0023   | 0.0195       | -0.0003   | 0.0972       | -0.0481 |
| 2, E1   | 0.2411        | -0.1460 | 0.2469   | -0.1117   | 0.2656       | -0.1470   | 0.3713       | -0.2780 |
| 2, E2   | 0.2287        | -0.1552 | 0.2519   | -0.1293   | 0.2464       | -0.1525   | 0.3705       | -0.2847 |
| 2, E3   | 0.2105        | -0.0950 | 0.1655   | -0.0237   | 0.2264       | -0.0925   | 0.2327       | -0.1361 |
| 2, E4   | 0.0011        | -0.0001 | 0.0001   | -1.11E-05 | 0.0002       | -2.76E-05 | 0.0003       | -0.0001 |
| 3       | 0.4307        | -0.3824 | 0.3173   | -0.2315   | 0.4484       | -0.3845   | 0.3873       | -0.3217 |
| 5       | 0.2291        | -0.1030 | 0.2301   | 0.0532    | 0.2707       | -0.0984   | 0.2143       | -0.0189 |
| 6       | 0.2357        | 0.2013  | 0.2549   | 0.2297    | 0.2120       | 0.1794    | 0.2861       | 0.2556  |
| 7       | 0.2542        | 0.2187  | 0.2747   | 0.2493    | 0.2306       | 0.1968    | 0.3089       | 0.2778  |
| 8       | 0.2372        | 0.2022  | 0.2563   | 0.2309    | 0.2137       | 0.1805    | 0.2891       | 0.2580  |


Ei: Escenario *i*-ésimo; RMSE: Raíz cuadrada del cuadrado medio del error; MBE: Error medio sesgado.

modelos empíricos convencionales, como el Modelo 5 ya que los valores RMSE son menores que los Modelos 1 y 2 en su escenario E1. Además el conocimiento de dichos modelos en sus variables describe al fenómeno en cuestión físicamente, y se refleja en los parámetros que integra a la ecuación, esto sirve de apoyo para conocer las variables de entrada en el entrenamiento de las


RNA para estimar, en este caso, la presión real de vapor de agua. En el ajuste, el Modelo 3 aproximó muy bien a los datos observados de las estaciones Batequis y Santa Rosa 2, pero ya en la validación el Modelo 3 presentó RMSE y MBE altos. En el ajuste el Modelo 5 aproximó bien a los datos observados debido a que, como ya se había explicado anteriormente, el Modelo 5 es considerado un buen estimador para estaciones donde la  $T_{\text{rocio}} \approx T_{\text{min}}$ ; en la validación este modelo fue el que menor error presentó para los modelos convencionales, con una buena aproximación a los datos observados y mantuvo un buen ajuste de los datos observados de manera general en las cuatro estaciones.



**Figura 6. Diferencias del Modelo 1 para nuevos conjuntos de datos en las diferentes estaciones.**



**Figura 7. Diferencias del Modelo 3 para nuevos conjuntos de datos en las diferentes estaciones.**



**Figura 8. Diferencias del Modelo 5 para nuevos conjuntos de datos en las diferentes estaciones.**

### 3.4 Conclusiones

De los modelos convencionales el que mejor aproximó a los datos observados de manera global fue el Modelo 5 ( $T_{min}$ ). De los dos modelos de RNA (*feedforward backpropagation* y *radial basis function*) el que realizó mejor aproximación a los datos observados de presión real de vapor de agua es la RNA *radial basis function* E4. De manera general las redes neuronales artificiales (RNA) muestran ser una herramienta robusta en la estimación de la presión real de vapor de agua, en sus Escenarios E4.

### 3.5 Literatura citada

- Allen G., R., Pereira L., S.; Raes D. and Smith M. 1998. Crop evapotranspiration Guidelines for computing crop water requirements. FAO Irrigation and drainage paper 56. Roma, 298 p.
- Baker J.M. 2005. Humidity. In: Hatfield, J.L. Baker, J.M. editors. Micrometeorology in Agricultural Systems. Agronomy Monograph No. 47. Madison, WI: ASA-CSA-SSSA, pp.31-42
- Bialobrzeski I. 2008. Neural modeling of relative air humidity. Computer and electronics in agriculture 60:1-7.
- Bosen, J.F. 1958. An approximation formula to compute relative humidity from dry bulb and dew point temperatures. Monthly Weather Rev. 86:486-486
- Cai Jiabing; Yiu Liu; Tingwu Lei y Luis Santos Pereira. 2007. Estimating reference evapotranspiration with the FAO Penman-Monteith equation using daily weather forecast messages. Agricultural and Forest Meteorology 145:22-35.
- Chen S., C.F. Cowan N., and P. Grant M. 1991. Orthogonal least squares learning algorithm for Radial Basis Functions networks. IEEE Transactions on neural networks 2:302-309
- Demuth H., Beale M. and Hagan M. 2008. Neural network toolbox™ 6. User's guide. 907 pp.

- Haykin S.S. 1994. Neural Networks. A comprehensive Foundation. MacMaster MacMillan Publishing Company, University, Hamilton, Ontario Canada, 696 p.
- He F.; Ma C.; Zhang J.; and Chen Y. 2007. Greenhouse air temperature and humidity prediction based on improved BP neural network and genetic algorithm. Springer-Verlag Berlin Heidelberg???
- Howell A. T. and A. D. Dusek. 1995. Comparison of vapor-pressure-deficit calculation methods-southern high plains. *Journal of Irrigation and Drainage Engineering* 121:191-198.
- Jensen M.E.; R. D. Burman and R. G. Allen. 1990. Evapotranspiration and Irrigation Water Requirements. ASCE manuals and reports on engineering practices No. 70. Published by American Society of Civil Engineers, New York, EUA. 360 pp.
- Linsley, R. K.; M. A. Kohler y J. L. H. Paulhus. 1988. Hidrología para ingenieros. Mac Graw-Hill/Interamericana de México, México. 386 pp.
- Mittal G.S. and Zhang J. 2003. Artificial neural network-based psychrometric predictor. *Biosystems Engineerig* 85:283-289.
- Murray F.W. 1967. On the computation of saturated vapor pressure. *Journal of Applied Meteorology* 6:203-204.
- Park J., and Sandberg J.W. 1991. Universal approximation using radial-basis-function networks. *Neural computation* 3:246-257.
- Pereira R. A. 2004. The Priestley-Taylor parameter and the decoupling factor for estimating reference evapotranspiration. *Agricultural and Forest Meteorology* 125:305-313.
- Sadler, E. J., and Evans, D. E. 1989. Vapor pressure deficit calculations and their effect on the combination equation. *Agricultural and Forest Meteorology* 49:55-80.
- Shank D.B., Hoogenboom G., and McClendon R.W. 2008a. Dew point temperature prediction using artificial neural networks. *Journal of applied meteorology and climatology* 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. *Applied artificial intelligence* 22:523-542.

Zhang G., Patuwo E. B., and Hu Y. M. 1998. Forecasting with artificial neural networks: The state of the art. *International Journal of forecasting*, 14:35-62.

## CAPÍTULO 4

### MODELOS CONVENCIONALES Y REDES NEURONALES ARTIFICIALES PARA ESTIMAR RADIACIÓN GLOBAL DIARIA EN EL DISTRITO DE RIEGO 075, SINALOA, MÉXICO<sup>1</sup>

#### RESUMEN

La dificultad de contar con datos de radiación global ha propiciado el desarrollo de modelos para su estimación, como la ecuación de Hargreaves que utiliza un mínimo de variables climatológicas, como temperatura máxima y mínima. El modelo de Prescott, derivado de Ångström, también requiere pocos datos, como la latitud, horas brillo sol y el valor de Angot. Los modelos de redes neuronales artificiales son herramientas eficientes para procesar en paralelo múltiples variables de entrada y estimar variables no lineales con una considerable precisión. El presente trabajo tuvo como propósito comparar la predicción de radiación global diaria para el Distrito de Riego 075 (DR 075), en los Mochis, estado de Sinaloa, México, con los modelos de Hargreaves, Prescott y las redes neuronales artificiales de retropropagación con alimentación hacia delante (*feedforward backpropagation*) y función de base radial (*radial basis function*). El modelo de Prescott con los coeficientes  $a$  y  $b$  calibrados, junto con la RNA multicapa con el algoritmo de retropropagación en sus escenarios E2 y E3, fueron los mejores estimadores de la radiación global diaria, pero ninguno fue mejor en todas las estaciones del DR 075.

**Palabras clave:** Base radial, predicción, radiación solar, retropropagación.

---

<sup>1</sup> Cervantes-Osornio R.; Arteaga-Ramírez R.; Vázquez Peña M. A.; Ojeda-Bustamante W.; Quevedo-Nolasco A. 2010. Enviado a la revista *Agrociencia*.

**CONVENTIONAL MODELS AND ITS COMPARISON WITH ARTIFICIAL NEURAL  
NETWORKS ESTIMATING DAIRY GLOBAL RADIATION IN THE IRRIGATION  
DISTRICT 075, SINALOA, MÉXICO**

**ABSTRACT**

It is difficult to have global radiation data it is been conductive to the development of models to its estimation, like the Hargreave's equation that uses a minimum of climatological variables, like maximum and minimum temperatures. Also Prescott model's derived from Angstrom requires a few data like latitude sunshine hours and the Angot value. The model of artificial neural network is an efficient tool to process in parallel multiple entry variables and to estimate nonlinear variables with notable accuracy. The present work had as a purpose to compare the prediction of dairy global radiation for the District irrigation 075 (DR 075) at Mochis Sinaloa State, Mexico, with the models of Hargreaves, Prescott and artificial neural networks feedforward backpropagation and radial basis function. The Prescott model with calibrated coefficients a and b, together with multilayer RNA with backpropagation algorithm on its sceneries E2 and E3 were the best estimators of dairy global radiation, but no one was the best on all stations of DR 075

**4.1 Introducción**

La radiación global diaria es un elemento importante en el proceso de fotosíntesis de las plantas, el cual implica la radiación solar y su conversión a energía química, en campo abierto o en invernaderos (Allen *et al.*, 1998). Además, es importante en el proceso de evapotranspiración

(Irmak *et al.*, 2003) y es una variable básica en los modelos de crecimiento de cultivos (Abraha y Savage, 2008).

