



Revista Mexicana de Ciencias Agrícolas

ISSN: 2007-0934

revista_atm@yahoo.com.mx

Instituto Nacional de Investigaciones

Forestales, Agrícolas y Pecuarias

México

Cervantes-Osornio, Rocio; Arteaga Ramírez, Ramón; Vázquez Peña, Mario A.; Ojeda Bustamante, Waldo

Red neuronal artificial backpropagation versus modelos empíricos para estimación de radiación global diaria en Sinaloa, México

Revista Mexicana de Ciencias Agrícolas, vol. 7, núm. 5, junio-agosto, 2016, pp. 1029-1042

Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias
Estado de México, México

Disponible en: <http://www.redalyc.org/articulo.oa?id=263146723005>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica

Red de Revistas Científicas de América Latina, el Caribe, España y Portugal

Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

Red neuronal artificial backpropagation versus modelos empíricos para estimación de radiación global diaria en Sinaloa, México*

Backpropagation artificial neural network versus empirical models for estimating daily global radiation in Sinaloa, Mexico

Rocio Cervantes-Osornio¹, Ramón Arteaga Ramírez^{2§}, Mario A. Vázquez Peña² y Waldo Ojeda Bustamante³

¹Campo Experimental Valle de México-INIFAP. Carretera Los Reyes-Textcoco, Coatlinchán, km 13.5, C. P. 56230, A. P. 307 y 10, Textcoco, Estado de México, México. Tel: 01 800 088 2222, Ext. 85565. (rcervanteso@hotmail.com). ²Universidad Autónoma Chapingo, Departamento de Irrigación, Sección Meteorología agrícola, km 38.5, Carretera México-Textcoco, C. P. 56230, Estado de México, México. Tel: 01 (595) 95 21500. Ext. 5157. (mvazquezp@correo.chapingo.mx). ³Instituto Mexicano de Tecnología del Agua, Paseo Cuauhnáhuac 8532, Colonia Progreso C. P. 62550, Jiutepec, Morelos, México. Tel: 01 (777) 3293 600. Ext: 445. (wojeda@tlaloc.imta.mx).

[§]Autor para correspondencia: rarteagar@taurus.chapingo.mx.

Resumen

Se compararon los resultados de los promedios de radiación global diaria estimados con el modelo de red neuronal artificial (RNA) backpropagation contra los obtenidos por los modelos empíricos Hargreaves, Angström-Prescott y los calibrados de estos. Se utilizó un modelo de red neuronal artificial backpropagation con el algoritmo Levenberg Marquardt para el pronóstico de los promedios diarios de radiación global de cuatro estaciones ubicadas en el distrito de riego 075 Valle del Fuerte, Los Mochis Sinaloa, México. La base de datos representa promedios diarios con vectores de 1 484 datos para entrenamiento, validación y prueba y 229 para pronóstico. Entre las variables de entrada proporcionadas por el Distrito de riego, fueron: temperatura mínima y temperatura máxima, otras fueron calculadas como: duración real de la insolación, fotoperiodo y radiación solar extraterrestre. Se obtuvieron escenarios con una, dos y tres capas ocultas, con diversos números de neuronas en cada capa oculta. La RNA e6{27} con las entradas temperatura mínima, máxima, horas brillo sol dividida por el fotoperiodo y radiación solar extraterrestre, obtuvo el mejor ajuste, con un RMSE de 1.6871 y R^2 de 0.89 para los 1484 datos y para los 229, lo obtuvo el modelo Angström-Prescott calibrado con un RMSE de 2.2812 y R^2 de 0.89. Para los 1 484 datos promedios, el escenario e6{27}

Abstract

The results were compared of average daily global radiation model estimated with artificial neural network (RNA) backpropagation against those obtained by empirical models Hargreaves, Angström-Prescott and these calibrated. A model of backpropagation artificial neural network was used with Levenberg Marquardt algorithm for forecasting average daily global radiation four stations located in the irrigation district 075 Valle del Fuerte, Los Mochis Sinaloa, Mexico. The database represents daily averages with 1 484 data vectors for training, validation and test and 229 for prognosis. Among the input variables provided by the irrigation district they were: minimum temperature and maximum temperature, others were calculated as actual duration of sunshine, photoperiod and extraterrestrial solar radiation. The scenarios with one, two and three hidden layers with different numbers of neurons in each hidden layer was obtained. The RNA e6{27} with entries minimum temperature, maximum, hours shine sun divided by photoperiod and extraterrestrial solar radiation, obtained the best fit with a RMSE of 1.6871 and R^2 of 0.89 for 1 484 and for data for 229, the Angstrom-Prescott won the calibrated model with RMSE of 2.2812 and R^2 of 0.89. For 1484 average data, the e6{27} scenario presents the best estimate of daily global radiation (R_g) and

* Recibido: abril de 2016
Aceptado: junio de 2016

presenta la mejor estimación de la radiación global diaria (R_s) y es mejor que los modelos empíricos, sin embargo para los 229 datos el modelo Angström-Prescott calibrado presenta una estimación de R_s mejor al 6{27} de la RNA.

Palabras clave: Angström-Prescott, Hargreaves, promedios, radiación solar, red neuronal artificial.

Introducción

La radiación global diaria es importante en áreas tales como: la ingeniería, la agricultura, física del suelo, hidrología agrícola, modelación de los cultivos y estimación de la evapotranspiración, así como en: modelación del clima y tiempo, monitoreo de crecimiento en los cultivos y control de enfermedades.

La radiación que alcanza la superficie de la tierra debido a los gases, nubes y partículas de la atmósfera, estas absorben y dispersan la radiación en sus diferentes niveles de onda. La necesidad de disponer con registros de radiación solar cobra importancia principalmente debido al incremento en aplicaciones de la energía solar. Obtener datos confiables de radiación requiere mediciones sistemáticas (Muribu, 2008). Las redes neuronales artificiales han demostrado ser excelentes herramientas para diferentes áreas de la investigación; puesto que son capaces de manejar interrelaciones no lineales (aproximación de función no lineal), separar datos (clasificación de datos), localizar relaciones ocultas en grupos de datos (clustering) o modelar sistemas naturales (simulación) (Demuth *et al.*, 2008).

En la estimación de la radiación global mediante redes neuronales artificiales se encuentra el trabajo de Hasni *et al.* (2012) citado por Yadav and Chandel (2014) estimaron la radiación global cada hora mediante una red neuronal artificial utilizando temperatura y humedad relativa, con un algoritmo feedforward backpropagation, de igual forma Jiang (2008) utilizó una red neuronal artificial (RNA) de este tipo para realizar un pronóstico de la radiación solar difusa y compara los resultados con dos modelos empíricos. Rehman and Mohandes (2008), utilizaron un modelo de red neuronal artificial recurrente para estimar la radiación global con valores medidos de temperatura y humedad relativa como entradas. Martínez-Romero *et al.* (2012) utilizaron: modelos de regresión lineal, el modelo de Hargreaves, Hargreaves calibrado y RNA para estimar radiación solar global, con datos medios mensuales de

is better than the empirical models, however for 229 data the Angstrom-Prescott calibrated model provides an estimate of R_s better e6{27} of the RNA.

Keywords: Angström-Prescott, Hargreaves, averages, artificial neural network, solar radiation.

Introduction

The daily global radiation is important in areas such as engineering, agriculture, soil physics, agricultural hydrology modeling crops and estimation of evapotranspiration, as well as: modeling climate and weather, growth monitoring crop and disease control.

The radiation reaching the surface of the earth due to gases, clouds and particles in the atmosphere, they absorb and scatter radiation at different wave levels. The need for records of solar radiation becomes important due to the increase in solar energy applications. Obtain reliable data radiation requires systematic measurements (Muribu, 2008).

The artificial neural networks have proven to be excellent tools for different areas of research; since they are able to handle nonlinear relationships (approximation of nonlinear function), separating data (data classification), find hidden relationships in data groups (clustering) or modeling natural systems (simulation) (Demuth *et al.*, 2008).

In estimating global radiation by artificial neural networks is the work of Hasni *et al.* (2012) cited by Yadav and Chandel (2014) estimated the global radiation each time using an artificial neural network using temperature and relative humidity with a feedforward backpropagation algorithm, similarly Jiang (2008) used an artificial neural network (RNA) of this type to make a prognosis of diffuse solar radiation and compares the results with two empirical models. Rehman and Mohandes (2008) used an artificial neural network model to estimate recurrent global radiation measured temperature and relative humidity values as inputs. Martínez-Romero *et al.* (2012), used to linear regression models, the model Hargreaves Hargreaves calibrated and RNA to estimate global solar radiation data with average monthly maximum temperature, minimum and extraterrestrial solar radiation.

temperatura máxima, mínima y radiación solar extraterrestre. Con respecto a los modelos empíricos Bandyopadhyay *et al.* (2008), utilizaron: Hargreaves, el calibrado de Angström-Prescott y Bristow and Campbell (Bristow and Campbell, 1984) para estimar la radiación solar.

