

Estimación de la fotosíntesis foliar en jitomate bajo invernadero mediante redes neuronales artificiales*

Foliar photosynthesis estimation in tomato under greenhouse conditions through artificial neural networks

José Manuel Vargas Sállago^{1§}, Irineo Lorenzo López Cruz² y Enrique Rico García³

¹Campo Experimental Valle de México- INIFAP. Carretera México-Lechería, km. 18.5. Chapingo, México. C. P. 56230. Tel: (595) 95 466 72. ²Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo. Carretera México-Texcoco, km. 38.5. Chapingo, México. C. P. 56230. Tel. (595) 95 215 51. (ilopez@correo.chapingo.mx). ³División de Estudios de Posgrado, Facultad de Ingeniería, Universidad Autónoma de Querétaro. Querétaro, Querétaro. México. C. P. 76010. Tel. (442)192-12-00. Ext. 6005. (ricog@uag.mx). §Autor para correspondencia: sallagojmv@yahoo.com.mx.

Resumen

Dentro de la teoría de identificación de sistemas, los modelos de redes neuronales artificiales (ANN) artificial neural networks por sus siglas en inglés, han mostrado gran capacidad para encontrar patrones de relación entre variables de procesos altamente no lineales, así como resolver la limitante de la regresión no lineal, donde no es posible usar variables correlacionadas como entradas. El objetivo de la presente investigación fue modelar la tasa de fotosíntesis foliar de plantas de jitomate, cultivadas bajo invernadero, mediante redes neuronales artificiales, empleando como variables de entrada: temperatura, humedad relativa, déficit de presión de vapor y concentración de dióxido de carbono (CO_2) del aire, así como radiación fotosintéticamente activa. El experimento se desarrolló durante 2009 en un invernadero experimental de la Universidad Autónoma de Querétaro, México. Se usó el equipo de fitomonitoreo PTM-48M (Daletown Company, Ltd), para registrar el intercambio de CO_2 de las hojas, así como las variables meteorológicas. Para eliminar ruidos de los sensores en las mediciones se aplicó el filtro Savitzky-Golay. Se evaluaron diferentes configuraciones para redes de retropropagación, siendo la de 4 capas con 10 neuronas en la primera capa oculta, 15 en la segunda y 10 más en la tercera, la que generó los mejores índices estadísticos sobre datos de prueba: coeficiente de

Abstract

Within the theory of systems identification, the models of artificial neural networks (ANN) have shown great ability to find patterns of relationships between variables of highly nonlinear processes, as well as solving the constraint of the nonlinear regression, where it is not possible to use correlated variables as inputs. The objective of this paper was to model the rate of foliar photosynthesis of tomato plants, grown under greenhouse conditions using artificial neural networks, using as input variables: temperature, relative humidity, vapor pressure deficit and concentration of carbon dioxide (CO_2) of the air, and photosynthetically active radiation. The experiment was conducted during 2009 in an experimental greenhouse of the Autonomous University of Querétaro, Mexico. The equipment used was the PTM-48M phyto-monitoring (Daletown Company, Ltd), to record CO_2 exchange on the leaves, and weather variables. In order to remove the sensor noise in the measurements, the Savitzky-Golay filter was used. Different configurations for back-propagation networks were evaluated, with 4 layers and 10 neurons in the first hidden layer, 15 in the second one and 10 more in the third one, which produced the best statistical indices on the test data: coefficient of determination, $R^2 = 0.9756$ and mean square error, $MSE = 0.8532$. Taking the best ANN

* Recibido: enero de 2012
Aceptado: agosto de 2012

determinación, $R^2=0.9756$ y cuadrado medio del error, CME=0.8532. Tomando las predicciones de la mejor ANN, se realizó una optimización estática, relacionando dos variables climáticas con la tasa de fotosíntesis, mediante gráficas en tercera dimensión, a fin de mostrar estrategias para maximizar la tasa de fotosíntesis.

Palabras clave: *Solanum lycopersicum* L., fitomonitor, modelos de caja negra.

Introducción

La producción de cultivos en invernaderos está en constante crecimiento en todo el mundo, debido a que, en comparación con la producción en campo abierto, los ambientes controlados permiten lograr altos rendimientos, mejor calidad de productos, producción fuera de temporada así como un uso muy eficiente del agua. Tan sólo en México, la evolución de la superficie cubierta con esta tecnología pasó de aproximadamente 721 hectáreas (ha) en el año 2000, a 3 214 ha en 2005 y para 2008 se incrementó a 9 948 ha (SAGARPA, 2008).

Los invernaderos varían desde construcciones simples cubiertas con plástico, hasta modernas instalaciones de vidrio con muy alta tecnología (Heuvelink, 2008). Independientemente del tipo de invernadero, el control climático al interior del mismo está enfocado a mantener las variables climáticas temperatura, humedad relativa, cantidad de radiación, déficit de presión de vapor y nivel de dióxido de carbono (CO_2) tan cerca como sea posible de las condiciones óptimas para el desarrollo del cultivo.

El mejoramiento del control ambiental dentro del invernadero, también requiere identificar la influencia de factores climáticos en la fisiología y desarrollo de las plantas cultivadas, puesto que la respuesta de la planta es la parte del proceso más importante en los sistemas de producción (Tantau, 1992; Roh *et al.*, 2007). Dentro de los aspectos fisiológicos más relevantes que deben ser considerados en un sistema de producción en invernadero, se encuentra el entendimiento del proceso de fotosíntesis y los elementos que influyen en ella positiva o negativamente (Evans y Loreto, 2000). El proceso de fotosíntesis está relacionado con la transformación del CO_2 y agua en asimilados que la planta emplea para su mantenimiento, crecimiento y desarrollo. La tasa de fotosíntesis es condicionada principalmente por la

predictions, we performed a static optimization, linking two climatic variables with the rate of photosynthesis, using three-dimensional graphics, to show strategies for maximizing the rate of photosynthesis.

Key words: *Solanum lycopersicum* L., black box models, phyto-monitor.

Introduction

Crop production in greenhouses is constantly growing worldwide, because, compared with production in the open, the controlled environments allow to achieve higher yields, better product quality, off-season production, using water quite efficiently. In Mexico alone, the evolution of the surface covered with this technology increased from approximately 721 hectares (ha) in 2000 to 3 214 ha in 2005 and for 2008, increased to 9 948 ha (SAGARPA, 2008).

The greenhouses range from simple constructions covered with plastic to modern glass facilities with very high technology (Heuvelink, 2008). Whatever the type of greenhouse, climate control is thereof focused on maintaining the climate variables of temperature, relative humidity, quantity of radiation, vapor pressure deficit and level of carbon dioxide (CO_2) as close as possible to the optimal conditions for the development of the crop.

Improved environmental control inside the greenhouse also requires to identifying the influence of the climatic factors on the physiology and development of the crop, since the response of the plant is the most important process in the production systems (Tantau, 1992; Roh *et al.*, 2007). Among the most relevant physiological aspects that must be considered in a greenhouse production system, is to understand the process of photosynthesis and the elements that influence it positively or negatively (Evans and Loreto, 2000). The process of photosynthesis is related to the transformation of CO_2 and water in the plant, assimilated used for maintenance, growth and development. The rate of photosynthesis is mainly conditioned by the intensity of light, CO_2 concentration and temperature as well (van Ooteghem, 2007), although, other climatic variables have significant influence in this process.

intensidad de luz, concentración de CO₂ y por la temperatura (van Ooteghem, 2007), aunque otras variables climáticas tienen bastante influencia en este proceso.

La mayoría de las acciones de control climático afectan más variables de las que debieran y por lo tanto pueden alterar las resistencias internas y externas de la hoja al intercambio gaseoso; por con esto, las acciones de control y efectividad de estos procedimientos deben ser cuidadosamente propuestos cuando el objetivo sea un buen control de temperatura y transpiración del dosel (Wilkinson, 2000). Por ejemplo, la sola manipulación de la humedad relativa dentro de un invernadero, no es por sí misma un sustituto del manejo que se debe hacer para modificar la tasa de transferencia del follaje; sin embargo, juega un papel muy importante en las tasas de intercambio gaseoso (vapor de agua y CO₂) (Stanghellini, 1988).

