

TÉCNICAS DE INTELIGENCIA ARTIFICIAL EN MODELADO Y CONTROL DEL AMBIENTE DE INVERNADEROS: ESTADO DEL ARTE, PARTE 2

ARTIFICIAL INTELLIGENCE TECHNIQUES IN MODELLING AND ENVIRONMENTAL CONTROL IN GREENHOUSES: STATE OF THE ART, PART 2

Elmer César Trejo-Zúñiga*; Irineo Lorenzo López-Cruz

Posgrado en Ingeniería Agrícola y Uso Integral del Agua, Universidad Autónoma Chapingo. Carretera México-Texcoco, km 38.5, Chapingo, Estado de México, C. P. 56230, MÉXICO. Correo-e: teze71@hotmail.com (*Autor para correspondencia).

RESUMEN

Los Algoritmos Evolutivos, Algoritmos Bio-inspirados y Algoritmos Híbridos, considerados como técnicas de Inteligencia Artificial, han cobrado gran importancia debido a su capacidad para dar solución a problemas complejos y no-lineales que los métodos convencionales no pueden resolver. En la última década se ha motivado la aplicación de estas técnicas para el desarrollo de algoritmos inteligentes que permitan identificar, pronosticar, optimizar y controlar el clima para cultivos en ambientes protegidos (invernaderos) y generar condiciones climáticas cercanas a las óptimas de los biosistemas para el crecimiento y desarrollo de los cultivos y obtener así un mayor rendimiento y calidad de los productos. El presente trabajo muestra una revisión de las técnicas de Inteligencia Artificial aplicadas en ingeniería agrícola, principalmente al modelado y control del ambiente de invernaderos, especialmente aquellos algoritmos inspirados en el comportamiento colectivo de sistemas biológicos, la evolución y la genética natural.

Palabras clave adicionales: Algoritmos evolutivos, Algoritmos bio-inspirados, Algoritmos híbridos, Invernaderos, modelado, control ambiental.

ABSTRACT

Evolutionary Algorithms, Bio-inspired Algorithms and Hybrid Algorithms, considered as Artificial Intelligence techniques have gained great importance due to their capacity to solve complex and nonlinear problems that conventional methods cannot solve. In the last decade the application of these techniques has been applied to the development of intelligent algorithms to identify, predict, optimize and control the weather for crops in protected environments (greenhouses) and to generate near optimal climatic conditions for biosystems for growth and crop development, and to obtain higher yields and product quality. The current paper shows a review of Artificial Intelligence Techniques applied in agricultural engineering, mainly to modeling and control of greenhouse environment, especially those algorithms inspired by the collective behavior of biological systems, evolution and natural genetics.

Additional key words: Evolutionary algorithms, Bio-inspired algorithms, Hybrid algorithms, Greenhouses, modeling, environmental control.

INTRODUCCIÓN

El surgimiento de algoritmos inspirados en la evolución genética (Algoritmos Evolutivos) y aquellos inspirados en el comportamiento natural de algunas especies animales (Bio-inspirados), ha generado un avance significativo en el modelado y control del clima de invernaderos debido a que permiten robustez, flexibilidad y soluciones a bajo costo de problemas complejos y altamente no-lineales con un margen pequeño de tolerancia a la imprecisión e incertidumbre (Huang *et al.*, 2010). Dentro

de estas estrategias, conocidas en la literatura como técnicas de Inteligencia Artificial (IA) (Chen *et al.*, 2008) destacan los Algoritmos Evolutivos (AE), Algoritmos Bio-inspirados (ABI) y Algoritmos Híbridos. Los Algoritmos Genéticos (GAs, Genetic Algorithms) son una de las técnicas de resolución de problemas más conocida dentro de lo que se ha definido como “Computación Evolutiva”, término que también agrupa a las Estrategias Evolutivas (ES, Evolution Strategies), la Programación Evolutiva (EP, Evolutionary Programming), Evolución Diferencial (DE, Differential Evolution) y Programación Genética (GP, Genetic

Programming). La Computación Bio-inspirada se basa en el uso de analogías con sistemas naturales o sociales para la resolución de problemas. Los ABI simulan el comportamiento de sistemas naturales para el diseño de métodos heurísticos y estocásticos de búsqueda, aprendizaje y comportamiento. Este enfoque abarca la Optimización por Colonia de Hormigas (ACO, Ant Colony Optimization), Optimización por Enjambre de Abejas (BCO, Bee Colony Optimization) y, Optimización por Enjambre de Partículas (PSO, Particle Swarm Optimization). Finalmente, los sistemas híbridos fusionan las ventajas inherentes de cada una de las técnicas involucradas en el proceso de diseño. Como ejemplo podemos citar los sistemas Neuro-Difusos que son la combinación de ANNs y FL. El presente trabajo presenta una revisión de las técnicas de Inteligencia Artificial aplicadas en ingeniería agrícola, principalmente al modelado y control del ambiente de invernaderos, especialmente los AE, ABI e híbridos.

