

MODELOS NEURO-DIFUSOS PARA TEMPERATURA Y HUMEDAD DEL AIRE EN INVERNADEROS TIPO CENTAL Y CAPILLA EN EL CENTRO DE MÉXICO

NEURO-FUZZY MODELS FOR AIR TEMPERATURE AND HUMIDITY OF ARCHED AND VENLO TYPE GREENHOUSES IN CENTRAL MÉXICO

Irineo L. **López-Cruz**, Leopoldo **Hernández-Larragoiti**

Postgrado en Ingeniería Agrícola y Uso Integral del Agua. Universidad Autónoma Chapingo.
Km. 38.5 Carretera México-Texcoco. Chapingo, México. (ilopez@correo.chapingo.mx)

RESUMEN

En la producción de hortalizas en invernadero es importante optimizar y controlar el manejo del ambiente usando modelos dinámicos. El desarrollo y uso de modelos mecanicistas es costoso y requiere mucho tiempo. Los modelos de caja negra, basados en mediciones de entradas y salidas, son un enfoque prometedor para estudiar sistemas complejos y no-lineales. En la presente investigación se estudiaron y generaron modelos neuro-difusos para predecir el comportamiento de la temperatura y la humedad relativa del aire dentro de dos invernaderos. Las variables de entrada fueron: la temperatura, la humedad relativa, la radiación solar global y la velocidad y dirección del viento, medidas fuera del invernadero. Las variables de salida fueron la temperatura y la humedad del aire medidas dentro del invernadero. El tiempo de muestreo fue cada minuto. Se generaron varios modelos neuro-difusos para la temperatura y la humedad, usando el modelo neuro-difuso ANFIS (Adaptive Neuro-Fuzzy training of Sugeno-type Inference System), disponible en el Fuzzy Logic Toolbox de Matlab. Los métodos de partición de rejilla y agrupamiento sustractivo se usaron para generar el sistema de inferencia difuso. Se analizaron varias particiones empíricas de los datos, tres tipos de funciones de membresía (Gaussiana, Campana generalizada y Trapezoidal), así como las funciones de membresía de salida constante y lineal. Además se probaron varias épocas de entrenamiento. Se usaron dos conjuntos de datos recolectados en dos invernaderos con ventilación natural, localizados en la Universidad Autónoma Chapingo y la Universidad Autónoma de Querétaro. El análisis de los resultados mostró que los modelos neuro-difusos predicen aceptablemente el comportamiento del clima dentro del invernadero.

ABSTRACT

In greenhouse vegetable production it is important to optimize and control the environmental management using dynamic models. The development and use of mechanistic models is expensive and time consuming. Black box models based on measurements of inputs and outputs are a promising approach for studying complex and nonlinear systems. In this work we have studied and generated neuro-fuzzy models to predict the behavior of temperature and relative humidity in two greenhouses. Input variables were: temperature, relative humidity, global solar radiation and wind speed and direction, measured outside the greenhouse. The output variables were temperature and humidity measured inside the greenhouse. The sampling time was every minute. Several neuro-fuzzy models for temperature and humidity were evaluated, using the neuro-fuzzy model ANFIS (Adaptive Neuro-Fuzzy training of Sugeno-type Inference System), available in the Fuzzy Logic Toolbox of Matlab. The methods of grid partition and subtractive clustering were used to generate the fuzzy inference system. Several empirical partitions of data were analyzed, as well as three types of membership functions (Gaussian, generalized Bell and Trapezoidal) and the constant and linear output membership functions. Also several training times were tested. Two sets of data were used, which were collected in two greenhouses with natural ventilation, located at the Universidad Autónoma de Chapingo and Universidad Autónoma de Querétaro. The analysis of the results showed that the neuro-fuzzy models acceptably predict the weather behavior inside the greenhouse.

Key words: ANFIS, controlled environment, optimal control, black box models.

* Autor responsable ♦ Author for correspondence.

Recibido: Octubre, 2009. Aprobado: Junio, 2010.

Publicado como ARTÍCULO en *Agrociencia* 44: 791-805. 2010.

Palabras clave: ANFIS, ambiente controlado, control óptimo, modelos de caja negra.

INTRODUCCIÓN

Para optimizar y controlar el ambiente de un invernadero se requieren modelos matemáticos precisos (López-Cruz *et al.*, 2007; Leal-Iga *et al.*, 2008). Varios enfoques han sido exitosos para describir el comportamiento de la temperatura, la humedad y la concentración de dióxido de carbono dentro de un invernadero (Castañeda-Miranda *et al.*, 2007; Guzmán-Cruz *et al.*, 2009, Fitz-Rodríguez *et al.*, 2010). Sin embargo, la generación de modelos mecanicistas demanda mucho tiempo y es costosa. Así, para grandes cantidades de datos experimentales que describan el comportamiento de variables de entrada y salida del sistema, los modelos de caja negra, como el enfoque difuso (Salgado y Cunha, 2005; Fitz-Rodríguez, 2008; Fitz-Rodríguez y Giacomelli, 2009), el enfoque basado en redes neuronales (Linker *et al.*, 1998; Fitz-Rodríguez, 2008; Fitz-Rodríguez y Giacomelli, 2009) y el enfoque neuro-difuso (Tien, 1997; Jang *et al.*, 1997; Babuška y Verbruggen, 2003), pueden ser una alternativa atractiva. Tien y Van Straten (1998) desarrollaron el sistema neuro-difuso NUFZY para predecir sistemas no lineales, y muestran que este enfoque puede predecir aceptablemente el crecimiento de la lechuga (*Lactuca sativa* L.) y la temperatura del invernadero en los Países Bajos. Sin embargo, los modelos neuro-difusos no se han usado para estudiar el clima de invernaderos con ventilación natural, como los prevalecientes en México. El enfoque neuro-difuso fue aplicado para modelar la evapotranspiración instantánea de una planta de jitomate (*Lycopersicon esculentum*, Mill) en invernadero (Ramos *et al.*, 2010) y también un sistema neuro-difuso se usó para predecir el comportamiento de la humedad relativa (Gamboa *et al.*, 2005) con información de estaciones meteorológicas.