El monitoreo en tiempo real y continuo de la respuesta fisiológica de la planta a los cambios del ambiente, proporciona información muy importante para controlar el microclima del invernadero de forma precisa; así mismo, el uso de esta tecnología es muy acertado como una herramienta para hacer investigación (Ton *et al.*, 2001). Sin embargo, adaptar una tecnología de fitomonitoreo a sistemas de producción convencional bajo invernadero resulta casi imposible por los elevados costos de los equipos (Roh *et al.*, 2007).

Afortunadamente, la modelación de procesos fisiológicos como la fotosíntesis, es una herramienta que permite conocer el comportamiento de los cultivos bajo ciertas condiciones ambientales de forma muy económica, sólo es necesario contar con modelos que lleven a cabo la predicción de manera precisa del comportamiento del proceso. Los modelos de fotosíntesis y de cultivos pueden ser usados para identificar las condiciones deseadas de crecimiento, explorar efectos de las condiciones de desarrollo relacionadas a la introducción de nuevas tecnologías, así como a la identificación de tratamientos que son particularmente importantes en un ambiente específico (Marcelis *et al.*, 2009).

Hasta la fecha se han reportado tanto modelos empíricos simples como modelos teóricos complejos para la fotosíntesis foliar (Pachepsky y Acock, 1996). Asimismo, una gran variedad de técnicas matemáticas han sido usadas en esos modelos, básicamente fórmulas algebraicas combinadas con métodos de integración especiales. Esta variedad de técnicas se debe a que muchos modelos fueron creados

Most of the climatic control actions affect more variable than they should and therefore may alter the internal resistance and external leaf gas exchange; for this reason, the control actions and effectiveness of these procedures must be carefully proposed when the target is a good temperature control and canopy transpiration (Wilkinson, 2000). For example, the mere manipulation of the relative humidity inside a greenhouse it's not a substitute for management itself, it should be done to change the transfer rate of the foliage, but it plays an important role in exchange rates of gas (water vapor and CO₂) (Stanghellini, 1988).

The real-time monitoring and continuous plant physiological response to changes in the environment, provides important information to control the greenhouse microclimate more accurately, likewise the use of this technology is very successful as a tool to research (Ton *et al.*, 2001). However, adapting a phyto-monitoring technology to conventional systems in greenhouse production is almost impossible due to the high equipment costs (Roh *et al.*, 2007).

Fortunately, modeling of physiological processes such as photosynthesis is a tool to understand the behavior of crops under certain environmental conditions, it is only necessary to have models to predict the behavior of the process. Models of photosynthesis and crops can be used to identify appropriate conditions of growth, exploring effects of developmental conditions related to the introduction of new technologies and to identify the treatments that are particularly important in a specific environment (Marcelis *et al.*, 2009).

Up to this day, empirical models have reported both simple and complex theoretical models for foliar photosynthesis (Pachepsky and Acock, 1996). Also, a variety of mathematical techniques have been used in these models, essentially algebraic formulas combined with special integration methods. This variety of techniques were created to solve different problems, from the need to provide a sub-model to a general model of photosynthetic productivity of the crops (Gijzen *et al.*, 1990), up to the need for specialized models to investigate the nature of one or more components in the process of photosynthesis (Pachepsky and Acock, 1996).

Most of the mechanistic models of photosynthesis require a large number of parameters as inputs and, they must be basically determined by direct measurement. Such

para resolver diferentes problemas, desde la necesidad de proveer de un sub-modelo de fotosíntesis a un modelo general de productividad de cultivos (Gijzen *et al.*, 1990), hasta la necesidad de modelos especializados para investigar la naturaleza de uno o más componentes en el proceso de la fotosíntesis (Pachepsky y Acoc, 1996).

La mayoría de los modelos mecanicistas de fotosíntesis requieren un gran número de parámetros como entradas y éstos deben ser determinados básicamente por medio de mediciones directas. Tales mediciones son usualmente costosas, consumen demasiado tiempo y son destructivas (Anten, 1997). No obstante la exhaustiva determinación de los parámetros de los modelos, para su uso en otros ámbitos, muchas veces es necesario reajustar los valores de estos parámetros, haciendo a los modelos poco confiables para su uso (Nederhoff y Vegter, 1994).

Debido a lo anterior, en los últimos años, los modelos llamados de caja negra han sido exitosamente usados en el área agrícola; por ejemplo, para modelar la temperatura del aire al interior del invernadero se han empleado los modelos auto-regresivos (ARX) con variables externas (López *et al.*, 2007), así como las redes neuronales artificiales (Ferreira *et al.*, 2002; Frausto y Pieters, 2004; Tantau *et al.*, 2008; Salazar *et al.*, 2008). Otros modelos de caja negra bastante exitosos en la predicción de la temperatura y humedad al interior del invernadero son los modelos neuro-difusos, que combinan las ventajas de las redes neuronales y de los sistemas difusos (López y Hernández, 2010).

Salazar *et al.* (2010), encontraron que con el uso de modelos de redes neuronales es posible hacer predicciones precisas (hasta con 5 y 10 minutos de anticipación) tanto de la temperatura dentro del invernadero, como de la fotosíntesis foliar de plantas de jitomate.

El objetivo de esta investigación fue predecir la tasa de fotosíntesis foliar de plantas de jitomate (*Solanum lycopersicum* L.), mediante redes neuronales artificiales, a partir de las condiciones climáticas al interior del invernadero: radiación fotosintéticamente activa, temperatura, humedad relativa, concentración de CO₂ y déficit de presión de vapor, sin emplear la variable respuesta, tasa de fotosíntesis, como parte de las variables de entrada del modelo. El comportamiento de las redes neuronales artificiales se contrastó con los valores de intercambio de dióxido de carbono, medidos en plantas de jitomate usando un sistema de fitomonitoreo. Usando el mejor modelo de red neuronal

measurements are usually expensive, consuming much time and are destructive (Anten, 1997). Despite the exhaustive determination of the model parameters for use in other areas, it is often necessary to readjust the values of these parameters, making the models unreliable for use (Nederhoff and Vegter, 1994).

Because of this, in the recent years, the so-called black box models have been successfully used in agriculture, for example, for modeling the air temperature inside the greenhouse, auto-regressive models (ARX) with external variables (López *et al.*, 2007) and artificial neural networks (Ferreira *et al.*, 2002; Frausto and Pieters, 2004; Tantau *et al.*, 2008; Salazar *et al.* 2008) have been used. Other black box models quite successful in predicting the temperature and humidity inside the greenhouse are the neuro-diffuse models, combining the advantages of both, the neural networks and diffuse systems (López and Hernández, 2010).

Salazar *et al.* (2010) found that, the use of neural network models can make accurate predictions (up to 5 to 10 minutes in advance) for both, the temperature inside the greenhouse, and foliar photosynthesis on tomato plants.

The objective of this research was to predict the rate of foliar photosynthesis of tomato plants (*Solanum lycopersicum* L.) using artificial neural networks, from the climatic conditions inside the greenhouse: photosynthetically active radiation, temperature, relative humidity, concentration of CO₂ and vapor pressure deficit, without using the response variable, rate of photosynthesis, as part of the input variables of the model. The behavior of artificial neural networks was compared with the values of exchange of carbon dioxide, measured in tomato plants using a system of phyto-monitoring. Using the best neural network model, surfaces in three dimensions were generated to more easily explain the effect of the interaction between the climatic variables and their effect on the rate of photosynthesis.

Materials and methods

The research was conducted in a greenhouse of the Experimental Field of the Autonomous University of Querétaro (20°42' north latitude), hooded-type with natural ventilation through side curtains on all four sides, covered with polyethylene. The dimensions are: 24 m long x 9 m

se generaron superficies en tres dimensiones para explicar de forma más sencilla el efecto de la interacción entre variables climáticas y su efecto en la tasa de fotosíntesis.