Algoritmos evolutivos

Un *Algoritmo Evolutivo* es un proceso estocástico e iterativo que opera sobre un conjunto de individuos (población). Cada individuo representa una solución potencial para el problema en cuestión. Nuevas soluciones son generadas mediante tres operadores llamados: mutación, cruzamiento y selección. En cada ciclo o iteración (generación) se seleccionan las soluciones que más se aproximan al objetivo buscado, eliminando soluciones pobres (Beyer, 2001).

Algoritmos genéticos. Los GAs determinan un valor óptimo conjuntamente con un procedimiento de búsqueda multipunto, iniciado en una población generada de manera aleatoria (Beasley *et al.*, 1993) basado en selección, cruzamiento y mutación genética (Goldberg, 1989; Holland, 1992; Michalewicz, 1996). Imitando a la evolución natural el GA genera en cada iteración mejores soluciones al problema hasta converger en una solución óptima o sub-óptima. La representación de las soluciones en la población es binaria en los GA clásicos (Holland, 1992, Goldberg, 1989) o mediante estructuras más complejas como vectores de números reales (Michalewicz, 1996).

Evolución diferencial. La DE mantiene una población de soluciones candidatas mediante vectores reales, el operador de mutación es una operación vectorial que introduce la diferencia de vectores seleccionados en forma aleatoria, el cruzamiento es una operación binomial y la selección se da con base en la competencia entre una solución nueva y una previa (padre e hijo) (López-Cruz *et al.*, 2003a; López-Cruz, 2002, Storn y Price, 1997; Price *et al.*, 2005; Chakraborty, 2008). La población es inicializada aleatoriamente, considerando los valores mínimos y máximos de cada variable:

$$x_{p,m}^1 = x_m^{min} + rand(0,1) * (x_m^{max} - x_m^{min}) \quad (1)$$

para $p = 1 \dots NP$, $m = 1 \dots n$, y $rand(0,1)$ (número aleatorio uniformemente distribuido). En la mutación se construyen NP vectores aleatorios, los cuales son creados a partir de tres indivi-

duos elegidos al azar, llamados vectores objetivo, x_a, x_b, x_c . Los vectores aleatorios (n_p^g) son obtenidos de la siguiente manera:

$$n_p^g = x_c + F(x_a - x_b) \quad (2)$$

Con p, a, b y c distintos entre sí, y $p = 1 \dots NP$. F es un parámetro que controla la tasa de mutación, y se encuentra en el rango $[0,2]$. Una vez obtenidos los NP vectores aleatorios, la recombinación se efectúa de manera aleatoria, comparándolos con los vectores originales (x_p^g), obteniendo los vectores de prueba (t_m^g) de la siguiente manera:

$$t_{p,m}^g = \begin{cases} n_{p,m}^g & \text{si } rand(0,1) < CR \\ x_{p,m}^g & \text{en otro caso} \end{cases} \quad (3)$$

para $p = 1 \dots NP$, $m = 1 \dots n$. CR es un parámetro de probabilidad de cruzamiento que controla la tasa de recombinación. Finalmente, la selección se realiza simplemente comparando los vectores de prueba con los originales, de manera que el vector de la generación siguiente será aquel que tenga el mejor valor de función de desempeño (Storn y Price, 1997; Chakraborty, 2008; Price *et al.*, 2005):

$$x_p^{g+1} = \begin{cases} t_p^g & \text{si } fit(t_p^g) > fit(x_p^g) \\ x_p^g & \text{en otro caso} \end{cases} \quad (4)$$