El objetivo del presente trabajo fue comparar los resultados de las estimaciones de los promedios de radiación global diaria de cuatro estaciones, ubicadas en el Distrito de Riego 075, Valle del Fuerte, Los Mochis, Sinaloa, realizadas con el modelo de red neuronal artificial (RNA) bakpropagation contra las estimaciones obtenidas por los modelos empíricos Hargreaves, Hargreaves calibrado, Angström-Prescott y Angström-Prescott calibrado. Se utilizaron los promedios de los datos por la cercanía de una estación con otra, ya que no existen diferencias significativas del clima preponderante entre estación y estación.

Materiales y métodos

Área de estudio y conjunto de datos climáticos utilizados

Se utilizaron datos medidos de abril de 1997 a mayo de 2001 (entrenamiento, evaluación y validación) y de junio a diciembre de ese mismo año (para pronóstico), de temperatura máxima, temperatura mínima, humedad relativa máxima, mínima, y radiación global diaria. Posteriormente, se obtuvieron los promedios de todas las variables de las cuatro estaciones, ubicadas en el DR 075 Valle del Fuerte, en Los Mochis, Sinaloa, cuyo nombres (claves), latitudes, longitudes y altitudes son: Ruiz Cortínez (3 843 II-2), 25° 39' 15", 108° 45' 20", 31 msnm; Batequis (3 546 II-3), 25° 45' 49", 32 msnm AC Santa Rosa 1 (3 765 III-1), 25° 45' 03", 108° 57' 21", 40 msnm; AC Santa Rosa 2 (9 610 III-1) 25° 51' 16", 108° 52' 03", 61 msnm; y finalmente: la radiación solar extraterrestre (R_a), y el fotoperiodo (N), se calcularon tal y como lo presentan Allen *et al.* (1998) y las horas brillo sol (n) como lo recomienda la WMO (1996).

Redes neuronales artificiales

Para aplicar el modelo de redes neuronales artificiales (RNA) se necesita un conjunto de datos de entrada, estos se dividen para: entrenamiento, validación y prueba. Se define el número de capas ocultas y el número de neuronas que se tendrán en cada capa, la función de activación es:

$$y_k = \varphi \left(\sum_{j=1}^m w_{kj} x_j \right) + b_k \quad 1)$$

Regarding empirical models Bandyopadhyay *et al.* (2008), used: Hargreaves, calibration of Angstrom-Prescott and Bristow and Campbell (Bristow and Campbell, 1984) to estimate solar radiation.

The aim of this study was to compare the results of estimates of average daily global radiation four stations, located in the Irrigation District 075, Valle del Fuerte, Los Mochis, Sinaloa, made with the model of artificial neural network (RNA) backpropagation against the estimates obtained by empirical models Hargreaves, Hargreaves calibrated, Angstrom-Prescott and Angström-Prescott calibrated. The averages of the data were used by the proximity of a station to another, since there are no significant differences in climate prevailing between stations.

Materials and methods

Study area and climate data set used

The measured data were used from april 1997 to may 2001 (training, evaluation and validation) and from june to december of the same year (for forecast), maximum temperature, minimum temperature, maximum relative humidity, minimum, and global radiation daily. Subsequently, the averages of all the variables of the four stations, located in 075 DR Valle del Fuerte, in Los Mochis, Sinaloa obtained, whose names (keys), latitudes, longitudes and altitudes are: Ruiz Cortínez (3 843 II-2), 25° 39' 15", 108° 45' 20", 31 msnm; Batequis (3 546 II-3), 25° 45' 49", 32 msnm AC Santa Rosa 1 (3 765 III-1), 25° 45' 03", 108° 57' 21", 40 msnm; AC Santa Rosa 2 (9 610 III-1) 25° 51' 16", 108° 52' 03", 61 msnm; and finally: the extraterrestrial solar radiation (R_a), and photoperiod (N), were calculated as the present Allen *et al.* (1998) and the sun shine hours (n) as recommended by the WMO (1996).

Artificial neural networks

To apply the model of artificial neural networks (RNA) a set of input data is needed, these are divided to: training, validation and testing. The number of hidden layers and the number of neurons in each layer have defined, the activation function is:

$$y_k = \varphi \left(\sum_{j=1}^m w_{kj} x_j \right) + b_k \quad 1)$$

Donde: x_1, x_2, \dots, x_m son las señales de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ son los pesos sinápticos de la neurona k ; b_k es el sesgo; $\varphi(\cdot)$ es la función de activación (Ecuación 2) y y_k es la señal de salida de la neurona

$$\varphi(v) = \frac{1}{1 + e^{(-a_1 v)}} \quad (2)$$

El algoritmo utilizado, en este trabajo, para la RNA fue el feedforward backpropagation, se basa en la regla de aprendizaje de corrección del error, esto es una generalización del algoritmo del error mínimo cuadrado, y consiste de dos pases a través de las diferentes capas de la red, un pase hacia adelante y uno hacia atrás (Haykin, 2008).

La nomenclatura para denominar un escenario en las RNA, se expresa como $eX\{1 \times 2 \times 1\}$, donde eX denota al escenario "X", los paréntesis tipo llave $\{1 \times 2 \times 1\}$, indican que se tienen 1, 2 y 1 número de neuronas en la primera, segunda y tercera capas ocultas, respectivamente, esto es, tres capas ocultas. Los diferentes escenarios con sus respectivas variables de entrada consideradas para el entrenamiento de la RNA backpropagation se muestran a continuación: $e1\{T_{\min}, T_{\max}, R_a\}$, $e2\{T_{\min}, T_{\max}, n\}$, $e3\{n, N, R_a\}$, $e4\{T_{\min}, T_{\max}, n/N\}$, $e5\{T_{\min}, T_{\max}, n, R_a\}$, $e6\{T_{\min}, T_{\max}, n/N, R_a\}$, $e11\{n/N, R_a\}$, $e12\{T_{\max} - T_{\min}, n\}$, $e13\{T_{\max} - T_{\min}, R_a\}$, $e14\{T_{\max} - T_{\min}, n, R_a\}$, $e15\{T_{\max} - T_{\min}, n/N, R_a\}$. Para los vectores de 1484 datos, se usaron: 25%, 25% y 50% para prueba, validación y entrenamiento, respectivamente (Demuth *et al.*, 2008).

Modelos empíricos

La ecuación de Hargreaves, de acuerdo con Allen *et al.* (1998) y Hargreaves and Samani (1982) es:

$$R_s = k_{RS} \sqrt{(T_{\max} - T_{\min})} R_a \quad (3)$$

Donde: R_a es la radiación extraterrestre [$\text{MJ m}^{-2} \text{d}^{-1}$], T_{\max} es la temperatura máxima del aire [$^{\circ}\text{C}$], T_{\min} es la temperatura mínima del aire [$^{\circ}\text{C}$], k_{RS} es un coeficiente de ajuste ($0.16 \dots 0.19$) [$^{\circ}\text{C}^{-0.5}$], $k_{RS} \approx 0.16$ para localidades en donde la masa de tierra domina y las masas de aire no están influenciadas por un gran cuerpo de agua, y $k_{RS} \approx 0.19$ para zonas "costeras". De la ecuación 3 se obtiene la ecuación 4, con la que se hace la calibración:

$$\ln(R_s/R_a) = \ln(k_{RS}) + z \ln(T_{\max} - T_{\min}) \quad (4)$$

Donde: z es el exponente (1/2) renombrado, esta ecuación se trata como una regresión lineal.

Where: x_1, x_2, \dots, x_m are the input signals; $w_{k1}, w_{k2}, \dots, w_{km}$ are the synaptic weights of neuron k ; b_k is the bias; $\varphi(\cdot)$ is the activation function (Equation 2) and y_k is the output signal of the neuron

$$\varphi(v) = \frac{1}{1 + e^{(-a_1 v)}} \quad (2)$$

The algorithm used in this work for the RNA was the feedforward backpropagation, is based on the learning rule error correction, this is a generalization of the algorithm of least square error and consists of two passes through the different layers network, a pass forward and one step back (Haykin, 2008).

