

## COMPARACIÓN DE CONFIGURACIONES DE REDES NEURONALES EN UN CULTIVO DE STEVIA UTILIZANDO COMO VARIABLE DE SALIDA LA TEMPERATURA

Romero-Velazco Fatima-Adriana<sup>1</sup>, García-Díaz Noel<sup>1</sup>, Castillo-Topete Víctor-Hugo<sup>2</sup>, Ruiz-Tadeo Ana-Claudia<sup>1</sup>, Verduzco-Ramírez Jesús-Alberto<sup>1</sup>

<sup>1</sup> Tecnológico Nacional de México, Campus Colima. División De Estudios de Posgrado e Investigación  
Avenida Tecnológico 1 A.P. 10 y 128, Villa de Álvarez, 28976 Villa de Álvarez, Col.  
Tel., (312) 312 6393, (312) 312 9920

<sup>2</sup> Universidad de Colima, Facultad de Ingeniería Mecánica y Eléctrica.  
Carretera Colima - Coquimatlán km 9, Valle de las Huertas, 28400 Coquimatlán, Col.  
Tel., (312) 316 1165

g2246016@colima.tecnm.mx, ngarcia@colima.tecnm.mx, victorc@ucol.mx, aruiz@colima.tecnm.mx, averduzco@colima.tecnm.mx

### RESUMEN

La stevia es una planta originaria de Sudamérica que se ha convertido en una alternativa al azúcar debido a su dulzor natural y bajo contenido de calorías. Predecir la Temperatura de un cultivo Stevia contribuirá en el desarrollo óptimo de la planta, tanto en el crecimiento como en nutrientes. Se implementó un modelo con las configuraciones de 3 y 6 variables de redes neuronales del tipo perceptrón multicapa para el análisis de variables con las que se trabajó y determinó la temperatura adecuada del cultivo. Las variables son pH, Temperatura, Humedad, Conductividad, Nitrógeno, Fósforo y Potasio. Se compararon las configuraciones del modelo, en el que se demostró que la configuración 1 con 3 variables fue mucho mejor que el de 6 variables. Estos resultados son útiles para los agricultores al brindarles una herramienta adicional para tomar decisiones informadas sobre el manejo del cultivo, optimización de los recursos y su producción.

**Palabras Clave:** Redes Neuronales, Cultivo, Inteligencia Artificial, Stevia.

### ABSTRACT

Stevia is a plant native to South America that has become an alternative to sugar due to its natural sweetness and low calorie content. Predicting the temperature of a Stevia crop will contribute to the optimal development of the plant, both in growth and nutrients. A model was implemented with the configurations of 3 and 6 variables of neural networks of the multilayer perceptron type for the analysis of variables with which we worked and determined the appropriate temperature of the crop. The variables are pH, Temperature, Humidity, Conductivity, Nitrogen, Phosphorus and Potassium. The configurations of the model were compared, in which it was shown that configuration 1 with 3 variables was much better than that of 6 variables. These results are useful for farmers by providing them with an additional tool to make informed decisions about crop management, resource optimization and production.

**Keywords:** Neural Networks, Cultivation, Artificial Intelligence, Stevia.

## 1. INTRODUCCIÓN

### 1.1 Antecedentes

La agricultura es una actividad económica y social muy antigua que se remonta a la prehistoria y ha sido fundamental para el desarrollo de las civilizaciones humanas [1].

La Temperatura es uno de los factores climáticos más importantes que afectan el crecimiento y la producción de los cultivos agrícolas. Los cultivos tienen un rango de Temperatura óptimo que favorecen el crecimiento y desarrollo de la producción. Cuando la Temperatura se encuentra fuera de este rango, se pueden producir daños en la planta lo que genera pérdidas en la calidad del producto y en su producción. Además, la Temperatura también influye en la distribución de los cultivos en diferentes regiones y puede limitar su crecimiento en lugares con temperaturas extremas [2].

El objetivo de este trabajo es realizar una comparación entre un modelo de red neuronal con diferentes configuraciones que utilizan diferentes conjuntos de variables y particionamiento, para predecir la Temperatura adecuada en un cultivo de Stevia. El primer modelo emplea tres variables pH, Humedad (H) y Conductividad Eléctrica (CE), mientras que el segundo modelo utiliza seis variables pH, H, CE, Nitrógeno (N), Fósforo (P) y Potasio (K), estas configuraciones son entrenadas y validadas con 100 y 200 épocas, además utilizaron el particionamiento 70-30% y el 80-20%. Esta comparación permitirá evaluar la influencia de la inclusión de un mayor número de variables en la precisión y capacidad predictiva del modelo. El entrenamiento y la validación del modelo utilizará conjuntos de datos que contienen mediciones de las variables mencionadas, así como la Temperatura correspondiente al cultivo de Stevia en diferentes momentos y condiciones.