Estrategias evolutivas. Las versiones canónicas de las ES se denotan por: $(\mu/\rho, \lambda) - ES$ y $(\mu/\rho + \lambda) - ES$ respectivamente. Aquí μ denota el número de padres, $\rho \leq \mu$ el número de mezclas (es decir, el número de padres que participan en la procreación de un hijo o nueva solución) y, λ es el número de descendientes. Los padres son seleccionados determinísticamente del (multi) conjunto de cualquiera de los descendientes, conocidos como *selección coma* (se debe mantener $\mu < \lambda$), o de ambos padres e hijos, conocida como *selección más* (Beyer, 2001). La selección se basa en el rango de aptitud de los individuos $F(y)$ que toma los mejores individuos (también conocida como la selección de truncamiento). En general, un *ES individual* $\alpha := (y, s, F(y))$ comprende el vector de parámetros objeto ($y \in \gamma$) a ser optimizado, un conjunto de los parámetros de estrategia (s), especialmente necesario en los ES auto-adaptables, y la aptitud individual observada $F(y)$ siendo equivalente a la función objetivo $f(y)$, es decir, $F(y) \equiv f(y)$ en el caso más simple (Beyer, 2001).

Programación genética. La GP utiliza programas de computación para realizar una tarea definida por el usuario. Es una especialización de los algoritmos genéticos en la que cada individuo de la población es un programa computacional (Koza, 2010). Es por tanto una técnica de aprendizaje automático utilizada para optimizar una población de programas de acuerdo a una función de ajuste que evalúa la capacidad de cada programa para llevar a cabo la tarea en cuestión (Willis *et al.*, 1997).

Programación evolutiva. La EP fue inventada por Lawrence J. Fogel (Fogel, 1962, 1963; Fogel, 2006). El enfoque inicial consideró a la predicción como una condición previa de

comportamiento inteligente. Una población de máquinas de estados finitos (FSM), que representa organismos individuales de una población de soluciones del problema, se expone al medio ambiente, es decir, la secuencia de imágenes que se ha observado hasta el momento. Como cada imagen de entrada es presentado a la máquina, la imagen de salida correspondiente se compara con la siguiente imagen de entrada. El valor de esta predicción se mide con respecto a la función de coste (por ejemplo, todo-nada, error cuadrático). Después de que la última predicción se realiza, una función de coste para la secuencia de imágenes (por ejemplo, la ganancia media por imagen) indica la adaptabilidad de la máquina o programa. Las máquinas de descendencia son creadas al azar por mutación de los padres y se califican de manera similar. Esas máquinas que proporcionan una mayor adaptabilidad se mantienen para convertirse en padres de la generación siguiente, y el proceso se repite. Cuando las nuevas imágenes son predichas, la mejor máquina disponible sirve como base para hacer una predicción y la observación nueva se agrega a la base de datos disponible. Fogel describe este proceso como “programación evolutiva”. Cabe señalar que el EP por lo general *no utiliza ningún tipo de cruza* como operador genético (Fogel y Fogel, 1986), sino sólo mutación.

Aplicaciones al modelado y control del clima de invernaderos

En el Cuadro 1 se pueden apreciar algunas aplicaciones de AE en el modelado y control del clima de invernaderos.

Algoritmos bio-inspirados

Los ABI imitan el comportamiento de sistemas naturales para el diseño de métodos heurísticos y estocásticos de búsqueda, aprendizaje y comportamiento. Esta técnica, conocida en la literatura como Inteligencia de Enjambre (SI, Swarm Intelli-

gence) es la disciplina que se ocupa de los sistemas naturales y artificiales compuestos de muchos individuos que se coordinan usando control descentralizado y auto-organización. En particular, la disciplina se centra en los comportamientos colectivos que resultan de las interacciones locales de los individuos entre sí y con su entorno (Kennedy y Eberhart, 1995; Kennedy *et al.*, 2001; Chen *et al.*, 2008).

Optimización por colonia de hormigas. La ACO se introdujo como un novedoso método bio-inspirado para la solución de problemas de optimización combinatoria (Dorigo *et al.*, 1996; Dorigo y Stützle, 2004). Este algoritmo está inspirado en el comportamiento real de las hormigas cuando realizan una exploración aleatoria del área cercana a su nido en busca de alimento. Una vez encontrada la fuente de alimento, la hormiga deposita feromona sobre el suelo, esta feromona capacita a las otras hormigas a encontrar la ruta más óptima entre su nido y la fuente de alimento (Jackson y Ratnieks, 2006). En general, para seleccionar la ruta de acceso siguiente, la probabilidad de transición de estado se define de la siguiente manera:

$$P_{ij} = \frac{(\tau_{ij})^{\gamma_1} (1/L_{ij})^{\gamma_2}}{\sum_{j=1}^{NA} \sum_{j \neq i} (\tau_{ij})^{\gamma_1} (1/L_{ij})^{\gamma_2}} \quad (5)$$

donde τ_{ij} y L_{ij} son la intensidad de feromona y la longitud de la trayectoria entre los nodos j , i . γ_1 y γ_2 son los parámetros de control para determinar los pesos de intensidad del rastro de feromona y la longitud de la trayectoria, respectivamente. NA es el número de hormigas. Después de seleccionar la ruta de acceso siguiente, la intensidad del rastro de feromona se actualiza a:

$$\tau_{ij}(k+1) = \rho \tau_{ij}(k) + \Delta \tau_{ij} \quad (6)$$

CUADRO 1. Aplicaciones de Algoritmos Evolutivos al modelado y control del clima de invernaderos.