The nomenclature to describe a scenario in RNA is expressed as $eX\{1 \times 2 \times 1\}$, where eX denotes the stage "X", parentheses key type $\{1 \times 2 \times 1\}$, indicate that having 1, 2, and 1 number of neurons in the first, second and third hidden layers, respectively, that is, three hidden layers. The different scenarios with their respective input variables considered for the training of RNA backpropagation below: $e1\{T_{\min}, T_{\max}, R_a\}$, $e2\{T_{\min}, T_{\max}, n\}$, $e3\{n, N, R_a\}$, $e4\{T_{\min}, T_{\max}, n/N\}$, $e5\{T_{\min}, T_{\max}, n, R_a\}$, $e6\{T_{\min}, T_{\max}, n/N, R_a\}$, $e11\{n/N, R_a\}$, $e12\{T_{\max} - T_{\min}, n\}$, $e13\{T_{\max} - T_{\min}, R_a\}$, $e14\{T_{\max} - T_{\min}, n, R_a\}$, $e15\{T_{\max} - T_{\min}, n/N, R_a\}$. For vectors 1 484 data were used: 25%, 25% and 50% for testing, validation and training, respectively (Demuth *et al.*, 2008).

Empirical models

The Hargreaves equation, according to Allen *et al.* (1998) and Hargreaves and Samani (1982) is:

$$R_s = k_{RS} \sqrt{(T_{\max} - T_{\min})} R_a \quad (3)$$

Where: R_a is the extraterrestrial radiation [$\text{MJ m}^{-2} \text{d}^{-1}$], T_{\max} is the maximum air temperature [$^{\circ}\text{C}$], T_{\min} is the minimum air temperature [$^{\circ}\text{C}$], k_{RS} is an adjustment coefficient ($0.16 \dots 0.19$) [$^{\circ}\text{C}^{-0.5}$], $k_{RS} \approx 0.16$ for locations where land mass dominates and air masses are not influenced by a large body of water, and $k_{RS} \approx 0.19$ for "coastal" areas. Of Equation 3 the Equation 4 is obtained, with which the calibration is done:

$$\ln(R_s/R_a) = \ln(k_{RS}) + z \ln(T_{\max} - T_{\min}) \quad (4)$$

Where: z is the exponent (1/2) renamed, this equation is a linear regression.

El modelo de Angström-Prescott de acuerdo con Allen *et al.* (1998) para el cálculo de la radiación solar es:

$$R_s = \left(a_s + b_s \frac{n}{N} \right) R_a \quad (5)$$

Donde: R_s es la radiación solar o de onda corta [$\text{MJ m}^{-2} \text{d}^{-1}$], n es la duración real de la insolación [horas], N es la duración máxima posible de la insolación [horas], n/N es la duración relativa de la insolación [adimensional], R_a es la radiación extraterrestre [$\text{MJ m}^{-2} \text{d}^{-1}$], a_s es la constante de regresión, que expresa la fracción de radiación extraterrestre que llega a la tierra en días muy nublados, $a_s + b_s$ es la fracción de la radiación extraterrestre que llega a la tierra en días despejados. Allen *et al.* (1998) recomiendan usar valores de $a_s = 0.25$ y de $b_s = 0.50$. El modelo de Angström-Prescott (Ecuación 5) se calibró mediante una transformación lineal, obteniéndose los coeficientes $a_s = -0.5535$ y $b_s = 1.3824$ con los vectores de 1 484 datos, se eliminaron los datos muy sesgados. La información de n no disponible se estimó de acuerdo con la WMO (1996) y Linacre (1992), quienes proponen que si en una hora se tiene un valor mayor de 120 W m^2 , entonces existe una hora brillo sol.

Estadísticos de evaluación

Para evaluar el desempeño (estimación) de los modelos utilizados se utilizaron el error estándar promedio o raíz cuadrada del cuadrado medio del error (RMSE), el error medio (MBE), llamado también sesgo o desviación, este caracteriza la bondad de cada uno de los modelos y el coeficiente de determinación (R^2), dados por las siguientes ecuaciones:

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

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

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

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).

Resultados y discusión

El modelo de Hargreaves sin calibrar con un $k_{Rs} = 0.19$ con 1 484 datos obtuvo un RMSE de 5.6735 y para un $k_{Rs} = 0.16$ obtuvo un RMSE de 3.4062 y se conserva la misma R^2 (0.59),

The model of Angstrom-Prescott according to Allen *et al.* (1998) to calculate the solar radiation is:

$$R_s = \left(a_s + b_s \frac{n}{N} \right) R_a \quad (5)$$

Where: R_s is solar or shortwave radiation [$\text{MJ m}^{-2} \text{d}^{-1}$], n is the actual duration of sunshine [hours], N is the maximum possible duration of sunshine [hours], n/N is the relative duration of sunshine [dimensionless], R_a is extraterrestrial radiation [$\text{MJ m}^{-2} \text{d}^{-1}$], a_s is the regression constant, which expresses the fraction of radiation alien who comes to earth on very cloudy days, $a_s + b_s$ is the fraction of extraterrestrial radiation reaching the earth on clear days. Allen *et al.* (1998) recommend using values $a_s = 0.25$ and of $b_s = 0.50$. The Angstrom-Prescott model (Equation 5) was calibrated by a linear transformation coefficients obtained $a_s = -0.5535$ and $b_s = 1.3824$ with 1 484 data vectors, the very skewed data were eliminated. The n information not available was estimated according to WMO (1996) and Linacre (1992), who propose yes in one hour has a value greater than 120 W m^2 , then there is sun shine one hour.

Statistical evaluation

To evaluate the performance (estimate) of the models used the average standard error or square root mean square error (RMSE), the average error (MBE), also called bias or deviation were used, this characterizes the goodness of each models and the coefficient of determination (R^2) given by the following equations:

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

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

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

Where: a_i is estimated by the model data, t_i is the observed data, to \bar{a} is the average of the data estimated by the model, \bar{t} is the average of the observed data and N is the total number of observations (Alexandris *et al.*, 2006; Tabari, 2009).

Results and discussion

The model Hargreaves uncalibrated with $k_{Rs} = 0.19$ with 1 484 data obtained an RMSE of 5.6735 and for $k_{Rs} = 0.16$ obtained an RMSE of 3.4062 and the same R^2 (0.59) is

para los 229 datos de validación se encontró un RMSE de 6.8224 y de 3.3696 para k_{Rs} de 0.19 y 0.16 respectivamente y R^2 de 0.73 para ambos. Los valores obtenidos de z y k_{Rs} del modelo de Hargreaves calibrado fueron 0.2995 y 0.2711, respectivamente y los valores estimados de radiación global para los 1 484 datos presentaron un RMSE de 3.0068 y una R^2 de 0.65 y para los 229 datos de validación un RMSE de 3.2460 con una R^2 de 0.75 para este modelo. Como se observa con un k_{Rs} = 0.16, se obtuvo mejor ajuste que con un k_{Rs} = 0.19, indicando que el distrito de Riego 075, en donde se ubican las cuatro estaciones se aproxima a ser una localidad donde la masa de tierra domina de acuerdo con el criterio de Allen *et al.* (1998) y que el modelo calibrado generó mejor ajuste del error estándar y del coeficiente de determinación, no obstante que el k_{Rs} del modelo calibrado se encuentra alejado de 0.16; Martínez-Romero *et al.* (2012) encontraron un RMSE de calibración de 1.43 MJ/m²día para el modelo de Hargreaves con un k_{Rs} de 0.15928, al estimar valores promedio mensuales de radiación solar global, este valor de k_{Rs} comentan los autores apenas difiere del valor de 0.16 por lo que utilizaron este último para obtener los RMSE de validación espacial y temporal, 1.23 y 1.66 MJ/m²día respectivamente, contra un RMSE de calibración de 1.17 MJ/m²día para una RNA con las entradas temperatura máxima, mínima y radiación solar extraterrestre.