La dificultad de obtener datos de radiación global diaria por el costo del equipo o por su sensibilidad (sensores) a ser dañado por los elementos meteorológicos, ha propiciado el desarrollo de modelos para estimar esta variable climática. Miller *et al.* (2008) probaron un método para estimar la radiación solar con datos de la duración de las horas brillo sol; Allen *et al.* (1998) propusieron el modelo de Ångström, modificado por Prescott, el cual relaciona la radiación solar con la radiación extraterrestre y la duración relativa de la insolación. También se reporta un método usando la serie de Fourier con datos de precipitación diaria (McCaskill, 1990). El modelo propuesto por Hargreaves, ajustado y validado, usa la temperatura máxima y la mínima (Allen *et al.*, 1998). Los modelos empíricos de Prescott y Hargreaves tienen la ventaja de usar un mínimo de datos climáticos, disponibles en la mayoría de las estaciones meteorológicas (Fortin *et al.*, 2008). Una desventaja que presenta el modelo de Prescott es la variabilidad que tienen las constantes de regresión  $a$  y  $b$  obtenidas empíricamente de acuerdo con Almorox *et al.* (2008), que determinaron modelos de regresión lineal simple para estimar la radiación global en Venezuela con dicha ecuación.

Las redes neuronales artificiales (RNA) son una herramienta importante para modelar sistemas no lineales y sistemas naturales (Tymvios *et al.*, 2008). El entrenamiento de una RNA consiste en determinar una matriz de parámetros de ponderación que se combinan linealmente con las variables de entrada, cuya finalidad es reducir el error cuadrático medio entre las respuestas estimadas y las observadas. Desde el punto de vista computacional, las RNA emulan a las neuronas del cerebro; ya que éstas trabajan en redes, tienen la habilidad para interconectarse y aprender del medio ambiente. Haykin (1994) indica que un modelo de RNA comúnmente utilizado es el perceptrón multicapa con interconexión hacia delante (*feedforward*), el cual se

aplica exitosamente para resolver diversos problemas de una forma supervisada con el algoritmo conocido como retropropagación. Otro modelo de red neuronal es el de base radial que, en su forma más básica, implica dos capas diferentes y es muy preciso en la estimación de sistemas no lineales. Recientemente, los modelos de RNA se han propuesto para estimar la radiación global, como en el trabajo de Alawi y Hinai (1998), o el planteamiento realizado por Elminir *et al.* (2005), el cual incluye un esquema de RNA multicapa con alimentación hacia delante para estimar los componentes de la radiación solar.

El objetivo del presente trabajo fue comparar la estimación de radiación global diaria realizada por los modelos de Hargreaves, Prescott calibrado localmente y Prescott con los coeficientes  $a$  y  $b$  que propone FAO 56, y la estimación hecha por los modelos de RNA multicapa de retropropagación con alimentación hacia delante (*feedforward backpropagation*) y el función de base radial (*radial basis function*).

## **4.2 Materiales y métodos**

### **4.2.1 Área de estudio y base de datos climática**

Las estaciones utilizadas en este estudio (cuatro) se ubican en el DR 075 Valle del Fuerte, en Los Mochis, Sinaloa, y sus nombres y claves son: Ruiz Cortínez (3843 II-2), Batequis (3546 II-3), AC Santa Rosa 1 (3765 III-1) y AC Santa Rosa 2 (9610 III-1). Las coordenadas geográficas (latitud, longitud y altitud) de cada una de ellas son: 28° 39' 15'', 108° 45' 20'' y 31 m; 25° 45' 49'', 108° 48' 41'' y 32 m; 25° 45' 03'', 108° 57' 21'' y 40 m y 25° 51' 16'', 108° 52' 03'' y 61 m.

La información climatológica usada pertenece a la base de datos de la red agroclimática de las estaciones automáticas del DR 075 y los datos son: radiación solar ( $\text{MJ m}^{-2} \text{ día}^{-1}$ ), humedad relativa (%), velocidad del viento a 2 m de altura ( $\text{m s}^{-1}$ ), precipitación (mm) y temperaturas

máximas y mínimas (°C). La información climatológica en la base de datos se almacena cada 15 min, por lo que se procesó diariamente, de abril de 1997 a mayo de 2001 y de junio a diciembre de 2001. El primer periodo se utilizó para el entrenamiento, validación y prueba de las RNA, y para el ajuste de los modelos convencionales; el segundo, para la validación de las RNA y los modelos convencionales. Los datos se preprocesaron en hojas de cálculo de Excell (Microsoft Office, 2007) y el software usado para el entrenamiento de las RNA fue el toolbox de redes neuronales para Matlab 7.0 (Demuth *et al.*, 2008); con este software también se obtuvieron gráficos.

#### 4.2.2 Obtención de datos faltantes

Con los datos de estaciones cercanas y su distancia, se calcularon los datos diarios faltantes mediante la Ecuación 1:

$$t_e = \frac{\sum_{i=1}^n \left(\frac{1}{d_i}\right) t_i}{\sum_{i=1}^n \left(\frac{1}{d_i}\right)} \quad (1)$$

donde,  $t_e$  es el dato estimado;  $d_i$  es la distancia (en km) entre la estación de referencia y la estación con el dato faltante;  $t_i$  es el dato de la estación que se toma como referencia y  $n$  es el número de estaciones cercanas o de referencia (Aparicio, 2009).

#### 4.2.3 Modelos utilizados en la estimación de la radiación global diaria

El cálculo de la radiación global diaria se efectuó por métodos tradicionales empíricos y el de redes neuronales artificiales (RNA). El Modelo 1 fue el de Hargreaves (Allen *et al.*, 1998) donde no se contempló una calibración previa para estimar la radiación global; para el Modelo 2 se utilizó el de Prescott, con los coeficientes  $a = 0.25$  y  $b = 0.5$  recomendados por Allen *et al.*

(1998); el Modelo 3 fue el de Prescott calibrado y se determinaron sus coeficientes  $a$  y  $b$  con vectores de 1498 datos; dichos coeficientes se obtuvieron con una regresión lineal simple; en el Modelo 4 se utilizó la RNA multicapa con el algoritmo de retropropagación, considerando los diferentes escenarios; para el Modelo 5 se usó la RNA función de base radial, de igual forma, considerando diferentes escenarios.

#### 4.2.4 Método de Hargreaves

Para estimar la radiación global se utilizó la ecuación de Hargreaves, de acuerdo con Allen *et al.* (1998):

$$R_s = k_{Rs} (T_{\max} - T_{\min})^{1/2} R_a \quad (2)$$

donde,  $T_{\max}$  es la temperatura máxima del aire, en °C;  $T_{\min}$  es la temperatura mínima del aire, en °C;  $k_{Rs}$  es un coeficiente de ajuste (0.16,..., 0.19), en °C<sup>-0.5</sup>; Allen *et al.* (1998) indican que para localizaciones costeras, como las estaciones ubicadas en el DR 075, situadas en la costa o cerca de una masa grande de tierra y donde las masas de aire están influenciadas por un cuerpo de agua cercano,  $k_{Rs} \approx 0.19$ ;  $R_a$  es la radiación extraterrestre, en MJ m<sup>-2</sup> día<sup>-1</sup>; esta variable de acuerdo con Allen *et al.* (1998) se calculó con la ecuación siguiente:

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

donde  $d_r = 1 + 0.033 \cos\left(J \frac{2\pi}{365}\right)$  es la distancia relativa inversa Tierra-Sol;  $J$  es el número de día en el año;  $\omega_s = \arccos[-\tan(\varphi) \tan(\delta)]$  es el ángulo de radiación a la puesta del sol, en radianes;  $\varphi$  es la latitud positiva (hemisferio norte), en radianes;  $\delta = 0.409 \left[ \sin\left(\frac{2\pi}{365} J - 1.39\right) \right]$  es la declinación solar en radianes.

#### 4.2.5 Método de Prescott

La Ecuación 4 (Allen *et al.*, 1998) usada para calcular la radiación es:

$$R_s = [a + b(n/N)] R_a \quad (4)$$

donde,  $R_s$  es la radiación solar o de onda corta, en  $\text{MJ m}^{-2} \text{ día}^{-1}$ ;  $n$  es la duración real de la insolación (en horas), pero como no se tuvo este dato se estimó de acuerdo con la World Meteorological Organization (WMO, 1996) y Linacre (1992) quienes proponen que si en una hora se tiene un valor mayor de  $120 \text{ W m}^{-2}$ , entonces existe una hora brillo sol;  $N$  es la duración máxima posible de la insolación, en horas;  $R_a$  es la radiación extraterrestre, en  $\text{MJ m}^{-2} \text{ día}^{-1}$ ,  $a$  y  $b$  son constantes de regresión obtenidas por calibración; cuando no se tienen datos para obtener  $a$  y  $b$ , Allen *et al.* (1998) recomiendan usar valores de  $a = 0.25$  y  $b = 0.5$ ;  $N$  se calculó con la siguiente ecuación:

$$N = \frac{24}{\pi} \omega_s \quad (5)$$

#### 4.2.6 RNA multicapa con el algoritmo de retropropagación y función de base radial

Para estimar la radiación global diaria se usaron dos tipos de RNA: la red perceptrón multicapa con el algoritmo de retropropagación con alimentación hacia delante y la RNA función de base radial.

Se utilizó el algoritmo retropropagación en la RNA multicapa donde el vector de pesos se ajusta para los valores dados de los vectores de entrada, el procedimiento es el siguiente:

1. Inicialización. Determinar la estructura de la red y los valores iniciales de los pesos.
2. Seleccionar el vector de entradas y verificar el error promedio.
3. Presentar un patrón de entrenamiento.
4. Computación hacia delante.
5. Computación hacia atrás.
6. Siguiendo

época. El modelo de RNA base radial consiste de los nodos de entradas, la capa oculta de una dimensión amplia y la capa de salida que suministra la respuesta a la red (Haykin, 1994).