Algoritmo	Aplicación	Referencia
GA's, EP y ES comparados con LSQ (Mínimos Cuadrados) y SQP (Programación Cuadrática Secuencial).	Calibración de parámetros de un modelo climático que describe el comportamiento de la Temperatura y Humedad Relativa.	Guzmán-Cruz <i>et al.</i> (2009).
Algoritmo evolutivo multi-objetivo (x-MOGA) basado en un GA.	Calibración de parámetros desconocidos del modelo a partir de datos experimentales (Temperatura y Humedad Relativa) en cultivo de rosas hidropónico.	Herrero <i>et al.</i> (2007).
GA Multi-objetivo.	Identificación de RBFNN en modelos acoplados para la humedad y temperatura.	Ferreira <i>et al.</i> (2005).
GA clásico.	Estimar costos de insumos.	Krink <i>et al.</i> (2001).
GA.	Reducción en el consumo de energía y agua para un sistema de refrigeración.	Blasco <i>et al.</i> (2007).
AE.	Optimizar el tamaño de las poblaciones y generaciones a emplear con diferentes horizontes de control para observar el efecto de variación de las variables involucradas.	Ursem <i>et al.</i> (2002).
ESEA y MSCEA del Toolbox de Matlab.	Predicción de la temperatura, humedad del aire y concentración de CO ₂ .	Pohlheim y Heißner (1996, 1999).

En la ecuación (6), ρ es un coeficiente que representa la evaporación del rastro de feromona entre el tiempo k y $k + 1$. Finalmente, $\Delta\tau_{ij}$ es la cantidad de rastro de feromona añadido a t_{ij} por las hormigas (Dorigo y Stützle, 2004; Niknam, 2008).

Optimización por colonia de abejas. La BCO es un algoritmo de búsqueda basado en población. En él se imita el comportamiento de alimentación de enjambres de abejas. En su versión básica, el algoritmo realiza una especie de búsqueda por vecindad combinada con la búsqueda aleatoria y puede ser utilizado para la optimización combinatoria y optimización funcional (Pham *et al.*, 2006; Sundar y Singh, 2010). El algoritmo BCO contiene tres grupos importantes de abejas: *obreras*, *observadoras* y *exploradoras*. La posición de una fuente de alimentos representa una posible solución al problema de optimización y la cantidad de néctar de una fuente de alimentación corresponde a la calidad (aptitud) de la solución asociada (Karaboga y Basturk, 2007; Karaboga y Akay, 2009; Karaboga y Ozturk, 2011).

Optimización por enjambres de partículas. La PSO es un enfoque estocástico basado en una población para resolver problemas de optimización discreta y continua. En PSO, los agentes de software simples, llamadas partículas, se mueven en el espacio de búsqueda del problema analizado (Eberhart y Shi, 2001). La posición de una partícula representa una solución potencial al problema de optimización en cuestión (Sierakowski y Coelho, 2005). Cada partícula busca una mejor posición en el espacio de búsqueda cambiando su velocidad de acuerdo a normas inspiradas originalmente en los modelos de comportamiento de las parvadas de aves (Kennedy y Eberhart, 1995; Eberhart y Shi, 2001). Durante la ejecución del algoritmo, las velocidades y posiciones de las partículas son actualizadas en cada iteración hasta que se cumple un criterio de paro. Las reglas de actualización son las siguientes:

$$\vec{v}_i^{t+1} = w\vec{v}_i^t + \varphi_1\vec{U}_1^t(\vec{b}_i^t - \vec{x}_i^t) + \varphi_2\vec{U}_2^t(\vec{l}_i^t - \vec{x}_i^t)$$