La hipótesis de esta investigación fue que los modelos neuro-difusos al combinar ventajas de las redes neuronales y de los sistemas difusos pueden mostrar un desempeño superior, especialmente en el caso de sistemas complejos y no-lineales como los presentes en el ambiente invernadero. Los objetivos fueron: 1) desarrollar un modelo neuro-difuso para predecir la temperatura del aire dentro de un invernadero considerando como variables de entrada la temperatura,

INTRODUCTION

To optimize and control the environment of a greenhouse, accurate mathematical models are required (López-Cruz *et al.*, 2007, Leal-Iga *et al.*, 2008). Several approaches have succeeded in describing the behavior of temperature, humidity and the concentration of carbon dioxide within a greenhouse (Castañeda-Miranda *et al.*, 2007, Guzmán-Cruz *et al.*, 2009, Fitz-Rodríguez *et al.*, 2010). However, the generation of mechanistic models is time consuming and costly. So an attractive alternative may be the development of black box models, such as the fuzzy approach (Salgado and Cunha, 2005, Fitz-Rodríguez, 2008, Fitz-Rodríguez and Giacomelli, 2009), the neural network approach (Linker *et al.*, 1998, Fitz-Rodríguez, 2008, Fitz-Rodríguez and Giacomelli, 2009) and the neuro-fuzzy approach (Tien, 1997; Jang *et al.*, 1997; Babuska and Verbruggen, 2003) based on large amounts of experimental data that describe the behavior of input and output variables of the system. Tien and Van Straten (1998) developed the neuro-fuzzy system NUFZY to predict nonlinear systems, and showed that this approach can acceptably predict the growth of lettuce (*Lactuca sativa* L.) and the greenhouse temperature in the Netherlands. However, neuro-fuzzy models have not been used to study the climate of greenhouses with natural ventilation, like those prevailing in México. The neuro-fuzzy approach was applied to model the instantaneous evapotranspiration of a tomato (*Lycopersicon esculentum*, Mill) plant under greenhouse conditions (Ramos *et al.*, 2010), and a neuro-fuzzy system was used to predict the behavior of relative humidity (Gamboa *et al.*, 2005) with information from weather stations.

The hypothesis of this research was that when the neuro-fuzzy models combine the advantages of neural networks and fuzzy systems they may have a better performance, especially in the case of complex and nonlinear systems, as those present in the greenhouse environment. The objectives were: 1) to develop a neuro-fuzzy model in order to predict the air temperature inside a greenhouse considering as input variables the temperature, relative humidity, global solar radiation, wind speed and direction, measured outside the greenhouse; 2) to develop and evaluate the performance of a neuro-fuzzy model to predict relative humidity inside a greenhouse; 3) to analyze

humedad relativa, radiación solar global, velocidad y dirección del viento medidas fuera del invernadero; 2) desarrollar y evaluar el comportamiento de un modelo neuro-difuso para predecir la humedad relativa dentro de un invernadero; 3) analizar el comportamiento de ambos modelos en dos invernaderos con ventilación natural.

MATERIALES Y MÉTODOS

Estructura del sistema adaptable de inferencia (ANFIS)

El modelo ANFIS (Jang, 1993; Jang *et al.*, 1997) consta de variables de entrada-salida, un conjunto de reglas SI-ENTONCES tipo Takagi-Sugeno (Takagi y Sugeno, 1985) y un sistema de inferencia difuso (Figura 1). En la capa 1, cada nodo cuadrado i tiene una función de membresía $O_i^1 = \mu_{A_i}(x)$, que especifica el grado para el cual x satisface A_i . En este modelo $\mu_{A_i}(x)$ es una campana generalizada:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (1)$$

o una función Gaussiana:

$$\mu_{A_i}(x) = \exp \left[- \left(\frac{x - c_1}{a_i} \right)^2 \right] \quad (2)$$

donde a_i, b_i, c_i son parámetros de premisa.

En la capa 2 cada nodo efectúa la operación: $w_i = \mu_{A_i}(x) \times \mu_{B_i}(y)$

the behavior of both models in two greenhouses with natural ventilation.

MATERIALS AND METHODS

Structure of the adaptive inference system (ANFIS)

The ANFIS model (Jang, 1993; Jang *et al.*, 1997) consists of input-output variables, a set of IF-THEN rules of the Takagi-Sugeno type (Takagi and Sugeno, 1985) and a fuzzy inference system (Figure 1). In layer 1, each square node i has a membership function $O_i^1 = \mu_{A_i}(x)$, which specifies the degree to which x satisfies A_i . In this model $\mu_{A_i}(x)$ is a generalized bell:

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \quad (1)$$

or a Gaussian function:

$$\mu_{A_i}(x) = \exp \left[- \left(\frac{x - c_1}{a_i} \right)^2 \right] \quad (2)$$

where a_i, b_i, c_i are parameters of premise.

In layer 2 each node performs the operation: $w_i = \mu_{A_i}(x) \times \mu_{B_i}(y)$, $i=1,2$. In layer 3, the i -th node calculates the ratio of the trigger force of the i -th rule to the sum of all shot forces

using: $\bar{w}_i = \frac{w_i}{w_1 + w_2}$, $i=1, 2$. In layer 4 each node i has a




Figura 1. Arquitectura ANFIS para el sistema de inferencia Takagi y Sugeno (1985).
Figure 1. ANFIS architecture for the Takagi and Sugeno inference system (1985).

