

Modelos Hargreaves Priestley-Taylor y redes neuronales artificiales en la estimación de la evapotranspiración de referencia

Reference Evapotranspiration Estimation by Hargreaves Priestley-Taylor and Artificial Neural Networks Models

Cervantes-Osornio Rocío

Instituto Nacional de Investigaciones
Forestales, Agrícolas y Pecuarias, Texcoco, Chapingo
Correo: cervantes.rocio@inifap.gob.mx

Arteaga-Ramírez Ramón

Posgrado en Ingeniería Agrícola y Uso Integral del Agua
Universidad Autónoma Chapingo, Texcoco, Estado de México
Correo: rarteagar@taurus.chapingo.mx

Vázquez-Peña Mario Alberto

Posgrado en Ingeniería Agrícola y Uso Integral del Agua
Universidad Autónoma Chapingo, Texcoco, Estado de México
Correo: mvazquezp@correo.chapingo.mx

Ojeda-Bustamante Waldo

Instituto Mexicano de Tecnología del Agua, Jiutepec, Morelos
Correo: wojeda@tlaloc.imta.mx

Quevedo-Nolasco Abel

Programa de Hidrociencias
Colegio de Posgraduados, Texcoco, Montecillo
Correo: anolasco@colpos.mx

Información del artículo: recibido: noviembre de 2010, reevaluado: febrero de 2012, aceptado: septiembre de 2012

Resumen

Resulta costoso medir directamente la evapotranspiración de referencia (ET_0) con un lisímetro, y al no contar con esta información se utilizó el método de Penman-Monteith modificado por la FAO (ET_0 FAO-56 P-M) para su cálculo. El objetivo del presente trabajo fue realizar una comparación de modelos empíricos como el de Hargreaves, Hargreaves calibrado y Priestley-Taylor, con el modelo de *redes neuronales artificiales función de base radial* (RNA BR), con las mismas variables de entrada, en la estimación de la ET_0 FAO-56 P-M. Las estimaciones de ET_0 se evaluaron en cuatro estaciones climáticas del Distrito 075, Valle del Fuerte en Sinaloa, México. Las RNABR3 y RNABR7 utilizaron las mismas variables de entrada (o menos) que los métodos convencionales de HARGC y P-T, respectivamente. Los RMSE de HARGC y P-T en el ajuste, variaron de 0.7092 a 0.7848 y de 0.4178 a 0.8207, y en la validación de 1.1898 a 0.6914 y de 0.3800 a 0.6889, respectivamente. De las RNA-BR3 y RNABR7 sus RMSE en el ajuste fueron de 0.5295 a 0.6737 y de 0.3574 a 0.4809, y en la validación de 1.3096 a 0.6254 y de 0.3470 a 0.4919, respectivamente. Los RMSE obtenidos en el ajuste y en la validación de las RNABR3 y RNABR7 definieron que éstas fueron mejores en la estimación de la ET_0 FAO-56 P-M que los métodos convencionales.

Descriptores:

- función de base radial
- Hargreaves
- modelos
- necesidades de agua
- Priestley-Taylor
- pronóstico

Abstract

Directly measuring evapotranspiration accurately through a lysimeter is difficult, and because of data lack the Penman-Monteith method modified by FAO (ET_0 FAO-56 P-M) was used to obtain the reference evapotranspiration observed. The objective of the present study was to perform a comparison of empirical models like: Hargreaves, Hargreaves calibrated and Priestley-Taylor with the artificial neural network radial basis function (RNA BR) model with the same entry variables, in the estimation of reference evapotranspiration. The estimations of ET_0 were evaluated in four stations of District 075, Valle del Fuerte in Sinaloa, México. RNABR3 y RNABR7 used same entry variables (or less) than HARGC and P-T conventional methods, respectively. HARGC and P-T RMSE's at fitting changed from 0.7092 to 0.7848 and from 0.4178 to 0.8207, and on validation changed from 1.1898 to 0.6914 and from 0.3800 to 0.6889, respectively. RMSE's from RNABR3 and RNABR7 at fitting changed from 0.5295 to 0.6737 and from 0.3574 to 0.4809, and on validation from 1.3096 to 0.6254 and from 0.3470 to 0.4919, respectively. RNABR3, RNABR7 RMSE's obtained fitting as well as validation defined that RNA BR were better on the estimation of ET_0 FAO-56 P-M than conventional methods.

Keywords:

- basis radial function
- Hargreaves
- models
- water necessities
- Priestley and Taylor
- forecasting

Introducción

El método Penman-Monteith (FAO56 P-M) 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), ya que diversos estudios realizados para evaluar diferentes modelos de ET_0 con datos obtenidos de lisímetro de pesada, tales como FAO-24 Penman (Doorenbos y Pruitt, 1980; Jensen *et al.*, 1990); FAO-24 Radiación (Doorenbos y Pruitt, 1980); Hargreaves (Hargreaves y Samani, 1985; Allen *et al.*, 1998), concluyeron que la ecuación de FAO-56 Penman-Monteith fue la mejor (Allen *et al.*, 1998; Steiner *et al.*, 1991; DehghaniSanij *et al.*, 2004; López-Urrea *et al.*, 2006). 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 la operación del recurso agua de manera adecuada (Jensen *et al.*, 1990; Ojeda, 2004). Variables climáticas que requieren ser conocidas e influyen en la evapotranspiración son: la temperatura del aire, humedad atmosférica, radiación solar y velocidad del viento (Allen *et al.*, 1998). Debido a que no todas estas variables están disponibles en cualquier estación meteorológica han sido propuestos diferentes modelos para estimar la evapotranspiración de referencia (ET_0) como la ecuación de Hargreaves (1994), que la estima en función de temperatura y tiene resultados razonables de ET_0 (Allen *et al.*, 1998). Otro modelo para estimar la ET_0 es Priestley-Taylor, que relaciona la evapotranspiración con la radiación. Estos de-

mandan el conocimiento de menos datos (Thornley y France, 2007). Mangliulo *et al.* (2003) utilizan un atmómetro modificado para la estimación de la ET_0 , de igual forma Doorenbos y Pruitt (1980) reportaron que existe una alta correlación entre los datos de un tanque evaporímetro y la ET_0 cuando éste se mantiene e instala apropiadamente. En años recientes, las Redes Neuronales Artificiales (RNA) 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). Zanetti *et al.* (2007), evaluaron una RNA multicapa en función de las temperaturas máximas y mínimas del aire para estimar ET_0 . De igual manera, Kumar *et al.* (2002) utilizaron una RNA con el algoritmo *backpropagation* y además de usar las temperaturas (máximas y mínimas) consideraron: humedad relativa máxima y mínima, velocidad del viento y radiación solar.