El modelo de Angström-Prescott sin calibrar obtuvo un RMSE para los 1484 datos de 5.1948, con una R^2 de 0.73, para el modelo calibrado (a_s = -0.5535 y b_s = 1.3824) el RMSE obtenido fue de 2.0889 con una R^2 de 0.84, esto indica que presentó mejor ajuste el modelo Angström-Prescott calibrado que el Hargreaves calibrado, corroborando lo indicado en Cervantes-Osornio *et al.* (2012). Liu *et al.* (2009) calibraron los coeficientes a y b con datos diarios, encontrando una mejor aproximación de la radiación global el modelo de Angstrom-Prescott calibrado que el Hargreaves calibrado, a diferencia de lo encontrado por Bandyopadhyay *et al.* (2008), que utilizaron el modelo de Hargreaves modificado, y Angström-Prescott calibrado para estimar datos mensuales de radiación solar y encontraron que el método de Hargreaves modificado por Annandale *et al.* (2002) fue mejor que el Angström-Prescott. Almorox *et al.* (2008) y Meza and Varas (2000), estimaron la radiación global mensual con la ecuación de Angström-Prescott, resultando que este modelo con los coeficientes calibrados es una herramienta útil, lo que corrobora, lo encontrado en el presente trabajo, calibrar los modelos genera un mejor ajuste que no hacerlo.

preserved for 229 data validation found a RMSE of 6.8224 and 3.3696 for k_{Rs} 0.19 and 0.16 respectively and R^2 of 0.73 for both. The values of z and k_{Rs} model Hargreaves calibrated were 0.2995 and 0.2711, respectively, and the estimated values of global radiation for the 1 484 data showed a RMSE of 3.0068 and an R^2 of 0.65 and for 229 data validation RMSE of 3.2460 with an R^2 of 0.75 for this model. As seen with k_{Rs} = 0.16, better fit than a k_{Rs} = 0.19, indicating that the irrigation district 075, where the four seasons are located is close to being a locality where land mass dominates according to obtained criteria Allen *et al.* (1998) and the calibrated model generated better fit the standard error and the coefficient of determination, however, that the k_{Rs} the calibrated model is far from 0.16; Martínez-Romero *et al.* (2012) found RMSE calibration of 1.43 MJ/m²day for Hargreaves model with k_{Rs} 0.15928, to estimate monthly average values of global solar radiation, this value k_{Rs} say the authors hardly differs from the value of 0.16 so they used the latter for the RMSE of spatial and temporal validation, 1.23 and 1.66 MJ/m²day respectively, against a calibration RMSE of 1.17 MJ/m²day for RNA with entries maximum temperature, minimum and extraterrestrial solar radiation.

The model of Angstrom-Prescott uncalibrated obtained an RMSE data for 1484 5.1948, with an R^2 of 0.73 for the calibrated model (a_s = -0.5535 and b_s = 1.3824) the RMSE obtained was 2.0889 with an R^2 of 0.84, this indicates that presented better fit the Angström-Prescott model calibrated the calibrated Hargreaves, corroborating indicated in Cervantes-Osornio *et al.* (2012). Liu *et al.* (2009) calibrated the coefficients a and b with daily data, finding a better approximation of the global radiation model Angstrom-Prescott calibrated the calibrated Hargreaves, unlike what was found by Bandyopadhyay *et al.* (2008), who used the model modified Hargreaves, and Angstrom-Prescott calibrated to estimate monthly solar radiation data and found that the method modified by Hargreaves Annandale *et al.* (2002) it was better than the Angstrom-Prescott. Almorox *et al.* (2008) and Meza and Varas (2000), estimated the monthly global radiation with the equation of Angström-Prescott, resulting in this model with the calibrated coefficients is a useful tool, which corroborates the findings in this paper, calibrate models generates a better fit than not.

In the Table 1 shows the results of the average standard error and average error for the training scenario 2, which was one of those who had values of RMSE and MBE closer to zero, in this observed shown that increasing the number

En el Cuadro 1 se muestran los resultados del error estándar promedio y error medio para el entrenamiento del escenario 2, que fue uno de los que presentó valores de RMSE y MBE más próximos a cero, en éste se observa que al aumentar el número de capas ocultas no incidió en mejorar el ajuste del RMSE y MBE, ya que el ajuste más cercano a cero fue el entrenamiento con dos capas ocultas de 24 x 24 neuronas en estas, en el entrenamiento con una capa oculta el mejor ajuste fue el que tuvo 30 neuronas en esta y con tres capas ocultas fue el de 9 x 24 x 9 neuronas, cuyo mejor ajuste de este último bloque no superó al de dos capas. Adicionalmente, el incremento del número de neuronas en las capas ocultas, no necesariamente mejora el ajuste de estos entrenamientos, para dos y tres capas ocultas, pero el e2, con una capa oculta obtuvo el mejor ajuste con el máximo número de neuronas (30).

of layers hidden not had an impact on improving the fit of RMSE and MBE, as the closest zero adjustment was training with two hidden layers of 24 x 24 neurons in these, in training with a hidden layer the best fit was the one who had 30 neurons in this and three hidden layers was 9 x 24 x 9 neurons, whose best fit of this last block did not exceed the two layers. Additionally, the increased number of neurons in the hidden layers, does not necessarily improve the fit of these tests, for two and three hidden layers, but e2, with a hidden layer obtained the best fit with the maximum number of neurons (30).

In the Table 2 shows the results of RMSE that are closer to zero, results of different workouts performed with RNA of the three scenarios for one, two and three hidden layers

Cuadro 1. RMSE y MBE para 1484 datos, del escenario 2 con entradas: temperatura mínima, máxima y horas brillo sol.
Table 1. RMSE and MBE to 1484 data, the stage with 2 inputs: minimum temperature, maximum brightness and sunshine hours.

1 capa oculta	e2 { T_{min} , T_{max} , n} 1484 datos		2 capas ocultas	e2 { T_{min} , T_{max} , n} 1484 datos		3 capas ocultas	e2 { T_{min} , T_{max} , n} 1484 datos	
	RMSE	MBE		RMSE	MBE		RMSE	MBE
{3}	1.8121	-0.0095	{3x3}	1.7906	-0.014233	{3x3x3}	1.854	-0.0092
{6}	1.7880	0.0981	{6x6}	1.7877	0.0255249	{3x6x3}	1.7992	-0.0169
{9}	1.7944	-0.0028	{9x9}	1.908	-0.013783	{6x9x6}	1.7974	0.0268
{12}	1.7974	0.05675	{12x12}	1.7643	-0.033802	{6x12x6}	1.806	-0.0719
{15}	1.8884	0.1316	{15x15}	1.7761	-0.058406	{6x15x6}	1.8573	-0.0022
{18}	1.7808	-0.0835	{18x18}	1.7653	-0.097926	{9x18x9}	1.7971	-0.03131
{21}	1.7949	-0.1265	{21x21}	1.8236	0.1556177	{9x21x9}	1.7931	-0.0535
{24}	1.7729	0.1247	{24x24}	1.7615	-0.01498	{9x24x9}	1.7735	0.0941
{27}	1.7726	-0.0321	{27x27}	1.9373	0.0302366	{9x27x9}	1.8124	-0.0565
{30}	1.7656	-0.0389	{30x30}	1.7652	-0.009287	{9x30x9}	1.7926	0.07199

RMSE= raíz cuadrada del cuadrado medio del error; MBE= error medio.

En el Cuadro 2 se muestran los resultados del RMSE que se aproximan más a cero, resultados de los diferentes entrenamientos realizados con RNA de los tres escenarios para una, dos y tres capas ocultas con sus variantes en el número de neuronas en tales capas. El mejor ajuste fue con el escenario e6 con una capa oculta y con 27 neuronas en esta, con las entradas: T_{min} , T_{max} , n/N y R_a , con un RMSE de 1.6871. El segundo mejor ajuste se presentó en el escenario e5, con entradas T_{min} , T_{max} , n y R_a , RMSE de 1.69 con dos capas ocultas con 18 neuronas en cada una de éstas y el tercer mejor ajuste fue el e5, con tres capas ocultas con 9, 27 y 9 neuronas en cada capa y un RMSE de 1.7019, y para cada uno de estos escenarios se tiene una R^2 de 0.89. Estos resultados, confirman lo ya mencionado, con tres capas ocultas no mejora el ajuste de los entrenamientos, con dos capas ocultas resulta suficiente para obtener un

with variations in the number of neurons in these layers are shown. The best fit was with the e6 stage with a hidden layer with 27 neurons in it, with the entries: T_{min} , T_{max} , n/N and R_a , with an RMSE of 1.6871. The second best adjustment was made in the e5 stage, with tickets T_{min} , T_{max} , n and R_a , RMSE of 1.69 with two hidden layers with 18 neurons in each of them and the third best fit was the e5, with three hidden layers 9, 27 and 9 neurons in each layer and RMSE of 1.7019, and for each of these scenarios has an R^2 of 0.89. These results confirm the above, with three hidden layers does not improve the fit workouts, with two hidden layers is sufficient to obtain an acceptable RMSE, in this sense, Tymvios *et al.* (2005), say that with an excessive number of hidden layers, often leads to a deterioration in the performance of the RNA, and also causes better adjustment feeding the RNA with the difference maximum and minimum temperature variable, or with the variable n/N .

RMSE aceptable, en este sentido, Tymvios *et al.* (2005), comentan que con un número excesivo de capas ocultas, frecuentemente lleva a un deterioro en el desempeño de la RNA, y tampoco ocasiona que mejore el ajuste alimentando la RNA con la variable diferencia temperatura máxima y mínima, ni con la variable n/N .