(y), $i=12$. En la capa 3, el i -ésimo nodo calcula la proporción de la fuerza de disparo de la i -ésima regla a la suma de todas las fuerzas de disparo, usando: $\bar{w}_i = \frac{w_i}{w_1 + w_2}$, $i=1, 2$. En la capa 4 cada nodo i tiene una función $O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$, donde $\bar{w}_i$ es la salida de la capa 3, y $\{p_i, q_i, r_i\}$ es el conjunto de parámetros conocidos como parámetros consecuentes. En la capa 5 se calcula una suma total: $O_1^5 = \text{salida total} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$. La salida f se puede re-escribir como:

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = f_2 = \\ &= \bar{w}_1 f_1 + \bar{w}_2 f_2 \\ &= (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2 \end{aligned} \quad (3)$$

La reglas difusas en ANFIS son del tipo siguiente:

Regla 1: Si x es A_1 y y es B_1 , entonces $f_1 = p_1 x + q_1 y + r_1$
 Regla 2: Si x es A_2 y y es B_2 , entonces $f_2 = p_2 x + q_2 y + r_2$ (4)

El sistema de inferencia se muestra en la Figura 2.

ANFIS usa un algoritmo de aprendizaje híbrido con dos pasos, uno hacia delante y otro hacia atrás. En el paso hacia delante los parámetros de consecuencia son identificados por el estimador de mínimos cuadrados. En el paso hacia atrás los índices de error se propagan hacia atrás y los parámetros de premisa se actualizan por el método del gradiente descendiente. Este enfoque híbrido converge más rápidamente que el método retro-propagación usado en el entrenamiento de redes neuronales.

function $O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$, where $\bar{w}_i$ is the output of layer 3, and $\{p_i, q_i, r_i\}$ is the set of parameters known as consequent parameters. In layer 5 a total sum is calculated:

$O_1^5 = \text{totalo output} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$. The f output can be rewritten as:

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 = f_2 = \\ &= \bar{w}_1 f_1 + \bar{w}_2 f_2 \\ &= (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2 \end{aligned} \quad (3)$$

The fuzzy rules in ANFIS are of the following type:

Rule 1: If x is A_1 and y is B_1 , then $f_1 = p_1 x + q_1 y + r_1$
 Rule 2: If x es A_2 and y is B_2 , then $f_2 = p_2 x + q_2 y + r_2$ (4)

The inference system is shown in Figure 2.

The ANFIS uses a hybrid learning algorithm with two steps, one forward and one backward. In the step forward the consequence parameters are identified by the least square estimator. In the step backward error rates propagate backward and the premise parameters are updated by the descent gradient method. This hybrid approach converges faster than the retro-propagation method used in training neural networks.

Data acquisition

Data acquisition was performed in an Arched type greenhouse located in the Agricultural Experiment Station Tlapeaxco of the Universidad Autónoma de Chapingo, Mexico, 19 ° 29' N, 98°




Figura 2. Razonamiento difuso (Jang, 1993; Jang *et al.*, 1997).
 Figure 2. Fuzzy reasoning (Jang, 1993; Jang *et al.*, 1997).

Adquisición de datos

La adquisición de datos se efectuó en un invernadero de tipo cenital ubicado en el Campo Agrícola Experimental Tlapeasco de la Universidad Autónoma Chapingo, México, a $19^{\circ} 29' N$, $98^{\circ} 54' O$ y altitud de 2244 m. El invernadero (Figura 3) tiene un área de 1080 m^2 , 170 m^2 de área de ventilación lateral y 60 m^2 de área de ventilación cenital; su área total está dividida en tres naves. El tiempo de muestreo fue de 1 min del 24 al 30 de enero del 2007 (Figura 4). El invernadero estuvo libre de cultivo durante el periodo de toma de datos.

Las variables de entrada fueron la radiación solar global (R_o , W m^{-2}), humedad relativa (R_{Ho} , %), velocidad del viento (W_S , m s^{-1}), dirección del viento (W_D , ϕ) y temperatura (T_o , $^{\circ}\text{C}$), medidas fuera del invernadero. Las variables de salida fueron la temperatura (T_i , $^{\circ}\text{C}$) y la humedad relativa (R_{Hi} , %), medidas dentro del invernadero. Se usaron 10080 mediciones.

Otro conjunto de datos se recolectó en un invernadero de la Universidad Autónoma de Querétaro, México, a $20^{\circ} 36' N$, $100^{\circ} 24' O$ y una altitud 1820 m. El invernadero es tipo capilla (Figura 5). Presenta ventanas laterales con 2.5 m de alto por 25 m de largo, frontales de 2.5 m de alto por 20 m de largo, ventanas cenitales de 0.8 m de alto por 20 m de largo, área de ventilación total de 257 m^2 , con apertura y cierre automático de ventanas.




Figura 3. Diagrama de sección del invernadero localizado en Chapingo, México.

Figure 3. Section diagram of the greenhouse located in Chapingo, México.

$54^{\circ} W$ and 2244 m height. The greenhouse (Figure 3) has an area of 1080 m^2 , 170 m^2 of side vent area and 60 m^2 on the roof vent area. Its total area is divided into three spans. The sampling time was 1 min from 24 to 30 January 2007 (Figure 4). The greenhouse was free of crop during the period of data collection.

Input variables were the global solar radiation (R_o , W m^{-2}), relative humidity (R_{Ho} , %), wind speed (W_S , m s^{-1}), wind




Figura 4. Variables meteorológicas en Chapingo, México, del 24 al 30 de enero de 2007.

Figure 4. Meteorological variables in Chapingo, México, January 24-30, 2007.