Los resultados obtenidos tendrán aplicaciones prácticas en el manejo y la optimización de la producción de cultivos de Stevia.

### 1.2 Stevia

La Stevia (Stevia Rebaudiana Bertoni), es una planta perenne, originaria de Paraguay y Brasil, conocida mundialmente por sus propiedades edulcorantes. Debido a la presencia de Esteviósidos y Rebaudiósidos (glicósidos de esteviol), sus hojas son 200 a 300 veces más dulces que el azúcar de caña común (que contiene sacarosa) [3].

En México existen diversas variantes de Stevia, para el presente trabajo se estudiará la Stevia Morita II.

La Stevia Morita II pertenece a la variedad que sostiene un alto porcentaje de rebaudiósido A; que crecen mejor en climas tropicales, tiene un sabor más noble y dulce que otras especies. Contiene alrededor de 10 a 12% Rebaudiósido A y 2.04% de Esteviósido, sin embargo, este tipo de Stevia requiere más trabajo y atención [4].

En [5] se menciona que el cultivo de Stevia Morita II se ha impulsado en México debido a las características y aplicaciones. Además, es relevante destacar el hecho de que es un producto agrícola en continua investigación, como se demuestra en los trabajos [5, 8]. Por lo que no sólo es relevante como elemento de consumo, sino como objeto de estudio.

La stevia ha sido capaz de desempeñar un papel importante en la biodiversidad porque precisa poco terreno y permite a los agricultores diversificar sus cosechas [6].

Actualmente, México cuenta con áreas propicias para cultivar la Stevia, presentando condiciones ecológicas ideales como el clima, suelos, topografía, hidrología y altitud entre otras [7].

Los estados productores que cultivan de manera comercial la Stevia son Quintana Roo, Yucatán, Nayarit, Chiapas, Veracruz y Colima [8]. En Colima, México el principal productor de Stevia es Rancho Tajeli (<https://www.rancho tajeli.com/>) hoy en día, ellos cuentan con alrededor de 2,500 metros cuadrados de cultivo en crecimiento, la empresa se encuentra ubicada en el municipio de Cuauhtémoc en las coordenadas (19°14'38.4"N 103°39'39.2"W). En las **Figuras 1 y 2** se muestra el cultivo de Stevia en Rancho Tajeli en fecha de producción.



Figura 1 Rancho Tajeli



Figura 2 Rancho Tajeli

### 1.3 Cultivo

Las condiciones climatológicas e hidrológicas en el estado de Colima benefician el cultivo de Stevia, tanto en suelo como en invernadero, debido a que predomina un clima cálido subhúmedo, lo que permite condiciones propicias para la producción del sector agrícola, generando una fuente económica considerable [8].

### 1.4 Inteligencia Artificial (IA)

La IA es un conjunto de tecnologías que permiten que las computadoras realicen una variedad de funciones avanzadas, incluida la capacidad de ver, comprender y traducir lenguaje hablado y escrito [9]. Otra de las funciones que hace es el análisis de datos, los cuales pueden ser desde números hasta imágenes.

### 1.5 Redes Neuronales (RN)

Una RN es un método de la IA que enseña a las computadoras a procesar datos de una manera que está inspirada en el cerebro humano. Se trata de un tipo de proceso de *machine learning* llamado aprendizaje profundo, que utiliza los nodos o las neuronas interconectados en una estructura de capas [10].

#### 1.5.1 Perceptrón Multicapa (PM)

Las RN de tipo PM se encuentran entre las arquitecturas de red más poderosas y populares. Están formadas por una capa de entrada, un número arbitrario de capas ocultas, y una capa de salida. Cada una de las neuronas ocultas o de salida reciben una entrada de las neuronas de la capa previa (conexiones hacia atrás), pero no existen conexiones laterales entre las neuronas dentro de cada capa [11].

Las características más importantes del PM son las siguientes [12]:

- Se trata de una estructura altamente no lineal.
- Presenta tolerancia a fallos.
- El sistema es capaz de establecer una relación entre dos conjuntos de datos.
- Existe la posibilidad de realizar una implementación hardware.