Materiales y métodos

La investigación se desarrolló en un invernadero del Campus Experimental de la Universidad Autónoma de Querétaro ($20^{\circ} 42'$ latitud norte), tipo capilla con ventilación natural por medio de cortinas laterales en los cuatro lados, con cubierta de polietileno. Las dimensiones de éste son: 24 m largo x 9 m de ancho y 6 m de altura al caballete, con orientación norte- sur en el sentido de las canaletas. El sistema para el control de temperatura está basado en apertura y cierre de las cortinas cuando las condiciones climáticas así lo requieren.

El experimento consistió en medir el intercambio de dióxido de carbono (CO_2) de las hojas de plantas de jitomate bien desarrollada, cultivadas en el invernadero usando el equipo de fitomonitoreo PTM-48M (Daletown Company Ltd), automático de cuatro cámaras, con sistema de tipo abierto. Las variables registradas por el fitomonitoreo PTM-48M fueron: concentración de CO_2 de referencia (ppm), CO_2 de la cámara durante la medición (ppm), flujo de aire al sistema de medición (ppm), fotosíntesis ($\mu\text{mol CO}_2 \text{m}^{-2} \text{s}^{-1}$), humedad absoluta del aire (gm^{-3}), temperatura ($T, ^\circ\text{C}$) y humedad relativa (HR, %) del aire, presión atmosférica (mbar) y déficit de presión de vapor (VPD, vapor pressure deficit, kPa), todas a nivel de hoja. Los sensores se colocaron a media profundidad del dosel, así como en la parte superior del mismo, en hojas con ancho mayor a 5cm, excluyendo hojas viejas. Se instaló también un sensor de radiación fotosintéticamente activa (PAR, photosynthetically active radiation, Watch Dog Model 450 (Spectrum Technologies Inc.); este sensor reporta las mediciones cada 5 min en unidades cuánticas, ($\mu\text{mol Fotones m}^{-2} \text{s}^{-1}$). Las mediciones se realizaron del 3 de noviembre (30 días después del trasplante) al 27 de diciembre de 2009.

Pre-procesamiento de datos

Las mediciones se hicieron cada 30 min con el equipo de fitomonitoreo, mientras que con el sensor de radiación se realizaban cada 5 min; por lo tanto, de acuerdo con Salazar *et al.* (2010), fue necesario hacer una interpolación lineal para los datos del fitomonitoreo a fin de generar dos puntos

wide and 6 m high to the ridge, facing north-south in the direction of the gutters. The system for the temperature control is based on opening and closing curtains when the weather conditions require it.

The experiment consisted of measuring the exchange of carbon dioxide (CO_2) from the leaves of well-developed tomato plants grown in the greenhouse using the phyto-monitoring equipment, PTM-48M (Daletown Company Ltd), automatic four-chamber system with open type. The variables recorded by the PTM-48M were: reference concentration of CO_2 (ppm), CO_2 from the chamber during the measurement (ppm), air flow measurement system (lpm), photosynthesis ($\mu\text{mol CO}_2 \text{m}^{-2} \text{s}^{-1}$), air absolute humidity (gm^{-3}), temperature ($T, ^\circ\text{C}$) and relative humidity (RH, %) of the air, atmospheric pressure (mbar) and vapor pressure deficit (VPD, kPa), all at leaf level. The sensors were placed at the mid-depth of the canopy, and on the top, in leaves more width than 5 cm, excluding old leaves. It was also installed a sensor of photosynthetically active radiation (PAR, Watch Dog, Model 450 (Spectrum Technologies Inc.)), this sensor reports measurements every 5 min in quantum units ($\mu\text{mol Fotones m}^{-2} \text{s}^{-1}$). Measurements were conducted from November 3rd (30 days after transplantation) to December 27th, 2009.

Pre-processing data

Measurements were made every 30 min with the phyto-monitoring equipment, while with the radiation sensor is performed every 5 min, and therefore, according to Salazar *et al.* (2010) it was necessary to make a linear interpolation of the data to the phyto-monitor to generate two extra points, thus having, data of all the equipment's variables every 10 min. Additional sensor data is changed from 5 min to 10 min by elimination.

With arrays of information created from the sensor signals, we proceeded to conduct a data filtering, in order to remove noise from the sensors, also excluding unwanted behaviors in the process of finding the best neural network configuration to estimate the tomato's foliar photosynthesis. The first filter applied to the data matrix was proposed by Savitzky and Golay (1964), using Matlab (The Mathworks Inc., 1984-2009). The filter coefficients were as follows: for photosynthesis and radiation variables used a second-order function and 25 curve trend data, for the variables temperature, relative humidity, CO_2 concentration and vapor pressure deficit,

extras, teniendo así, datos de todas las variables del equipo cada 10 min. Los datos del sensor adicional se cambiaron de 5 min a 10 min por eliminación.

Con las matrices de información creadas a partir de las señales de los sensores, se procedió a llevar a cabo un filtrado de datos, con la finalidad de eliminar los ruidos de los sensores, excluyendo también comportamientos no deseados para el proceso de búsqueda de la mejor configuración de red neuronal para estimar la fotosíntesis foliar del jitomate. El primer filtro aplicado a las matrices de datos fue el propuesto por Savitzky y Golay (1964), por medio de Matlab (The Mathworks INC, 1984-2009). Los coeficientes del filtro quedaron de la siguiente forma: para las variables fotosíntesis y radiación se empleó una función de segundo orden y 25 datos de tendencia de curva; para las variables temperatura, humedad relativa, concentración de CO₂ y déficit de presión de vapor, se empleo el mismo orden y 7 mediciones adelante y atrás del valor estimado. El tiempo de retrasos y adelantos entre las variables que se filtran dependen del tipo de cada una, así como al desfasamiento, hacia la derecha o izquierda, de los datos nuevos con respecto de los originales por acción de la tendencia que sigue el filtro.

Se eliminaron también los datos del fitomonitor en que el intercambio de CO₂ presenta valores negativos, correspondiendo éstos al proceso fisiológico de la respiración durante las horas sin radiación; asimismo, se convirtieron a ceros los registros en que la radiación durante la noche es diferente de ese valor, debido a la alta precisión de los sensores, que son capaces de captar factores externos. Finalmente, se eliminaron las colas de las curvas de radiación y fotosíntesis que seguían una tendencia negativa debido a la aplicación del filtro Savitzky. Como ya se explicó, ninguna de estas variables puede tener valores por debajo de cero.

Para la creación de las redes neuronales se realizó una división de la matriz de información, a lo largo de los 4 820 puntos de mediciones, de forma aleatoria, quedando los siguientes subconjuntos: 50% de datos para entrenamiento, 25% para validación y 25% restante para prueba.

Redes neuronales

Las redes neuronales artificiales son una forma de inteligencia artificial que “aprenden” al procesar datos en patrones a través de su arquitectura interna y tienen la capacidad de modelar relaciones no lineales entre variables.

we used the same order and 7 measurements and forth the estimated value. Time delays and advances between the variables that are filtered on the type of each, and the phase shift to the right or left, the new data with respect to the original per share of trend following the filter.

Data of the phyto-monitor that presented negative values for the exchange of CO₂ were also eliminated, corresponding to the physiological process of breathing during hours of radiation, also converted to zeros records that the radiation at night is different from that value, due to the high precision of the sensors, which are able to pick external factors. Finally, we removed the tails of the curves of radiation and photosynthesis following a negative trend due to the application of the Savitzky filter. As already explained, none of these variables can have values below zero.

For the creation of neural networks is performed a division of the matrix information, along the 4820 measurement points, at random, being the following subassemblies: 50% data for training, validation and 25% for 25% remaining for testing.

Neural networks

Artificial neural networks are a form of artificial intelligence to "learn" to process data patterns through its internal architecture and have the ability to model nonlinear relationships between the variables.

These networks are composed of information processing units acting in parallel, called nodes. These receive an input signal and generate an output transfer functions using nonlinear and sigmoidal and hyperbolic functions. The nodes are present in layers. A network of multi-layer perceptron architecture is used in an ANN. It consists of three layers: incoming calls, hidden and output. A layer consists of individual nodes and these are interconnected by directed arcs by weights associated (Hagan *et al.*, 1996). Each layer has a weight matrix, a bias vector and a vector of outputs (Figure 1) shows a 3-layer neural network.