Debido a que en México no se encontraron trabajos realizados utilizando redes neuronales artificiales de base radial para estimar la evapotranspiración de referencia, se pretende con este estudio definir si las RNA BR estiman con menor error la evapotranspiración de referencia (ET_0) obtenida con el método de Penman-Monteith, con las mismas (o menos) variables de entrada que utilizan los métodos convencionales de Hargreaves (calibrado y sin calibrar) y Priestley-Taylor, en las condiciones climáticas del distrito de riego 075 ubicado en los Mochis, Sinaloa. Por lo que el objetivo del presente trabajo fue determinar si las RNA de Base Radial con las mismas (o menos) variables de entrada que utilizan los métodos convencionales de: Hargreaves (HARG), Har-

greaves calibrado (HARGC) y Priestley-Taylor ($P-T$), son mejores al estimar la ET_0 obtenida con Penman-Monteith FAO-56.

Materiales y métodos

Área de estudio y datos climatológicos

Se utilizaron datos climatológicos de cuatro estaciones: temperaturas máximas y mínimas en °C, radiación global en $\text{MJ m}^{-2} \text{ día}^{-1}$, humedad relativa en % y velocidad del viento en m s^{-1} , que se obtuvieron de la red agroclimática automatizada Valle del Fuerte y fueron proporcionados por el Distrito de Riego 075, en Los Mochis, Sinaloa. Las coordenadas de dichas estaciones se presentan en el cuadro 1.

Estos datos se preprocesaron a nivel diario, comprendieron del periodo abril de 1997 a diciembre de 2001. El conjunto de datos de abril de 1997 a mediados de mayo de 2001 (1484 días), se utilizaron para el ajuste de la evapotranspiración de referencia (ET_0) con los diferentes modelos, así como en el entrenamiento, validación y prueba de las RNA, y de mediados de mayo a diciembre de 2001 (229 días) se utilizó para realizar la validación de los modelos. Los datos se preprocesaron en hojas de cálculo y el software usado para el entrenamiento de las RNA es el *toolbox* de redes neuronales para Matlab 7.0^{MR}.

Penman-Monteith FAO 56

Debido a la dificultad de obtener datos de lisímetro de ET_0 se tomaron como datos observados, la evapotranspiración de referencia obtenida por el método FAO-56 Penman-Monteith, recomendado por los expertos como único método estándar para el cálculo de ET_0 (Allen *et al.*, 1998). La ecuación para estimar ET_0 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 = evapotranspiración de referencia en mm día^{-1} ,
 R_n = radiación neta en $\text{MJ m}^{-2} \text{ día}^{-1}$,

G = densidad de flujo de calor del suelo en $\text{MJ m}^{-2} \text{ día}^{-1}$,
 T = temperatura media del aire a 2 m de altura en °C,
 u_2 = velocidad del viento media a 2 m de altura en m s^{-1} ,
 e_s = presión de vapor a saturación a la temperatura del aire T en kPa,
 e_a = presión de vapor actual en kPa,
 $e_s - e_a$ = déficit de presión de vapor en kPa,
 Δ = pendiente de la curva de presión de vapor a saturación en $\text{kPa } ^\circ\text{C}^{-1}$,
 γ = constante psicométrica en $\text{kPa } ^\circ\text{C}^{-1}$ (Allen *et al.*, 1998).

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

Hargreaves (HARG)

La ecuación de Hargreaves es:

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

donde:

T_{media} = temperatura media en °C,
 T_{max} y T_{min} = temperaturas máximas y mínimas, respectivamente y
 R_a = radiación extraterrestre en mm día^{-1} , este dato se calcula de acuerdo con la metodología propuesta en Allen *et al.* (1998).

Hargreaves calibrado (HARGC)

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

$$ET_{0, PM} = 0.0023 (T_{media} + 17.8) (T_{max} - T_{min})^{HE} R_a \quad (3)$$

donde:

$ET_{0, PM}$ = evapotranspiración de referencia calculada con FAO-56 P-M (Allen *et al.*, 1998),

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

Cuadro 1. Nombre, clave, longitud, latitud y altitud de las estaciones objeto de este estudio

HE = exponente empírico de Hargreaves, que fue calibrado con los vectores de 1484 datos disponibles para cada una de las estaciones.

Modelo Priestley-Taylor (P-T)

La ecuación de Priestley y Taylor (1972):

$$E = \frac{\alpha}{\lambda} \frac{\Delta}{\Delta + \gamma} (R_n - G) \quad (4)$$

donde:

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

Red Neuronal Artificial función de base radial (RNA BR)

La red de función de *base radial* (BR) con n entradas y un escalar como salida se representa en la ecuación 5, tal red implementa un mapeo $f_r: R^n \rightarrow R$ de acuerdo con:

$$f_r(x) = \lambda_0 + \sum_{i=1}^{n_r} \lambda_i \phi(\|x - c_i\|) \quad (5)$$

donde:

$x \in R^n$ = vector de entrada,
 $\phi(\cdot)$ = función dada de R^+ a R ,
 $\|\cdot\|$ = norma euclidiana,
 λ_i , $0 \leq i \leq n_r$ = pesos o parámetros,
 $c_i \in R^n$, $1 \leq i \leq n_r$ = conocidas como los centros BR, y
 n_r = número de centros.