En la **Figura 3** se muestra una arquitectura de una RN PM, con  $n$  variables de entrada,  $m$  capas ocultas y una salida.

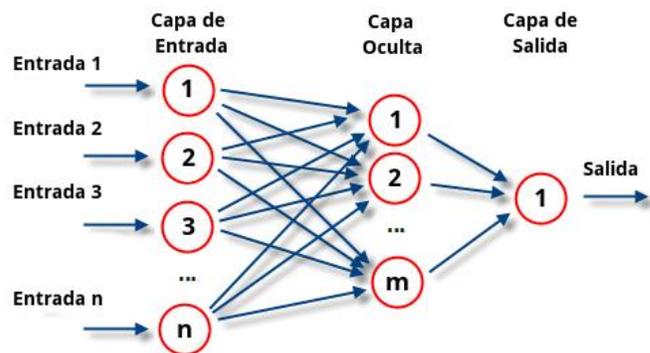


Figura 3 Arquitectura de una RN PM [13]

### 1.6 Trabajos relacionados

Se hizo una revisión de la literatura donde fueron encontrados los siguientes trabajos.

En [14] se muestra que la Temperatura influye sobre la disponibilidad de nutrientes del suelo, la germinación, el crecimiento de los nuevos brotes, la fotosíntesis, la respiración y muchos otros procesos metabólicos en la planta de Stevia, mostrando que la temperatura si tiene un efecto sobre la producción de Esteviósidos de manera directa entre la variación del día o noche. En [15] se presenta un procedimiento para obtener un modelo dinámico lineal de auto regresión con variables exógenas (ARX) para predecir el comportamiento de la temperatura del aire en el interior de un invernadero. En [16] se desarrollaron modelos basados en RN del tipo "backpropagation", para predecir la ocurrencia de heladas, a partir de datos meteorológicos de Temperatura, humedad relativa, nubosidad, dirección y velocidad del viento. En los trabajos relacionados [14-16] se encontraron grandes resultados, sin embargo, fueron detectadas algunas áreas de oportunidad, como se indica a continuación.

En [14] se predice la Temperatura para un cultivo de Stevia, pero no utiliza ninguna técnica de IA, tal como se hará en el presente trabajo. En [15] se predice el comportamiento de la Temperatura en un invernadero utilizando modelos ARX, pero no se utiliza ninguna técnica de IA para poder predecir dicha variable, tal como se hará en este trabajo.

En [16] utilizan la técnica de IA de RN para predecir heladas, pero no lo aplican en un cultivo de Stevia Morita II, tal como se hará en este trabajo.

## 2. DESARROLLO

Para la construcción, entrenamiento del modelo y manipulación de los datos se utilizó las librerías Pandas y Tensorflow de Python.

Para la comparación de los modelos de RN se utilizaron datos de las variables pH, H, CE, N, P y K.

La propuesta de solución se enfoca en utilizar modelos de RN para predecir la Temperatura adecuada para el cultivo de Stevia. Se proponen el modelo con las siguientes configuraciones: configuración 1 con 3 variables (pH, H y CE) y configuración 2 con 6 variables (pH, H, CE, N, P y K). Ambas configuraciones utilizan una arquitectura de RN del tipo PM.

En su trabajo Jeng-Fung & Quang Hung [17] mencionaron que existen diferentes métricas para evaluar el desempeño de los modelos difusos, neuro-difusos y de RN. Para evaluar el desempeño de los modelos propuestos en este trabajo se usó el coeficiente de determinación ( $r^2$ ). De acuerdo con Humphrey [18], se considera aceptable un modelo predictivo cuando  $r^2 \geq 0.5$ .

En este trabajo se realizan comparaciones entre diferentes configuraciones, variando el porcentaje de partición tanto de entrenamiento como de validación, así como el número de épocas de entrenamiento.

### 2.1 Variables

Los valores de las variables (entrada) para las configuraciones de 3 y 6 variables fueron obtenidos de [5] los cuales se capturaron durante los meses de enero y febrero de 2023.

La variable de salida es la Temperatura del cultivo de Stevia. Dicha variable tiene valores óptimos en un rango que va de los 5° a 30° C [19].

### 2.2 Conjunto de Datos

El conjunto de datos fue extraído de [5] quienes utilizaron una red de sensores y consta de 2,009 registros que incluyen las variables de entrada y la variable de salida Temperatura. En la **Tabla 1** se muestra un extracto de dicho dataset.