The layers of a multilayer network play different roles. The layer that produces the outputs of the network is called output layer. The rest of them are named hidden layers. A multilayer network can be a universal approximator of functions. For example, a network of two layers, where in the first layer is sigmoid and the second layer is linear, trained to adjust any function in a manner quite adequate (Hagan *et al.*, 1996; Demuth *et al.*, 2009).

Se componen de unidades de procesamiento de información actuando en paralelo, llamadas nodos. Estos reciben una señal de entrada y generan una salida usando funciones de transferencia no lineales como funciones sigmoidales e hiperbólicas. Los nodos se presentan en capas. Una red de perceptrones con varias capas es la arquitectura más usada en una ANN. Ésta consta de tres capas: llamadas de entrada, oculta y de salida. Una capa está formada por nodos individuales y éstos se encuentran interconectados mediante arcos dirigidos por medio de pesos asociados (Hagan *et al.*, 1996). Cada capa tiene una matriz de pesos, un vector de sesgos, así como un vector de salidas. En la Figura 1 se muestra una red neuronal de 3 capas.

Las capas de una red multicapa juegan diferentes roles. La capa que produce las salidas de la red se llama capa de salida (*output layer*). El resto de ellas son nombradas capas ocultas (*hidden layers*). Una red multicapa puede ser un aproximador universal de funciones. Por ejemplo, una red de dos capas, donde la primera capa es sigmoidal y la segunda capa es lineal, puede ser entrenada para ajustar cualquier función de una manera bastante adecuada (Hagan *et al.*, 1996; Demuth *et al.*, 2009).

Las Redes de retropropagación (backpropagation) aprenden mediante una generalización de la regla de aprendizaje Widrow-Hoff (también conocida como mínimos cuadrados medios del error, LMSE, least mean squares errors, por sus siglas en inglés) para redes multicapa y funciones de transferencia no lineales diferenciables. Se usan vectores de entrada y los correspondientes vectores objetivos para entrenar la red hasta que ésta pueda aproximar una función o asociar un vector específico de entrada a un vector específico de salida (Hagan *et al.*, 1996).

Una red estándar de retropropagación emplea el algoritmo del gradiente descendente, tal como la regla de aprendizaje Widrow-Hoff, en la cual, los pesos de la red se mueven a través de la parte negativa del gradiente de la función de desempeño. El término, retropropagación, se refiere a la forma en que el gradiente es calculado para redes multicapa no lineales, donde el error se calcula para ajustar los valores de los pesos propagándose hacia atrás (de derecha a izquierda). Hay un gran número de variaciones, en el algoritmo básico, que están basadas en las técnicas de optimización estándar, tal como gradiente conjugado o el método de Newton.

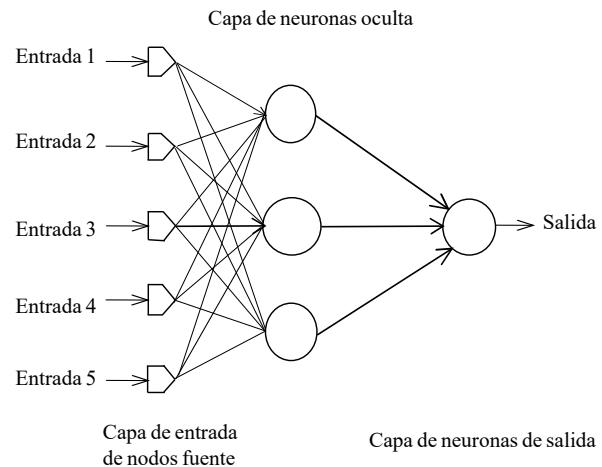


Figura 1. Esquema simplificado de una red neuronal de varias capas.

Figure 1. Simplified schematic of a multilayer neural network.

The back-propagation networks learn through a generalization of the learning rule of Widrow-Hoff (also known as the minimum mean square error (LMSE) for multilayer networks and functions of transfer linear differentiable. Input vectors are used and the corresponding objective vectors to train the network until it can approximate a function, or associates a specific input vector to a specific output vector (Hagan *et al.*, 1996).

A standard network back-propagation algorithm uses the gradient descent, as the learning rule of Widrow-Hoff, wherein the network weights move through the negative gradient of the performance function. The term, back-propagation refers to the way in which the gradient is calculated for nonlinear multilayer networks, where the error is calculated to adjust the values of the weights propagating backward (from right to left). There are a number of variations on the basic algorithm, which are based on standard optimization techniques such as conjugate gradient or Newton's method.

During the investigation we evaluated different configurations of ANN to predict the rate of photosynthesis as a function of 5 input climatic variables, measured inside the greenhouse. The difference between the configurations of the tested ANN lies in its structure (number of layers that make up and number of neurons in each of them) and the origin of the training data directly from the sensors or filtered.

Durante la investigación se evaluaron diferentes configuraciones de ANN para predecir la tasa de fotosíntesis en función de 5 variables climáticas de entrada, medidas al interior del invernadero. La diferencia entre las configuraciones de la ANN probadas, radica en su estructura (número de capas que las integran y, número de neuronas en cada capa), así como el origen de los datos de entrenamiento, directos de los sensores o filtrados.

Se empleó el ambiente de programación Matlab (Neural Network Toolbox), para la generación, prueba y validación de las redes. Todas las redes diseñadas fueron de retropropagación, usando el algoritmo de Levenberg-Marquardt para su entrenamiento; función de aprendizaje por gradiente descendente con momento; como función de desempeño el cuadrado medio del error; una función de transferencia hiperbólica tangente sigmoidal para las capas ocultas y función de transferencia lineal para la capa de salida. Lo anterior se debe a que, si en la capa de salida se emplean neuronas sigmoidales, la salida de la red se limita a un rango muy pequeño; por el contrario, al usar una neurona lineal, la salida puede tomar cualquier valor (Ljung, 2008).

Generación de las rutas de la fotosíntesis

Para entender, de manera general, el comportamiento de la fotosíntesis (de las plantas de jitomate del experimento) como respuesta a diferentes condiciones de las variables que definen el microclima al interior del invernadero, se generaron superficies en 3 dimensiones de las funciones de respuesta que describen las rutas que toma la fotosíntesis como consecuencia de esta interacción. Cada función se generó usando dos variables climáticas a la vez como entradas (con datos filtrados por medio del método Savitzky Golay) y tomando en todos los casos como variable respuesta, la tasa de fotosíntesis que predice la mejor red neuronal artificial. Las superficies se crearon para las siguientes combinaciones en contra de la tasa de fotosíntesis: 1) temperatura-concentración de CO_2 ; 2) radiación-déficit de presión de vapor; y 3) temperatura-humedad relativa.

Resultados y discusión

Después de varias iteraciones durante el entrenamiento de las redes, tanto para datos directos de los sensores o filtrados, se toman como redes válidas aquellas con el

We used the Matlab programming environment (Neural Network Toolbox), for generating, testing and validating the networks. All back-propagation networks were designed using the Levenberg-Marquardt algorithm for training and, learning function by gradient of descent with the momentum; performance as a function of the mean squared error, a hyperbolic tangent transfer function sigmoid for hidden layers and linear transfer function for the output layer. This is because, if the output layer neurons are used sigmoidal, the output of the network is limited to a very small range, on the contrary, when using a linear neuron, the output can assume any value (Ljung, 2008).

Routes of photosynthesis generation

In order to understand, in general, the behavior of photosynthesis (tomato plants of the experiment) in response to different conditions of variables defining the microclimate inside the greenhouse, 3-dimensional surfaces were generated of the response functions that describe the routes taken photosynthesis as a result of this interaction. Each function was generated using two climatic variables, both as inputs (filtered data using Savitzky Golay method) and taking in all cases as the response variable, the rate of photosynthesis that predicts the best artificial neural network. The surfaces were created for the following combinations against the rate of photosynthesis: 1) temperature-concentration CO_2 ; 2) radiation, vapor pressure deficit; and 3) temperature-relative humidity.