El tiempo de muestreo fue de 1 min, del 9 junio al 22 de julio del 2008 (Figura 6). Se usaron 54662 observaciones. Las variables de entrada fueron las mismas que para el primer invernadero, excepto ráfagas de viento (GS, m s^{-1}). Durante la toma de datos el invernadero estuvo ocupado por un cultivo de jitomate con un índice de área foliar cercano a la unidad. En ambos invernaderos la cubierta es de plástico de $180 \mu\text{m}$ de grosor con tratamiento ultravioleta y se usaron dos estaciones HOBO® Weather Station Data Logger Modelo H21-001 (Onset Computers Corporation, USA) para medir las variables meteorológicas.

Procedimiento

Subconjuntos de datos para generación y validación del modelo

Ambos conjuntos de datos fueron divididos en dos subconjuntos y uno fue usado para la generación del modelo y otro para su validación. Se probaron las particiones: 50 %:50 %; 60 %:40 %; 65 %:35 %; 70 %:30 %; 75 %:25 %; y 80 %:20 %; para la temperatura y la humedad relativa del aire dentro del invernadero.

Generación del Sistema de Inferencia Difuso Inicial

Para generar el sistema de inferencia difuso (Jang *et al.*, 1997; Babuška y Verbruggen, 2003) se usó el método de partición de




Figura 5. Diagrama de sección del invernadero localizado en Querétaro, México.

Figure 5. Section diagram of the greenhouse located in Querétaro, México.

direction (WD, ϕ) and temperature (T_o , $^{\circ}\text{C}$), measured outside the greenhouse. The output variables were temperature (T_i , $^{\circ}\text{C}$) and relative humidity (Rhi, %), measured inside the greenhouse; 10080 measurements were used.

Another set of data was collected in a greenhouse of the Universidad Autónoma de Querétaro, México, $20^{\circ} 36' \text{ N}$, $100^{\circ} 24' \text{ W}$ and an altitude of 1820 m. The greenhouse is Venlo type (Figure 5). It has side windows 2.5 m high by 25 m long; front windows of 2.5 m high by 20 m long; windows on the roof 0.8 m




Figura 6. Variables meteorológicas del invernadero en Querétaro, del 9 de junio al 22 de julio de 2008.

Figure 6. Meteorological variables of the greenhouse in Querétaro, June 9 - July 22, 2008.

rejilla (The Mathworks Inc., 1995-2005), el cual está programado en la función `genfis1.m` de Matlab. En este método el espacio de las entradas se divide en una malla dependiendo del número de funciones de membresía. El sistema de Inferencia Difuso tipo Sugeno se generó también mediante la función `genfis1.m`. Se evaluó el agrupamiento sustractivo (The Mathworks Inc., 1995-2005) usando la función `genfis2.m` de Matlab. En este caso los vectores de datos son candidatos a centros de grupos de acuerdo a su similitud (Jang *et al.*, 1997; Babuška y Verbruggen, 2003). Las funciones de membresía evaluadas fueron: gaussiana, campana generalizada y trapezoidal. Para cada variable de entrada se evaluaron dos y tres funciones de membresía.

Entrenamiento del sistema neuro-difuso

Todos los sistemas neuro-difusos fueron entrenados mediante ANFIS como ésta programado en la función `anfis.m` de Fuzzy Logic Toolbox de Matlab (The Mathworks Inc, 1995-2005). El método de optimización usado fue el híbrido, el cual combina el estimador mínimos cuadrados con retro-propagación de los errores. La función “`evalfis.m`” se usó para obtener la calidad de predicción de los modelos.

Calidad de predicción de los modelos

Para evaluar el desempeño de los modelos neuro-difusos se usó la raíz del error cuadrático medio (RMSE), el coeficiente de determinación (R^2), la gráfica de dispersión entre mediciones y predicciones, así como la ecuación de regresión lineal simple entre las mediciones y predicciones de los modelos.

RESULTADOS Y DISCUSIÓN

Estructura de los modelos

En la Figura 7 se muestra la estructura de los modelos neuro-difusos generados usando la partición de rejilla y entrenado con ANFIS, para temperatura y humedad relativa. Sus características son: dos funciones de membresía en cada entrada, 32 reglas difusas, 92 nodos, 32 parámetros lineales, 30 parámetros no-lineales y una función de membresía de salida ya sea constante o lineal.

La estructura de los modelos neuro-difusos para la temperatura y la humedad relativa, generados mediante agrupamiento sustractivo y entrenados con ANFIS, se muestra en las Figuras 8 y 9. Las propiedades del modelo neuro-difuso obtenido mediante agrupamiento sustractivo para la temperatura (Figura 8) son: seis funciones de membresía en cada entrada,

high by 20 m long; a total ventilation area of 257 m², with automatic opening and closing of windows.

The sampling time was 1 min, from June 9 to July 22, 2008 (Figure 6); 54662 observations were used. Input variables were the same used in the first greenhouse, except wind gusts (GS, m s⁻¹). During data collection the greenhouse was occupied by a crop of tomatoes with a leaf area index close to unity. In both greenhouses the cover is plastic of 180 μm thick with ultraviolet treatment and two stations HOBO® Weather Station Data Logger Model H21-001 (Onset Computers Corporation, USA) were used to measure meteorological variables.

Procedure

Subsets of data for model generation and validation

Both data sets were divided into two subsets and one was used for model generation and the other for validation. The partitions tested were: 50 %: 50 %; 60 %: 40 %; 65 %: 35 %; 70 %: 30 %; 75 %: 25 %; and 80 %: 20 %, for air temperature and relative humidity inside the greenhouse.

