

## Redes neuronales artificiales aplicadas a mediciones de fitomonitoreo para simular fotosíntesis en jitomate bajo invernadero

José Manuel Vargas Sállago<sup>1§</sup>, Irineo Lorenzo López Cruz<sup>2</sup> y Enrique Rico García<sup>3</sup>

<sup>1</sup>Campo Experimental Valle de México. INIFAP. Carretera México-Lechería km 18.5. Chapingo, México. C. P. 56230. Tel: (595) 95 466 72. <sup>2</sup>Posgrado 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. <sup>3</sup>División 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@uaq.mx. §Autor para correspondencia: sallagojm@yahoo.com.mx.

### Resumen

Se utilizaron Redes Neuronales Artificiales (ANN, Artificial Neural Networks) para simular la tasa de fotosíntesis de plantas de jitomate, empleando como variables de entrada: temperatura, humedad relativa, déficit de presión de vapor y concentración de dióxido de carbono ( $\text{CO}_2$ ) del aire, así como radiación fotosintéticamente activa. El experimento se desarrolló en un invernadero experimental, con control climático totalmente convencional, de la Universidad Autónoma de Querétaro, México. Se empleó un cultivo con índice de área foliar mayor a 2 para llevar a cabo las mediciones. Para registrar el intercambio de dióxido de carbono ( $\text{CO}_2$ ) de las hojas de las plantas, así como las variables meteorológicas, se usó el monitor de fotosíntesis (PTM-48M, Daletown Company, Ltd), con sistema automático de cuatro canales de tipo abierto, así como un sensor de radiación fotosintéticamente activa (Watch Dog Model 450). 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 determinación,  $R^2=0.9756$  y cuadrado medio del error, CME= 0.8532.

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

### Introducción

El mejoramiento de muchos sistemas de control ambiental dentro del invernadero, independientemente de si son construcciones simples cubiertas con plástico hasta modernas instalaciones de vidrio con muy alta tecnología, 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; Heuvelink *et al.*, 2008).

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 *et al.*, 2000). La tasa de fotosíntesis es condicionada principalmente por la intensidad de luz, concentración de  $\text{CO}_2$  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 (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 durante el intercambio de vapor de agua y CO<sub>2</sub> (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 (Marcelis *et al.*, 2009).

Los modelos matemáticos son herramientas muy poderosas para probar hipótesis, sintetizar conocimiento y entender complejos sistemas, así como comparar diferentes escenarios; además, han sido empleados en sistemas de apoyo a toma de decisiones, control de clima y fertiriego, así como para la predicción y planeación de la producción (Heuvelink *et al.*, 2008; 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). Esta variedad de técnicas se debe a que muchos modelos fueron creados para resolver diferentes problemas, desde la necesidad de proveer de un sub-modelo de fotosíntesis a un modelo general de productividad de cultivos (Gijzen, 1990); hasta la necesidad de modelos especializados para investigar la naturaleza de uno o más componentes en el proceso de la fotosíntesis (Pachepsky y Acock, 1996).

Por ejemplo; los modelos mecanicistas de fotosíntesis requieren un gran número de parámetros como entradas y éstos deben ser determinados básicamente por medio de mediciones directas que son costosas, destructivas y consumen demasiado tiempo (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 al anterior inconveniente, 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, 2002; Frausto, 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 (López y Larragoiti, 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 min de anticipación) tanto de la temperatura dentro del invernadero, como de la fotosíntesis foliar de plantas de jitomate.

En esta investigación se simuló la tasa de fotosíntesis foliar de plantas de jitomate (*Solanum lycopersicum*), mediante redes neuronales artificiales, tomando como variables de entrada las condiciones climáticas al interior del invernadero: radiación fotosintéticamente activa, temperatura, humedad relativa, concentración de CO<sub>2</sub> 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 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

El cultivo se estableció en un invernadero del Campus Experimental de la Universidad Autónoma de Querétaro (20° 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 \* 9 m de ancho y 6 m de altura al caballete, con orientación Norte- Sur en el sentido de las cañaleras.