Results and discussion

After several iterations during the training of the networks, both for direct data or filtered sensors, the networks are taken as valid, those with the best fit of its predictions on the test data, but avoiding overestimation, i.e. considered acceptable the ones in which the degree of adjustment in both test and validation is lower than in the training (estimate). The best networks are presented in Tables 1 and 2. For the unfiltered data (Table 1), the best performance on the dataset it's the neural network with 3 layers and 15 neurons in two hidden layers. As shown, an adjustment was achieved 97.248% with a mean square error equal to 1.9802. In the case of the filtered data (Table 2), the best performance it is the neural network with 4 layers, 10

mejor ajuste de sus predicciones sobre el conjunto de datos de prueba, pero evitando sobreestimación; es decir, se consideran aceptables aquellas en las que el grado de ajuste tanto en prueba como en validación es menor que en entrenamiento (estimación). Las mejores redes se presentan en los Cuadros 1 y 2. Para los datos sin filtrar (Cuadro 1), el mejor desempeño sobre el conjunto de datos lo tiene la red neuronal con 3 capas y 15 neuronas en ambas capas ocultas. Como puede observarse, se logró un ajuste de 97.248% con un cuadrado medio del error igual a 1.9802. En el caso de los datos filtrados (Cuadro 2), el mejor desempeño lo tiene la red neuronal con 4 capas, 10 neuronas en la primera capa oculta, 15 en la segunda y 10 más en la tercera. El ajuste llega a 98.821% con un cuadrado medio del error de 0.9908. Puede notarse que a partir del número de neuronas indicado para cada capa, un incremento en el número de éstas, provoca que el desempeño de la red comience a decrecer, tomando en cuenta el cuadrado medio del error.

Cuadro 1. Estadísticos de las mejores configuraciones de red para los datos no filtrados.**Table 1. Statistics of the best network settings for the unfiltered data.**

Capas	Desempeño según arquitectura de la red				*
	2	5	10	15	
3	96.08	96.37	96.75	96.75	R ²
	2.8634	2.6591	2.3283	2.3283	CME
	5,5	10,5	15,5	15,5	*
	96.412	97.147	97.103	97.103	R ²
	2.522	2.0925	2.4382	2.4382	CME
	5,10	10,10	15,10	15,10	*
	96.363	97.052	97.182	97.182	R ²
	2.7722	2.3559	2.1714	2.1714	CME
	5,15	10,15	15,15	15,15	*
	97.034	96.867	97.248	97.248	R ²
4	2.2567	2.1152	1.9802	1.9802	CME
	10,10,10	10,15,10	15,10,15	15,10,15	*
	96.876	97.08	97.491	97.491	R ²
	2.6573	2.4661	2.4434	2.4434	CME
	15,10,10	15,15,10	15,15,15	15,15,15	*
	97.349	97.188	97.576	97.576	R ²
	2.1972	2.4374	2.6369	2.6369	CME

(*) Número de neuronas en las capas ocultas.

neurons in the first hidden layer, 15 in the second one and 10 more in the last one. The adjustment comes to 98.821% with a mean square error of 0.9908. It may be noted that from the indicated number of neurons for each layer, an increase in their number causes the network performance begins to decrease, taking into account the mean squared error.

Comparing the best neural networks generated (Table 3), both for unfiltered input (network-1) and the filtered data by Savitzky Golay (network-2), we observed that, although the network-1 is simpler in structure, the degree of adjustment is only 1.573% lower than the filtered data generated network, but taking into account the mean squared error that the network-2 has only 50.03% of the generated error direct data network of sensors. Therefore, the neural network is more efficient than the filtered data generated, although it has a more complex architecture.

Cuadro 2. Estadísticos de las mejores configuraciones de red para los datos filtrados por medio del método Savitzky.
Table 2. Statistics of the best network settings for the filtered data by the method of Savitzky.

Capas	Desempeño según arquitectura de la red				*
	2	5	10	15	
2	97.35	97.672	97.816	97.816	R ²
	1.8387	1.5937	1.5065	1.5065	CME
3	5,5	10,5	15,5	15,5	*
	97.638	97.813	98.147	98.147	R ²
3	1.6749	1.7101	1.4984	1.4984	CME
	5,10	10,10	15,10	15,10	*
3	98.016	98.241	98.369	98.369	R ²
	1.6603	1.3203	1.2688	1.2688	CME
3	5,15	10,15	15,15	15,15	*
	98.019	98.276	98.697	98.697	R ²
3	1.4319	1.3082	1.1821	1.1821	CME
	10,10,10	10,15,10	15,10,15	15,10,15	*
4	98.522	98.821	98.879	98.879	R ²
	0.99778	0.99088	1.0115	1.0115	CME
4	15,10,10	15,15,10	15,15,15	15,15,15	*
	98.692	98.584	98.89	98.89	R ²
4	1.1807	1.2792	1.1678	1.1678	CME

(*) Número de neuronas en las capas ocultas.

Al comparar las mejores redes neuronales generadas (Cuadro 3), tanto para datos de entrada sin filtrar (red -1) como para los datos filtrados por Savitzky Golay (red-2), se observa que, a pesar de que la red-1 es más simple en estructura, su grado de ajuste es sólo 1.573% menor que la red generada con datos filtrados; sin embargo, al tomar en cuenta el cuadrado medio del error, resulta que la red-2 tiene únicamente 50.03% del error generado por la red de datos directos de los sensores. Por lo tanto, la red neuronal más eficiente es la generada con datos filtrados, a pesar de ser más compleja en arquitectura.

Simulation of the rate of photosynthesis with the best neural network

After selecting the best neural network it is used for the simulation of all data, both climatic variables inside the greenhouse, as well as the phyto-monitoring equipment, and recalculates the degree of fitness (R^2) as well as the square average error (MSE). This is done because R^2 and CME reported by the Neural Network Toolbox of MATLAB Graphical User Interface is the statistical average of these three subsets of data from 100%.

Cuadro 3. Comparación entre las mejores redes neuronales para cada tipo de datos de entrada.
Table 3. Comparison between the best neural network for each type of input data.

Origen de los datos	Estructura de la red			R^2	CME
	Número de capas	Neuronas en capas ocultas	Estadísticos		
Sin filtrar	3	15-15	97.248	1.9802	
Filtrados	4	10-15-10	98.821	0.9908	

Simulación de la tasa de fotosíntesis con la mejor red neuronal

Una vez elegida la mejor red neuronal se emplea para realizar la simulación de todos los datos, tanto de las variables climáticas al interior del invernadero, como del equipo de fitomonitoreo, y se recalcula el grado de ajuste (R^2), así como el cuadrado medio del error (CME). Esto se hace porque el R^2 y CME reportados por el Neural Network Toolbox Graphical User Interface de MATLAB, es el promedio de esos estadísticos para tres subconjuntos que provienen 100% de datos.

En la Figura 2 se muestra la simulación de la red neuronal, para seis días del periodo de experimentación, donde es clara la alta capacidad de las redes neuronales artificiales para predecir procesos altamente no lineales, como la fotosíntesis foliar de plantas de jitomate.

Para evaluar el comportamiento general de la red neuronal elegida (a lo largo de los 4820 puntos de mediciones), se empleó la herramienta de ajuste de curvas, disponible en Matlab (Curve Fitting Toolbox). Los estadísticos de la regresión lineal aplicada (Figura 3) entre datos medidos y simulados son los siguientes: $R^2=0.9756$, $CME=0.8532$ y $RCME=0.9237$.

Con la regresión lineal se logra 97.56% de ajuste entre los valores de fotosíntesis simulada con la red neuronal y la fotosíntesis medida. Asimismo, se puede observar claramente como la mayor parte de la nube de datos está dentro de los límites de confianza a 95% para la ecuación de ajuste, lo cual se debe a que la raíz del cuadrado medio del error (RCME) es pequeño, 0.9237. Al realizar las pruebas estadísticas a la red neuronal de 4 capas y 10-15-10 neuronas en las capas ocultas, para los datos de entrada filtrados por el método Savitzky, se observa el excelente desempeño de ésta para todo el conjunto de datos. El valor del ajuste en la regresión mostrada en la Figura 3, es sólo 1.261% menor al reportado por el Neural Network Toolbox Graphical User Interface de MATLAB (Cuadro 3). El Cuadrado medio del error entre la tasa de fotosíntesis simulada por la ANN para todas las mediciones resultó ser menor (0.8532) que el valor generado como promedio de los subconjuntos de datos para entrenar la red (0.9908). Por lo tanto, se encontró una red válida que no sobreestima el ajuste para todo el conjunto de datos, además de conservar las tendencias estadísticas resultantes después de ser entrenada.