Generation of the Initial Fuzzy Inference System

To generate the fuzzy inference system (Jang *et al.*, 1997, Babuska and Verbruggen, 2003) the grid partitioning method (The Mathworks Inc., 1995-2005) was used, which is implemented in the function `genfis1.m` of Matlab. In this method the input space is divided in a grid depending on the number of membership functions. The Sugeno type Fuzzy Inference System was also generated by using the `genfis1.m` function. Subtractive clustering was evaluated (The Mathworks Inc., 1995-2005) by using the `genfis2.m` function of Matlab. In this case, the data vectors are candidates for centers of clusters according to their similarity (Jang *et al.*, 1997; Babuška and Verbruggen, 2003). The membership functions evaluated were: Gaussian, generalized bell and trapezoid. For each input variable two and three membership functions were assessed.

Training of the neuro-fuzzy system

All neuro-fuzzy systems were trained using ANFIS, as programmed in the function `anfis.m` of Fuzzy Logic Toolbox of Matlab (The Mathworks Inc, 1995-2005). The optimization method used was the hybrid, which combines the least squares estimator with the retro-propagation of errors. The “`evalfis.m`” function was used to obtain prediction quality models was used.




Figura 7. Estructura de los modelos neuro-difusos de la temperatura (Ti) y humedad relativa (Hri) obtenidos por partición en rejilla y entrenados con ANFIS.

Figure 7. Structure of the neuro-fuzzy models of temperature (Ti) and relative humidity (Hri), obtained by grid partitioning and trained with ANFIS.




Figura 8. Estructura de los modelos neuro-difusos para la temperatura (Ti), obtenidos con agrupamiento sustractivo y ANFIS.

Figure 8. Structure of the neuro-fuzzy models for temperature (Ti), obtained by subtractive clustering and ANFIS.




Figura 9. Estructura de los modelos neuro-difusos de humedad relativa (Hri), obtenidos con agrupamiento sustractivo y ANFIS.

Figure 9. Structure of the relative humidity neuro-fuzzy models (Hri), obtained using subtractive clustering and ANFIS.

80 nodos, 36 parámetros lineales, 60 parámetros no-lineales y seis reglas difusas.

Las propiedades de la estructura mostrada en la Figura 9 son: cuatro funciones de membresía en cada

Prediction quality of the models

To evaluate the performance of the neuro-fuzzy models the root mean square error (RMSE) was used, as well as the

entrada, 56 nodos, 24 parámetros lineales, 40 parámetros no-lineales y cuatro reglas difusas. Comparando las Figuras 7 contra las Figuras 8 y 9 es claro que el agrupamiento sustractivo fue mejor ya que los modelos fueron menos complejos. Es notable además que aparentemente se pueda modelar la humedad relativa con un modelo neuro-difuso menos complejo que en el caso de la temperatura dentro de un invernadero.

Evaluación de los modelos neuro-difusos para la temperatura

En el Cuadro 1 se muestra los mejores valores de RMSE y R^2 obtenidos usando partición de rejilla y agrupamiento sustractivo para el entrenamiento de ANFIS y el tipo de función de membresía que tuvo mejor desempeño. Sólo se muestran los mejores modelos. La mejor partición fue la que usó 80 % de datos para generar el modelo y 20 % para validación. También se observa un mejor comportamiento cuando se usó agrupamiento sustractivo.

Los resultados obtenidos para el invernadero de Querétaro se muestran en el Cuadro 2. Nuevamente, las diferencias en el comportamiento de los modelos para las particiones de datos de entrenamiento y prueba fueron pequeñas. Ambas estadísticas fueron mejores en el caso de uso de agrupamiento sustractivo.

coefficient of determination (R^2), the scatterplot between measurements and predictions, and the simple linear regression equation between measurements and model predictions.

RESULTS AND DISCUSSION

Structure of models

In Figure 7 it is shown the structure of neuro-fuzzy models generated using grid partitioning and trained with ANFIS for temperature and relative humidity. Its features include two membership functions in each input, 32 fuzzy rules, 92 nodes, 32 linear parameters, 30 non-linear parameters and an output membership function, either constant or linear.

The structure of neuro-fuzzy models for temperature and relative humidity generated by subtractive clustering and trained with ANFIS is shown in Figures 8 and 9. The properties of the neuro-fuzzy model obtained by subtractive clustering for temperature (Figure 8) are: six membership functions on each input, 80 nodes, 36 linear parameters, 60 non-linear parameters and six fuzzy rules.

The properties of the structure shown in Figure 9 are: six membership functions for each input, 56 nodes, 24 linear parameters, 40 nonlinear parameters and four fuzzy rules. When comparing Figure 7 with

Cuadro 1. Valores estadísticos como medidas del desempeño de los modelos de temperatura obtenidos con partición de rejilla y agrupamiento sustractivo, utilizados para entrenar el sistema ANFIS para el invernadero de Chapingo, México.

Table 1. Statistical values as measures of performance of the models of temperature obtained with grid partitioning and subtractive clustering, used to train the ANFIS system for the greenhouse of Chapingo, México.

Partición	FM [§] entrada	NE ^{††}	FM salida	R ²		RMSE	
				E ^b	P ^c	E	P
PR [†] (65:35)	2:campana	450	Lineal	0.97	0.86	1.08	3.52
	gen.		Const.	0.95	0.95	1.68	2.10
PR(80:20)	2:campana	450	Lineal	0.96	0.89	1.42	2.99
	gen.		Const.	0.95	0.95	1.73	2.10
AS [‡] (65:35)	Radio:0.48	450 ---		0.95	0.94	1.63	2.25
AS (80:20)	Radio:0.53	450 ---		0.95	0.95	1.76	1.96

[†]Partición de rejilla; [‡]Agrupamiento sustractivo; [§] Función de membresía; ^bEntrenamiento; ^cPrueba; ^{††}Número de épocas ^{‡‡}Grid partitioning; ^{‡‡}Subtractive clustering; [§]Membership function; ^bTraining; ^cTest; ^{††}Number of times.