El experimento consistió en medir el intercambio de dióxido de carbono ( $\text{CO}_2$ ) de las hojas de plantas de jitomate bien desarrolladas, 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 Fitomonitor PTM-48M fueron: concentración de  $\text{CO}_2$  de referencia (ppm),  $\text{CO}_2$  de la cámara durante la medición (ppm), flujo de aire al sistema de medición (lpm), fotosíntesis ( $\mu\text{mol CO}_2 \text{ m}^{-2} \text{s}^{-1}$ ), humedad absoluta del aire ( $\text{gm}^{-3}$ ), temperatura (T, °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.

Con las matrices de información, creadas a partir de las señales de los sensores muestradas cada 10 min, se procedió a llevar a cabo un filtrado de datos, con la finalidad de eliminar los ruidos de los sensores. 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  $\text{CO}_2$  y déficit de presión de vapor, se empleó el mismo orden y 7 mediciones adelante y atrás del valor estimado.

Se eliminaron también los datos del fitomonitor en que el intercambio de  $\text{CO}_2$  presenta valores negativos, correspondiendo éstos al proceso fisiológico de la respiración durante las horas sin radiación; así mismo, 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 captan 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 G. pues, 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.

Las redes neuronales artificiales (Artificial Neural Network, ANN, por sus siglas en inglés) son modelos de caja-negra, una forma de inteligencia artificial que “aprende” al procesar datos en patrones a través de su arquitectura interna y tienen la capacidad de modelar relaciones altamente no lineales entre variables. Una red multicapa de perceptrones es la arquitectura más usada en una ANN; típicamente, tiene tres capas, consistentes en una capa de entrada, una capa oculta y una capa de salida. Cada capa está formada por nodos individuales y éstos se encuentran interconectados a través de las capas por funciones de transferencia no lineales, expresadas en términos de nodos de variables de entrada y conexiones por medio de pesos (Hagan *et al.*, 1996).

Cada capa tiene una matriz de pesos  $\mathbf{W}$ , un vector de sesgos  $\mathbf{b}$ , así como un vector de salidas  $\mathbf{a}$ . En la Figura 1 se muestra una red neuronal de 3 capas, que tiene  $R^1$  entradas,  $S^1$  neuronas en la primer capa,  $S^2$  neuronas en la segunda capa, etc. Es común que se tenga diferente número de neuronas para diferentes capas. Se puede notar que las salidas de cada capa intermedia, son la entrada de la siguiente capa. Por lo tanto, la capa 2 puede ser analizada como una red de una capa con  $S^1$  entradas,  $S^2$  neuronas, y  $S^2 \times S^1$  matriz de pesos  $\mathbf{W}^2$ . La entrada de la capa 2 es  $a^1$ ; la salida es  $a^2$ .

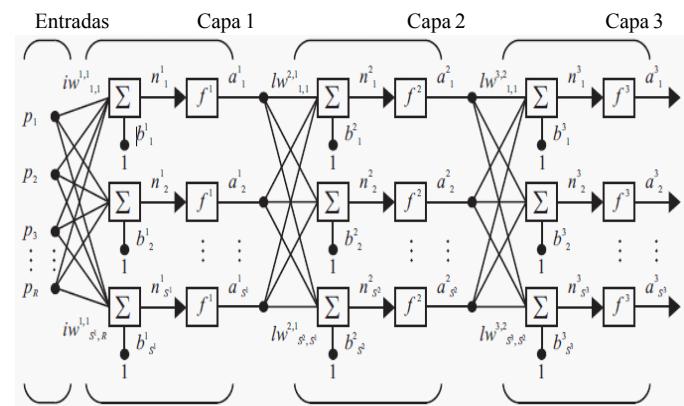


Figura 1. Esquema de una red neuronal multicapa.

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*). La red mostrada en la Figura 1 tiene una red de salida (capa 3) y dos capas ocultas (capa 1 y 2).