The coefficients of determination obtained in these scenarios are closer to one than the R^2 of 0.84, obtained from an empirical model (Angström-Prescott calibrated). Tymvios *et al.* (2005), with an RNA with two hidden and 23 x 46 layers neurons in these they found a RMSE of 5.67%, better fit compared with the RMSE obtained from Angstrom model

Cuadro 2. Error estándar del ajuste de los 1484 datos observados versus estimados con RNA.

Table 2. Standard error adjustment of the 1 484 observed data versus estimated with RNA.

# capas ocultas	Escenario 1 ^{er} . mejor ajuste	RMSE	Escenario 2 ^{do} . mejor ajuste	RMSE	Escenario 3 ^{er} . mejor ajuste	RMSE
{3}	e2{T _{min} , T _{max} , n}	1.8121	e14{T _{max} - T _{min} , n, R _a }	1.8255	e15{T _{max} - T _{min} , n/N, R _a }	1.86
{6}	e6{T _{min} , T _{max} , n/N, R _a }	1.7474	e5{T _{min} , T _{max} , n, R _a }	1.7788	e2{T _{min} , T _{max} , n}	1.788
{9}	e6{T _{min} , T _{max} , n/N, R _a }	1.7118	e5{T _{min} , T _{max} , n, R _a }	1.7233	e2{T _{min} , T _{max} , n}	1.7944
{12}	e6{T _{min} , T _{max} , n/N, R _a }	1.7034	e5{T _{min} , T _{max} , n, R _a }	1.7450	e14{T _{max} - T _{min} , n, R _a }	1.7667
{15}	e14{T _{max} - T _{min} , n, R _a }	1.7855	e12{T _{max} - T _{min} , n}	1.8477	e5{T _{min} , T _{max} , n, R _a }	1.8727
{18}	e5{T _{min} , T _{max} , n, R _a }	1.7118	e2{T _{min} , T _{max} , n}	1.7808	e6{T _{min} , T _{max} , n/N, R _a }	1.8026
{21}	e6{T _{min} , T _{max} , n/N, R _a }	1.7163	e5{T _{min} , T _{max} , n, R _a }	1.7494	e14{T _{max} - T _{min} , n, R _a }	1.7638
{24}	e6{T _{min} , T _{max} , n/N, R _a }	1.7004	e5{T _{min} , T _{max} , n, R _a }	1.7397	e14{T _{max} - T _{min} , n, R _a }	1.7646
{27}	e6{T _{min} , T _{max} , n/N, R _a }	1.6871	e5{T _{min} , T _{max} , n, R _a }	1.7354	e15{T _{max} - T _{min} , n/N, R _a }	1.7591
{30}	e5{T _{min} , T _{max} , n, R _a }	1.7189	e6{T _{min} , T _{max} , n/N, R _a }	1.7413	e2{T _{min} , T _{max} , n}	1.7656
{3x3}	e5{T _{min} , T _{max} , n, R _a }	1.7900	e2{T _{min} , T _{max} , n}	1.7906	e6{T _{min} , T _{max} , n/N, R _a }	1.8187
{6x6}	e5{T _{min} , T _{max} , n, R _a }	1.7288	e2{T _{min} , T _{max} , n}	1.7877	e6{T _{min} , T _{max} , n/N, R _a }	1.8199
{9x9}	e6{T _{min} , T _{max} , n/N, R _a }	1.7158	e5{T _{min} , T _{max} , n, R _a }	1.7340	e14{T _{max} - T _{min} , n, R _a }	1.7565
{12x12}	e5{T _{min} , T _{max} , n, R _a }	1.7085	e6{T _{min} , T _{max} , n/N, R _a }	1.7203	e14{T _{max} - T _{min} , n, R _a }	1.7573
{15x15}	e6{T _{min} , T _{max} , n/N, R _a }	1.7642	e5{T _{min} , T _{max} , n, R _a }	1.7735	e2{T _{min} , T _{max} , n}	1.7761
{18x18}	e5{T _{min} , T _{max} , n, R _a }	1.6901	e2{T _{min} , T _{max} , n}	1.7653	e6{T _{min} , T _{max} , n/N, R _a }	1.7659
{21x21}	e14{T _{max} - T _{min} , n, R _a }	1.7737	e15{T _{max} - T _{min} , n/N, R _a }	1.7988	e2{T _{min} , T _{max} , n}	1.8236
{24x24}	e6{T _{min} , T _{max} , n/N, R _a }	1.6951	e2{T _{min} , T _{max} , n}	1.7615	e14{T _{max} - T _{min} , n, R _a }	1.7351
{27x27}	e5{T _{min} , T _{max} , n, R _a }	1.6983	e6{T _{min} , T _{max} , n/N, R _a }	1.7365	e14{T _{max} - T _{min} , n, R _a }	1.7581
{30x30}	e6{T _{min} , T _{max} , n/N, R _a }	1.7115	e5{T _{min} , T _{max} , n, R _a }	1.7355	e15{T _{max} - T _{min} , n/N, R _a }	1.7634
{3x3x3}	e14{T _{max} - T _{min} , n, R _a }	1.8332	e6{T _{min} , T _{max} , n/N, R _a }	1.8379	e2{T _{min} , T _{max} , n}	1.854
{3x6x3}	e6{T _{min} , T _{max} , n/N, R _a }	1.7646	e2{T _{min} , T _{max} , n}	1.7992	e12{T _{max} - T _{min} , n}	1.8565
{6x9x6}	e6{T _{min} , T _{max} , n/N, R _a }	1.7315	e5{T _{min} , T _{max} , n, R _a }	1.7338	e14{T _{max} - T _{min} , n, R _a }	1.7708
{6x12x6}	e2{T _{min} , T _{max} , n}	1.8060	e14{T _{max} - T _{min} , n, R _a }	1.8172	e12{T _{max} - T _{min} , n}	1.8338
{6x15x6}	e5{T _{min} , T _{max} , n, R _a }	1.7670	e15{T _{max} - T _{min} , n/N, R _a }	1.7840	e6{T _{min} , T _{max} , n/N, R _a }	1.8087
{9x18x9}	e5{T _{min} , T _{max} , n, R _a }	1.7260	e15{T _{max} - T _{min} , n/N, R _a }	1.7648	e2{T _{min} , T _{max} , n}	1.7971
{9x21x9}	e5{T _{min} , T _{max} , n, R _a }	1.7283	e6{T _{min} , T _{max} , n/N, R _a }	1.7558	e15{T _{max} - T _{min} , n/N, R _a }	1.7601
{9x24x9}	e5{T _{min} , T _{max} , n, R _a }	1.7063	e6{T _{min} , T _{max} , n/N, R _a }	1.7249	e2{T _{min} , T _{max} , n}	1.7735
{9x27x9}	e5{T _{min} , T _{max} , n, R _a }	1.7019	e6{T _{min} , T _{max} , n/N, R _a }	1.7320	e14{T _{max} - T _{min} , n, R _a }	1.7766
{9x30x9}	e6{T _{min} , T _{max} , n/N, R _a }	1.7897	e2{T _{min} , T _{max} , n}	1.7926	e5{T _{min} , T _{max} , n, R _a }	1.7931

Elaboración propia: T_{min} = Temperatura mínima; T_{max} = Temperatura máxima; n = horas brillo sol; N = fotoperiodo; R_a = radiación teórica extraterrestre; RMSE = raíz cuadrada del cuadrado medio del error.

Los coeficientes de determinación obtenidos en estos escenarios, resultan más cercanos a uno que la R^2 de 0.84, obtenida de un modelo empírico (Angström-Prescott

of 13.36%, overall, this coincides with the findings in the this study, data for 1 484 shows the RNA best fit the model of Angström-Prescott calibrated.

calibrado). Tymvios *et al.* (2005), con una RNA con dos capas ocultas y 23 x 46 neuronas en estas encontraron un RMSE DE 5.67%, mejor ajuste comparado con el RMSE obtenido del modelo Angström de 13.36%, de manera global, esto coincide con lo encontrado en el presente trabajo, para los 1484 datos la RNA muestra mejor ajuste que el modelo de Angström-Prescott calibrado.

Los entrenamientos con RNA con sus diferentes entradas (Cuadro 2) que mostraron el RMSE más próximo a cero o mejor ajuste, fueron los escenarios que incluyen a la temperatura máxima, temperatura mínima y horas brillo sol, lo que también se presenta en el Cuadro 1 (escenario 2), no se realizaron entrenamientos considerando solo a la temperatura máxima y mínima, esto es, prescindiendo de la variable horas brillo sol, porque como se presentó en Cervantes-Osornio *et al.* (2012), y como lo afirman Benghanem *et al.* (2009), la variable horas brillo sol ocasiona que mejore la exactitud de la estimación de la radiación global diaria.