Aunque el caso de salida escalar es considerado aquí por simplicidad rotacional. De hecho, una red BR multisalida puede separarse siempre en un grupo de una red BR de una sola salida. En la red BR la forma funcional $\phi(\cdot)$ y los centros c_i se asumen 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 λ_i se determinan con el método lineal de mínimos cuadrados. Sin embargo, las elecciones de $\phi(\cdot)$ y c_i deben considerarse cuidadosamente para que la red BR 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 BR. Por ejemplo, sea la elección una función Gaussiana

$$\phi(v) = \exp(-v^2 / \beta^2) \quad (6)$$

donde β 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).

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 simuló los datos de salida observados con la red entrenada con el código $a = sim(net, P)$, donde a es la salida de la red.

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

Se utilizaron nueve escenarios de las redes neuronales artificiales de base radial (RNA BR) que a continuación se presentan, así como las {variables de entrada} que se utilizaron en cada una de ellas: La RNABR1 { $Tmin$, $Tmax$ }, RNABR2 { $Tmedia$, Ra }, RNABR3 { $Tmin$, $Tmax$, Ra }, RNABR5 { $Tmedia$, Rn }, RNABR6 { Rn , $Delta$ }, RNABR7 { $Tmin$, $Tmax$, Rn }, RNABR8 { $Tmedia$, RG , $HRmedia$, VV }, RNABR9 { $Tmedia$, RG , DPV , VV }, RNABR10 { $Tmin$, $Tmax$, RG , $HRmin$, $HRmax$, VV }, donde $Tmin$ y $Tmax$

son temperatura máxima y mínima, respectivamente, T_{media} promedio de las temperaturas, Ra radiación extraterrestre, Rn radiación neta, Δ pendiente de la curva de presión de vapor a saturación, HR_{media} promedio de la humedad relativa máxima y mínima, RG radiación global, DPV déficit de presión de vapor, VV velocidad de viento, HR_{min} y HR_{max} humedad relativa mínima y máxima, respectivamente.

Índices estadísticos para evaluar los modelos

Se obtuvieron los siguientes estadísticos de prueba para los diferentes modelos:

Error estándar promedio o raíz cuadrada del cuadrado medio del error ($RMSE$),

$$RMSE = \left(\frac{\sum_{i=1}^N (a_i - t_i)^2}{N} \right)^{1/2} \quad (7)$$

Índice de Willmot (Willmot, 1981),

$$d = 1 - \frac{\sum_{i=1}^N (a_i - t_i)^2}{\sum_{i=1}^N (|a_i - \bar{a}| + |t_i - \bar{t}|)^2} \quad (8)$$

Coefficiente de determinación, R^2 ,

$$R^2 = \frac{\left[\sum_{i=1}^N (a_i - \bar{a})(t_i - \bar{t}) \right]^2}{\left[\sum_{i=1}^N (a_i - \bar{a})^2 \right] \left[\sum_{i=1}^N (t_i - \bar{t})^2 \right]} \quad (9)$$

donde:

R^2 = coeficiente de determinación,
 a_i = dato estimado por el modelo,
 t_i = dato observado,
 N = número de observaciones o estimaciones,
 $\bar{a}$ = promedio de los datos estimados por el modelo,
 $\bar{t}$ = promedio de los datos observados, (Cai *et al.*, 2007).

Resultados y discusión

Los valores estimados del exponente HE de $HARGC$ fueron 0.1245, 0.1401, 0.1051, 0.0818 para las estaciones Ruiz Cortínez, Batequis, Santa Rosa 1 y Santa Rosa 2, respectivamente. En el cuadro 2 se observa que $HARGC$ presentó un mejor ajuste que $HARG$, debido a la calibración del coeficiente HE , esto concuerda con Trajkovic (2007), que comenta que la ecuación de Hargreaves sin calibrar tiende a sobreestimar la evapotranspiración

Modelo	m	b	R^2	$RMSE$	d
Estación Ruiz Cortínez					
$HARG$	0.7739	1.5953	0.6836	1.0387	0.8729
$HARGC$	0.7110	1.2507	0.7363	0.7848	0.9163
$RNABR1$	0.6578	1.5582	0.6579	0.8895	0.8882
$RNABR2$	0.7315	1.2225	0.7315	0.7879	0.9177
$RNABR3$	0.8038	0.8935	0.8037	0.6737	0.9431
Estación Batequis					
$HARG$	0.8161	1.3040	0.7217	0.9206	0.8988
$HARGC$	0.7633	1.0972	0.7512	0.7497	0.9262
$RNABR1$	0.6790	1.5123	0.679	0.8509	0.8967
$RNABR2$	0.7329	1.2584	0.7329	0.7762	0.9184
$RNABR3$	0.8373	0.7667	0.8372	0.6058	0.9540
Estación Santa Rosa 1					
$HARG$	0.7856	1.6540	0.6642	1.1727	0.8498
$HARGC$	0.7088	1.1656	0.7679	0.7553	0.9234
$RNABR1$	0.6816	1.3787	0.6816	0.8691	0.8977
$RNABR2$	0.7880	0.9181	0.7880	0.7092	0.9382
$RNABR3$	0.8473	0.6611	0.8473	0.6019	0.9572
Estación Santa Rosa 2					
$HARG$	0.8558	1.7483	0.7599	1.3918	0.8223
$HARGC$	0.6767	1.2450	0.8334	0.7092	0.9317
$RNABR1$	0.6839	1.3271	0.6839	0.8891	0.8987
$RNABR2$	0.8425	0.6608	0.8425	0.6275	0.9559
$RNABR3$	0.8879	0.4705	0.8879	0.5295	0.9696

Cuadro 2. Resumen de estadísticos del ajuste de los métodos que estiman ET_0 diaria $HARG$, $HARGC$ y $RNABR1$, 2, 3, comparadas con FAO-56 P-M

m = pendiente, b = intercepto, R^2 = coeficiente de determinación, $RMSE$ = raíz cuadrada del cuadrado medio del error en $mm\ día^{-1}$, d = índice de Willmott

en regiones húmedas y puesto que Valle del Fuerte Los Mochis, Sinaloa es una zona de riego que presenta humedad relativa de 70.4% anual, de acuerdo con Doorenbos y Pruitt (1980), se clasifica como zona de humedad relativa alta.