Las salidas para las capas 1, 2 y 3 pueden describirse de la siguiente forma:

$$a^1 = f^1(IW^{1,1}p + b^1) \quad 1)$$

$$a^2 = f^2(LW^{2,1}a^1 + b^2) \quad 2)$$

$$a^3 = f^3(LW^{3,2}a^2 + b^3) \quad 3)$$

Por lo tanto, la salida de la capa 3, es la salida de interés de la Red Neuronal y puede ser descrita con la siguiente ecuación:

$$a^3 = f^3(LW^{3,2}f^2(LW^{2,1}f^1(IW^{1,1}p + b^1) + b^2) + b^3) = y \quad 4)$$

Una red multicapa puede ser un aproximador universal. 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) son una generalización de la regla de aprendizaje Widrow-Hoff 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.

Widrow y Hoff tuvieron la idea de estimar el cuadrado medio del error  $F(x)$  usando los cuadrados de los errores en cada iteración.

$$F(x) = (t(k) - a(k))^2 = e^2(k) \quad 5)$$

Después de cada iteración se calcula el gradiente:

$$\nabla F(x) = \nabla e^2(k) \quad 6)$$

Los primeros  $R$  elementos de  $\nabla e^2(k)$  son derivados con respecto de los pesos de la red, mientras que los  $R + I$  elementos, son derivados con respecto de los sesgos (Hagan *et al.*, 1996). Entonces, se tiene:

$$[\nabla e^2(k)]_j = \frac{\partial e^2(k)}{\partial w_{1,j}} = 2e(k) \frac{\partial e(k)}{\partial w_{1,j}} \text{ para } j = 1, 2, \dots, R \quad 7)$$

$$[\nabla e^2(k)]_{R+1} = \frac{\partial e^2(k)}{\partial b} = 2e(k) \frac{\partial e(k)}{\partial b} \quad 8)$$

Ahora, la derivada parcial con respecto del error:

$$\frac{\partial e^2(k)}{\partial w_{1,j}} = \frac{\partial [t(k) - a(k)]}{\partial w_{1,j}} = \frac{\partial [t(k) - Wp(k) + b]}{\partial w_{1,j}} \quad 9)$$

O bien,

$$\frac{\partial e(k)}{\partial w_{1,j}} = \frac{\partial}{\partial w_{1,j}} [t(k) - (\sum_{i=1}^R w_{1,i} p_i(k) + b)] \quad 10)$$

Donde:  $p_i(k)$  es el  $i^{th}$  elemento del vector de entradas a la  $k^{th}$  iteración. Esto se puede simplificar como:

$$\frac{\partial e(k)}{\partial w_{1,j}} = -p_j(k) \quad 11)$$

$$\frac{\partial e(k)}{\partial b} = -1 \quad 12)$$

Finalmente, cambiando la matriz de pesos y sesgos queda:

$$2ae(k)p(k) \quad 13)$$

$$2ae(k) \quad 14)$$

Estas dos ecuaciones forman la base del algoritmo de aprendizaje Widrow-Hoff(LMS). Los resultados se pueden extender al caso de capas múltiples, y escribirse en forma de matriz como:

$$W(k+1) = W(k) + 2ae(k)p^T(k) \quad 15)$$

$$b(k+1) = b(k) + 2ae(k) \quad 16)$$

Aquí, el error  $e$ , así como el sesgo  $b$  son vectores y  $\alpha$  es la tasa de aprendizaje. Si  $\alpha$  es grande, el aprendizaje ocurre rápidamente, pero si es demasiado grande, pueden surgir inestabilidades y los errores se pueden incrementar.

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.

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).

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 proveniente de la simulación

de la mejor red neuronal artificial. Las superficies se crearon para las siguientes combinaciones en contra de la tasa de fotosíntesis: 1) temperatura-concentración de  $\text{CO}_2$ ; y 2) radiación-déficit de presión de vapor.

## Resultados y discusión

Las mejores redes se presentan en los Cuadros 1 y 2. Se toman como redes válidas aquellas con el 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).

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.**

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

(\*) Número de neuronas en las capas ocultas.

**Cuadro 2. Estadísticos de las mejores configuraciones de red para los datos filtrados por medio del método Savitzky Golay.**

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

(\*) 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 sólo 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.