Todos los entrenamientos de la RNA multicapa con el algoritmo retropropagación fueron con una sola capa oculta, ensayando con diferente número de neuronas en ésta, se utilizó la función de transferencia tangente-sigmoidea (*tansig*), y se uso el algoritmo Levenberg-Marquardt; para el entrenamiento se ocupo 50 % de los datos, para la validación 25 % y para la prueba 25 %. En la RNA función de base radial se utilizó dicha red en Matlab denominada exacta, declarada con el código  $\{net=newrbe(P,T,spread)\}$ , donde  $P$  son los vectores de entradas,  $T$  es el target o los valores observados de radiación global y  $spread$  es la constante de extendido para la capa base radial; esta constante tomó valores de 100 y 1000. Para la validación de los cinco modelos se utilizaron los datos de los últimos 229 días del año 2001. Se utilizaron diferentes combinaciones de las variables de entrada para ambos tipos de RNA.

#### 4.2.7 Evaluación estadística de los resultados de los modelos de estimación

Los estadísticos de prueba considerados en esta investigación fueron el error estándar promedio o raíz cuadrada del cuadrado medio del error (*RMSE*), el cual se calculó con la siguiente ecuación:

$$RMSE = \left( \frac{\sum_{i=1}^N (a_i - t_i)^2}{N} \right)^{1/2} \quad (6)$$

el error medio (*MBE*), llamado también sesgo o desviación, calculado con el fin de caracterizar la bondad de cada uno de los modelos, dado por:

$$MBE = \frac{\sum_{i=1}^N (a_i - t_i)}{N} \quad (7)$$

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

$$R^2 = \frac{\left[ \sum_{i=1}^N (a_i - \bar{a})(t_i - \bar{t}) \right]^2}{\left[ \sum_{i=1}^N (a_i - \bar{a})^2 \right] \left[ \sum_{i=1}^N (t_i - \bar{t})^2 \right]} \quad (8)$$

donde  $a_i$  es el dato estimado por el modelo,  $t_i$  es el dato observado,  $\bar{a}$  es el promedio de los datos estimados por el modelo,  $\bar{t}$  es el promedio de los datos observados y  $N$  es el número total de observaciones (Alexandris *et al.*, 2006; Tabari, 2009).

### 4.3 Resultados y discusión

Se obtuvieron los estadísticos de ajuste de los modelos:  $R^2$ , el error promedio ( $MBE$ ) y la raíz cuadrada media del cuadrado medio del error ( $RMSE$ ), entre los vectores de datos observados, y los datos estimados con los tres primeros modelos, los resultados se observan en el Cuadro 1. Spokas *et al.* (2006), en un estudio que realizaron para ajustar a la radiación solar horaria con el modelo de Hargreaves, reportan que obtuvieron un  $R^2$  de 0.92, a diferencia del obtenido por el Modelo 1 en este estudio que fue de 0.74. Esto se debió a que se trabajó con el modelo, como lo propone Hargreaves (1994), pero si se quiere mejorar su ajuste se debe calibrar el coeficiente  $k_{RS}$ , como lo propone Samani (2000), y el exponente 0.5 de la diferencia (Trajnovic, 2007). Con respecto al Modelo 3, las  $R^2$  varían entre 0.80 y 0.83, este último resultado es similar con los valores obtenidos por Liu *et al.* (2009) para la calibración de los coeficientes usando datos diarios, ya que sus valores variaron entre 0.61 y 0.89 con una media de 0.82. Por sus estadísticos de ajuste, el mejor fue el Modelo 3, de Prescott con las calibraciones de  $a$  y  $b$ . Lo anterior

concuenda con lo afirmado por Podestá *et al.* (2004) que aseveran que si se cuenta con el dato de horas brillo sol la ecuación de Prescott puede usarse exitosamente para estimar la radiación solar diaria, no obstante que ellos calibraron los coeficientes mensualmente. De igual forma, el Modelo 3 en cada una de las estaciones, presenta los errores promedios mínimos. Almorox *et al.* (2008), Meza y Varas (2000), estimaron la radiación global mensual con la ecuación de Prescott y encontraron que este modelo es una herramienta conveniente si los coeficientes se calibran, corroborando lo encontrado en este trabajo.

En el Cuadro 2 se observan los resultados de los estadísticos de prueba entre el vector de datos observados denominado como target y los datos estimados por el modelo de red neuronal artificial tipo retropropagación con alimentación hacia delante con los diferentes escenarios de variables de entradas. Hay que mencionar que se entrenó con diversas combinaciones de las variables de entrada a partir de tres variables, por cuestiones de espacio solo se muestran los mejores entrenamientos. Esto es el Escenario 1 (E1) con cuatro variables de entrada, cuatro neuronas en la capa oculta y la salida (4 x 4 x 1), el E2 (5 x 6 x 1), y el E3 (8 x 8 x 1). Alawi y Hinai (1998), con datos mensuales, encontraron un valor de  $R^2$  de 0.98 en la predicción de la radiación global con siete variables de entrada (localización, mes, presión media atmosférica, Temperatura media, presión media de vapor, humedad relativa, velocidad del viento y horas brillo sol), valor más alto que los encontrados en este trabajo, los cuales variaron de 0.83 a 0.87, pero con datos diarios. La variable horas brillo sol, como ya lo afirmó Benghanem *et al.* (2009), ocasiona que mejore la exactitud de la estimación de la radiación global diaria por medio de este modelo, ya que en otros experimentos de entrenamientos, en cuyas variables de entrada no participó la variable horas brillo sol, no se obtuvieron tan buenos ajustes como los expuestos en el Cuadro 2, en donde participó dicha variable. También se observa que aumentando el número de

Cuadro 1. Estadísticos de prueba entre la radiación medida y la estimada por los métodos de Hargreaves, Prescott calibrado y Prescott con las constantes propuestas por Allen *et al.* (1998), para las diferentes estaciones.

| Método                                      | m      | b      | R <sup>2</sup> | RMSE   | MBE    |
|---------------------------------------------|--------|--------|----------------|--------|--------|
| Modelo 1. Hargreaves                        |        |        |                |        |        |
| Ruiz Cortínez                               | 0.7599 | 8.5554 | 0.5525         | 5.2880 | 3.4785 |
| Batequis                                    | 0.7933 | 8.4120 | 0.5418         | 5.7672 | 4.1594 |
| Santa Rosa 1                                | 0.7294 | 9.2775 | 0.4531         | 5.8686 | 3.6963 |
| Santa Rosa 2                                | 0.8966 | 7.6743 | 0.5485         | 6.9439 | 5.6597 |
| Modelo 2. Prescott ( $a = 0.25$ $b = 0.5$ ) |        |        |                |        |        |
| Ruiz Cortínez                               | 0.7188 | 6.9854 | 0.7276         | 3.0505 | 1.0398 |
| Batequis                                    | 0.7356 | 6.9480 | 0.7125         | 3.2064 | 1.5082 |
| Santa Rosa 1                                | 0.7263 | 7.1385 | 0.7154         | 3.2409 | 1.4948 |
| Santa Rosa 2                                | 0.7477 | 7.1558 | 0.6696         | 3.6324 | 2.2417 |
| Modelo 3. Prescott calibrado                |        |        |                |        |        |
| Ruiz Cortínez                               | 0.8784 | 2.6170 | 0.8288         | 2.2934 | 0.0448 |
| Batequis                                    | 0.8805 | 2.4996 | 0.8206         | 2.2589 | 0.0416 |
| Santa Rosa 1                                | 0.8723 | 2.6706 | 0.8163         | 2.3335 | 0.0369 |
| Santa Rosa 2                                | 0.8667 | 2.6721 | 0.7955         | 2.2538 | 0.0759 |

R<sup>2</sup>, coeficiente de determinación; RMSE, raíz cuadrada del cuadrado medio del error (MJ m<sup>-2</sup> d<sup>-1</sup>); MBE, error promedio sesgado (MJ m<sup>-2</sup> d<sup>-1</sup>), m, pendiente; b, intercepto.

Cuadro 2. Estadísticos de prueba de los escenarios entre los datos observados y los estimados por el Modelo 4 de la RNA multicapa con el algoritmo retropropagación, para las diferentes estaciones.

| Modelo 4. RNA multicapa                  | m      | b      | R <sup>2</sup> | RMSE   | MBE     |
|------------------------------------------|--------|--------|----------------|--------|---------|
| E1{Tmin, Tmax, HR, HBS}                  |        |        |                |        |         |
| Ruiz Cortínez (4x4x1)                    | 0.8448 | 3.2889 | 0.8567         | 2.0812 | 0.0070  |
| Batequis (4x4x1)                         | 0.8393 | 3.2836 | 0.8493         | 2.0466 | -0.0231 |
| Santa Rosa 1 (4x4x1)                     | 0.8348 | 3.4327 | 0.8281         | 2.2351 | 0.0254  |
| Santa Rosa 2 (4x4x1)                     | 0.8268 | 3.3969 | 0.8321         | 2.0109 | 0.0229  |
| E2{Tmin, Tmax, HR, HBS, VA}              |        |        |                |        |         |
| Ruiz Cortínez (5x6x1)                    | 0.8686 | 2.7500 | 0.8639         | 2.0266 | -0.0295 |
| Batequis (5x6x1)                         | 0.8239 | 3.6038 | 0.8521         | 2.0331 | -0.0201 |
| Santa Rosa 1 (5x6x1)                     | 0.8547 | 2.9057 | 0.8431         | 2.1376 | -0.0915 |
| Santa Rosa 2 (5x6x1)                     | 0.8450 | 2.9931 | 0.8489         | 1.9073 | -0.0264 |
| E3{DJ, Tmin, Tmax, PMV, HR, VV, HBS, VA} |        |        |                |        |         |
| Ruiz Cortínez (8x8x1)                    | 0.8780 | 2.5360 | 0.8703         | 1.9797 | -0.0449 |
| Batequis (8x8x1)                         | 0.8457 | 3.0619 | 0.8508         | 2.0389 | -0.1134 |
| Santa Rosa 1 (8x8x1)                     | 0.8631 | 2.8715 | 0.8521         | 2.0734 | 0.0483  |
| Santa Rosa 2 (8x8x1)                     | 0.8527 | 2.8649 | 0.8530         | 1.8804 | -0.0053 |

E, escenario; DJ, día juliano; Tmin, temperatura mínima; Tmax, temperatura máxima; HR, humedad relativa; VA, valor de Angot; HBS, horas brillo sol; PMV, presión media de vapor; VV, velocidad del viento; m, pendiente; b, intercepto; R<sup>2</sup>, coeficiente de determinación; RMSE, raíz cuadrada del cuadrado medio error (MJ m<sup>-2</sup>d<sup>-1</sup>); MBE, error promedio sesgado (MJ m<sup>-2</sup> d<sup>-1</sup>).