Las tres RNA BR propuestas presentaron RMSE menores que los de HARG (cuadro 2). HARGC fue mejor que RNABR1, muy semejante a la RNABR2, pero no superó a la RNABR3, con base en los RMSE. RNABR3 tienen mejor desempeño en este periodo de ajuste que HARG y HARGC. Contar en la zona de estudio con una RNA BR entrenada, validada y probada con datos de entrada de T_{max} y T_{min} , dará mejores resultados que el HARG, y dado que el valor de R_a no se obtiene de un instrumento (se calcula), su implementación en RNA BR es fácil y disminuye el error que se comete al estimar la ET_0 FAO56 P-M diaria, lo cual repercute en una mejor estimación de las necesidades de agua de los cultivos. La RNABR3 utiliza un dato menos (temperatura media) que HARG y HARGC.

En el cuadro 3 las tres RNA BR propuestas presentaron menos error (RMSE), al utilizar las mismas o menos variables de entrada que P-T. Esto se debe a que la región de estudio es un distrito de riego, donde los cultivos no están estresados hídricamente y la R_n en estas condiciones es la principal componente de la evapotranspiración, y según Stagnitti *et al.* (1989) aproxima-

damente 95% de la demanda evapotranspirativa es proporcionada por el término radiactivo en condiciones de buena humedad del suelo.

Esta característica la presenta también el Modelo P-T, ya que, de manera general, tiene RMSE menores (cuadro 3) que HARG y HARGC (cuadro 2). La RNABR7 que tiene las mismas variables que P-T, posee la característica que se acaba de comentar, por esto es la mejor de todas las RNA BR en este proceso de ajuste.

En el cuadro 4 se presentan tres RNA BR a las que se les adicionó el término aerodinámico. De diferente forma, en función a la información que se tenga de la humedad atmosférica se estudiaron estos tres escenarios para conocer su desempeño en la estimación de la ET_0 diaria FAO-56 Penman-Monteith. Todos los indicadores son muy adecuados: $m \approx 1$ y $b \approx 0$, $R^2 \approx 1$, $d \approx 1$ y los errores (RMSE) son menores de dos décimas de mm día⁻¹. La RNABR10 obtuvo valores de R^2 de 0.99 en todas las estaciones. González *et al.* (2008), consiguieron una R^2 semejante en la estación Santa Rosa 1, pero utilizaron una RNA *feedforward backpropagation*.

Validación de los modelos

Las tres RNA BR, en las estaciones Ruiz Cortínez y Santa Rosa 2, sus RMSE fueron mejores que los de HARG, y en las restantes fueron RNABR2 y RNABR3 con el

Modelo	m	b	R^2	RMSE	d
Estación Ruiz Cortínez					
P-T	1.0717	-0.4506	0.8649	0.6649	0.9575
RNABR5	0.8721	0.5823	0.8722	0.5437	0.9648
RNABR6	0.8664	0.6086	0.8664	0.5559	0.9630
RNABR7	0.9024	0.4446	0.9023	0.4751	0.9737
Estación Batequis					
P-T	1.0245	-0.5727	0.8365	0.8207	0.9327
RNABR5	0.8484	0.7143	0.8484	0.5848	0.9575
RNABR6	0.8388	0.7596	0.8389	0.6031	0.9544
RNABR7	0.8975	0.4829	0.8974	0.4809	0.9723
Estación Santa Rosa 1					
P-T	1.0914	-0.3613	0.9099	0.5482	0.9719
RNABR5	0.9143	0.3710	0.9143	0.4508	0.9772
RNABR6	0.9101	0.3893	0.9101	0.4618	0.9760
RNABR7	0.9342	0.2848	0.93412	0.3951	0.9827
Estimación Santa Rosa 2					
P-T	0.9540	0.0882	0.9349	0.4178	0.9820
RNABR5	0.9402	0.2511	0.9401	0.3868	0.9844
RNABR6	0.9364	0.2669	0.9364	0.3987	0.9833
RNABR7	0.9489	0.2144	0.9489	0.3574	0.9867

Cuadro 3. Resumen de estadísticos del ajuste de los métodos que estiman ET_0 diaria P-T y RNABR5, 6, 7, comparada con FAO-56 P-M

m = pendiente, b = intercepto, R^2 = coeficiente de determinación, RMSE = raíz cuadrada del cuadrado medio del error en mm día⁻¹, d = índice de Willmott

conjunto de datos (mayo a diciembre de 2001) que se utilizó en la validación de los modelos (cuadro 5). *HARGC* fue mejor (debido al ajuste del exponente *HE*), en las estaciones Ruíz Cortínez y Santa Rosa 2, que las tres *RNA BR* debido a sus *RMSE* más bajos, en las restantes sólo la *RNABR3* presentó *RMSE* un poco más bajos (cuadro 5). Por lo anterior, la *RNABR3* con datos de entrada de temperaturas máximas y mínimas y un dato menos (temperatura media), que los métodos convencionales *HARG* y *HARGC*, presentó un mejor desempeño en la estimación de ET_0 .

Los valores de *RMSE* en el cuadro 6 (validación) indican que las tres *RNA BR* tienen valores más bajos que *P-T* en las estaciones Ruíz Cortínez, Batequis y Santa Rosa 1. En Santa Rosa 2 *P-T* estima mejor que las tres *RNA BR*, puesto que presenta menor *RMSE*.