Observándose también en el Cuadro 1, que sí en la entrada se incluye el dato de N y R_a mejora el ajuste, aunque no tanto, como cuando se incluye a la variable horas brillo sol. Además, que entre más variables de entrada se tengan para alimentar a la RNA lleva a un mejor ajuste, pero también ocasiona que el equipo de cómputo realice más procesamientos y por lo tanto se consuman más recursos de toda índole. Los resultados obtenidos de RMSE del escenario 2 (Cuadro 1), no superaron a los resultados de RMSE ni al coeficiente de determinación del modelo empírico Angström-Prescott calibrado (Figura 1), pero en una estación que sólo cuenta con las mencionadas tres variables de entrada, esto es suficiente para entrenar la RNA.

En los Cuadros 2 y 3, se observa que los mejores ajustes, en su mayoría corresponden a los escenarios e5 y e6, que son los que tienen más variables de entrada, pero también se observa que con un número pequeño de variables de entrada, como temperatura máxima y temperatura mínima se puede hacer un pronóstico aceptable de la radiación global diaria, con una variación de milésimas en el RMSE, pero dado que existen estaciones meteorológicas que no tienen una extensa gama de instrumentos para medir la totalidad de variables climatológicas que requiere un escenario e5 ó e6, entonces un escenario e2 es suficiente para pronóstico. El Cuadro 3 se conformó con los mismos escenarios del Cuadro 2, el primer, segundo y tercer mejor ajuste que se observan en el Cuadro 3 se presentaron como sigue: con tres capas ocultas, el escenario e15 con las entradas $T_{\max}-T_{\min}$, n/N , R_a , con 9x18x9 neuronas en las capas ocultas y un RMSE de 1.9847; el e2 con las entradas

The training with RNA with different inputs (Table 2) showed the closest to zero or better fit RMSE, were the scenes that include the maximum temperature, minimum temperature and hours shine sun, which is also presented in Table 1 (scenario 2), no workouts were performed considering only the maximum and minimum temperature, that is, regardless of the hours varying brightness sun, because as presented in Cervantes-Osornio *et al.* (2012), and as stated by Benghanem *et al.* (2009), the hours sun causes varying brightness improves the accuracy of the estimate of daily global radiation.

It also observed in Table 1 that the N and R_a data is included in the entry itself improves the fit, although not as much as when you include the hours varying brightness sun. In addition, the more input variables have to feed the RNA leads to a better fit, but also causes the computer equipment perform more processing and therefore more resources of all kinds are consumed. The results of RMSE scenario 2 (Table 1), did not exceed the results of RMSE or the coefficient of determination of Angström-Prescott empirical model calibrated (Figure 1), but in a season that has only said three variables entrance, this is enough to train the RNA.

In the Tables 2 and 3, it is observed that the best settings, mostly correspond to e5 scenarios and e6, which are those with more input variables, but also noted that a small number of input variables, such as maximum temperature and minimum temperature can make an acceptable prognosis of daily global radiation, with a variation of thousandths in the RMSE, but since there are weather stations that do not have an extensive range of instruments to measure all of climatological variables requiring e6 or e5 scenario, then a stage e2 is sufficient for prognosis. The Table 3 was formed with the same scenarios in Table 2, the first, second and third best fit observed in Table 3 were presented as follows: with three hidden layers, setting e15 with $T_{\max}-T_{\min}$, n/N , R_a , with 9x18x9 neurons in the hidden layers and a RMSE of 1.9847; the e2 entries with T_{\min} , T_{\max} , n , , with 9x24x9 in the hidden layers with a RMSE of 1.9918, and e15 with $T_{\max}-T_{\min}$, n/N , R_a with a hidden layer, and three neurons in it with a RMSE of 1.9939, although these do not match the best fits obtained in practice with 1 484 data. Jiang (2008) to estimate the diffuse solar radiation monthly average determined empirical models RMSE's of 0.783, 0.871 where the neural network model used, obtained a RMSE of 0.746, with the variables: index of daylight, percentage of hours brightness sun and output the average daily diffuse fraction.

T_{\min} , T_{\max} , n , con $9 \times 24 \times 9$ en las capas ocultas, con un RMSE de 1.9918, y e15 con las entradas $T_{\max} - T_{\min}$, n/N , R_a con una capa oculta y tres neuronas en ella con un RMSE de 1.9939, aunque estos no coinciden con los mejores ajustes obtenidos en los entrenamientos con 1484 datos. Jiang (2008) al estimar la radiación solar difusa media mensual determina en los modelos empíricos RMSE's de 0.783, 0.871 donde el modelo de red neuronal utilizado, obtuvo un RMSE de 0.746, con las variables: índice de claridad del día, porcentaje de horas brillo sol y como salida la fracción media diaria difusa.

In Figures 1 and 2 shows that the maximum and minimum temperature, with the figure for hours shine sun divided by photoperiod and extraterrestrial radiation (e6{27}) the best fit for training with 1484 vectors is reached data (R^2 of 0.89 and RMSE of 1.6871), and the RNA and trained a new estimate of 229 data R_s (R^2 of 0.88 and RMSE of 2.5475), which as shown in Table 3 is not for the best fit is performed results for global data 229, in this connection Senkal and Kuleli (2009) found correlation coefficient values for the training set and evaluation 0978 and 0971 respectively; and

Cuadro 3. Error estándar de ajuste de los 229 datos observados versus estimaciones con RNA.

Table 3. Standard error adjustment of the 229 observed data versus estimates RNA.

# capas ocultas	Escenario 1er. mejor ajuste	RMSE	Escenario 2º. mejor ajuste	RMSE	Escenario 3er. mejor ajuste	RMSE
{3}	e2{ T_{\min} , T_{\max} , n }	2.3337	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1491	e15{ $T_{\max} - T_{\min}$, n/N , R_a }	1.9940
{6}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.4499	e5{ T_{\min} , T_{\max} , n , R_a }	2.2926	e2{ T_{\min} , T_{\max} , n }	2.2473
{9}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.3480	e5{ T_{\min} , T_{\max} , n , R_a }	2.2855	e2{ T_{\min} , T_{\max} , n }	2.3655
{12}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6696	e5{ T_{\min} , T_{\max} , n , R_a }	2.4298	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1303
{15}	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.0228	e12{ $T_{\max} - T_{\min}$, n }	2.1793	e5{ T_{\min} , T_{\max} , n , R_a }	2.6225
{18}	e5{ T_{\min} , T_{\max} , n , R_a }	2.4279	e2{ T_{\min} , T_{\max} , n }	2.2956	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.4736
{21}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.5573	e5{ T_{\min} , T_{\max} , n , R_a }	2.5344	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1966
{24}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6016	e5{ T_{\min} , T_{\max} , n , R_a }	2.5110	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1684
{27}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.5475	e5{ T_{\min} , T_{\max} , n , R_a }	2.5316	e15{ $T_{\max} - T_{\min}$, n/N , R_a }	2.1070
{30}	e5{ T_{\min} , T_{\max} , n , R_a }	2.6182	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6800	e2{ T_{\min} , T_{\max} , n }	2.3271
{3x3}	e5{ T_{\min} , T_{\max} , n , R_a }	2.1909	e2{ T_{\min} , T_{\max} , n }	2.3395	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.2422
{6x6}	e5{ T_{\min} , T_{\max} , n , R_a }	2.4623	e2{ T_{\min} , T_{\max} , n }	2.2890	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.4429
{9x9}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.4569	e5{ T_{\min} , T_{\max} , n , R_a }	2.7467	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1805
{12x12}	e5{ T_{\min} , T_{\max} , n , R_a }	2.5214	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.3651	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1963
{15x15}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6739	e5{ T_{\min} , T_{\max} , n , R_a }	2.7528	e2{ T_{\min} , T_{\max} , n }	2.4951
{18x18}	e5{ T_{\min} , T_{\max} , n , R_a }	2.6202	e2{ T_{\min} , T_{\max} , n }	2.3946	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.5563
{21x21}	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1853	e15{ $T_{\max} - T_{\min}$, n/N , R_a }	2.2015	e2{ T_{\min} , T_{\max} , n }	2.1792
{24x24}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6534	e2{ T_{\min} , T_{\max} , n }	2.3202	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.2036
{27x27}	e5{ T_{\min} , T_{\max} , n , R_a }	2.6423	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6350	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.5870
{30x30}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.5884	e5{ T_{\min} , T_{\max} , n , R_a }	2.8588	e15{ $T_{\max} - T_{\min}$, n/N , R_a }	2.3436
{3x3x3}	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1439	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.5014	e2{ T_{\min} , T_{\max} , n }	2.3805
{3x6x3}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.2795	e2{ T_{\min} , T_{\max} , n }	2.4035	e12{ $T_{\max} - T_{\min}$, n }	2.2951
{6x9x6}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.3708	e5{ T_{\min} , T_{\max} , n , R_a }	2.5424	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.1032
{6x12x6}	e2{ T_{\min} , T_{\max} , n }	2.5072	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.2496	e12{ $T_{\max} - T_{\min}$, n }	2.2698
{6x15x6}	e5{ T_{\min} , T_{\max} , n , R_a }	2.4811	e15{ $T_{\max} - T_{\min}$, n/N , R_a }	2.1214	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.3913
{9x18x9}	e5{ T_{\min} , T_{\max} , n , R_a }	2.3122	e15{ $T_{\max} - T_{\min}$, n/N , R_a }	1.9847	e2{ T_{\min} , T_{\max} , n }	2.4131
{9x21x9}	e5{ T_{\min} , T_{\max} , n , R_a }	2.4648	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6346	e15{ $T_{\max} - T_{\min}$, n/N , R_a }	2.0135
{9x24x9}	e5{ T_{\min} , T_{\max} , n , R_a }	2.4281	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.4794	e2{ T_{\min} , T_{\max} , n }	1.9918
{9x27x9}	e5{ T_{\min} , T_{\max} , n , R_a }	2.6010	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.5653	e14{ $T_{\max} - T_{\min}$, n , R_a }	2.0010
{9x30x9}	e6{ T_{\min} , T_{\max} , n/N , R_a }	2.6286	e2{ T_{\min} , T_{\max} , n }	2.3453	e5{ T_{\min} , T_{\max} , n , R_a }	2.6287