Tabla 1 Datos del Sensor [4]

pH	H	CE	N	P	K	Temperatura
3	100	399	21	29	300	26
3	100	398	20	28	300	26
3	100	402	21	28	300	26
3	100	397	20	28	300	26
3	100	391	20	27	300	26
3	100	388	20	27	300	26
3.1	100	384	20	27	310	26
3.1 7	100	386	20	27	317	26
3.1 7	100	387	20	27	317	26
3.1 7	100	391	20	27	317	26.4
3.1 7	100	392	20	28	317	26.4

### 2.3 Método Hold-Out

En la **Figura 4**, se puede observar que los datos son divididos (particionados) en dos partes distintas. La primera partición es para el entrenamiento del modelo, mientras que la segunda se utiliza para evaluar o probar el modelo. El porcentaje de división se determina en función del tamaño del conjunto de datos. En general, se utiliza una división del 70-30 %, donde el 70 % del conjunto de datos se utiliza para el entrenamiento y el restante 30 % se utiliza para probar el modelo. Existen otras particiones, tales como 80-20% y 60-40% [20].

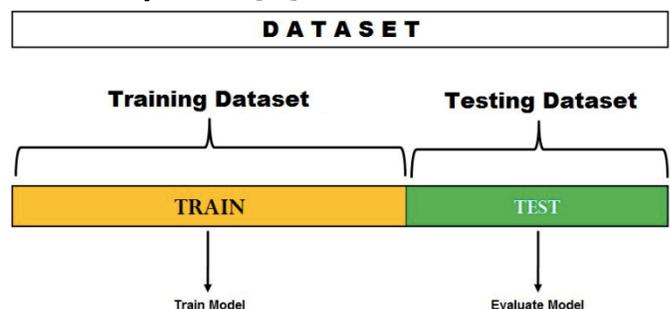


Figura 4. Método de espera (Hold-Out) para la evaluación del modelo [21]

Figura 5. Arquitectura General de la Red Neuronal Perceptron Multicapa

**2.4 Modelo de Red Neuronal Propuesto**

Las configuraciones propuestas con 3 y 6 variables de entrada basado en la **Figura 3** utilizan las siguiente arquitectura de RN:

- Una capa de entrada (con 3 y 6 variables respectivamente)
- Una capa oculta (con variación de 100 a 650 neuronas, con incremento de 50 neuronas)
- Una capa de salida (1 neurona)
- Utilizaron la función de activación “ReLU”.

El Modelo fue sometido a **4** configuraciones diferentes con la finalidad de determinar el mejor rendimiento, como se muestra en la **Tabla 2**.

Tabla 2 Configuraciones del Modelo

<b>Configuración 1:</b>	70-30% con 100 épocas.
<b>Configuración 2:</b>	70- 30% con 200 épocas.
<b>Configuración 3:</b>	80-20% con 100 épocas.
<b>Configuración 4:</b>	80-20% con 200 épocas.

En la siguiente Figura se muestra la Arquitectura General de la Red Neuronal:

La arquitectura de este modelo se describe como un modelo secuencial en Keras. Está compuesto por 14 capas densas (Dense), cada una con un número diferente de neuronas en su capa de salida, que van desde 50 hasta 650. Cada capa densa está completamente conectada a la capa anterior, lo que significa que todas las neuronas en una capa se conectan con todas las neuronas de la capa anterior. El número de parámetros en cada capa varía según el número de neuronas y las conexiones. En total, el modelo tiene 1,825,351 parámetros entrenables, lo que indica la complejidad del modelo y su capacidad para aprender representaciones de datos.

**3. RESULTADOS**

Los resultados obtenidos en el entrenamiento y prueba del modelo propuesto con las configuraciones pueden variar dependiendo de la calidad y cantidad de los datos utilizados, así como de la configuración y diseño de la RN. Es importante realizar un análisis detallado de los resultados para evaluar la eficacia de cada modelo en la precisión de la Temperatura adecuada para el cultivo de Stevia.

En la **Tabla 3** se muestran los resultados obtenidos.