Los valores de los *RMSE* de *P-T* son menores en la validación (cuadro 6) que en el ajuste (cuadro 3). Para las tres *RNA BR*, sólo en Santa Rosa 2 los *RMSE* son menores en el periodo de ajuste con respecto al de validación.

Las *RNABR8*, 9 y 10 en el proceso de validación (cuadro 7) presentaron *RMSE* menores a 0.2 mm día^{-1} , semejantes a los del ajuste, la excepción es en la estación Ruíz Cortínez que son menores de 0.3 mm día^{-1} . Los resultados de los Modelos *RNABR8*, 9 y 10 en todos sus escenarios (cuadro 7) son similares a lo encontrado por

Trajkovic *et al.* (2003), que utilizó una *RNA BR* para estimar ET_0 pero de manera mensual con una R^2 de 0.94. Las *RNABR5*, 6 y 7 con menos o igual datos que *P-T*, presentaron mejor capacidad en la estimación de la ET_0 FAO-56 P-M, la mejor fue la *RNABR7* (cuadro 6).

A su vez, Sudheer *et al.* (2003) encontraron una R^2 de 0.8645 en un escenario semejante al *RNABR8*, éste varió entre 0.9564 a 0.9968. Según los *RMSE* en esta fase de validación (cuadro 7) resultó mejor el Modelo *RNABR9* que el modelo *RNABR10*, no siendo así en el ajuste. La *RNABR9*, con las variables de entrada temperatura media, radiación global, déficit de presión de vapor y velocidad del viento fue el modelo de mejor desempeño en la estimación de la evapotranspiración de referencia.

En la figura 1, en las cuatro estaciones, los métodos *HARG*, *RNABR2* y *RNABR3* sobreestiman el valor de ET_0 FAO-56 P-M (método base). *HARG* y *RNABR2* en la estación Ruíz Cortínez de mayo a agosto (1 a 120) presentan sus máximas desviaciones, con respecto al método base. La *RNABR3* estima mejor la ET_0 FAO-56 P-M en Santa Rosa 1 y 2. Todo lo anterior concuerda con los *RMSE* (cuadro 5).

HARGC en las estaciones Ruíz Cortínez y Santa Rosa 2 de la figura 2, presenta un mejor comportamiento que *RNABR2* y *RNABR3*. Aquí también se observa que *HARGC* y *RNABR2* de mayo a julio tienen sus máximas desviaciones. En Batequis y Santa Rosa 1,

Modelo	<i>m</i>	<i>b</i>	R^2	<i>RMSE</i>	<i>d</i>
Estación Ruíz Cortínez					
<i>RNABR8</i>	0.9887	0.0516	0.9886	0.1619	0.9971
<i>RNABR9</i>	0.9913	0.0397	0.9912	0.1420	0.9978
<i>RNABR10</i>	0.9929	0.0322	0.9930	0.1278	0.9982
Estación Batequis					
<i>RNABR8</i>	0.9854	0.0688	0.9854	0.1815	0.9963
<i>RNABR9</i>	0.9903	0.0459	0.9902	0.1482	0.9975
<i>RNABR10</i>	0.9925	0.0352	0.9926	0.1297	0.9981
Estación Santa Rosa 1					
<i>RNABR8</i>	0.9911	0.0383	0.9912	0.1449	0.9978
<i>RNABR9</i>	0.9922	0.0339	0.9922	0.1363	0.9980
<i>RNABR10</i>	0.9937	0.0272	0.9938	0.1221	0.9984
Estación Santa Rosa 2					
<i>RNABR8</i>	0.9876	0.0521	0.9876	0.1763	0.9969
<i>RNABR9</i>	0.9901	0.0419	0.9900	0.1573	0.9975
<i>RNABR10</i>	0.9919	0.0341	0.9918	0.1425	0.9979

Cuadro 4. Resumen de estadísticos del ajuste de los métodos que estiman ET_0 diaria *RNABR8*, 9, 10 comparada con FAO-56 P-M

m = pendiente, *b* = intercepto, R^2 = coeficiente de determinación, *RMSE* = raíz cuadrada del cuadrado medio del error en mm día^{-1} , *d* = índice de Willmott

Modelo	m	b	R^2	RMSE	d
Estación Ruiz Cortínez					
HARG	1.1208	0.8766	0.6093	1.6334	0.6479
HARGC	1.0456	0.7023	0.6374	1.1898	0.7623
RNABR1	1.0784	0.8604	0.7704	1.3118	0.7320
RNABR2	1.0773	0.7340	0.6916	1.2705	0.7445
RNABR3	1.1547	0.4138	0.695	1.3096	0.743
Estación Batequis					
HARG	0.9224	1.1872	0.8208	1.0416	0.8749
HARGC	0.8614	1.1972	0.7663	0.9045	0.8968
RNABR1	0.7406	1.9924	0.6616	1.1732	0.8238
RNABR2	0.8488	1.3455	0.7646	0.9646	0.8827
RNABR3	0.9488	0.8988	0.8447	0.8838	0.9080
Santa Rosa 1					
HARG	0.7993	1.6840	0.8750	1.0046	0.9009
HARGC	0.7180	1.4231	0.856	0.7055	0.9425
RNABR1	0.6572	2.0211	0.7394	1.0085	0.8835
RNABR2	0.8214	1.1456	0.8534	0.7365	0.9452
RNABR3	0.8827	0.8998	0.9137	0.6254	0.9621
Santa Rosa 2					
HARG	1.0414	1.3364	0.8376	1.62	0.7425
HARGC	0.8372	1.0717	0.8165	0.6914	0.9243
RNABR1	0.7596	1.8781	0.6414	1.2042	0.7975
RNABR2	1.0926	0.3017	0.8370	0.9324	0.8974
RNABR3	1.1392	0.0710	0.8573	0.898	0.9069

Cuadro 5. Resumen de estadísticos de la validación de los métodos que estiman ET_0 diaria con HARG, HARGC y RNABR1, 2, 3, comparada con FAO-56 P-M

m = pendiente, b = intercepto, R^2 = coeficiente de determinación, RMSE = raíz cuadrada del cuadrado medio del error en mm día⁻¹, d = índice de Willmott