Cuadro 3. Estadísticos de prueba para diferentes escenarios de entrenamiento entre los datos medidos y los estimados por el Modelo 5 RNA de base radial para las estaciones Ruiz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2.

| Modelo 5. RNA <i>Radial Basis Function</i> | m      | b      | R <sup>2</sup> | RMSE   | MBE       |
|--------------------------------------------|--------|--------|----------------|--------|-----------|
| E1{Tmin, Tmax, HBS}                        |        |        |                |        |           |
| Ruiz Cortínez                              | 0.8640 | 2.8760 | 0.8639         | 2.1002 | -0.0019   |
| Batequis                                   | 0.8631 | 2.8164 | 0.8630         | 2.0113 | 7.82E-08  |
| Santa Rosa 1                               | 0.8601 | 2.8846 | 0.8601         | 2.1567 | 4.58E-06  |
| Santa Rosa 2                               | 0.8561 | 2.8039 | 0.8559         | 1.9515 | 6.45E-05  |
| E2{Tmin, Tmax, HR, HBS, VV}                |        |        |                |        |           |
| Ruiz Cortínez                              | 0.8538 | 3.0888 | 0.8539         | 1.9564 | -4.08E-05 |
| Batequis                                   | 0.8543 | 2.9978 | 0.8543         | 1.9139 | 0.0007    |
| Santa Rosa 1                               | 0.8398 | 3.3029 | 0.8398         | 2.0234 | 0.0008    |
| Santa Rosa 2                               | 0.8417 | 3.0828 | 0.8418         | 1.8668 | 0.0002    |
| E3{DJ, Tmin, Tmax, PMV, HR, VV, HBS, VA}   |        |        |                |        |           |
| Ruiz Cortínez                              | 0.8779 | 2.5809 | 0.8780         | 1.9200 | -0.0021   |
| Batequis                                   | 0.8756 | 2.5605 | 0.8755         | 1.8589 | 1.15E-06  |
| Santa Rosa 1                               | 0.8664 | 2.7534 | 0.8664         | 1.9694 | -0.0014   |
| Santa Rosa 2                               | 0.8646 | 2.6367 | 0.8645         | 1.8052 | -0.0005   |

DJ, día juliano; Tmin, temperatura mínima; Tmax, temperatura máxima; HR, humedad relativa; VA, valor de Angot; HBS, horas brillo sol; PMV, presión media de vapor; VV, velocidad del viento; R<sup>2</sup>, coeficiente de determinación; RMSE, raíz cuadrada del cuadrado medio del error; MBE, error medio del sesgo; m, pendiente, b, intercepto.

variables de entrada en los Escenarios 2 y 3 no se contribuye demasiado a que aumente el coeficiente de determinación, ni que disminuya el RMSE; pero se observa que en este ajuste de parámetros, las  $R^2$  obtenidas por el modelo 4 resultan ser aún mayores que las obtenidas por el Modelo 3. Ahora bien, en el Cuadro 3 se observan los resultados de los estadísticos para el ajuste del Modelo 5, éstos son mejores que los que presentan el ajuste del Modelo 4 (Cuadro 2). Hay que notar que con un mínimo de tres variables de entrada en el Modelo 5 los estadísticos de ajuste para el E1 se encuentran dentro de los criterios aceptables dados por Allen *et al.* (1998); además, que en los Escenarios 2 y 3, aun con el incremento en el número de variables de entrada, sólo se genera cambios mínimos en el  $R^2$  y en el RMSE.

Se eligió graficar los pronósticos de tres modelos: el 5 E1, con las variables mínimas; el 3, con los coeficientes calibrados  $a$  y  $b$ ; y el 1, contra los datos observados del periodo de junio a diciembre de 2001 (229 días). Esto se presenta en las Figuras 1, 2, 3 y 4 para las respectivas estaciones. En las Figuras 1 a 4, el Modelo 1 sobreestima, de forma considerable, los valores observados de radiación global diaria. Los RMSE obtenidos para este nuevo periodo con el Modelo 1 para Ruiz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2 fueron de 9.53, 6.97, 4.83 y 7.35, respectivamente; con respecto al Modelo 3, los RMSE obtenidos para las estaciones Ruiz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2 fueron de 1.99, 2.72, 2.10 y 2.58 respectivamente. Éste pronostica los datos de radiación global diaria de forma óptima, con respecto al modelo 5 E1 con las variables de entrada temperatura mínima, máxima y horas brillo sol; los RMSE obtenidos fueron de 2.71, 2.87, 2.07 y 2.75. Se observa que el Modelo 3 pronostica mejor en tres de las cuatro estaciones. Existen periodos en donde se observa en las figuras mejor ajuste de los datos pronosticados con el Modelo 3 y los datos observados, que con el Modelo 5 E1, prueba de ellos son los RMSE; los RMSE obtenidos para este nuevo periodo de datos con el Modelo 3 indican una predicción con un mejor ajuste a los datos observados en las




Figura 1. Predicción de la radiación global para la estación Ruíz Cortínez con tres modelos.




Figura 2. Predicción de la radiación global para la estación Batequis con tres modelos.




Figura 3. Predicción de la radiación global para la estación Santa Rosa 1 con tres diferentes modelos.




Figura 4. Predicción de la radiación global para la estación Santa Rosa 2 con tres diferentes modelos.

estaciones Ruiz Cortínez, Batequis y Santa Rosa 2 que con el Modelo 5 E1, no así en la estación Santa Rosa 1, donde existió un mejor ajuste por parte del Modelo 5 E1. Lo anterior coincide con

las conclusiones de Tymvios *et al.* (2008) quienes afirman que algunas veces la RNA función de base radial sobreajusta las estimaciones para algunas estaciones. Esto se observa con los RMSE obtenidos para el Modelo 5 E2 los cuales fueron de 2.83, 2.97, 2.13 y 2.65 y para el Modelo 5 E3 con valores de 2.79, 2.98, 3.70 y 2.83. Los RMSE obtenidos para el Modelo 4 E1 fueron: 2.34, 2.87, 2.20 y 2.73, para el Modelo 4 E2, de 2.64, 2.59, 1.99 y 2.73; para el Modelo 4 E3, de 2.68, 2.98, 2.03 y 2.46. Hay que observar que los RMSE obtenidos para este periodo de validación indican un mejor ajuste del Modelo 4 E3 en la estación Santa Rosa 1 y Santa Rosa 2 que el Modelo 3. El Modelo 4 E2 obtuvo estadísticos de prueba de mejor ajuste en las estaciones Batequis y Santa Rosa 1 que el Modelo 3 y los resultados de RMSE son semejantes a los encontrados por Elizondo *et al.* (1994) quienes realizaron un pronóstico de la radiación global diaria con una RNA multicapa retropropagación con alimentación hacia delante y encontraron valores de RMSE entre 2.92 y 3.64. Únicamente en la estación Santa Rosa 1 el Modelo 5 E1 con un mínimo de variables de entrada, ejecuta mejor la tarea de estimar los datos observados que el Modelo 4 E1. En general, se obtuvieron RMSE mejores en los escenarios del Modelo 4 que en los escenarios del Modelo 5, esto reafirma una de las observaciones de Sfetsos y Coonick (2000), quienes compararon varios modelos para pronosticar la radiación solar horaria incluyendo un modelo con alimentación hacia delante(*feedforward*), un modelo función de base radial y un Elman recurrente, y concluyeron que la RNA multicapa con alimentación hacia delante (*feedforward*), usando el algoritmo Levenberg-Marquardt, fue el óptimo en la predicción. Finalmente, se puntualiza que en este periodo de validación el Modelo 3 se ajusta mejor a los datos observados, le sigue el de RNA retropropagación con alimentación hacia delante y, por último, el modelo RNA función base radial.

Las redes neuronales muestran tener un buen grado de precisión al estimar la radiación global diaria, y con un mínimo de variables son excelentes estimadores y predictores de la radiación

global diaria en comparación con el modelo de Hargreaves. Sin embargo, con respecto al modelo de Prescott calibrado, éste es un excelente estimador de la radiación global diaria, puesto que en dos de cuatro estaciones, con los datos del periodo de validación, presenta un mejor ajuste que los modelos de RNA. De las dos redes neuronales, la multicapa con el algoritmo de retropropagación y la de función de base radial, la RNA de predicción más acertada de la variable radiación global resultó ser la RNA multicapa con el algoritmo de retropropagación. En relación con la RNA función de base radial, las estimaciones para un nuevo periodo de datos sobreestimaron los datos observados en el periodo de validación, razón por la cual es importante no ignorar a los modelos convencionales para estimar la radiación global diaria, específicamente el modelo de Prescott calibrado localmente con los coeficientes  $a$  y  $b$ . Sí se incrementa el número de variables disponibles para realizar la predicción, aumenta la exactitud de ésta, pero se puede afirmar que si sólo se dispone únicamente de los datos de temperaturas mínima, máximas y horas brillo sol en una estación, esto resulta ser suficiente para estimar la radiación global diaria con un considerable grado de precisión con la RNA función de base radial. De esto se desprende que la variable horas brillo sol resulta ser una variable esencial en la estimación de la radiación global diaria, de allí la conveniencia de contar con datos de dicha variable.