$$\vec{x}_i^{t+1} = \vec{x}_i^t + \vec{v}_i^{t+1}$$

donde w es llamado *peso inercial*, φ_1 y φ_2 son llamados *coeficientes de aceleración*, \vec{U}_1^t y \vec{U}_2^t son matrices diagonales $n \times n$ en el cual las entradas de la diagonal principal son números aleatorios uniformemente distribuidos en el intervalo $[0,1]$. El vector \vec{l}_i^t conocido como la *mejor vecindad*, es la mejor posición encontrada por una partícula en la vecindad de partículas P_i , es decir $f(\vec{l}_i^t) \leq f(\vec{b}_i^t) \forall p_j \in N_i$. Si los valores de w , φ_1 y φ_2 son seleccionados apropiadamente, se garantiza que la velocidad de las partículas no tiendan a infinito (Kennedy y Eberhart, 1995; Eberhart y Shi, 2001).

Aplicación al modelado y control del clima de invernaderos

Las aplicaciones de los ABI al modelado del ambiente de invernaderos es muy incipiente y por lo tanto esta familia de algoritmos tienen un gran potencial de aplicación futura. Coelho *et al.* (2002, 2005) aplicaron un algoritmo de Optimización por Enjambre de partículas (PSO) para el diseño de un controlador

predictivo basado en un modelo para el clima de invernadero sujeto a restricciones. El algoritmo PSO fue comparado con otros algoritmos de optimización como SQP y GA. Para simular el clima interno y externo del invernadero hicieron uso de modelos ARX y series de tiempo auto-regresivos. El conjunto de datos usados fueron obtenidos experimentalmente a través de sensores ubicados estratégicamente dentro y fuera del invernadero. El mejor desempeño fue obtenido con el algoritmo PSO.

Algoritmos híbridos

Los algoritmos híbridos más comunes son los *Neuro-Difusos* (AND), constituidos principalmente de ANN y FL lo cual permite una relación simbiótica, aprovechándose el conocimiento de un experto y la capacidad de aprendizaje y eficiencia computacional de la red neuronal, logrando un sistema de decisiones más inteligente. Debido a que cada técnica tiene capacidades y limitaciones, su aplicación en el modelado y control del ambiente en invernaderos los hace aptos para esta tarea una vez que han sido fusionados (López-Cruz y Hernández-Larragoiti, 2010; Fitz-Rodríguez y Giacomelli, 2009; Cheng-Jian y Yong-Ji, 2007; Tien y Van Straten, 1998). Un AND popular es el ANFIS (Adaptive Network-based Fuzzy Inference System) el cual es un sistema de inferencia difuso implementado en el marco de redes neuronales adaptivas (Jang, 1993; Jang y Chuen-Tsai, 1995), este algoritmo usa un procedimiento de aprendizaje híbrido combinando los algoritmos gradiente descendente y filtro de Kalman, realiza un mapeo entrada-salida basado en conocimiento humano (a base de reglas difusas *si-entonces*) y pares de datos entrada-salida estipulados (Jang y Chuen-Tsai, 1995). Otro sistema Neuro-Difuso integrado propuesto por Tien (1997) es el llamado NUFZY, este es un sistema difuso simplificado representado por el modelo Takagi-Sugeno de orden cero. Es un tipo especial de ANN caracterizado por conexiones parciales en su primera y segunda capas. A través de las conexiones de la red el sistema NUFZY realiza un razonamiento difuso particular (Tien y Van Straten, 1998). Los ANDs ofrecen la ventaja de modelar sistema no-lineales y adionar robustez en situaciones de datos incompletos e imprecisos, donde existe incertidumbre (Fitz-Rodríguez y Giacomelli, 2009).

Aplicación al modelado y control del clima de invernaderos

En el Cuadro 2 se puede apreciar algunas aplicaciones de los algoritmos híbridos en el modelado y control del clima de invernaderos.

CONCLUSIONES

Los Algoritmos Bio-inspirados sólo han empezado a ser estudiados y aplicados en problemas de Ingeniería Agrícola y en el sistema invernadero. En el caso del Cómputo Evolutivo, algunos algoritmos como los GA's y los DE son muy comunes en aplicaciones de modelado pero su aplicación al control es muy incipiente y escasa. Los Algoritmos Híbridos han sido poco usados para el control del clima. Sin embargo, la aplicación al modelado está incrementando considerablemente. Por lo tanto, se considera a los algoritmos Bio-inspirados, evolutivos e híbridos un área bastante prometedora para optimizar y controlar el ambiente de los invernaderos.

CUADRO 2. Aplicaciones de los algoritmos híbridos al modelado y control del clima de invernaderos.