Modelo	m	b	R^2	RMSE	d
Estación Ruiz Cortínez					
P-T	0.8550	0.3226	0.7449	0.5826	0.9143
RNABR5	0.6888	1.3054	0.6889	0.5695	0.9002
RNABR6	0.7400	1.0753	0.7746	0.4843	0.9294
RNABR7	0.7780	1.0359	0.7889	0.4919	0.9303
Estación Batequis					
P-T	0.9644	-0.2675	0.8643	0.6889	0.9419
RNABR5	0.8317	0.7540	0.8677	0.5154	0.9616
RNABR6	0.8305	0.7776	0.8705	0.5111	0.9621
RNABR7	0.8359	0.8127	0.8907	0.4792	0.9667
Estación Santa Rosa 1					
P-T	1.0827	-0.1282	0.9518	0.4904	0.9805
RNABR5	0.9106	0.5614	0.9561	0.3961	0.9848
RNABR6	0.9204	0.5125	0.9541	0.3971	0.9849
RNABR7	0.9127	0.5637	0.972	0.347	0.9883
Estación Santa Rosa 2					
P-T	1.1078	-0.3097	0.9847	0.3860	0.9806
RNABR5	1.1243	-0.2557	0.9516	0.4451	0.9747
RNABR6	1.1204	-0.2335	0.9494	0.4513	0.9739
RNABR7	1.0870	-0.0965	0.9526	0.4231	0.9763

Cuadro 6. Resumen de estadísticos de la validación de los métodos que estiman ET_0 diaria con P-T y RNABR5, 6, 7 comparada con FAO-56 P-M

m = pendiente, b = intercepto, R^2 = coeficiente de determinación, RMSE = raíz cuadrada del cuadrado medio del error en mm día⁻¹, d = índice de Willmott

Modelo	m	b	R^2	RMSE	d
Estación Ruiz Cortéz					
RNABR8	0.8828	0.3412	0.9564	0.2546	0.9824
RNABR9	0.9093	0.2660	0.9659	0.2159	0.9876
RNABR10	0.8705	0.4205	0.9291	0.2904	0.9769
Estación Batequis					
RNABR8	0.9415	0.1481	0.9892	0.1982	0.9948
RNABR9	0.9404	0.2142	0.9930	0.1488	0.9970
RNABR10	0.9392	0.1684	0.9864	0.2059	0.9943
Estación Santa Rosa 1					
RNABR8	0.9795	0.0507	0.9968	0.1058	0.9989
RNABR9	0.9828	0.0590	0.9978	0.0826	0.9994
RNABR10	0.9814	0.0491	0.9952	0.1216	0.9987
Estación Santa Rosa 2					
RNABR8	0.9604	0.1407	0.9829	0.1738	0.9954
RNABR9	0.9671	0.1138	0.9775	0.1967	0.9941
RNABR10	0.9389	0.2041	0.9882	0.1612	0.9959

Cuadro 7. Resumen de estadísticos de la validación de los métodos que estiman ET_0 diaria con RNABR8, 9, 10, comparada con FAO-56 P-M

m = pendiente, b = intercepto, R^2 = coeficiente de determinación, RMSE = raíz cuadrada del cuadrado medio del error en mm día⁻¹, d = índice de Willmott




Figura 1. Comparación de los datos ET_0 FAO-56 P-M con los estimados por los métodos HARG, RNABR2 y RNABR3 para el periodo de validación (229 días)




Figura 2. Comparación de los datos ET_0 FAO-56 P-M con los estimados por los métodos *HARGC*, *RNABR2* y *RNABR3* para el periodo de validación (229 días)

HARGC y *RNABR3* tienen mejor estimación del método base. En las cuatro estaciones, los tres métodos presentan su mejor estimación en los meses de octubre a diciembre (151 a 210). También se resalta que *HARGC* disminuye la sobreestimación en comparación con *HARG*.

En la figura 3 Santa Rosa 2 *P-T* presenta mejor estimación que la *RNABR7*, en las otras estaciones es esta última. Suleiman y Hoogenboom (2007) encontraron que en época de invierno el Modelo *P-T* subestima a los datos observados de ET_0 en todas sus estaciones, lo que también aquí se presentó (figura 3).

En la figura 4 se confirma lo que se presentó en el cuadro 7, que el Modelo *RNABR9* es mejor que el *RNABR8*.

Por todo lo expuesto aquí, se deriva que los modelos convencionales tienden a sobreestimar o subestimar la ET_0 , debido a que tienen parámetros definidos en función de los datos climatológicos que utilicen, si se está estimando en invierno o verano, o si la zona es húmeda o seca, cálida o fría. La bondad en el ajuste de los modelos de RNA se debe al entrenamiento, validación y prueba con datos particulares de la región, lo que hace que sean más flexibles y eficientes en la estimación, ya que integran en los pesos de la etapa de entrenamiento, características climáticas de la región y eso repercute en

una buena estimación de la ET_0 diaria. Hargreaves calibrado posee también esta flexibilidad de integrar en el ajuste de *HE*, características climáticas de la región que ayuda en la estimación de la ET_0 . El mejor método de los convencionales fue *P-T* en tres estaciones, le siguió *HARGC* y al final *HARG*. En Batequis el primero fue *HARGC* y *P-T* fue segundo.