Cuadro 2. Valores estadísticos como medidas del desempeño de los modelos de temperatura obtenidos con partición de rejilla y agrupamiento sustractivo, utilizados para entrenar el sistema ANFIS para el invernadero de Querétaro, México.**Table 2. Statistical values as measures of performance of the models of temperature obtained with grid partitioning and subtractive clustering, used to train the ANFIS system for the greenhouse of Querétaro, México.**

Partición	FM [§] entrada	NE ^{††}	FM salida	R ²		RMSE E	ANFIS P
				E ^b	P		
PR [†] (65:35)	2:campana gen.	450	Const.	0.96	0.95	1.35	1.69
PR(80:20)	2:campana gen.	450	Const.	0.96	0.96	1.42	1.44
AS [‡] (65:35)	Radio:0.5	450	---	0.96	0.95	1.29	1.63
AS(80:20)	Radio:0.53	450	---	0.96	0.97	1.39	1.42

[†]Partición de rejilla; [‡]Agrupamiento sustractivo; [§]Función de membresía; ^bEntrenamiento; [°]Prueba; ^{††}Número de épocas ♦ [‡]Grid partitioning; [‡]Subtractive clustering; [§]Membership function; ^bTraining; [°]Test; ^{††}Number of times.

Evaluación de los modelos neuro-difusos para humedad relativa

Los resultados de los modelos neuro-difusos evaluados para el caso de la variable humedad relativa, para los dos conjuntos de datos se muestran en los Cuadros 3 y 4. En ambos casos se obtuvo un mejor desempeño de los modelos, en términos de R² y de RMSE, para los datos de estimación y los de validación cuando se usó el agrupamiento sustractivo.

Calidad de predicción de los modelos neuro-difusos para temperatura

En la Figura 10 se muestra la comparación entre las predicciones del modelo neuro-difuso para la

Figures 8 and 9 it is clear that subtractive clustering was better since the models were less complex. It is also notable that relative humidity can be apparently modeled with a neuro-fuzzy model less complex than in the case of temperature inside a greenhouse.

Evaluation of neuro-fuzzy models for temperature

In Table 1 it is shown the best RMSE and R² values obtained using grid partitioning and subtractive clustering for training with ANFIS and the type of membership function that recorded the best performance. Only the best models are shown. The best partition was the one using 80 % of data to generate the model and 20 % for validation. Also

Cuadro 3. Valores estadísticos como medidas del desempeño de los modelos para la humedad relativa obtenidos con partición de rejilla y agrupamiento sustractivo, usados para entrenar el sistema ANFIS para el invernadero de Chapingo, México.**Table 3. Statistical values as measures of performance of the models for relative humidity obtained with grid partitioning and subtractive clustering, used to train the ANFIS system for the greenhouse of Chapingo, México.**

Partición	FM [§] entrada	NE ^{††}	FM salida	R ²		RMSE E	ANFIS P
				E ^b	P		
PR [†] (70:30)	2:campana gen.	450	Const.	0.95	0.93	5.04	6.24
	2:Gauss	450	Lineal	0.97	0.90	3.65	7.48
PR(75:25)	2:campana gen.	450	Const.	0.95	0.92	4.85	6.84
	2:Gauss	450	Lineal	0.97	0.90	3.54	7.95
PR(80:20)	2:campana gen.	450	Lineal	0.97	0.91	3.56	7.46
		450	Const.	0.95	0.93	4.88	6.99
AS [‡] (70:30)	Radio:0.68	450	--	0.95	0.94	4.83	5.41
AS(75:25)	Radio:0.52	450	--	0.95	0.94	4.65	5.92
AS(80:20)	Radio:0.73	450	--	0.95	0.95	4.62	5.80

[†]Partición de rejilla; [‡]Agrupamiento sustractivo; [§]Función de membresía; ^bEntrenamiento; [°]Prueba; ^{††}Número de épocas ♦ [‡]Grid partitioning; [‡]Subtractive clustering; [§]Membership function; ^bTraining; [°]Test; ^{††}Number of times.

Cuadro 4. Valores estadísticos como medidas del desempeño para los modelos de humedad relativa obtenidos con partición de rejilla y agrupamiento sustractivo, usados para entrenar el sistema ANFIS para el invernadero de Querétaro, México.

Table 4. Statistical values as measures of performance of the models for relative humidity obtained with grid partitioning and subtractive clustering, used to train the ANFIS system for the greenhouse of Querétaro, México.

Partición	FM [§] entrada	NE ^{††}	FM salida	R ²		RMSE E	ANFIS P
				E ^b	P		
PR [†] (65:35)	2:campana gen.	450	Const.	0.96	0.95	1.35	1.69
PR(80:20)	2:campana gen.	450	Const.	0.96	0.96	1.42	1.44
AS [‡] (65:35)	Radio:0.5	450	--	0.96	0.95	1.29	1.63
AS(80:20)	Radio:0.53	450	--	0.96	0.97	1.39	1.42

[†]Partición de rejilla; [‡]Agrupamiento sustractivo; [§]Función de membresía; ^bEntrenamiento; ^cPrueba; ^{††}Número de épocas ♦ [†]Grid partitioning; [‡]Subtractive clustering; [§] Membership function; ^bTraining; ^cTest; ^{††}Number of times.

temperatura usando agrupamiento sustractivo, 80 % de datos para generar el modelo y 20 % para validación, para los dos invernaderos estudiados. Las gráficas muestran que las predicciones de los modelos

a better performance was observed when subtractive clustering was used.