#### **4.4 Conclusiones**

Las dos redes neuronales artificiales realizaron un mejor pronóstico que el modelo de Hargreaves, sin embargo la RNA multicapa de alimentación hacia delante con el algoritmo de retropropagación fue mejor en el pronóstico de los datos observados que la RNA función de base radial, debido a que esta RNA al aumentar el número de variables, no mejoró su pronóstico.

El modelo de Prescott, con los coeficientes calibrados localmente ( $a$  y  $b$ ), y la RNA multicapa de alimentación hacia delante con el algoritmo de retropropagación, en sus Escenarios E2 y E3, fueron los modelos que mejor pronosticaron la radiación global diaria.

#### 4.5 Literatura citada

- Abraha, M., G., and M. Savage J. 2008. Comparison of estimates of daily solar radiation from air temperature range for application in crop simulations. *Agric. For. Meteorol.* 148:401-416.
- Alawi, S., M., and H.A. Hinai. 1998. An ANN-based approach for predicting global radiation in locations with no direct measurements instrumentation. *Renewable Energy* 14:199-204.
- Alexandris, S., P. Kerkides, and A. Liakatas. 2006. Daily reference evapotranspiration estimates by the “Copais” approach. *Agric. Water Manage.* 82:371-386.
- Allen, G., R., L. Pereira S., D. Raes, and M. Smith. 1998. Crop evapotranspiration Guidelines for computing crop water requirements. FAO Irrigation and drainage paper 56. Roma, 298 p.
- Almorox, J., M. Benito, and C. Hontoria 2008. Estimation of global solar radiation in Venezuela. *Interciencia* 33:280-283.
- Aparicio M., F. J. 2009. Fundamentos de Hidrologia de superficie. Ed. Limusa, México. 291 p
- Benghanem, M., A. Mellit, and S. N. Alamri. 2009. ANN-based modeling and estimation of daily global solar radiation data: A case study. *Energy Conversion Manage.* 50:1644-1655.
- Demuth, H., M.Beale, and M.Hagan. 2008. Neural network toolbox™ 6. User’s guide. 907 p.
- Elizondo, D., G. Hoogenboom, and R.W. McClendon. 1994. Development of a neural network model to predict daily solar radiation. *Agric. For. Meteorol.* 71:115-132.
- Elminir, K., H., F. Areed F., and T. Elsayed S. 2005. Estimation of solar radiation components incident on Helwan site using neural networks. *Solar Energy* 79: 270-279.

- Fortin, G., J., F. Anctil, L. Parent, and M.A. Bolinder. 2008. Comparison of empirical daily surface incoming solar radiation models. *Agric. For. Meteorol.* 148:1332-1340.
- Hargreaves, G., H. 1994. Defining and using reference evapotranspiration. *J. Irrigation and Drainage Eng. ASCE* 120:1132-1139
- Haykin, S., S. 1994. *Neural Networks. A comprehensive Foundation.* MacMaster MacMillan Publishing Company, University, Hamilton, Ontario Canada, 696 p.
- Irmak, S., A. Irmak, R. Allen G., and J. Jones W. 2003. Solar and net radiation-based equations to estimate reference evapotranspiration in humid climates. *J. Irrigation and Drainage Eng. ASCE* 129: 336- 347.
- Linacre, E. 1992. *Climate Data and Resources. A Reference and Guide.* British Library Cataloguing in Publication Data. Pp: 170-172
- Liu, X., X. Mei, Y. Li, Y. Zhang, Q. Wang, J. R. Jensen, and J. R. Porter. 2009. Calibration of the Angström-Prescott coefficients ( $a, b$ ) under different time scales and their impacts in estimating global solar radiation in the Yellow River basin. *Agric. For. Meteorol.* 149:697-710.
- McCaskill, R., M. 1990. An efficient method for generation of full climatological records from daily rainfall. *Austr. J. Agric. Res.* 41:595-602.
- Meza, F., and E. Varas. 2000. Estimation of mean monthly solar global radiation as a function of temperature. *Agr. Forest. Meteorol.* 100:231-241.
- Miller, D., G., M. Rivington, K.B. Matthews, K. Buchan, and G. Bellocchi. 2008. Testing the spatial applicability of the Johnson-Woodward method for estimating solar radiation from sunshine duration data. *Agr. Forest. Meteorol.* 148: 466-480.
- Podestá, G., P., L. Nuñez, C. A. Villanueva, and M. A. Skansi. 2004. Estimating daily solar radiation in the Argentine Pampas. *Agr. Forest. Meteorol.* 123:41 -53.

- Samani, Z. 2000. Estimating solar radiation and evapotranspiration using minimum climatological data. *J. Irrig. Drain. E. ASCE* 126:265-267.
- Sfetsos, A., and A.H. Coonick. 2000. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. *Sol. Energy* 68: 169-178.
- Spokas, K., and F. Forcella. 2006. Estimating hourly incoming solar radiation from limited meteorological data. *Weed Sci.* 54:182-189.
- Tabari, H. 2009. Evaluation of reference crop evapotranspiration equations in various climates. *Water Resour. Manag.* 24:2311-2337
- Trajkovic, S. 2007. Hargreaves versus Penman-Monteith under humid conditions. *J. Irrig. Drain. E. ASCE* 133:38-42
- Tymvios, F.S., S.C. Michaelides, and C.S. Skouteli. 2008. Estimation of surface solar radiation with artificial neural networks. *In: Bodescu V. (ed). Modeling Solar Radiation at the Earth's Surface. Recent Advances. Heidelberg Berlin, 2008, Springer. Pp: 221-256.*
- World Meteorological Organization. 1996. Guide to Meteorological instruments and methods of observations, No.8. Sixth edition.

## CAPÍTULO 5

### HARGREAVES, PRIESTLEY-TAYLOR Y REDES NEURONALES ARTIFICIALES EN LA ESTIMACIÓN DE LA EVAPOTRANSPIRACIÓN DE REFERENCIA<sup>1</sup>

#### RESUMEN

Resulta costoso medir directamente la evapotranspiración de referencia a través de un lisímetro, esto ha propiciado el desarrollo de modelos para estimar dicha variable, y puesto que no se contaron con datos medidos directamente de lisímetro se utilizó el método de Penman-Monteith modificado por la FAO para obtener la evapotranspiración de referencia observada. La importancia de esta variable radica en estimar con anticipación las necesidades de riego de los cultivos para distribuir de manera eficiente los volúmenes de agua, y resulta ser también un elemento importante en la modelación de cultivos. El objetivo del presente trabajo fue realizar una comparación de modelos empíricos como el de Hargreaves, Hargreaves calibrado y Priestley y Taylor con un modelo de red neuronal artificial de función de base radial (*RBF*) en la estimación de la evapotranspiración de referencia. Las estimaciones de la evapotranspiración de referencia fueron evaluadas en cuatro estaciones climáticas del Distrito 075, Valle del Fuerte en Sinaloa, México, se obtuvieron estadísticos de prueba para evaluar las estimaciones hechas por los diferentes modelos, encontrando que las redes neuronales artificiales función de base radial en un escenario con cuatro variables de entrada resulta ser un estimador de la evapotranspiración de referencia de forma exitosa.

**Palabras clave:** Función de base radial, Hargreaves, modelos, necesidades de agua, Priestley y Taylor, pronóstico.

---

<sup>1</sup> Cervantes-Osornio R.; Arteaga-Ramírez R.; Vázquez Peña M. A.; Ojeda-Bustamante W.; Quevedo-Nolasco A. 2010. Enviado a la revista *Ingeniería, Investigación y Tecnología*.

## HARGREAVES, PRIESTLEY-TAYLOR AND ARTIFICIAL NEURAL NETWORK IN THE ESTIMATION OF THE REFERENCE EVAPOTRANSPIRATION

### ABSTRACT

Directly measuring evapotranspiration accurately through a lysimeter is difficult, this has led to the development of models to estimate this variable, and because of data were not directly measured by lysimeter, it was used method of Penman-Monteith modified by FAO to obtain the reference evapotranspiration observed. The importance of this parameter lies in estimating in advance the need for irrigation of crops to efficiently distribute water volumes, and also it results to be an important parameter in crop modeling. The aim of this study was a comparison of empirical models such as Hargreaves, Hargreaves calibration, Priestley and Taylor with an artificial neural network model of radial basis function (*RBF*) in the estimation of reference evapotranspiration. Evapotranspiration's estimates were evaluated in four seasons of District 075, Valle del Fuerte in Sinaloa, México, test statistics were obtained to evaluate the estimates made by different models, finding that artificial neural networks radial basis function with an scenery of four entry variables prove to be an estimator of reference evapotranspiration successfully.

**Key words:** *Basis radial function*, Hargreaves, models, water necessities, Priestley and Taylor, forecasting.

### 5.1 Introducción

El método Penman-Monteith propuesto por la Organización de las Naciones Unidas para la alimentación en el boletín FAO 56 es el único método estándar recomendado para el cálculo de la evapotranspiración de referencia ( $ET_0$ ), éste requiere datos de diversas variables climáticas, (Allen *et al.*, 1998). La evapotranspiración es la principal componente del ciclo hidrológico, por

lo que resulta necesario conocerla con anticipación para estimar las necesidades de agua de los cultivos para realizar una planeación acertada de los calendarios de riego y distribución del recurso agua de manera adecuada, (Jensen *et al.*, 1990; Ojeda, 2004). Tales variables climáticas que requieren ser conocidas e influyen en la evapotranspiración son: la temperatura del aire, humedad atmosférica, radiación solar y velocidad del viento. Debido a que no todas estas variables están disponibles en cualquier estación meteorológica han sido propuestos diferentes modelos para estimar la evapotranspiración de referencia ( $ET_0$ ) como la ecuación de Hargreaves (1993), que la estima en función únicamente de las temperaturas y ha producido resultados razonables de  $ET_0$  con cierta validez global (Allen *et al.*, 1998). Mangliulo *et al.* (2003) utilizan un atmómetro modificado para la estimación de la  $ET_0$ , de igual forma Doorenbos and Pruitt (1977) reportaron que existe una alta correlación entre los datos de un tanque evaporímetro y la  $ET_0$  cuando éste es mantenido e instalado apropiadamente. Otro modelo para estimar la  $ET_0$  es el de Priestley y Taylor que relaciona la evapotranspiración con la radiación y demanda el conocimiento de menos datos al usuario (Thornley and France, 2007).