T_{\min} = temperatura mínima; T_{\max} = temperatura máxima; n = horas brillo sol; N = fotoperiodo; R_a = radiación teórica extraterrestre; RMSE = raíz cuadrada del cuadrado medio del error.

En las Figuras 1 y 2 se observa que con la temperatura máxima y mínima, con el dato de horas brillo sol dividido por el fotoperiodo y la radiación extraterrestre ($e_6\{27\}$) se alcanza el mejor ajuste para el entrenamiento con 1 484 vectores de datos (R^2 de 0.89 y RMSE de 1.6871), y con la RNA ya entrenada se realiza una nueva estimación de 229 datos de R_s (R^2 de 0.88 y RMSE de 2.5475), que como se observa en el Cuadro 3 no corresponde al mejor ajuste del global de resultados para 229 datos, en relación con esto Senkal and Kuleli (2009) encontraron valores del coeficiente de correlación para el conjunto de entrenamiento y de evaluación de 0.978 y de 0.971 respectivamente; y Fadare (2009) encontró valores del coeficiente de correlación y RMS (raíz media cuadrada) para el entrenamiento de 99.36% y 2.32 MJ/m² y para la evaluación de 88.39% y 3.94 MJ/m² respectivamente, lo que indica que en el conjunto de evaluación los valores de error tienden a crecer.

Fadare (2009) found values of the correlation coefficient and RMS (root mean square) for training 99.36% and 2.32 MJ/m² and for evaluation of 88.39% and 3.94 MJ/m² respectively, indicating that all evaluation error values tend to grow.

Additionally in Figure 2 shows that both models calibrated Angström-Prescott models Hargreaves, Hargreaves calibrated and RNA including backpropagation overestimate the data observed daily global radiation. Tymvios *et al.* (2005) used three model variations Angström with different calibrated values for b and RNA performing training with different input variables including: month duration of hours brightness sun, maximum temperature and duration of hours brightness theoretical sun (photoperiod), their results they are similar to those found in this work; the artificial neural network model that used Tymvios *et al.* (2005) with the

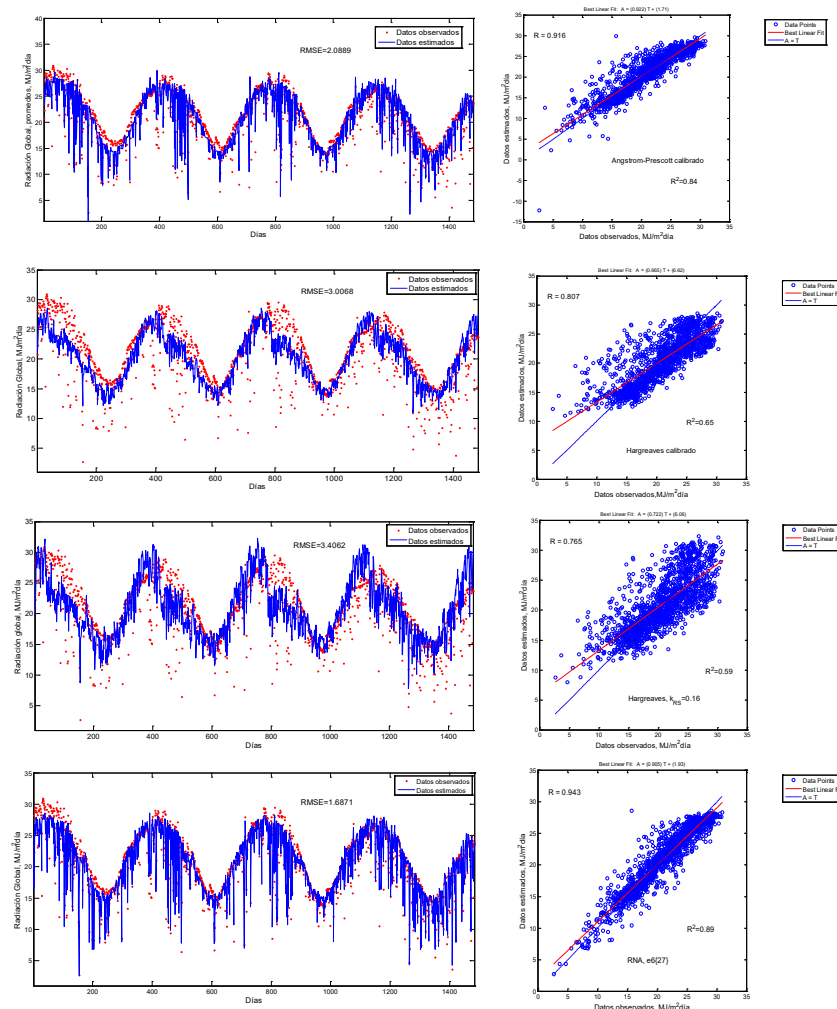


Figura 1. RMSE y R^2 para estimaciones de los modelos Angström-Prescott calibrado, Hargreaves calibrado, Hargreaves con $k_{RS}=0.16$ y RNA $e_6\{27\}$ de los 1484 datos de radiación global promedio.

Figure 1. RMSE and R^2 for estimates of Angström-Prescott models Hargreaves, Hargreaves calibrated with $k_{RS}=0.16$ and RNA $e_6\{27\}$ of the 1 484 average global radiation data.

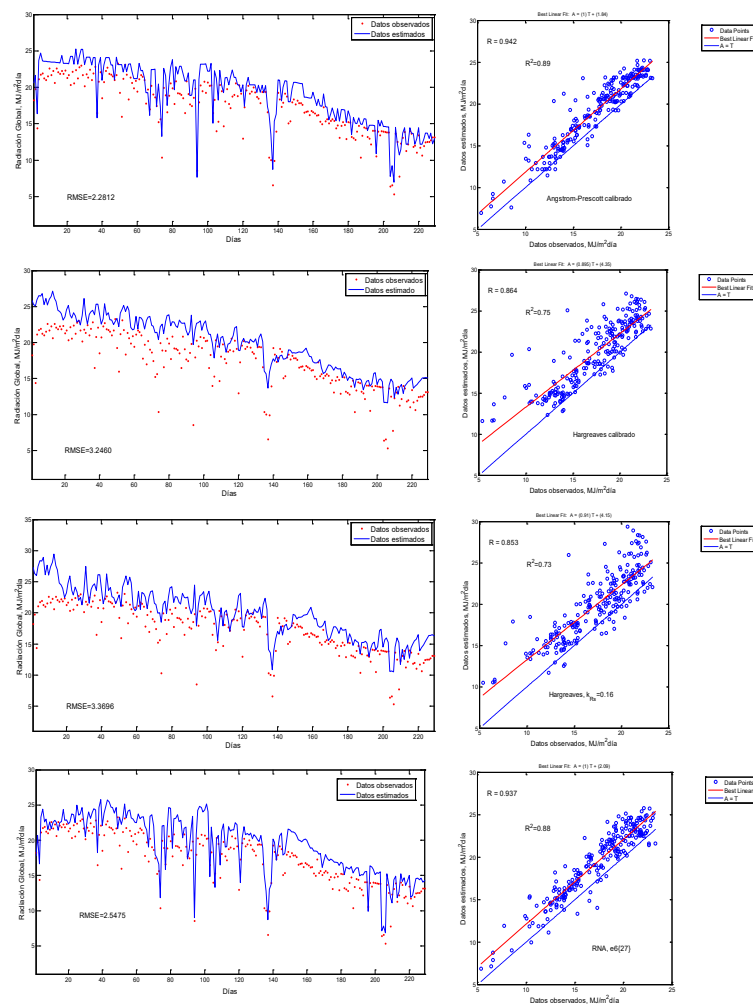


Figura 2. RMSE y R^2 para estimaciones de los modelos Angström-Prescott calibrado, Hargreaves calibrado, Hargreaves con $k_{RS}=0.16$ y RNA e6{27} de 229 datos de radiación global promedio.