Los modelos *RNABR8*, *RNABR9* y *RNABR10* muestran un excelente ajuste, tanto en la simulación como en la validación, ya que considera las variables de entrada que están directamente relacionadas con los dos procesos importantes de la evapotranspiración: el radiactivo y el aerodinámico, la carencia de variables, tales como la velocidad del viento y la humedad atmosférica (humedad relativa o déficit de presión de vapor) limita el desempeño tanto de los modelos convencionales como de las redes neuronales artificiales, pero al retomar el objetivo de estudio, no todas las estaciones cuentan con el total de instrumentos para realizar las mediciones de todas las variables que requiere la estimación de ET_0 FAO-56 P-M y puesto que los instrumentos mínimos con que cuentan cualquier estación son los que miden temperaturas máximas y mínimas que utilizó el modelo de *RNABR3* o radiación neta en *RNABR7*. De ahí la bondad de los modelos y los resultados de los cuadros y figuras, los cuales mostraron que esta información es




Figura 3. Comparación de los datos ET_0 FAO-56 P-M con los estimados por los métodos: $P-T$ y $RNABR7$ para el periodo de validación (229 días)




Figura 4. Comparación de los datos ET_0 FAO-56 P-M con los estimados por los métodos: $RNABR8$, $RNABR9$ y $RNABR10$, para el periodo de validación (229 días)

suficiente para entrenar la red neuronal artificial y obtener buena estimación de la evapotranspiración de referencia diaria. Lo anterior corrobora lo encontrado por Sudheer *et al.* (2003) y Trajkovic *et al.* (2003).

Conclusiones

Los resultados indican que al comparar las *RNABR3* y *RNABR7* con igual (o menos) número de variables de entrada que sus respectivos modelos convencionales, se determinó que ambas fueron mejores en la estimación de la evapotranspiración de referencia calculada con Penman-Monteith FAO-56.

Referencias

- 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 Meteorology*, volumen 145, julio 2007: 22-35.
- Chen S., Cowan N.C.F., Grant M.P. Orthogonal Least Squares Learning Algorithm for Radial Basis Functions Networks. *IEEE Transactions on Neural Networks*, volumen 2 (número 2), marzo 1991: 302-309.
- DehghaniSanij H., Yamamoto T., Rasiah V. Assessment of Evapotranspiration Estimation Models for Use in Semiarid Environments. *Agricultural Water Management*, volumen 64, 2004: 91-106.
- Demuth H., Beale M., Hagan M. *Neural Network Toolbox™ 6, User's Guide*, 2008, pp. 292-307.
- Doorenbos J. y Pruitt W.O. *Las necesidades de agua de los cultivos. Estudios FAO: riego y drenaje*. Paper 24. Organización de las Naciones Unidas para la agricultura y la alimentación, Roma, 1980, pp. 15-16.
- González-Camacho J.M., Cervantes-Osornio R., Ojeda-Bustamante W., López-Cruz I. Predicción de la evapotranspiración de referencia mediante redes neuronales artificiales. *Ingeniería Hidráulica en México*, volumen 23 (número 1), enero-marzo 2008: 127-138.
- Hargreaves G.H. Defining and Using Reference Evapo Transpiration. *Journal of Irrigation and Drainage Engineering*, ASCE, volumen 120 (número 6), noviembre-diciembre 1994: 1132-1139.
- Hargreaves G.H. y Samani Z.A. Reference Crop Evapotranspiration from Temperature. *Applied Engineering in Agriculture*, volumen 1 (número 2), 1985: 96-99.
- Jensen M.E., Burman R.D., Allen R.G. Evapotranspiration and Irrigation Water Requirements. ASCE Manuals and Reports on Engineering Practices Núm. 70, Published by American Society of Civil Engineers, Nueva York, 1990, pp. 164-265.
- Kumar M., Raghuwanshi N.S., Singh R., Wallender W.W., Pruitt W.O. Estimating Evapotranspiration Using Artificial Neural Network. *Journal of Irrigation and Drainage Engineering*, ASCE, volumen 128, julio-agosto 2002: 224-233.
- López-Urrea R., Martín de Santa-Olalla F., Fabeiro C., Moratalla A. Testing Evapotranspiration Equations Using Lysimeter Observations in a Semiarid Climate. *Agricultural Water Management*, volumen 85, 2006: 15-26.
- Mangliulo V., d'Andria R., Rana G. Use of Modified Atmometer to Estimate Reference Evapotranspiration in Mediterranean Environments. *Agricultural Water Management*, volumen 63 (número 1), noviembre 2003: 1-14.
- Ojeda-Bustamante W. Calendarización del riego en tiempo real, en: Fundamentos del riego y riego por gravedad, volumen 1. X curso internacional de Sistemas de Riego. Universidad Autónoma Chapingo, Departamento de Irrigación, 2004, pp. 79-111.
- Priestley C.H.B. y Taylor R.J. On the Assessment of Surface Heat-Flux and Evaporation Using Large-Scale Parameters. *Monthly Weather Review*, volumen 100 (número 2), febrero 1972: 81-92.
- Stagnitti F., Parlange J.Y., Rose C.W. Hydrology of a Small Wet Catchment. *Journal of Hydrological Processes*, volumen 3 (número 2), 1989: 137-150.
- Steiner J.L., Howell T.A., Schneider A.D. Lysimetric Evaluation of Daily Potential Evapotranspiration Models for Grain Sorghum. *Agronomy Journal*, volumen 83, 1991: 240-247.
- Sudheer K.P., Gosain A.K., Ramasastri K.S. Estimating Actual Evapotranspiration from Limited Climatic Data Using Neural Computing Technique. *Journal of Irrigation and Drainage Engineering*, ASCE, volume 129 (número 3), mayo-junio 2003: 214-218.
- Suleiman A.A., y Hoogenboom G. Comparison of Priestley-Taylor and FAO-56 Penman-Monteith for Daily Reference Evapotranspiration Estimation in Georgia. *Journal of Irrigation and Drainage Engineering*, ASCE, volumen 133 (número 2), 2007: 175-182.
- Thornley J.H.M y France J. *Mathematical Models in Agriculture. Quantitative Methods for the Plant, Animal and Ecological Sciences*, 2nd ed., Cromwell Press, Trowbridge United Kingdom, 2007, pp. 362-363.
- Trajkovic S., Todorovic B., Stankovic M. Forecasting of Reference Evapotranspiration by Artificial Neural Networks. *Journal of Irrigation and Drainage Engineering*, ASCE, volumen 129 (número 6), diciembre 2003: 454-457.