Tabla 3 Comparativa de 3 y 6 Variables Comparativa de modelo 1 y modelo 2

Partición	r <sup>2</sup> Modelo 1	Precisión n Modelo 1	r <sup>2</sup> Modelo 2	Precisión Modelo 2
<b>70-30% con 100 épocas</b>	0.8192	0.777990 7584190 369	0.8086	0.7923039 197921753
<b>70-30% con 200 épocas</b>	0.8610	0.815904 1404724 121	0.8521	0.7558801 770210266
<b>80-20% con 100 épocas</b>	0.8213	0.766712 4271392 822	0.7559	0.7644725 441932678
<b>80-20% con 200 épocas</b>	0.8696	0.750518 6796188 354	0.8541	0.8025999 665260315

En la comparación de las configuraciones, se puede observar que el caso con mejor precisión es el siguiente:

Utilizando 200 épocas en el conjunto de datos para el modelo 1 (3 variables) con una partición de entrenamiento y validación del 70% y 30% respectivamente, se alcanzó una precisión de

```

Model: "sequential"
Layer (type) Output Shape Param #
-----
dense (Dense) (None, 50) 200
dense_1 (Dense) (None, 100) 5100
dense_2 (Dense) (None, 150) 15150
dense_3 (Dense) (None, 200) 30200
dense_4 (Dense) (None, 250) 50250
dense_5 (Dense) (None, 300) 75300
dense_6 (Dense) (None, 350) 105350
dense_7 (Dense) (None, 400) 140400
dense_8 (Dense) (None, 450) 180450
dense_9 (Dense) (None, 500) 225500
dense_10 (Dense) (None, 550) 275550
dense_11 (Dense) (None, 600) 330600
dense_12 (Dense) (None, 650) 390650
dense_13 (Dense) (None, 1) 651
-----
Total params: 1,825,351
Trainable params: 1,825,351
Non-trainable params: 0
    
```

0.8159041404724121. Además, se obtiene un  $r^2$  de 0.8610, lo que indica un buen ajuste del modelo a los datos.

Aunque en otro caso (80-20% con 200 épocas) se logra un valor más alto de  $r^2$ , la precisión fue mucho menor.

#### 4. CONCLUSIÓN

Con base en los resultados obtenidos se concluye:

- Las configuraciones propuestas con 3 y 6 variables son aceptables, debido a que en ambos casos el coeficiente de determinación ( $r^2$ ) supera ampliamente el 0.5.
- De acuerdo con el modelo propuesto con la configuración de 3 variables, la utilización de una RN de tipo PM resultó con mayor precisión para la Temperatura de un cultivo de Stevia.
- El particionamiento de los datos en 70 y 30% mostró mejores resultados que el particionamiento 80 y 20%.
- Se comprobó que el particionamiento 70 y 30% con 200 épocas obtuvo mejores resultados que cualquier otro particionamiento de 100 épocas, en cuanto a la precisión.
- Se deduce que el modelo con la configuración de 3 variables es mucho mejor en varios aspectos que el de 6 variables, desde su precisión hasta optimización y costo.
- Estos resultados son útiles para los agricultores al brindarles una herramienta adicional para tomar decisiones informadas sobre el manejo del cultivo, optimización de los recursos y su producción.
- Los agricultores de Stevia obtendrán una mejor cosecha cuando los niveles de la variable de salida (Temperatura) se encuentren en los rangos óptimos.
- Un nivel aceptable de Temperatura evitará la pérdida de la cosecha.

#### 5. TRABAJO A FUTURO

Se recomienda como trabajo a futuro implementar otro tipo de RN en la cual se varíe la arquitectura de la red, utilizar diferentes particionamientos del dataset y variar el número de épocas. Además, se recomienda usar alguna otra técnica de IA con el fin de comparar los resultados con el presente trabajo.

#### 6. REFERENCIAS

- [1] Diamond, J. (1997). *Guns, Germs, and Steel: The Fates of Human Societies*. W.W. Norton & Company.
- [2] Challinor, A. J., Watson, J., Lobell, D. B., Howden, S. M., Smith, D. R., & Chhetri, N. (2014). A meta-analysis of crop yield under climate change and adaptation. *Nature Climate Change*, 4(4), 287-291. <https://doi.org/10.1038/nclimate2153>
- [3] M. Peralta, A. Nilson, V. Grosso, A. Soltermann and R. Miazzo, "Stevia (Stevia rebaudiana Bertoni): un aditivo natural efectivo en avicultura?", *Revista Ciencias Veterinarias*, vol. 36, no. 1, p. 7, 2018.
- [4] Tipos y clases de Stevia | NutraBlog. (s.f.). NutraStevia | Edulcorantes naturales a base de Stevia. <http://www.nutrastevia.pe/nutrablog/tipos-y-clases-de>

stevia#:~:text=Plantas%20Morita%20II%20pertenece%20a,más%20dulce%20que%20otras%20especies.