Figure 2. RMSE and R^2 for estimates of Angström-Prescott models Hargreaves, Hargreaves calibrated with $k_{RS}=0.16$ and RNA e6{27} of the 229 average global radiation data.

Adicionalmente en la Figura 2 se observa que tanto los modelos de Angström-Prescott calibrado, Hargreaves, Hargreaves calibrado e inclusive la RNA backpropagation sobreestiman los datos observados de radiación global diaria. Tymvios *et al.* (2005) usaron tres variaciones del modelo de Angström con diferentes valores calibrados para a y b y RNA realizando entrenamientos con diferentes variables de entrada entre ellas: mes, duración de horas brillo sol, temperatura máxima y duración de horas brillo sol teóricas (fotoperiodo), sus resultados son similares a los hallados en este trabajo; el modelo de red neuronal artificial que usaron Tymvios *et al.* (2005) con las entradas temperatura máxima, horas brillo sol medidas y fotoperiodo obtuvo un RMSE de 5.67%, seguido muy de cerca por uno de los modelos de Angström con un RMSE de 5.81%. No obstante, Wan *et al.*

maximum temperature inputs, sun shine hours photoperiod measures and obtained an RMSE of 5.67%, followed closely by one of the models of Angström with RMSE of 5.81%. However Wan *et al.* (2008) found that the model of Angstrom calibrated in nine warm-seven areas with sunny weather in China, obtained a similar performance in the statistics RMSE and MBE fit with those found in this work, for 229 data, compared with the setting a neural network.

Conclusions

Invariably all workouts containing the variable sun shine hours (n) have a good fit.

(2008), encontraron que el modelo de Angström calibrado en nueve zonas cálidas y siete con clima soleado en China, obtuvieron un similar desempeño en los estadísticos de ajuste RMSE y MBE con los encontrados en este trabajo, para los 229 datos, comparados con el ajuste de una red neuronal.

Conclusiones

Invariablemente todos los entrenamientos que contienen la variable horas brillo sol (n), presentan un buen ajuste.

El aumento de capas ocultas no mejora el valor de ajuste del RMSE, con una y dos capas es suficiente para entrenar una RNA para la estimación de la radiación global diaria.

Las variables temperatura mínima, temperatura máxima y horas brillo sol (n) resultan indispensables para hacer un buen pronóstico de la radiación global diaria. La variable radiación teórica extraterrestre (R_a) no es relevante en el pronóstico de la radiación global diaria.

Para los 1484 datos promedios, la red neuronal artificial backpropagation en su escenario e6{27} presenta la mejor estimación de la radiación global diaria (R_s), y es mejor que los modelos empíricos, sin embargo para los 229 datos de pronóstico, el modelo Angström-Preseott calibrado presenta una estimación de R_s ligeramente mejor al e6{27}.

Literatura citada

Alexandris, S.; Kerkides, P. and Liakatas, A. 2006. Daily reference evapotranspiration estimates by the "Copais" approach. *Agric. Water Manage.* 82:371-386.

Allen, G. R.; Pereira, S. L.; Raes, D. and Smith, M. 1998. Crop evapotranspiration Guidelines for computing crop water requirements. FAO Irrigation and drainage paper 56. Roma. 298 p.

Almorox, J.; Benito, M. and Hontoria, C. 2008. Estimation of global solar radiation in Venezuela. *Interciencia* 33:280-283.

Annandale, J. G.; Jovanovic, N. Z.; Benadé, N. and Allen, R. G. 2002. Software for missing data error analysis of Penman-Monteith reference evapotranspiration. *Irrig. Sci.* 21:57-67.

Bandyopadhyay, A.; Bhadra, A.; Raghuwanshi, N. S. and Singh, R. 2008. Estimation of monthly solar radiation from measured air temperatures extremes. *Agricultural and forest meteorology*, 148:1707-1718.

The increase in hidden layers does not improve the setting value of RMSE, with one and two layers is sufficient to train an RNA for estimating daily global radiation.

The variables minimum temperature, maximum temperature and sun shine hours (n) are essential for a good prognosis of daily global radiation. Variable theoretical extraterrestrial radiation (R_a) is not relevant in the prognosis of daily global radiation.

For 1 484 average data, artificial neural network backpropagation in your scenario e6{27} presents the best estimate of daily global radiation (R_s), and is better than the empirical models, however for 229 forecast data, the Angström-Preseott calibrated model provides an estimate of R_s slightly better e6{27}.

End of the English version



Benghanem, M.; Mellit, A. and Alamri, S. N. 2009. ANN-based modeling and estimation of daily global solar radiation data: A case study. *Energy Conversion Manage.* 50:1644-1655.

Bristow, K. L. and Campbell, G. S. 1984. On the relationship between incoming solar radiation and daily maximum and minimum temperature. *Agric. Forest Meteorol.* 31:159-166.

Cervantes, O. R.; Arteaga, R. R.; Vázquez, P. M.A. y Ojeda, B. W. 2012. Radiación global diaria estimada con métodos convencionales y redes neuronales artificiales en el Distrito de Riego 075. *Ingeniería Agrícola y Biosistemas.* 4(2):55-60.

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

Fadare, D. A. 2009. Modelling of solar energy potential in Nigeria using an artificial neural network model. *Applied Energy.* 86:1410-1422.

Hargreaves, G. H. and Samani, Z. A. 1982. Estimating potential evapotranspiration. *J. Irrig. Drain. Eng., ASCE.* 108(3):225-230.

Haykin, S. 2008. Neural networks: A comprehensive foundation. 2nd. Edition. Ed. Prentice Hall. United States of America. 842 p.

Hasni, A.; Sehli, A.; Draoui, B.; Bassou, A. and Amieur, B. 2012. Estimating global solar radiation using artificial neural network and climate data in the south-western region of Algeria. *Energy Procedia.* 18:531-537.

Jiang, Y. 2008. Prediction of monthly mean daily diffuse solar radiation using artificial neural networks and comparison with other empirical models. *Energy Policy* 36:3833-3837.

Linacre, E. 1992. Climate data and resources. A reference and guide. British Library Cataloguing in Publication Data. 170-172 pp.

Liu, X.; Mei, X.; Li, Y.; Zhang, Y.; Wang, Q.; Jensen, J. R. and Porter, J. R. 2009. Calibration of the Angström-Preseott coefficients (a, b) under different time scales and their impacts in estimating global solar radiation in the Yellow River basin. *Agric. Forest Meteorol.* 149:697-710.

- Martínez, R, A.; Ortega, J. F.; de Juan, J. A.; Tarjuelo, J. M. y Moreno, M. A. 2012. Modelos de estimación de radiación solar global con limitación de datos y su distribución espacial en Castilla-La-Mancha. 108(4):426-449.
- Meza, F. and Varas, E. 2000. Estimation of mean monthly solar global radiation as a function of temperature. Agricultural and forest meteorological. 100:231-241.
- Muribu, J. 2008. Predicting total solar irradiation values using artificial neural networks. Renewable Energy. 33:2329-2332.
- 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.
- Senkal, O. and Kuleli, T. 2009. Estimation of solar radiation over Turkey using artificial neural network and satellite data. Applied Energy 86:1222-1228.
- Tabari, H. 2009. Evaluation of reference crop evapotranspiration equations in various climates. Water Resour. Manag. 24:2311-2337.
- Tymvios, F. S.; Jacovides, C. P.; Michaelides, S. C. and Skouteli, C. S. 2005. Comparative study of Angström's and artificial neural networks' methodologies in estimating global solar radiation. Solar Energy. 78:752-762.
- Wan, K. K. W.; Hang, H. L.; Yang, L. and Lam, J. C. 2008. An analysis of thermal and solar zone radiation models using an Angstrom-Prescott equation and artificial neural networks. Energy. 33:1115-1127.
- WMO. 1996. Guide to meteorological instruments and methods of observations, No. 8. Sixth edition. 157-198 pp.
- Yadav, A. K. and Chandel, S. S. 2014. Solar radiation prediction using artificial neural network techniques: A review. Renewable and sustainable energy reviews. 33:772-781.