En años recientes las redes neuronales artificiales han demostrado ser herramientas excelentes en la investigación debido a su capacidad para manejar las interrelaciones no-lineales existentes al estimar diversos fenómenos climáticos (Tymvios *et al.*, 2008). Trabajos de investigación para estimar la evapotranspiración de referencia ( $ET_0$ ) con redes neuronales artificiales se han hecho, tal como el de Zanetti *et al.* (2007), que evaluaron una red neuronal artificial multicapa en función de las temperaturas máximas y mínimas del aire. De igual manera se encuentra el trabajo de Kumar *et al.* (2002) que utiliza una RNA con el algoritmo *backpropagation* para estimar la  $ET_0$  con las variables de entrada: temperatura máxima y mínima, humedad relativa máxima y mínima, velocidad del viento y radiación solar.

El objetivo del presente trabajo fue realizar una comparación de los métodos convencionales Hargreaves, Hargreaves calibrado y Priestley y Taylor con el modelo de redes neuronales artificiales función de base radial (*RBF*) para estimar evapotranspiración de referencia.

## 5.2 Materiales y métodos

### 5.2.1 Área de estudio y datos climatológicos

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

| Cuadro 1. Nombre, clave, longitud, latitud y altitud de las estaciones objeto de este estudio |                 |              |             |             |
|-----------------------------------------------------------------------------------------------|-----------------|--------------|-------------|-------------|
| Clave de estación                                                                             | Nombre estación | Longitud     | Latitud     | Altitud (m) |
| 3843 II-2                                                                                     | Ruiz Cortínez   | 108° 45' 20" | 25° 39' 15" | 31          |
| 3546 II-3                                                                                     | Batequis        | 108° 48' 41" | 25° 45' 49" | 32          |
| 3765 III-1                                                                                    | AC Santa Rosa 1 | 108° 57' 21" | 25° 45' 03" | 40          |
| 9610 III-1                                                                                    | AC Santa Rosa 2 | 108° 52' 03" | 25° 51' 16" | 61          |

Estos datos se preprocesaron a nivel diario, comprendieron del periodo abril de 1997 a mayo de 2001, generando vectores de 1484 datos, los cuales se utilizaron para el ajuste de la evapotranspiración de referencia ( $ET_0$ ) por los diferentes modelos, así como para el entrenamiento, validación y prueba de las RNA. Un nuevo conjunto de datos del periodo de mayo a diciembre de 2001 (229 días) se utilizó para realizar la validación de los modelos realizando una predicción de la evapotranspiración de referencia. Los datos se preprocesaron en hojas de

cálculo y el software a usado para el entrenamiento de las RNA es el toolbox de redes neuronales para Matlab 7.0<sup>T.M.</sup>.

### 5.2.2 Penman-Monteith FAO 56

Debido a la dificultad de obtener datos de lisímetro de evapotranspiración se tomaron como datos observados la evapotranspiración de referencia obtenida por el método FAO Penman-Monteith, puesto que es el método recomendado por los expertos como único método estándar para el cálculo de la evapotranspiración de referencia (Allen *et al.*, 1998). La ecuación utilizada por dicho método de manera diaria es:

$$ET_0 = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (1)$$

donde  $ET_0$  es la evapotranspiración de referencia en mm día<sup>-1</sup>;  $R_n$  es la radiación neta en la superficie del pasto en MJ m<sup>-2</sup> día<sup>-1</sup>;  $G$  es la densidad de flujo de calor del suelo en MJ m<sup>-2</sup> día<sup>-1</sup>;  $T$  es la temperatura media del aire a 2 m de altura en °C;  $u_2$  es la velocidad del viento media a 2 m de altura en m s<sup>-1</sup>;  $e_s$  la presión de vapor a saturación a la temperatura del aire  $T$  en kPa;  $e_a$  es la presión de vapor actual en kPa;  $e_s - e_a$  es el déficit de presión de vapor en kPa;  $\Delta$  es la pendiente de la curva de presión de vapor a saturación en kPa °C<sup>-1</sup>;  $\gamma$  es la constante psicrométrica en kPa °C<sup>-1</sup> (Allen *et al.*, 1998).

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

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

Modelo 1. Hargreaves.

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

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

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

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

donde  $d_r = 1 + 0.033 \cos\left(J \frac{2\pi}{365}\right)$ , es la distancia relativa inversa Tierra-Sol,  $J$  es el número de día

en el año;  $\omega_s = \arccos[-\tan(\varphi) \tan(\delta)]$ , es el ángulo de radiación a la puesta del sol en radianes;

$\varphi$  es la latitud positiva para el hemisferio norte y negativa para el hemisferio sur en radianes;

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

## Modelo 2. Hargreaves calibrado

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

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

donde  $ET_{0,PM}$  es la evapotranspiración de referencia calculada con la metodología de Penman-Monteith (Allen *et al.*, 1998),  $HE$  es un exponente empírico ajustado de Hargreaves, que es calibrado con los vectores de los 1484 datos disponibles para cada una de las estaciones.

## Modelo 3. Priestley y Taylor.

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

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

donde  $E$  es la evapotranspiración de referencia mm día<sup>-1</sup>;  $R_n$  es la radiación neta medida a 2 m en MJ m<sup>-2</sup> día<sup>-1</sup>;  $G$  es la densidad de flujo de calor en el suelo, en MJ m<sup>-2</sup> día<sup>-1</sup>,  $G = 0$  en una escala

en el tiempo diaria de acuerdo con Allen *et al.* (1998);  $\lambda$  es el calor latente de vaporización igual a  $2.45 \text{ MJ kg}^{-1}$ ;  $\gamma = \frac{c_p P}{\varepsilon \lambda} = 0.665 \times 10^{-3} \times P$ , es la constante psicrométrica;  $c_p$  es el calor específico a presión constante,  $1.013 \times 10^{-3}$  en  $\text{MJ kg}^{-1} \text{ } ^\circ\text{C}^{-1}$ ;  $\varepsilon$  es el cociente del peso molecular de vapor de agua/aire seco = 0.622;  $P = 101.3 \left( \frac{293 - 0.0065z}{293} \right)^{5.26}$ , es la presión atmosférica en kPa;  $z$  es la altitud en m.

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

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

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

donde  $x \in R^n$  es el vector de entrada,  $\phi(\cdot)$  es una función dada de  $R^+$  a  $R$ ,  $\|\cdot\|$  denota la norma euclidiana,  $\lambda_i$ ,  $0 \leq i \leq n_r$ , son los pesos o parámetros,  $c_i \in R^n$ ,  $1 \leq i \leq n_r$ , son conocidas como los centros *RBF*, y  $n_r$  es el número de centros. Aunque el caso de salida escalar es considerado aquí por simplicidad rotacional. De hecho, una red *RBF* multisalida puede separarse siempre en un grupo de una red *RBF* de una sola salida. En la red *RBF* la forma funcional  $\phi(\cdot)$  y los centros  $c_i$  se asumen son fijos. Se suministra un conjunto a la entrada  $x(t)$  y la salida deseada correspondiente  $d(t)$  para  $t = 1$  hasta  $N$ , los valores de los pesos  $\lambda_i$  pueden determinarse usando el método lineal de mínimos cuadrados. Sin embargo las elecciones de  $\phi(\cdot)$  y  $c_i$  deben considerarse cuidadosamente para que la red *RBF* sea capaz de igualar exactamente la representación de la red neuronal de dos capas.

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

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

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

#### 5.2.4 Implementación de la red neuronal función de base radial

El código que se usó para implementar la red neuronal en Matlab es el siguiente: *net = newrbe(P, T, spread)* donde *spread* es la constante de extendido de la capa base radial, *P* son los vectores de entrada, *T* es el target o vector de salida, *newrbe* es la función que llama a la red base radial de diseño exacto que de acuerdo con Demuth *et al.* (2008) pueden producir un error de cero en los vectores de entrenamiento; la constante de extendido tomó el valor de 100 pues con dicho valor se observó que la red proveía un buen ajuste, se simularon los datos de salida observados con la red entrenada con el código *a = sim(net,P)*, donde *a* es la salida de la red.

#### 5.2.5 Índices estadísticos para evaluar los modelos

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

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

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

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

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

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

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

### 5.3 Resultados y discusión

Primero, se observan en el Cuadro 2 los estadísticos para evaluar la  $ET_0$  estimada por los diferentes modelos convencionales (1, 2 y 3); en el Modelo 2 se estimó la  $ET_0$  diaria con los valores de  $HE$  que se obtuvieron de la ecuación de Hargreaves ajustada que fueron 0.1245, 0.1401, 0.1051, 0.0818 para cada una de las estaciones Ruiz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2 respectivamente. Se observa que el Modelo 2 presenta un mejor ajuste que el Modelo 1, debido a la calibración mencionada previamente del coeficiente  $HE$ , esto reafirma lo encontrado por Trajkovic (2007) que comenta que la ecuación de Hargreaves sin calibrar tiende a sobreestimar la evapotranspiración en regiones húmedas y Valle del Fuerte Los Mochis, Sinaloa siendo una zona de riego, adquiere características de alta humedad atmosférica (si los cultivos están bien regados), resultando necesario calibrar dicho coeficiente.