Algoritmo	Aplicación	Referencia
NUFZY.	Identificación del clima, el crecimiento de lechuga y crecimiento del jitomate.	Tien y Van Straten (1998). (Tien y Van Straten, 1995, 1996).
ANFIS.	Predicción del rendimiento en la producción de jitomate.	Qaddoum e Illiescu (2011).
ANFIS, Adaptive Neuro-Fuzzy training of Sugeno-type Inference System.	Predecir la temperatura y humedad relativa del aire con ventilación natural.	López-Cruz y Hernández-Larragoiti (2010).
Modelo Neuro-Difuso.	Modelar la evapotranspiración instantánea de una planta de jitomate.	Ramos-Fernández <i>et al.</i> (2010).
ANN y FL.	Predicción del rendimiento y caracterización del modo de crecimiento del cultivo de jitomate.	Fitz-Rodríguez y Giacomelli (2009).
ANN (BP) y GA.	Predecir temperatura y humedad.	He <i>et al.</i> (2007).
ANN y FL.	Modelado de producción de materia seca en el cultivo del jitomate.	Kazheunikau <i>et al.</i> (2004).
DE, ACW (Control Ajustable de variación de Peso).	Control óptimo de la concentración de nitratos en lechuga.	López-Cruz <i>et al.</i> (2003b).
FL y GA.	Control de temperatura.	Goggos y King (2000).

LITERATURA CITADA

- Beasley D.; Bull D. R.; Martin R. R. 1993. An Overview of Genetic Algorithms: Part 1, Fundamentals. *University Computing*, 15(2): 58-69.
- Beyer H. G. 2001. *The Theory of Evolution Strategies*. Natural Computing Series. Springer, Berlin 2001, 380 p.
- Blasco X.; Martínez M.; Herrero J. M.; Ramos C.; Sanchis J. 2007. Model-based predictive control of greenhouse climate for reducing energy and water consumption. *Computers and Electronics in Agriculture* 55: 49-70. DOI:10.1016/j.compag.2006.12.001
- Chakraborty U. K. 2008. *Advances in Differential Evolution*. Studies in Computational Intelligence 143, Springer-Verlag Berlin Heidelberg, 338 p.
- Chen S. H.; Jakeman A. J.; Norton J. P. 2008. Artificial Intelligence techniques: An introduction to their use for modelling environmental systems. *Mathematics and Computers in Simulation* 78: 379-400. DOI: 10.1016/j.matcom.2008.01.028
- Cheng-Jian L.; Yong-Ji X. 2007. Design of Neuro-Fuzzy Systems Using a Hybrid Evolutionary Learning Algorithm. *Journal of Information Science and Engineering* 23: 463-477.
- Coelho J. P.; de Moura-Oliveira P.; Cunha J. B. 2002. Greenhouse air temperature control using the particle swarm optimisation algorithm. *IFAC*.
- Coelho J. P.; de Moura-Oliveira P.; Cunha J. B. 2005. Greenhouse air temperature predictive control using the particle swarm optimisation algorithm. *Computers and Electronics in Agriculture* 49: 330-344. DOI: 10.1016/j.compag.2005.08.003
- Dorigo M.; Stützle T. 2004. *Ant Colony Optimization*. MIT Press, Cambridge, MA.
- Dorigo M.; Maniezzo V.; Colnari A. 1996. Ant System: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics - Part B*, 26(1): 29-41.
- Eberhart R. C.; Shi Y. 2001. *Particle Swarm Optimization: Developments, Applications and Resources*. IEEE. DOI: 10.1109/CEC.2001.934374
- Ferreira P. M.; Ruano A. E.; Fonseca C. M. 2005. Evolutionary Multiobjective design of Radial Basis Function Networks for Greenhouse environmental control. *Proc. of the 16th IFAC World*. DOI: 10.3182/20050703-6-CZ-1902.00871
- Fitz-Rodríguez E.; Giacomelli G. A. 2009. Yield Prediction and Growth Mode Characterization of Greenhouse with Neural Networks and Fuzzy Logic. *Transactions of the ASABE*, Vol. 52(6): 2115-2128.
- Fogel D. 2006. *Evolutionary Computation. Toward a new philosophy of machine intelligence*. IEEE Press.
- Fogel L. J. 1962. *Autonomous automata*. *Industrial Research*, Vol. 4: pp. 14-19.
- Fogel L. J. 1963. *Biotechnology: Concepts and Applications*, Prentice-Hall, Englewood, NJ.
- Fogel L. J.; Fogel D. B. 1986. *Artificial intelligence through evolutionary programming*. Final Report, Contract PO-9-X56-1102C-1, U.S. Army Research Institute. DOI: 10.4249/scholarpedia.1818
- Goggos V.; King R.E. 2000. Qualitative-evolutionary design of greenhouse environment control agents. *Computers and Electronics in Agriculture* 26: 271-282. DOI: 10.1016/S0168-1699(00)00080-6
- Goldberg D. E. 1989. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, Reading, MA 412 p.
- Guzmán-Cruz R.; Castañeda-Miranda R.; García-Escalante J. J.; López-Cruz I. L.; Lara-Herrera A.; De la Rosa J. I. 2009. Calibration of a greenhouse climate model using evolutionary algorithms. *Biosystem Engineering* 104: 135-142. DOI: 10.1016/j.biosystemseng.2009.06.006
- He F.; Ma C.; Zhang J.; Chen Y. 2007. Greenhouse Air Temperature and Humidity Prediction Based on Improved BP Neural Network and Genetic Algorithm. D. Liu *et al.* (Eds.): *ISNN 2007*, Part III, LNCS 4493, pp. 973-980, Springer-Verlag Berlin Heidelberg 2007. DOI: 10.1007/978-3-540-72395-0_119
- Herrero J. M.; Blasco X.; Martínez M.; Ramos C.; Sanchis J. 2007. Non-linear robust identification of a greenhouse