The results of the Querétaro greenhouse are shown in Table 2. Again, the differences in the




Figura 10. Comparación de las predicciones de los modelos neuro-difusos, contra mediciones de la temperatura (Ti). A) Conjunto de entrenamiento. B) Conjunto de prueba.

Figure 10. Comparison of the predictions of neuro-fuzzy models with measurements of temperature (Ti). A) Set of training. B) Test set.

siguen la tendencia de las mediciones de la temperatura.

Las gráficas de dispersión y ecuaciones de regresión correspondientes a las mediciones y predicciones de los modelos se muestran en la Figura 11. Tanto las gráficas 1:1 como los coeficientes de regresión confirman un alto ajuste de las predicciones de los modelos a las mediciones. Además estos resultados corroboran los reportados para la temperatura en invernaderos tipo Venlo con cubierta de vidrio y con un cultivo de jitomate de los Países Bajos durante el otoño (Tien, 1997; Tien y Van Straten, 1998).

Pero a diferencia de modelo NUFZY donde se usaron menos de 1500 datos y no se incluyó como variable de entrada la velocidad del viento, en el presente estudio el modelo neuro-difuso para la temperatura de los invernaderos con ventilación natural presentó una mejor calidad de predicción porque se usó un mayor número de datos y se incluyeron más variables climáticas en el modelo. De hecho, la velocidad y dirección del viento son variables de entrada fundamentales en invernaderos donde la ventilación natural es la más relevante para el manejo de las variables climáticas dentro de ese ambiente.

behavior of the models for the partitions of training and test data were small. Both statistics were better when subtractive clustering was used.

Evaluation of neuro-fuzzy models for relative humidity

The results of neuro-fuzzy models evaluated for the relative humidity variable, in both sets of data are shown in Tables 3 and 4. In both cases a better performance of the models was obtained in relation to R^2 and RMSE for both the estimation and validation data when subtractive clustering was used.

Prediction quality of neuro-fuzzy models for temperature

In Figure 10 it is shown the comparison between the predictions of neuro-fuzzy model for temperature using subtractive clustering, 80 % of data to generate the model and 20 % of data for validation, for the two greenhouses studied. The graphs show that the model predictions follow the trend of the temperature measurements.




Figura 11. Gráficas 1:1 y ecuaciones de regresión entre las mediciones y predicciones de los modelos neuro-difusos para la temperatura (Ti). A) Conjunto de entrenamiento. B) Conjunto de prueba.

Figure 11. Graphs 1:1 and regression equations among measurements and predictions of the neuro-fuzzy models for temperature (Ti). A) Set of training. B) Test set.

Calidad de predicción de los modelos neuro-difusos para humedad relativa

En la Figura 12 se muestra la comparación entre las predicciones del modelo neuro-difuso generado para la humedad relativa usando agrupamiento sustractivo, 80 % de datos para generar el modelo y 20 % para la validación en ambos invernaderos. Las simulaciones muestran que las predicciones siguen en forma precisa el comportamiento de las mediciones de la humedad en ambos invernaderos.

Es notable que el desempeño de los modelos neuro-difusos para humedad fuera similar en ambos invernaderos a pesar de las diferencias de clima, tipo de invernadero y condiciones de cultivo. Esto significa que los modelos neuro-difusos pueden modelar procesos no lineales (Tien y Van Straten, 1998) con precisión y, además, que son bastante robustos (Tien, 1997).

The scatterplots and regression equations for the model measurements and predictions are shown in Figure 11. Both the graphs 1:1 and the regression coefficients confirm a high adjustment of the model predictions to measurements. Besides, these results corroborate those reported for temperature in the Venlo-type greenhouses, with a glass cover and the cultivation of tomatoes (*Lycopersicum esculentum* Mill) from the Netherlands during the autumn (Tien, 1997; Tien and Van Straten, 1998).

But unlike the NUFZY model in which less than 1500 data were used and wind speed was not included as an input variable, in the present study the neuro-fuzzy model for temperature of the greenhouses with natural ventilation had a higher quality prediction, since more data were used and more climate variables were included in the model. In fact, wind speed and direction are key input variables in a greenhouse where natural ventilation is the most important for




Figura 12. Comparación de las predicciones de los modelos neuro-difusos, contra mediciones de la humedad relativa (HRi). A) Conjunto de entrenamiento. B) Conjunto de prueba.

Figure 12. Comparison of prediction from neuro-fuzzy models, against measurements of relative humidity (HRi), A) Set of training. B) Test set.




Figura 13. Gráficas 1:1 y ecuaciones de regresión entre las mediciones y predicciones de los modelos neuro-difusos para la humedad relativa (HRi). A) Conjunto de entrenamiento. B) Conjunto de prueba.

Figure 13. Plots 1:1 and regression equations among measurements and predictions of the neuro-fuzzy models for relative humidity (HRi). A) Training set. B) Test set.

Las gráficas de dispersión y ecuaciones de regresión correspondientes a las mediciones y predicciones de los modelos se muestra en la Figura 13. Tanto las gráficas 1:1, como los coeficientes de regresión reflejan un alto ajuste de los modelos neuro-difusos a las mediciones. Estos resultados son similares a los reportados por Gamboa *et al.* (2005) para la predicción de la humedad relativa fuera del invernadero, en el estado de Jalisco, México.

CONCLUSIONES

Los modelos neuro-difusos generados para la temperatura y humedad relativa de dos invernaderos con ventilación natural, con y sin presencia de cultivo, presentaron un buen desempeño cuando se usó el método de partición de agrupamiento sustractivo de los datos, combinado con 80 % de los datos para generar el modelo y 20 % de la información para validación. Dado que se estudiaron dos invernaderos con ventilación natural en condiciones climáticas diferentes y durante estaciones contrastantes (invierno y verano), aparentemente los modelos neuro-difusos

the management of climatic variables within such environment.