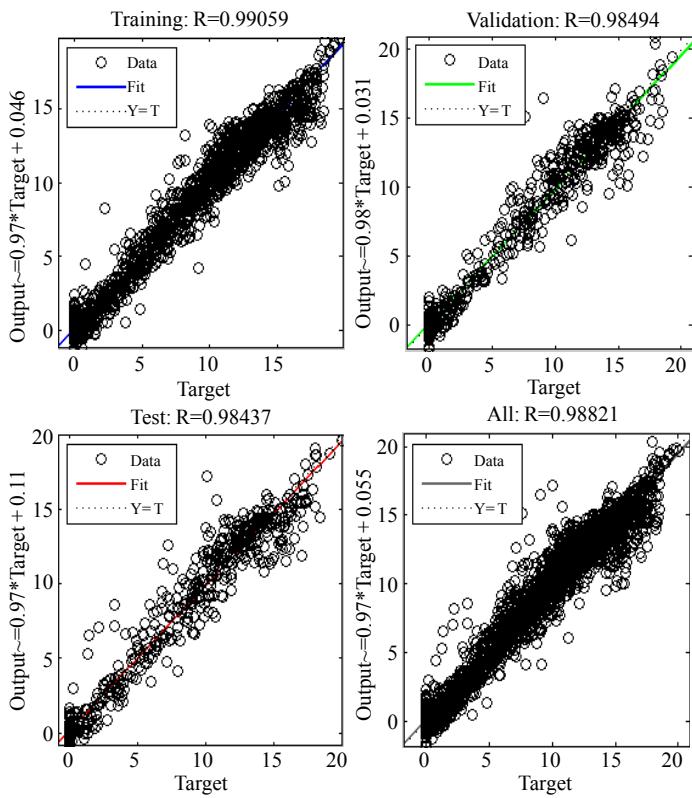
**Cuadro 3. Comparación entre las mejores redes neuronales para cada tipo de datos de entrada.**

Origen de los datos	Estructura de la red		R <sup>2</sup>	Estadísticos CME
	Número de capas	Neuronas en capas ocultas		
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

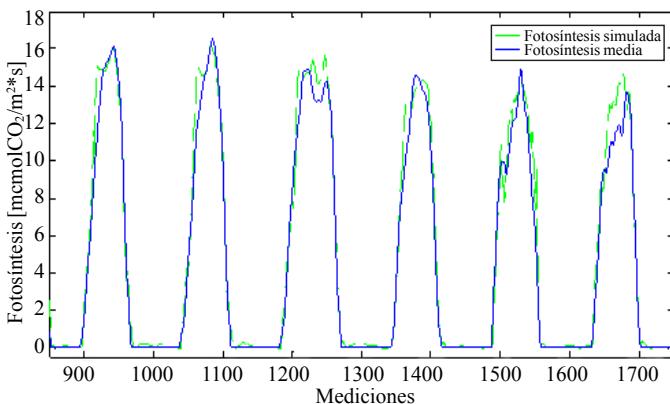
Una vez elegida la mejor red neuronal se emplea para realizar la simulación de todos los datos, tanto de las variables climáticas al interior del invernadero, como del equipo de fitomonitoreo, y se recalcula el grado de ajuste (R<sup>2</sup>), así como

el cuadrado medio del error (CME). Esto se hace porque el R<sup>2</sup> y CME reportados por el Neural Network Toolbox Graphical User Interface de MATLAB, (Figura 2) es el promedio de esos estadísticos para tres subconjuntos que provienen de 100% de datos: entrenamiento (50%), validación (25%) y prueba (25%). Los datos de cada subconjunto se eligen de forma aleatoria a lo largo de la matriz de información.



**Figura 2.** Ajuste de la mejor red neuronal para los subconjuntos: entrenamiento, validación y prueba. En el cuarto cuadrante (derecha, inferior) se encuentra el promedio de estos.