- model using multi-objective evolutionary algorithms. *Biosystems Engineering* 98: 335-346. DOI: 10.1016/j.biosystemseng.2007.06.004
- Holland J. H. 1992. Genetic algorithms. *Sci. Am.* July: 44-50.
- Huang Y.; Lan Y.; Thomson S. J.; Fang A.; Hoffmann W. C.; Lacey R. E. 2010. Development of soft computing and applications in agricultural and biological engineering. *Computers and electronics in Agriculture*, 71: 107-127. DOI: 10.1016/j.compag.2010.01.001
- Jackson D. E.; Ratnieks F. L. W. 2006. Communication in ants. *Current Biology*, 16: 570-574.
- Jang J. S. R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23: pp. 665-685.
- Jang, J. S. R.; Chuen-Tsai S. 1995. Neuro-Fuzzy Modeling and Control. *Proceeding of the IEEE*. DOI: 10.1109/5.364486
- Karaboga D.; Akay B. 2009. A comparative study of Artificial Bee Colony algorithm. *Applied Mathematics and Computation* 214: 108-132. DOI: 10.1016/j.amc.2009.03.090
- Karaboga D.; Basturk B. 2007. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *J Glob Optim* (2007) 39:459-471.
- Karaboga D.; Ozturk C. 2011. A novel clustering approach: Artificial Bee Colony (ABC) algorithm, *Applied Soft Computing* 11: 652-657. DOI: 10.1016/j.asoc.2009.12.025
- Kazheunikau M.; Ferreira P. M.; Ruano A. E. 2004. Neuro-fuzzy modeling of plant growth in a Hydroponic Greenhouse. *Proceedings of CONTROLO'2004, the 6th Portuguese Conference on Automatic Control*, June 2004, Faro, Portugal.
- Kennedy J.; Eberhart R. C.; Shi Y. 2001. *Swarm Intelligence*. San Francisco, CA: Morgan Kaufmann Publishers.
- Kennedy J.; R. C. Eberhart R. C. 1995. Particle Swarm Optimization. *Proc. IEEE Int. Conf. on N.N.*, pp: 1942-1948.
- Koza J. R. 2010. Human-competitive results produced by genetic programming. *Genet Program Evolvable Mach*, 11: 251-284. DOI 10.1007/s10710-010-9112-3
- Krink T.; Ursem R. K.; Filipic B. 2001. Evolutionary Algorithms in Control Optimization: The Greenhouse Problem. In *Proceedings of the Genetic and Evolutionary Computation Conference*, pp. 440-447.
- López-Cruz I. L. 2002. Efficient evolutionary algorithms for optimal control. PhD Thesis. Wageningen University. The Netherlands.
- López-Cruz I. L.; Hernández-Larragoiti L. 2010. Neuro-fuzzy models for Air Temperature and Humidity of arched and venlo type Greenhouses in central México. *Agrociencia* 44: 791-805.
- López-Cruz I. L.; Van Willigenburg L. G.; Van Straten G. 2003a. Efficient Differential Evolution algorithms for multimodal optimal control problems. *Applied Soft Computing* 3: 97-122. DOI: 10.1016/S1568-4946(03)00007-3
- López-Cruz I. L.; Van Willigenburg L. G.; Van Straten G. 2003b. Optimal control of nitrate in lettuce by a hybrid approach: differential evolution and adjustable control weight gradient algorithms. *Computers and Electronics in Agriculture* 40: 179-197. DOI: 10.1016/S0168-1699(03)00019-X
- Michalewicz Z. 1996. *Genetic algorithms + Data structures = evolution programs*. Springer-Verlag. Berlin, 387 p.
- Niknam T. 2008. A new approach based on ant colony optimization for daily Volt/Var control in distribution networks considering distributed generators. *Energy Conversion and Management* 49: 3417-3424. DOI: 10.1016/j.enconman.2008.08.015