Prediction quality of neuro-fuzzy models for relative humidity

In Figure 12 it is shown the comparison between the predictions of the neuro-fuzzy model developed for relative humidity using subtractive clustering, 80 % of data to generate the model and 20 % of data for validation in both greenhouses. The simulations show that the predictions follow accurately the behavior of humidity measurements in both greenhouses.

It is remarkable that the performance of neuro-fuzzy models for humidity was similar in both greenhouses despite differences in climate, type of greenhouse and cultivation conditions. This means that neuro-fuzzy models can model nonlinear processes (Van Tien and Straten, 1998) accurately and are in addition quite robust (Tien, 1997).

The scatterplots and regression equations for the model measurements and predictions are shown in Figure 13. Both graphs 1:1 and the regression

son una opción para generar modelos para el clima del invernadero con propósitos de optimización y control.

LITERATURA CITADA

- Babuška, R., and H. Verbruggen. 2003. Neuro-fuzzy methods for nonlinear system identification. *Ann. Rev. Control* 27: 73-85.
- Castañeda-Miranda, R., E. Ventura-Ramos, R. del R. Peniche-Vera, and G. Herrera-Ruiz. 2007. Analysis and simulation of a greenhouse physical model under weather conditions of the central region of Mexico. *Agrociencia* 41(3): 317-335.
- Fitz-Rodríguez, E. 2008. Decision support systems for greenhouse tomato production. PhD. Thesis. The University of Arizona. 171 p.
- Fitz-Rodríguez, E., and G.A. Giacomelli. 2009. Yield prediction and growth mode characterization of greenhouse tomatoes with neural networks and fuzzy logic. *Trans. ASABE* 52(6): 2115-2128.
- Fitz-Rodríguez, E., Ch. Kubota, G.A. Giacomelli, M. E. Tignor, S.B. Wilson, and M. McMahon. 2010. Dynamic modeling and simulation of greenhouse environment under several scenarios: a web-based application. *Computers Electronics Agric.* 70: 105-116.
- Gamboa, N., M. Castro, and F. Herrera. 2005. Use of an ANFIS network for relative humidity behaviour modelling on the south region of Jalisco Mexico. *Res. Computing Sci.* 16: 75-84.
- Guzmán-Cruz, R., R. Castañeda-Miranda, J.J. García-Escalante, I.L. López-Cruz, A. Lara-Herrera, and J.I. de la Rosa. 2009. Calibration of a greenhouse climate model using evolutionary algorithms. *Biosyst. Eng.* 104: 135-142.
- Jang J., S. R. 1993. ANFIS: Adaptive-Network-Based fuzzy inference system. *IEEE Trans. on Systems, Man and Cybernetics* 23(3): 665-685.
- Jang J., S. R., C.T. Sun, and E. Mizutani. 1997. *Neuro-Fuzzy and Soft Computing*. Prentice Hall. New Jersey, USA. 614 p.
- Kumar, K.S., K. J. Madan, K.N. Tiwari, and A. Singh. 2010. Modeling and evaluation of greenhouse for floriculture in subtropics. *Energy and Buildings* 42: 1075-1083.
- Leal-Iga, J., J. Leal-Iga, C. Leal-Iga, and R. Ayala-Flores. 2008. Effect of air density variations on greenhouse temperature model. *Math. Computer Modelling* 47 (9-10): 855-867.
- Linker, R., I. Seginer, and P.O. Gutman. 1998. Optimal CO₂ control in a greenhouse modelled with neural networks. *Computers Electronics Agric.* 19: 289-310.
- López-Cruz, I.L., A. Rojano-Aguilar, W. Ojeda-Bustamante, y R. Salazar-Moreno. 2007. Modelos ARX para predecir la temperatura del aire de un invernadero: una metodología. *Agrociencia* 41 (2): 181-192.

coefficients reflect a high adjustment of neuro-fuzzy models to the measurements. These results are similar to those reported by Gamboa *et al.* (2005) for the prediction of relative humidity outside the greenhouse, in the state of Jalisco, México.

CONCLUSIONS

The neuro-fuzzy models generated for temperature and relative humidity of two greenhouses with natural ventilation, with and without the presence of crop, showed a good performance when the method of subtractive clustering partition of the data was used, combined with 80 % of data to build the model and 20 % of data for validation. After studying two naturally ventilated greenhouses under different climatic conditions and during contrasting seasons (winter and summer), the neuro-fuzzy models seem to be an option to generate models for greenhouse climate for control and optimization purposes.

—End of the English version—

---*---

- Ramos-Fernández, J.C., V. López-Morales, F. Lafont, G. Enea, y J. Duplaix. 2010. Una estructura neurodifusa para modelar la evapotranspiración instantánea en invernaderos. *Ing. Investigación Tecnol.* XI (2): 127-139.
- Salgado, P., and J.B. Cunha. 2005. Greenhouse climate hierarchical fuzzy modelling. *Control Eng. Practice* 13 (5): 613-628.
- Takagi, T., and M. Sugeno. 1985. Fuzzy identification of systems and its applications to modeling and control. *IEEE Trans. on Systems, Man and Cybernetics* 15(1): 116-132.
- Tien, B.T. 1997. Neural-Fuzzy approach for system identification. PhD Thesis. Wageningen University. The Netherlands. 155 p.
- Tien, B.T., and G. Van Straten. 1998. A Neuro-Fuzzy approach to identify lettuce growth and greenhouse climate. *Artificial Intelligence Rev.* 12 (13): 71-93.
- The Mathworks Inc. 1995-2005. *Fuzzy Logic Toolbox. For Use with Matlab.* 295 p.