Salazar *et al.* (2010) aplicaron una red neuronal para predecir la tasa de fotosíntesis en hojas de jitomate, en la que, además de las variables climáticas, se emplea como variable de

The Figure 2 shows the simulation neural network for six days in the period of experimentation, where it is clear that the high capacity of artificial neural networks predict highly nonlinear processes such as foliar photosynthesis.

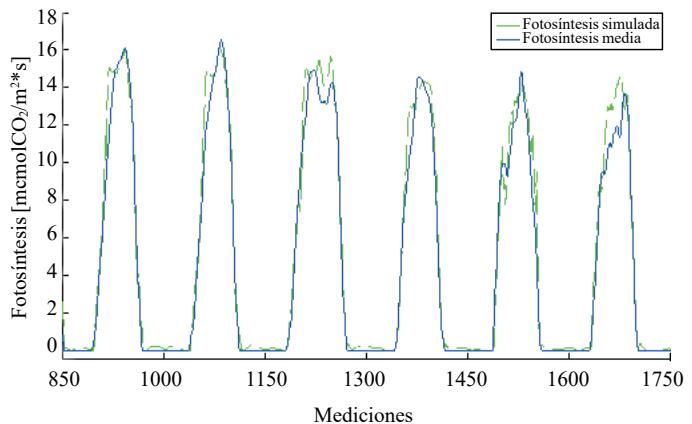


Figura 2. Simulación de la ANN para los datos de seis días.
Figure 2. ANN simulation data for six days.

In order to evaluate the overall performance of the chosen neural network (over 4820 points of measurements), we used the curve-fitting tool, available in Matlab (Curve Fitting Toolbox). The linear regression statistics applied (Figure 3) between measured and simulated data are as follows: $R^2= 0.9756$, $MSE= 0.8532= 0.9237$ and $RCME$.

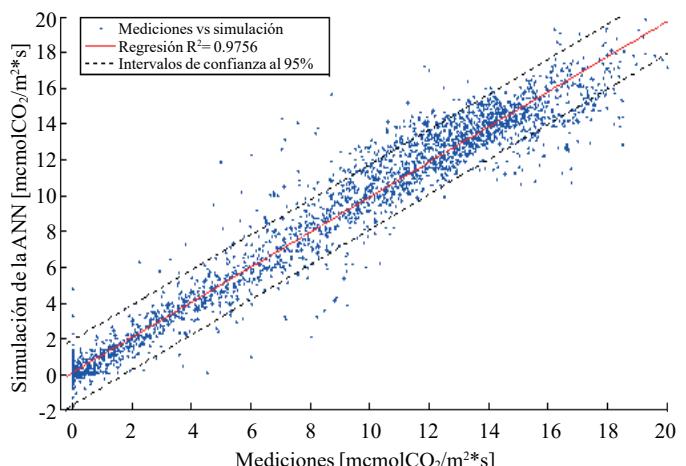


Figura 3. Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones.

Figure 3. Linear regression between measured and simulated photosynthesis with the ANN for the entire set of measurements.

entrada el vector de valores de fotosíntesis, encontrado que el desempeño de ésta se encuentra entre 97.49% y 98.77% para predicciones 5 y 10 min adelante, respectivamente. En la presente investigación se logra un coeficiente de correlación de 97.56% sin emplear los datos de fotosíntesis como variable de entrada.

Fotosíntesis en función de su relación con la temperatura y la concentración de CO₂

En la Figura 4 se observa, que las mayores tasas de fotosíntesis se obtienen cuando los rangos de temperatura se encuentran entre 25°C a 30°C. El máximo de la curva de ajuste para temperatura está situado en 27°C.

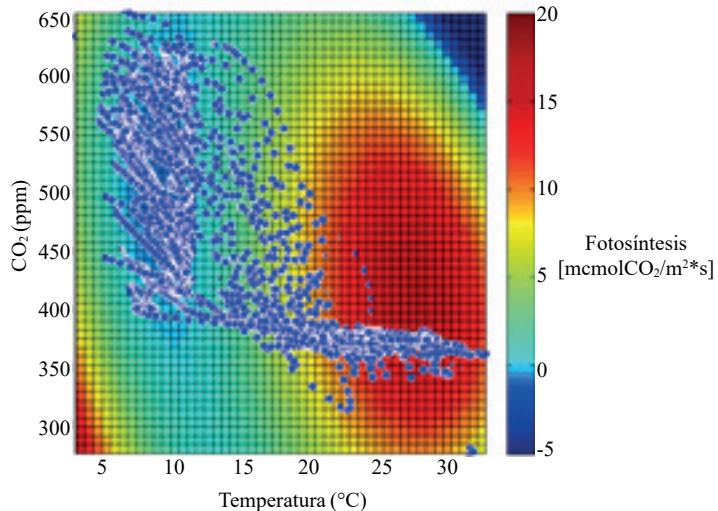
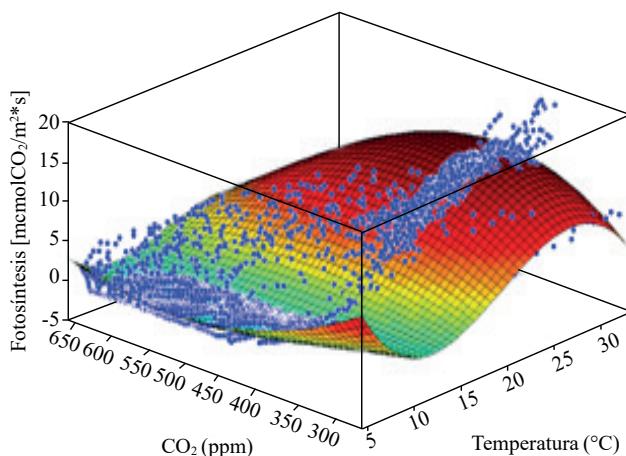


Figura 4. Fotosíntesis en función de las variables temperatura y concentración de CO₂. Izquierda, superficie de la función polinomial de orden 3-2, con ajuste de 91.95% para los datos.

Figure 4. Photosynthesis as a function of the variables temperature and concentration of CO₂. Left, surface of the polynomial function on the order 3-2, with 91.95% adjustment for the data.

Por su parte, para los datos de entrada a la red neuronal, niveles de 380 ppm en la concentración del CO₂ generan las mayores tasas de fotosíntesis registradas. No obstante, al observar la superficie, se puede notar que la concentración del gas dentro del invernadero de estudio no es lo suficientemente alto para alcanzar el máximo de la función (máxima fotosíntesis), que requiere cerca de 450 ppm.

Fotosíntesis en función de su relación con la radiación y el déficit de presión de vapor

De la Figura 5 es clara la importancia de la radiación fotosintéticamente activa en el incremento de la tasa de fotosíntesis, puesto que a medida que la primera

With the linear regression is achieved 97.56% of fitness between the values of photosynthesis simulated by the neural network and measured photosynthesis. It can also be seen quite clearly that most of the data cloud is within the confidence limits 95% for the fitting equation, which is that the root mean square error (RCME) is small, 0.9237. In conducting statistical tests to the 4-layer neural network and 10-15-10 neurons in the hidden layers to the input data filtered by the Savitzky method, we see the excellent performance of this method for the entire dataset. The value of the adjustment in the regression shown in Figure 3 is only 1 261% lower than that reported by the Neural Network Toolbox of MATLAB Graphical User Interface (Table 3).

The mean square error between the rate of photosynthesis simulated by the ANN for all measurements was lower (0.8532) than the average value generated as subsets of data to train the network (0.9908). Therefore, a valid network is found not overestimating the setting for the entire set of data, and statistical trends result retained after being trained.