Cuadro 2. Diferentes estadísticos de prueba entre la radiación medida y la estimada por los modelos de Priestley-Taylor, Hargreaves y Hargreaves calibrado para las diferentes estaciones

| Método                         | $m$    | $b$     | $R^2$  | $RMSE$ | $d$    |
|--------------------------------|--------|---------|--------|--------|--------|
| Modelo 1. Hargreaves           |        |         |        |        |        |
| Ruiz Cortínez                  | 0.7739 | 1.5953  | 0.6836 | 1.0387 | 0.8729 |
| Batequis                       | 0.8161 | 1.3040  | 0.7217 | 0.9206 | 0.8988 |
| Santa Rosa 1                   | 0.7856 | 1.6540  | 0.6642 | 1.1727 | 0.8498 |
| Santa Rosa 2                   | 0.8558 | 1.7483  | 0.7599 | 1.3918 | 0.8223 |
| Modelo 2. Hargreaves calibrado |        |         |        |        |        |
| Ruiz Cortínez                  | 0.7110 | 1.2507  | 0.7363 | 0.7848 | 0.9163 |
| Batequis                       | 0.7633 | 1.0972  | 0.7512 | 0.7497 | 0.9262 |
| Santa Rosa 1                   | 0.7088 | 1.1656  | 0.7679 | 0.7553 | 0.9234 |
| Santa Rosa 2                   | 0.6767 | 1.2450  | 0.8334 | 0.7092 | 0.9317 |
| Modelo 3. Priestley-Taylor     |        |         |        |        |        |
| Ruiz Cortínez                  | 1.0717 | -0.4506 | 0.8649 | 0.6649 | 0.9575 |
| Batequis                       | 1.0245 | -0.5727 | 0.8365 | 0.8207 | 0.9327 |
| Santa Rosa 1                   | 1.0914 | -0.3613 | 0.9099 | 0.5482 | 0.9719 |
| Santa Rosa 2                   | 0.9540 | 0.0882  | 0.9349 | 0.4178 | 0.9820 |

$m$ : pendiente;  $b$ : intercepto;  $R^2$ : coeficiente de determinación;  $RMSE$ : Raíz cuadrada del cuadrado medio del error en  $\text{mm d}^{-1}$ ;  $d$ : Índice de Willmott.

Cuadro 3. Estadísticos de prueba de las simulaciones entre los datos medidos y los estimados por el Modelo 4 de la RNA función de base radial, para las diferentes estaciones.

| Modelo 4. RNA función de base radial | $m$    | $b$    | $R^2$  | $RMSE$ | $d$    |
|--------------------------------------|--------|--------|--------|--------|--------|
| E1{Tmin, Tmax, RG, HRmin, HRmax, VV} |        |        |        |        |        |
| Ruiz Cortínez                        | 0.9929 | 0.0322 | 0.9930 | 0.1278 | 0.9982 |
| Batequis                             | 0.9925 | 0.0352 | 0.9926 | 0.1297 | 0.9981 |
| Santa Rosa 1                         | 0.9937 | 0.0272 | 0.9938 | 0.1221 | 0.9984 |
| Santa Rosa 2                         | 0.9919 | 0.0341 | 0.9918 | 0.1425 | 0.9979 |
| E2{Tmedia, RG, HRmedia, VV}          |        |        |        |        |        |
| Ruiz Cortínez                        | 0.9887 | 0.0516 | 0.9886 | 0.1619 | 0.9971 |
| Batequis                             | 0.9854 | 0.0688 | 0.9854 | 0.1815 | 0.9963 |
| Santa Rosa 1                         | 0.9911 | 0.0383 | 0.9912 | 0.1449 | 0.9978 |
| Santa Rosa 2                         | 0.9876 | 0.0521 | 0.9876 | 0.1763 | 0.9969 |
| E3{Tmedia, RG, DPV, VV}              |        |        |        |        |        |
| Ruiz Cortínez                        | 0.9913 | 0.0397 | 0.9912 | 0.1420 | 0.9978 |
| Batequis                             | 0.9903 | 0.0459 | 0.9902 | 0.1482 | 0.9975 |
| Santa Rosa 1                         | 0.9922 | 0.0339 | 0.9922 | 0.1363 | 0.9980 |
| Santa Rosa 2                         | 0.9901 | 0.0419 | 0.9900 | 0.1573 | 0.9975 |

$m$ : pendiente;  $b$ : intercepto;  $R^2$ : coeficiente de determinación;  $RMSE$ : Raíz cuadrada del cuadrado medio del error en  $\text{mm d}^{-1}$ ;  $d$ : Índice de Willmott,  $E_i$ : Escenario  $i$ -ésimo; Tmin: Temperatura mínima; Tmax: Temperatura máxima; RG: Radiación global; HRmin: Humedad relativa mínima; HRmax: Humedad relativa máxima; VV: Velocidad del viento; Tmedia: Temperatura media; HRmedia: Humedad relativa media; DPV: Déficit de presión de vapor.

Segundo, al observar los estadísticos de prueba, el que muestra mejor ajuste es el Modelo 3 puesto que los *RMSE* son los que están más cercanos a cero a excepción de la estación Batequis, y el índice de Willmott (*d*) varia entre 0.93 y 0.98 y el coeficiente de determinación ( $R^2$ ) entre 0.84 y 0.93 fueron los más cercanos a 1, esto concuerda con Villa Nova *et al.* (2007), Priestley y Taylor (1972) y Jensen *et al.* (1990), que comentan, que existe una limitación aparente en la ecuación de Priestley y Taylor (Modelo 3) en la estimación de la evapotranspiración diaria, pero que para regiones húmedas representa un apoyo experimental substancial en la estimación de la  $ET_0$ .

Tercero, no obstante el Modelo 2 y 3 resultaron mejores modelos para ajustar a la  $ET_0$ , Khoob, (2008) recomienda que cuando no se tienen suficientes datos para conocer la  $ET_0$  diaria por Penman-Monteith, la ecuación de Hargreaves se puede usar puesto que únicamente requiere las temperaturas diarias máximas y mínimas disponibles en cualquier estación.

Con respecto al Cuadro 3 la primera observación es que el mejor escenario de entrenamiento fue el E1 con el mayor número de variables de entrada, puesto que el *RMSE* varió entre 0.12 y 0.14, la  $R^2$  obtuvo valores de 0.99 para cada una de las estaciones, destacando que este valor de  $R^2$  fue igual a lo encontrado para la misma estación Santa Rosa 1 evaluada en el trabajo de González-Camacho *et al.* (2008), pero con una RNA *feedforward backpropagation*.

La segunda observación es que cambiando la variable de entrada humedad relativa por el déficit de presión de vapor genera que el Modelo 4 E3 mejore su ajuste a los datos observados, pero no supera al ajuste de los estadísticos de prueba del E1. Una tercera es que cualquiera de los escenarios del Modelo 4 (E1, E2, E3) se ajustan mejor a los datos observados que el modelo de mejor ajuste del Cuadro 2 (Modelo 3), es decir de cualquiera de los métodos convencionales.

### 5.3.1 Validación de los modelos

En las Figuras 1, 2, 3, 4 se observa que el modelo de Priestley y Taylor tiende a ajustar a los datos observados con un error mayor que el Modelo 4 E1. Los errores se comportan en esta validación de igual forma que en el ajuste y los valores de *RMSE* obtenidos aquí variaron 0.3860 a 0.6889 y son similares a los encontrados por Tabari (2010) para estimar la  $ET_0$  pero de manera mensual en un clima húmedo frío variando sus *RMSE* entre 0.382 a 0.532 y para un clima semi-árido de 0.417 a 1.880.

Los *RMSE* obtenidos en este periodo de validación para las estaciones Ruiz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2 para el Modelo 1 fueron de 1.6334, 1.0416, 1.0046 y 1.6200, para el Modelo 2 de 1.1898, 0.9045, 0.7055 y 0.6914, para el Modelo 3 y el Modelo 4 E1 se muestran en las Figuras (1, 2, 3 y 4) respectivamente; para el Modelo 4 E2 los *RMSE* fueron de 0.2546, 0.1982, 0.1058 y 0.1738, y para el Modelo 4 E3 fueron de 0.2159, 0.1488, 0.0826 y 0.1967, respectivamente. Con respecto al índice de Willmot ( $d$ ), éste obtuvo valores para el Modelo 1 de 0.6479, 0.8749, 0.9009 y 0.7425; para el Modelo 2 de 0.7623, 0.8968, 0.9425 y 0.9243; para el Modelo 4 E2 0.9824, 0.9948, 0.9989 y 0.9954 y para el Modelo 4 E3 0.9876, 0.9970, 0.9994 y 0.9941, respectivamente. Obsérvese que los resultados de los estadísticos en este periodo de validación muestran que el mejor escenario fue el E3 que a diferencia de los resultados para el ajuste con los 1484 datos fue mejor el E1, a excepción de la estación Santa Rosa 2 donde continuó siendo el E1 el de menor error.

El coeficiente de determinación ( $R^2$ ) para el periodo de validación obtenidos para las estaciones Ruiz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2 para el Modelo 1 fueron de 0.6093, 0.8208, 0.8750 y 0.8376; para el Modelo 2 fueron de 0.6374, 0.7663, 0.8560 y 0.8165;

para el Modelo 3 fueron de 0.7449, 0.8643, 0.9518, 0.9487; para el Modelo 4 E1 de 0.9293, 0.9864, 0.9952, 0.9882; para el Modelo 4 E2 de 0.9565, 0.9892, 0.9968, 0.9829; y para el Modelo 4 E3 fueron de 0.9659, 0.9930, 0.9978, 0.9775.




Figura 1. Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Ruíz Cortínez.

Los resultados del Modelo 4 en todos sus escenarios son similares a lo encontrado por Trajnovic *et al.* (2003), que utilizó una RNA *RBF* para estimar  $ET_0$  pero de manera mensual, puesto que el coeficiente de correlación que obtuvieron en su trabajo fue de 0.97 proporcionando una  $R^2$  de 0.94. De igual forma Sudheer *et al.* (2003) encontraron coeficientes de correlación para diferentes combinaciones de variables de entrada con una RNA función de base radial, para un escenario similar al de este trabajo, cuyas variables de entrada fueron temperatura media, humedad relativa, velocidad del viento y duración de las horas brillo sol, encontraron una  $R$  de 0.93, valor un poco mas bajo que la  $R$  para el Modelo 4 E2 que varió entre 0.978 y 0.9984.