- Trajkovic S. Hargreaves Versus Penman-Monteith under Humid Conditions. *Journal of Irrigation and Drainage Engineering, ASCE*, volumen 133 (número 1), enero 2007: 38-42.
- Tymvios F.S., Michaelides S.C., Skouteli C.S. Estimation of Surface Solar Radiation with Artificial Neural Networks, en: *Modeling Solar Radiation at the Earth's Surface. Recent Advances*, Bodescu V. (ed), Heidelberg Berlin, 2008, Springer, pp. 221-256.
- Willmott C.J. On the Validation of Model. *Physical Geography*, volumen 2, 1981: 184-194.
- Zanetti S.S., Sousa E.F., Oliveira V.P.S., Almeida F.T., Bernardo S. Estimating Evapotranspiration Using Artificial Neural Network and Minimum Climatological Data. *Journal of Irrigation and Drainage Engineering, ASCE*, volumen 133 (número 2), marzo 2007: 83-89.

Este artículo se cita:

Citación estilo Chicago

Cervantes-Osornio, Rocío, Ramon Arteaga-Ramírez, Mario Alberto Vazquez-Peña, Waldo Ojeda-Bustamante, Abel Quevedo-Nolasco. Modelos Hargreaves, Priestley-Taylor y redes neuronales artificiales en la estimación de la evapotranspiración de referencia. *Ingeniería Investigación y Tecnología*, XIV, 02 (2013): 163-176.

Citación estilo ISO 690

Cervantes-Osornio R., Arteaga-Ramirez R., Vazquez-Peña M.A., Ojeda-Bustamante W., Quevedo-Nolasco A. Modelos Hargreaves, Priestley-Taylor y redes neuronales artificiales en la estimación de la evapotranspiración de referencia. *Ingeniería Investigación y Tecnología*, volumen XIV (número 2), abril-junio 2013: 163-176.

Semblanza de los autores

Rocío Cervantes-Osornio. Egresada en 2002 de la Universidad Autónoma Chapingo (UACH) en donde estudió la carrera de ingeniero mecánico agrícola. Obtuvo la maestría en ciencias en 2005 por el Programa de Cómputo Aplicado del Colegio de Posgraduados, Campus Montecillo. Es coautor de un artículo científico y autor principal de otro, ambos en revistas indexadas por CONACYT. Laboró en la Secretaría de la Reforma Agraria como evaluador de proyectos. Obtuvo el doctorado en ingeniería agrícola y uso integral del agua de la UACH. Actualmente labora como investigador del Instituto Nacional de Investigaciones Agrícolas Pecuarias y Forestales (INIFAP). Se ha desarrollado en las áreas de meteorología agrícola, redes neuronales artificiales, mecanización y modelación.

Ramón Arteaga-Ramírez. Realizó los estudios profesionales en la Escuela Nacional de Agricultura (actualmente Universidad Autónoma Chapingo, UACH), donde obtuvo el título como ingeniero agrónomo especialista en irrigación. La maestría y el doctorado los realizó en Hidrociencias por el Colegio de Postgraduados. Ha laborado como profesor en el Departamento de Irrigación y en el Posgrado de Ingeniería Agrícola y Uso Integral del Agua, de la UACH. Colaboró en el Colegio de Postgraduados en el centro de Hidrociencias. Es miembro del Sistema Nacional de Investigadores, Nivel I. Ha elaborado 15 artículos como autor principal y 30 como coautor y es primer coautor de cuatro libros. Se ha desarrollado en las áreas de agrometeorología, agroclimatología, evapotranspiración de cultivos y cambio climático.

Mario Alberto Vázquez-Peña. Estudió ingeniería agrónoma especialista en irrigación, y obtuvo el título en el año 1988. Realizó estudios de maestría en el programa de agrometeorología del Colegio de Postgraduados culminando en el año de 1990. En el año de 1994 inició los estudios de doctorado en el área de estadística en el Colegio de Postgraduados. Se ha desempeñado como profesor investigador de la Universidad Autónoma Chapingo desde 1990 impartiendo clases de licenciatura, maestría y doctorado en el Posgrado de Ingeniería Agrícola y Uso Integral del Agua. Realizó tres artículos como autor principal y diez como coautor. Es autor de tres libros y se ha desarrollado en las áreas de agrometeorología, agroclimatología, estadística, instrumentación y micro-controladores.

Waldo Ojeda-Bustamante. Ingeniero agrónomo especialista en irrigación por la Universidad Autónoma Chapingo. Estudió la maestría en computación aplicada por el Colegio de Postgraduados y el doctorado en ciencias del suelo y del agua por la Universidad de Arizona. Actualmente es investigador del Instituto Mexicano de Tecnología del Agua (IMTA) en la coordinación de riego y drenaje. Es miembro del Sistema Nacional de Investigadores, Nivel I. Su investigación está orientada al estudio del impacto del medio ambiente en el desarrollo y producción de los cultivos con énfasis en las áreas de cambio climático, modelación biológica y biometeorología. Ha dirigido 8 tesis de maestría y 15 de licenciatura, publicado 5 libros y más de 26 artículos arbitrados.

Abel Quevedo-Nolasco. Doctor en ciencias en edafología (2005) y maestro en agrometeorología con mención honorífica (1994), por el Colegio de Postgraduados. Egresó de la Universidad Autónoma Chapingo como ingeniero agrónomo especialista en irrigación (1988). Realizó actualizaciones en la Universidad de Tottori, Japón y en el Servicio Forestal de Estados Unidos. Ha publicado cinco artículos científicos y un cuaderno. Es coautor de dos libros, cotraductor y compilador. Es profesor investigador asociado, ha graduado estudiantes de doctorado y maestría. Su área de desarrollo profesional se ubica dentro de la agrometeorología, riego, diseño de software y diseño de multimedia.