Salazar *et al.* (2010) applied a neural network to predict the rate of photosynthesis in the leaves of tomato, in which, besides the climatic variables, it's used as an input variable for the vector of values of photosynthesis, finding that the performance is between 97.49% and 98.77% for the predictions 5 and 10 min later, respectively. In the present

aumenta, la segunda lo hace también. La tasa máxima de fotosíntesis registrada (de acuerdo a la función) se alcanza aproximadamente con una radiación PAR de 230 Wm^{-2} . Sin embargo, el máximo de la función se encuentra más allá de 250 Wm^{-2} .

Por su parte, cuando el déficit de presión de vapor está por arriba de 2.5 kPa , la trayectoria de la fotosíntesis no se dirige hacia el máximo de la función, por el contrario, comienza a decrecer aún para los mismos niveles de radiación PAR. Por lo tanto es importante mantener el VPD por debajo de 2.5 kPa cuando se presentan elevados niveles de radiación, para asegurar la apertura estomática y con ello, el ingreso del CO_2 al interior de las hojas.

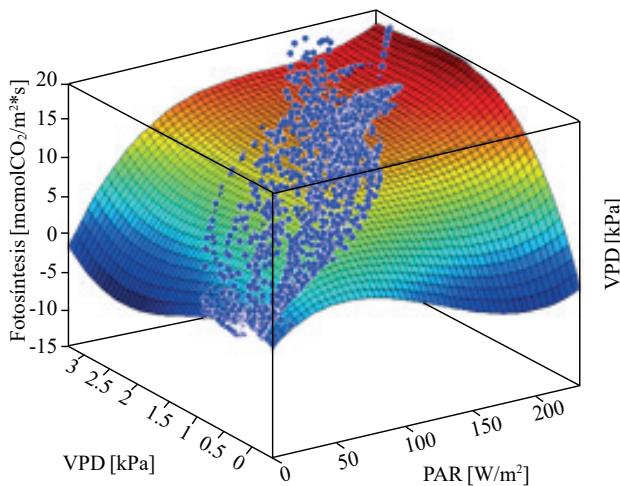


Figura 5. Fotosíntesis en función de las variables PAR y VPD. Izquierda, superficie de la función polinomial de orden 3-3, con ajuste de 97.67% para los datos.

Figure 5. Photosynthesis as a function of the variables PAR and VPD. Left, surface of the polynomial function on the order 3-3, with adjustment of 97.67% for the data.

Fotosíntesis en función de su relación con la temperatura y la humedad relativa

De las variables climáticas más fácilmente medidas en los invernaderos, debido al bajo costo de los sensores, se encuentran la temperatura y la humedad relativa. Por consiguiente, es muy importante conocer las relaciones entre estas variables y la fotosíntesis.

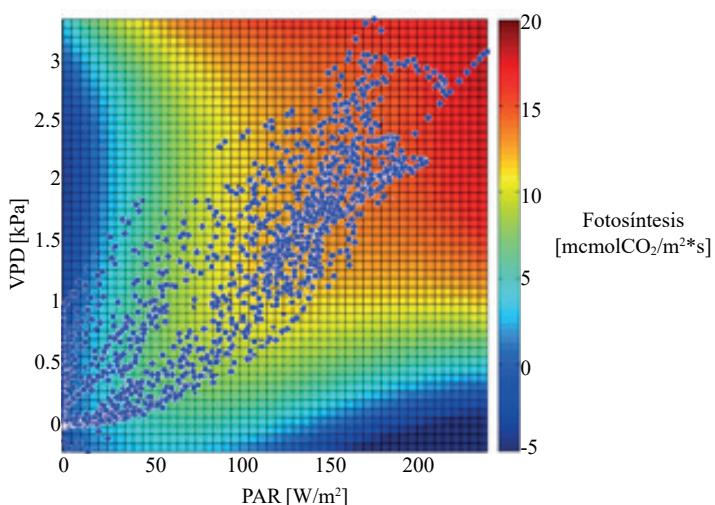
Como se observa en la Figura 6, la combinación de una baja temperatura y humedad relativa altas generan tasas de fotosíntesis bastante bajas, por debajo de $5 \mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$; caso contrario los niveles más altos de fotosíntesis se generan cuando la temperatura está entre los $25\text{-}30^\circ\text{C}$, mientras que la

investigation a correlation coefficient of 97.56% without using the data of photosynthesis as an input variable was achieved.

Photosynthesis in terms of their relationship with temperature and concentration of CO_2

The Figure 4 shows that, the highest rates of photosynthesis are obtained when the temperature ranges are between 25°C and 30°C . The maximum of the curve for temperature adjustment is located at 27°C .

For data input to the neural network, levels of 380 ppm CO_2 concentration generated higher rates of photosynthesis. However, by observing the surface, we may notice that the



concentration of greenhouse gas in the study is not high enough to reach the maximum of the function (maximum photosynthesis), which requires about 450 ppm .

Photosynthesis in terms of its relationship with radiation and vapor pressure deficit

Considering the Figure 5, it is clearly important to the photosynthetically active radiation in increasing the rate of photosynthesis, since as the first one increase, so does the second one. The maximum rate of photosynthesis recorded (according to the function) is reached about a PAR of 230 Wm^{-2} . However, the maximum of the function is higher than 250 Wm^{-2} .

humedad relativa se ubica entre 30-40%. Se aprecia también que por arriba de 80% de HR independientemente de la temperatura, los niveles de fotosíntesis son muy bajos, del orden de $\frac{1}{4}$ parte de la tasa máxima registrada. Asimismo, una temperatura aceptable mínima es 18 °C, pues a partir de ella la tasa de fotosíntesis se encuentra por encima del 50% de la tasa máxima, siempre y cuando la HR se tenga valores de 30 a 65%.

When the vapor pressure deficit is above 2.5 kPa, the trajectory of photosynthesis is not directed towards the maximum of the function; however, it still starts to decrease for the same levels of PAR. Therefore, it is important to maintain the VPD below 2.5 kPa when there are high levels of radiation, to secure the stomatal opening and thus the entry of CO₂ into the leaves.

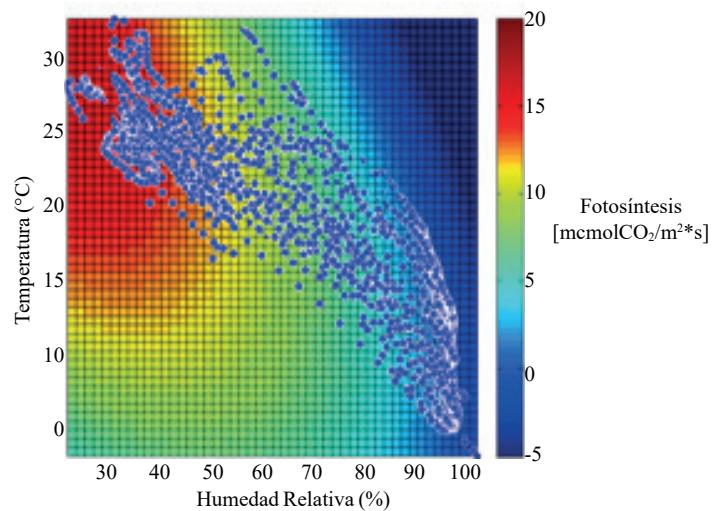
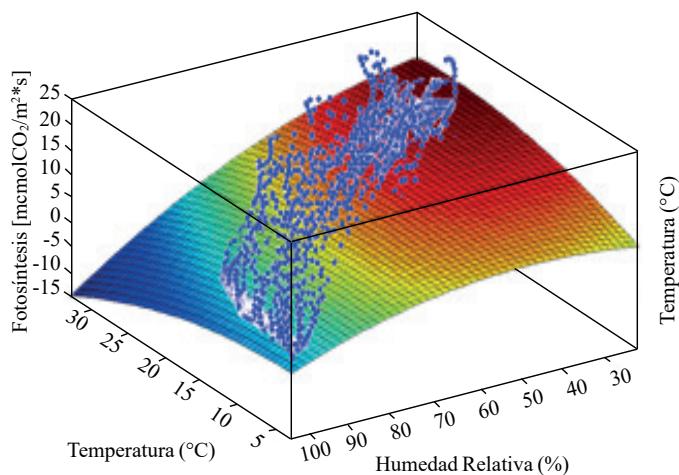


Figura 6. Fotosíntesis en función de las variables Temperatura y humedad relativa. Izquierda, superficie de la función polinomial de orden 2-2, con ajuste de 98.29% para los datos.