Figura 2. Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Batequis.




Figura 3. Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Santa Rosa 1.

Obsérvese que los coeficientes de determinación para este periodo de validación mostraron ser mejores para el Modelo 1 en tres de cuatro estaciones con respecto al Modelo 2, difiriendo de lo

encontrado en los resultados del ajuste y contrario a lo mostrado por el *RMSE* para el periodo de validación, las  $R^2$  altas indican un buen modelo de ajuste a los datos observados, pero finalmente el *RMSE* del Modelo 2 mas cercano a cero que el del Modelo 1, es el que da pauta para afirmar que es mas exacto en el pronóstico que el Modelo 1. Referente al Modelo 3, éste se comportó igual que en la validación, resultando de los métodos convencionales el que mayor bondad muestra, con una mayor exactitud en su pronóstico que el Modelo 1 y 2.




Figura 4. Estimación para un nuevo conjunto de 229 días de la evapotranspiración de referencia para la Estación Santa Rosa 2.

De manera global las redes neuronales artificiales *radial basis function* muestran mayor potencial en la estimación de la evapotranspiración de referencia y de los tres escenarios el E3 con las variables de entrada temperatura media, radiación global, déficit de presión de vapor y velocidad del viento es el que resultó ser el mejor estimador de la evapotranspiración de referencia en este estudio. Lo anterior se debe a que el escenario E3 considera las variables de entrada que están directamente relacionadas con los dos procesos importantes de la evapotranspiración: el energético y el aerodinámico.

## 5.4 Conclusiones

De los modelos convencionales el que mejor estimó a los datos observados de evapotranspiración de referencia fue el de Priestley y Taylor, sin embargo no superó al modelo de red neuronal función de base radial (*RBF*) en sus tres escenarios.

La red neuronal artificial función de base radial (*RBF*) con las variables de entrada temperatura media, radiación global, déficit de presión de vapor y velocidad del viento (Modelo 4 E3) es el modelo de mejor desempeño en la estimación de la evapotranspiración de referencia.

## 5.5 Literatura citada

Allen R.G., Pereira S. L., Raes D., Smith M. Crop evapotranspiration Guidelines for computing crop water requirements. FAO Irrigation and drainage paper 56. Roma. 1998. pp. 29-86.

Cai J., Liu Y., Lei T., Pereira S. L. Estimating reference evapotranspiration with the FAO Penman-Monteith equation using daily weather forecast messages. *Agricultural and forest meterology*, 145:22-35. July 2007. ISSN: 0168-1923

Chen S., Cowan N.C.F., Grant M.P. Orthogonal least squares learning algorithm for Radial Basis Functions networks. *IEEE Transactions on neural networks*, 2 (2):302-309. March 1991. ISSN: 1045-9227.

Demuth H., Beale M. and Hagan M. Neural network toolbox TM 6. User's guide. 2008. pp. 907.

Doorenbos, J., Pruitt, W. O. Crop water requirements. Irrigation and drainage. Paper 24. Food and Agricultural Organization of the United Nations, Rome (revised). 1977.

González-Camacho J.M., Cervantes-Osornio R., Ojeda-Bustamente W., y López-Cruz I. Predicción de la evapotranspiración de referencia mediante redes neuronales artificiales. *Ingeniería Hidráulica en México*, 23(1):127-138. Enero-Marzo 2008. ISSN: 0186-4076.

Hargreaves H. G. Defining and using reference evapotranspiration. *Journal of irrigation and drainage engineering, ASCE*; 120(6):1132-1139. November-December 1994. ISSN: 0733-9437.

Haykin S.S. 1994. Neural Networks. A comprehensive Foundation. MacMaster MacMillan Publishing Company, University, Hamilton, Ontario Canada, 696 p.

Khoob A.R. Comparative study of Hargreave's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. *Irrigation Science* 26(3):253-259. April 2008. ISSN: 0342-7188.

Kumar M., Raghuwanshi N.S., Singh R., Wallender W.W., and Pruitt W.O. Estimating evapotranspiration using artificial neural network. *Journal of irrigation and drainage engineering, ASCE*; 128:224-233. July-August 2002. ISSN: 0733-9437.

Jensen M.E.; R. D. Burman and R. G. Allen. Evapotranspiration and Irrigation Water Requirements. ASCE manuals and reports on engineering practices No. 70. Published by American Society of Civil Engineers, New York, EUA. 360 pp. 1990.

Mangliulo V., R d'Andria y G. Rana. Use of modified atmometer to estimate reference evapotranspiration in Mediterranean environments. *Agricultural Water Management* 63(1):1-14. November 2003. ISSN: 0378-3774.

Ojeda B.W. Calendarización del riego en tiempo real. In: Fundamentos del riego y riego por gravedad, vol. 1. X curso internacional de Sistemas de Riego. Universidad Autónoma Chapingo, Depto de Irrigación pp. 79-111. 2004.

Priestley, C.H.B., and Taylor R.J. On the assessment of surface heat-flux and evaporation using large-scale parameters. *Monthly Weather Review* 100(2):81-92. February 1972. ISSN: 0027-0644.

Sudheer K.P., Gosain A. K., and Ramasastri K. S. Estimating actual evapotranspiration from limited climatic data using neural computing technique. *Journal of irrigation and drainage engineering*, ASCE; 129(3):214-218. May-June 2003. ISSN: 0733-9437.

Tabari H. Evaluation of reference crop evapotranspiration equations in various climates. *Water Resources Management* 24(10): 2311-2337. 2010. ISSN: 0920-4741.

Thornley J. H. M and J. France. Mathematical models in agriculture. Quantitative methods for the plant, animal and ecological sciences. 2nd. edition. Cromwell Press, Trowbridge United Kingdom. 2007.

Tymvios F. S.; Michaelides S.C. and Skouteli C.S. Estimation of surface solar radiation with artificial neural networks. *In: Modeling solar radiation at the Earth's surface. Recent advances.* Bodescu V. (ed), Heidelberg Berlin, 2008, Springer. pp 221 – 256. 2008. ISBN: 978-3-540-77454-9.

Trajkovic S., Todorovic B. and Stankovic M. Forecasting of reference evapotranspiration by artificial neural networks. *Journal of irrigation and drainage engineering, ASCE*, 129(6):454-457. December 2003. ISSN: 0733-9437

Trajkovic S. Hargreaves versus Penman-Monteith under humid conditions. *Journal of irrigation and drainage engineering, ASCE*, 133(1):38-42. January 2007. ISSN: 0733-9437

Villa Nova N. A., Pereira A. B. and Shock C.C. Estimation of reference evapotranspiration by an energy balance approach. *Biosystems engineering*. 96(4):605-615. April 2007. ISSN: 1537-5110.

Willmott, C. J. On the validation of model. *Physical Geography* 2:184-194. 1981.

Zanetti S. S.; E. F. Sousa; V.P.S. Oliveira; F.T. Almeida and S. Bernardo. Estimating evapotranspiration using artificial neural network and minimum climatological data. *Journal of irrigation and drainage engineering, ASCE*, 133(2):83-89. March 2007. ISSN:0733-9437.

## CAPÍTULO 6

### CONCLUSIONES Y COMENTARIOS GENERALES

#### 6.1 Conclusiones

Se realizó una revisión de las redes neuronales artificiales aplicadas a variables relacionadas con la agricultura y así como existe bastante trabajo realizado para estimar y/o predecir algunas variables climatológicas relacionadas al área agrícola con redes neuronales artificiales, tal como la evapotranspiración de referencia y radiación global, existe poco trabajo en la estimación de lluvias con RNA por ejemplo.

La mayor parte del trabajo de estimación de variables climatológicas se hace con la red más común que es la multicapa *feedforward* con el algoritmo *backpropagation* que es una red estática, falta más investigación en aplicar redes dinámicas para estimar y/o predecir variables agroclimáticas

En la estimación de la presión real de vapor de agua el modelo convencional que utiliza únicamente  $T_{\min}$  sustituyéndolo en la expresión dada por Allen *et al.* (1998) presentó muy buen ajuste, sin embargo fue superado por los modelos de RNA; el modelo de RNA *radial basis function* con las variables de entrada temperatura máxima y mínima, humedad relativa máxima y mínima fue el que mejor aproximó a los datos observados de dicha variable.

En la estimación de la radiación global diaria los dos tipos de RNA (*radial basis function* y *feedforward backpropagation*) superaron en precisión al modelo de Hargreaves, sin embargo,

particularmente el modelo convencional de Prescott con los coeficientes  $a$  y  $b$  calibrados resultó ser también un muy buen estimador de la radiación global diaria.

Los dos resultados previos hacen reflexionar acerca de no prescindir de los modelos convencionales puesto que éstos arrojan mucha luz sobre con que variables de entrada empezar a entrenar y no pasar demasiado tiempo tratando de adivinar que variables usar en el entrenamiento para estimar determinado parámetro.

En la estimación de la evapotranspiración de referencia y de la presión actual de vapor de agua se pudo observar que los errores fueron mínimos con el modelo de RNA *radial basis function* siguiéndole en orden la RNA *feedforward* con el algoritmo *backpropagation* y los modelos convencionales.

En general las RNA mostraron ser mejores estimadores de las variables relacionadas con la evapotranspiración de referencia, tal como la presión real de vapor de agua, la radiación global diaria y la propia evapotranspiración de referencia que los modelos convencionales, sobretodo por la alta no linealidad que son capaces de manejar las RNA y contienen dichas variables.

## **6.2 Sugerencias**

En la estimación de la radiación global diaria se recomienda realizar entrenamientos de RNA usando la duración real de la insolación y la duración máxima posible de la insolación para observar si mejora el ajuste