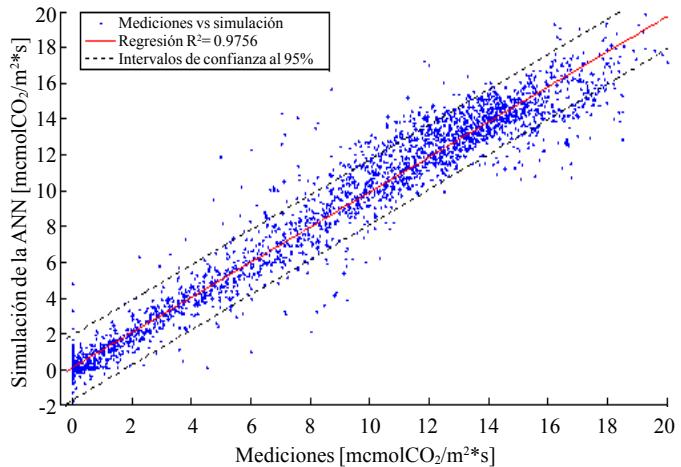
En la Figura 3 se muestra la simulación de la red neuronal, para seis días del periodo de experimentación, donde es clara la alta capacidad de las redes neuronales artificiales para predecir procesos altamente no lineales, como la fotosíntesis foliar de plantas de jitomate.



**Figura 3.** Simulación de la ANN para los datos de seis días.

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 4) entre datos medidos y simulados son los siguientes:  $R^2 = 0.9756$ , CME = 0.8532 y RCME = 0.9237.



**Figura 4.** Regresión lineal entre fotosíntesis medida y simulada con la ANN para todo el conjunto de mediciones.

Con la regresión lineal se logra 97.56% de ajuste entre los valores de fotosíntesis simulada con la red neuronal y la fotosíntesis medida. Así mismo, se puede observar claramente como la mayor parte de la nube de datos está dentro de los límites de confianza al 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 Golay, se observa el excelente desempeño de ésta para todo el conjunto de datos. El valor del ajuste en la regresión mostrada en la Figura 4, 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 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 CO<sub>2</sub>

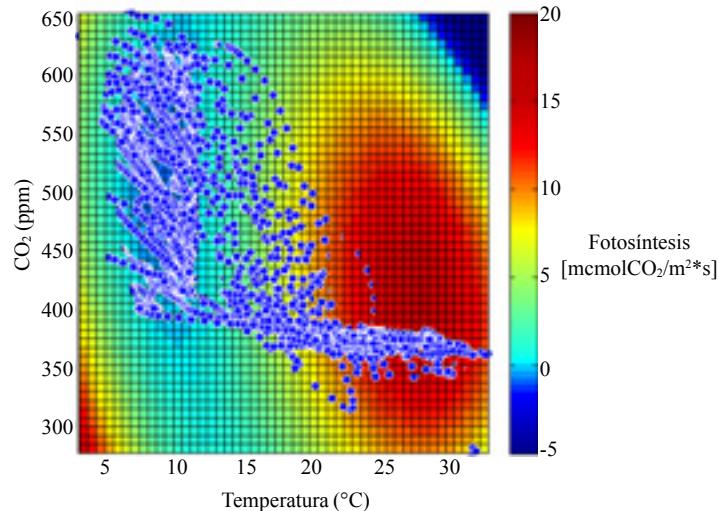
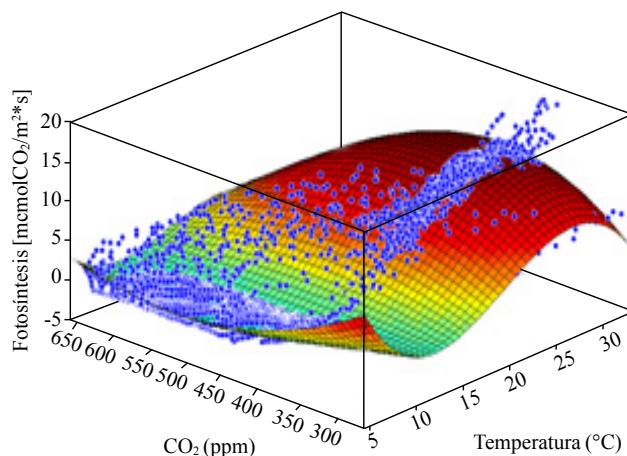
En la Figura 5 se observa, que la tasa de fotosíntesis más alta se obtiene cuando los rangos de temperatura se encuentran entre 25 °C a 30 °C. El máximo de la curva de ajuste para temperatura está situado en 27 °C.