- Pham D. T.; Ghanbarzadeh A.; Koc E.; Otri S.; Rahim S.; Zaidi M. 2006. The Bees Algorithm -A Novel Tool for Complex Optimisation Problems, *Proceedings of IPROMS 2006 Conference*, pp: 454-461.
- Pohlheim H.; Heißner A. 1996. Optimal control of greenhouse climate using Genetic Algorithms. *MENDEL'96 - 2nd International Conference on Genetic Algorithms*. Brno, Czech Republik, pp. 112-119.
- Pohlheim H.; Heißner A. 1999. Optimal Control of Greenhouse Climate using Real-World Weather Data and Evolutionary Algorithms. In Banzhaf, W. (ed.): *GECCO'99 - Proceedings of the Genetic and Evolutionary Computation Conference*, San Francisco, CA: Morgan Kaufmann, pp. 1672-1677.
- Price K. V.; Storn R. M.; Lampinen J. A. 2005. *Differential Evolution. A practical Approach to Global Optimization*. Natural Computing Series, Springer-Verlag Berlin Heidelberg, 538 p.
- Qaddoum K.; Hines E.; Illiescu D. 2011. Adaptive Neuro-Fuzzy Modeling For Crop Yield Prediction. *AIKED'11 Proceedings of the 10th WSEAS international conference on Artificial intelligence, knowledge engineering and data bases*, 198-204.
- Ramos-Fernández J. C.; López-Morales V.; Lafont F.; Enea G.; Duplaix J. 2010. A Neurofuzzy Structure Modelling Evapotranspiration in a Greenhouse Crop. *Ingeniería Investigación y Tecnología*. Vol. XI. Núm.2: 127-139.
- Sierakowski C. A.; Dos Santos Coelho L. 2005. Study of two Swarm Intelligence techniques for path planning of mobile robots. *IFAC*.
- Storn R.; Price K. 1997. Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. *Journal of Global Optimization* 11: 341-359.
- Sundar S.; Singh A. 2010. A swarm intelligence approach to the quadratic minimum spanning tree problem. *Information Sciences* 180: 3182-3191. DOI: 10.1016/j.ins.2010.05.001
- Tien B. T. 1997. Neural-Fuzzy approach for system identification. PhD Thesis. Wageningen University the Netherlands. 155 p.
- Tien B. T.; Van Straten G. 1996. Recursive Prediction Error Algorithm for the NUFZY System to Identify Nonlinear Systems. In *Proceedings of the 9th International Conference on IEA/AIE-96*, 569-574. Fukuoka, Japan, June 4-7.
- Tien B. T. Van Straten G. 1995. Neural-Fuzzy Systems for Non-Linear System Identification-Orthogonal Least Squares Training Algorithms and Fuzzy Rule Reduction. In *Preprint of the 2nd IFAC/IFIP/EurAgEng Workshop on AI in Agriculture*, 249-254. Wageningen, The Netherlands, May 29-31.
- Tien B. T.; Van Straten G. 1998. A Neuro-Fuzzy Approach to Identify Lettuce Growth and Greenhouse Climate. *Artificial Intelligence Review* 12: 71-93. DOI: 10.1023/A:1006592422202
- Ursem R. K.; Filipic B.; Krink T. 2002. Exploring the Performance of an Evolutionary Algorithm for Greenhouse Control. *Journal of Computing and Information Technology* 10, 3: 195-201.
- Willis M. J.; Hiden H. G.; Marenbach P.; McKay B.; Montague G. A. 1997. *Genetic Programming: An Introduction and Survey of Applications*. Symbolic Optimisation Research Group (SORG), Dept. of Chemical and Process Engineering University of Newcastle upon Tyne NE1 7RU, UK.