Figure 6. Photosynthesis as a function of temperature and relative humidity variables. Left, surface of the polynomial function on the order 2-2, with adjustment of 98.29% for the data.

Conclusiones

Debido a sus capacidades de aproximador universal de funciones, las redes neuronales artificiales describen con un grado de ajuste muy alto, R²=97.56%, la relación entre la fotosíntesis de un cultivo de jitomate en invernadero y las variables climáticas: radiación, temperatura, humedad relativa, déficit de presión de vapor y concentración de CO₂. La mejor configuración de red neuronal, para simular la tasa de fotosíntesis foliar de plantas de jitomate tuvo un arquitectura de 4 capas con 10-15-10 neuronas en las capas ocultas.

A partir de las superficies de respuesta generadas con los valores de tasa de fotosíntesis foliar, predichos por la mejor red neuronal artificial, es posible tener una mejor comprensión de la interacción entre las condiciones climáticas dentro de los invernaderos y la tasa de fotosíntesis foliar del cultivo del jitomate. Es decir, con base

Photosynthesis in terms of its relationship with temperature and relative humidity

Of the climatic variables more easily measured in greenhouses because of the low cost of sensors include the temperature and relative humidity too. It is therefore very important to know the relationships between these variables and photosynthesis.

As shown in Figure 6, the combination of a low temperature and high relative humidity generated photosynthesis rates quite low, below 5 $\mu\text{molCO}_2\text{m}^{-2}\text{s}^{-1}$, otherwise the highest levels of photosynthesis are generated when the temperature is between 25-30 °C, while the relative humidity is between 30-40%. It is also noted that above 80% RH regardless of the temperature, photosynthesis levels are very low, of the order of $\frac{1}{4}$ of the maximum recorded. Also, a minimum acceptable temperature is 18 °C, since from it; photosynthesis rate is above 50% of the maximum rate, as long as the RH has values of 30 to 65%.

en las funciones con que se generaron las superficies, se pueden ver las rutas que deben seguir las variables climáticas, de tal forma de que el control ambiental de los invernaderos siempre esté enfocado hacia el máximo de la función; es decir, a la obtención de la tasa máxima de fotosíntesis dependiendo de las condiciones climáticas prevalecientes.

Literatura citada

- Anten, N. P. R. 1997. Modelling canopy photosynthesis using parameters determined from simple non-destructive measurements. *Ecol. Res.* 12:77-88.
- Demuth, H.; Beale, M. and Hagan, M. 2009. Neural network toolbox™ 6. User's Guide. The MathWorks, Inc. Natick, MA. 901 p.
- Evans, J. R. and Loreto, F. 2000. Acquisition and diffusion of CO₂ in higher plant leaves. *Photosynthesis, physiology and metabolism*. Kluwer Academic Publishers. The Netherlands. 321-351 pp.
- Ferreira, P. M.; Faria, E. A. and Ruano, A. E. 2002. Neural network models in greenhouse air temperature prediction. *Neurocomputing*. 43:51-75.
- Frausto, H. U. and Pieters, J. G. 2004. Modelling greenhouse temperature using system identification by means of neural networks. *Neurocomputing* 56:423-428.
- Gijzen, H.; Vegter, J. G. and Nederhoff, E. M. 1990. Simulation of greenhouse crop photosynthesis: validation with cucumber, sweet pepper and tomato. *Acta Hort.* 268: 71-80.
- Heuvelink, E.; Bakker, M.; Marcelis, L. F. M. and Raaphorst, M. 2008. Climate and yield in a closed greenhouse. *Acta Hort.* 801:1083-1092.
- Hagan, M. T.; Demuth, H. E. and Beale, M. 1996. Neural network design. PWS publishing Company. USA. 734 p.
- Ljung, L. 2008. Perspectives on system identification. 17th IFAC World Congress in Seoul, Korea. 13 p.
- López, C. I. L.; Rojano, A. A.; Ojeda, B. W. y Salazar, M. R. 2007. Modelos ARX para predecir la temperatura del aire de un invernadero: una metodología. *Agrociencia*. 41:181-192.
- López, C. I. L. y Hernández, L. L. 2010. Modelos neurodifusos para temperatura y humedad del aire en invernaderos tipo cenital y capilla en el centro de México. *Agrociencia*. 44:791-805.

Conclusions

Because on its universal approximation capabilities of the functions, the artificial neural networks described with a high degree of fitness, R²= 97.56%, the relationship between photosynthesis of a greenhouse of tomato and the climatic variables: radiation, temperature, relative humidity, vapor pressure deficit and CO₂ concentration. The best neural network configuration to simulate the rate of foliar photosynthesis on tomato plants had a 4-layer architecture with 10-15-10 neurons in the hidden layers.

From the response surfaces generated with the values of the foliar photosynthetic rate, predicted by the best artificial neural network, we may have a better understanding of the interaction between the climatic conditions inside the greenhouses and, the rate of foliar photosynthesis of the crop. That is, based on the functions that were generated, we can see the routes to be followed by the climatic variables, so that the environmental control of the greenhouses is always focused on the maximum of the function, i.e., to obtain the maximum rate of photosynthesis depending on the prevailing climatic conditions.

End of the English version



- Marcelis, L. F. M.; Elings, A.; de Visser, P. H. B. and Heuvelink, E. 2009. Simulating growth and development of tomato crop. *Acta Hort.* 821:101-110.
- Nederhoff, E. M., and Vegter, J. G. 1994. Canopy photosynthesis of tomato, cucumber and sweet pepper in greenhouses: measurements compared to models. *Ann. Bot.* 73: 421-427.
- Pachepsky, L. B., and Acock, B. 1996. An adequate model of photosynthesis-II. Dependence of parameters on environmental factors. *Agric. Systems*. 50:227-238.
- Roh, M. Y.; Nam, Y. I.; Cho, M. W.; Yu, I. H.; Choi, G. L. and Kim, T. Y. 2007. Environmental control in greenhouse based on phytomonitoring - leaf temperature as a factor controlling greenhouse environments. *Acta Hort.* 761:71-76.
- Secretaría de Agricultura Desarrollo Rural, Pesca y Alimentación (SAGARPA) 2008. Plan Nacional de Agricultura Protegida. Disponible en www.amhpac.org.

- Salazar, M. R.; López, C. I. L. and Rojano, A. A. 2008. A neural network model to control greenhouse environment. Sixth Mexican International Conference on Artificial Intelligence, Special Session. 311-318 pp.
- Salazar, M. R.; Schmidt, U.; Huber, C.; Rojano, A. A. and López, C. I. L. 2010. Neural networks models for temperature and CO₂ control. *Inter. J. Agric. Res.* 1-10 pp.
- Savitzky, A. and Golay, M. J. E. 1964. Smoothing and differentiation of data by simplified least squares procedures. *Analy. Chem.* 36:1627-1639.
- Stanghellini, C. 1988. Microclimate and greenhouse crops. *Acta Hort.* 229:405-410.
- Tantau, H. J. 1992. Estimation of the relative opening of the leaf stomata using energy balances. *Acta Hort.* 304:167-172.
- Tantau, H. J.; Patil, S. L. and Salokhe, V. M. 2008. Modelling of tropical greenhouse temperature by auto regressive and neural network models. *Bios. Eng.* 99:423-431.
- Ton, Y.; Nilov, N. and Kopyt, M., 2001. Phytomonitoring: the new information technology for improving crop production. *Acta Hort.* 562:257-262.
- Van Ooteghem, R. 2007. Optimal control design for a solar greenhouse. Ph. D. Thesis Wageningen University. The Netherlands. 312 p.
- Wilkinson, R. E. 2000. Plant-Environment Interactions. 2th. Marcel Dekker, Inc. The University of Georgia, Griffin, Georgia. United States of America. 466 p.