Por su parte, para los datos de entrada a la red neuronal, niveles de 380 ppm en la concentración del CO<sub>2</sub> generan las mayores tasas de fotosíntesis registradas. No obstante, al

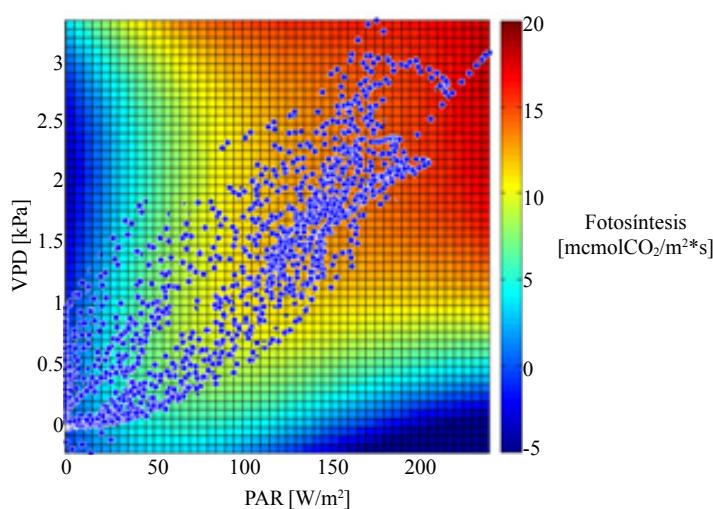
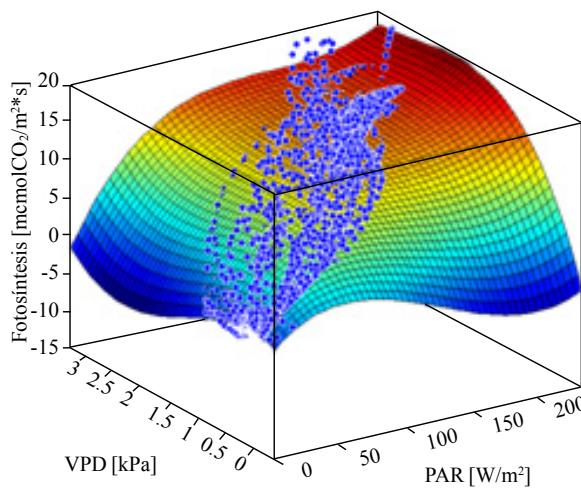
observar la superficie, se puede notar que la concentración del gas dentro del invernadero de estudio no es lo suficientemente alto para alcanzar el máximo de la función (máxima fotosíntesis), que requiere cerca de 450 ppm.

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

De la Figura 6 es clara la importancia de la radiación fotosintéticamente activa en el incremento de la tasa de fotosíntesis, puesto que a medida que la primera 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 W m<sup>-2</sup>. Sin embargo, el máximo de la función se encuentra más allá de 250 W m<sup>-2</sup>.



**Figura 5. Fotosíntesis en función de las variables temperatura y concentración de CO<sub>2</sub>. Izquierda, superficie de la función polinomial de orden 3-2, con ajuste del 91.95% para los datos.**



**Figura 6. 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.**

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<sub>2</sub> al interior de las hojas.

## Conclusiones

Las redes neuronales artificiales describen con un grado de ajuste muy alto, R<sup>2</sup>=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 CO<sub>2</sub>. 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 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. 120 p.
- Evans, J. R. and Loreto, F. 2000. Acquisition and diffusion of CO<sub>2</sub> 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. 17<sup>th</sup> 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.
- 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.
- 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 CO<sub>2</sub> control. *Intern. J. Agric. Res.* 1-10.
- Savitzky, A. and Golay, M. J. E. 1964. Smoothing and differentiation of data by simplified least squares procedures. *Analytical 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. 42 p.
- Wilkinson, R. E. 2000. Plant-environment interactions, 2<sup>nd</sup> edition. Marcel Dekker, Inc. The University of Georgia, Griffin, Georgia. United States of America. 466 p.