[5] V.-C. Angel, G.-D. Noel, T.-M. Carlos, G.-V. Juan, R.-T. Ana y L.-M. Olimpo, "SISTEMA DE MONITOREO DE CALIDAD DE SUELO PARA CULTIVO DE STEVIA REBAUDIANA MORITA II", *ELECTRO*, vol. 44, octubre de 2022, art. n.º 5.

[6] Cultivo de la stevia - PureCircle Stevia Institute. (s. f.). PureCircle Stevia Institute. <https://www.purecirclestevia.com/consumidores/historia-de-la-stevia/cultivo-de-la-stevia/#:~:text=Conocida%20cient%20C%20Adficamente%20como%20Stevia%20Rebaudiana,Kenia%20C%20China%20y%20Estados%20Unidos>.

[7] V. de la Cruz Delgado and J. Flores Galaviz, "Plan de negocio para elevar la competitividad de las PYMES productoras de stevia: caso municipio Valle de Chalco, estado de México", *Eumed.net*, 2022.

[8] M.-A. Dante-Alberto, G.-D. Noel, G.-V. Juan, V.-R. Jesús-Alberto, H.-M. José-Román y R.-T. Ana-Claudia, "DISEÑO DE SISTEMA DE MONITOREO INTELIGENTE EN INVERNA", *ELECTRO*, vol. 44, octubre de 2020, art. n.º 1.

[9] "¿Qué es la inteligencia artificial o IA? | Google Cloud | Google Cloud". Google Cloud. <https://cloud.google.com/learn/what-is-artificial-intelligence?hl=es-419> (accedido el 22 de mayo de 2023).

[10] "¿Qué es una red neuronal? - Explicación de las redes neuronales artificiales - AWS". Amazon Web Services, Inc. <https://aws.amazon.com/es/what-is/neural-network/#:~:text=Una%20red%20neuronal%20es%20un,lo%20hace%20el%20cerebro%20humano>. (accedido el 22 de mayo de 2023).

[11] Castillo, E., Cobo, A., Gutiérrez, J.M., Pruned, R.E.: *Introducción a las Redes Funcionales con Aplicaciones. Un Nuevo Paradigma Neuronal*. Editorial Paraninfo S.A. Madrid. España. pp.5-8; 8-16; 21-24, 30-34, 53-100. (1999).

[12] D. Mercado Polo, L. Pedraza Caballero y E. Martínez Gómez, "Comparación de Redes Neuronales aplicadas a la predicción de Series de Tiempo.", *Prospectiva*, vol. 13, n.º 2, p. 88, diciembre de 2015. Accedido el 22 de mayo de 2023. [En línea]. Disponible: <https://doi.org/10.15665/tp.v13i2.491>

[13] Colaboradores de los proyectos Wikimedia. (2005). *Perceptrón multicapa - Wikipedia, la enciclopedia libre* [Imagen]. Wikipedia, la enciclopedia libre. [https://es.wikipedia.org/wiki/Perceptr%C3%B3n\\_multicapa#/media/Archivo:RedNeuronalArtificial.png](https://es.wikipedia.org/wiki/Perceptr%C3%B3n_multicapa#/media/Archivo:RedNeuronalArtificial.png)

[14] A. Jarma Orozco, C. Cardona Ayala y C. Fernández Herrera, "Efecto de la temperatura y radiación en la producción de glucósidos de esteviol en Stevia rebaudiana en el caribe húmedo colombiano", *Revista U.D.C.A Actualidad & Divulgación Científica*, vol. 15, n.º 2, diciembre de 2012. Accedido el 19 de junio de 2023. [En línea]. Disponible: <https://doi.org/10.31910/rudca.v15.n2.2012.833>

[15] López-Cruz, I. L., Rojano-Aguilar, A., Ojeda-Bustamante, W., & Salazar-Moreno, R. (2007). Modelos Arx para predecir la temperatura del aire de un invernadero: una metodología. *SciELO - Scientific Electronic Library Online*. [https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1405-31952007000200181](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-31952007000200181)

[16] G. Ovando, M. Bocco y S. Sayago, "REDES NEURONALES PARA MODELAR PREDICCIÓN DE HELADAS", *Agricultura Técnica*, vol. 65, n.º 1, marzo de 2005. Accedido el 19 de junio de 2023. [En línea]. Disponible: <https://doi.org/10.4067/s0365-28072005000100007>

[17] Jeng-Fung, C. & Quang Hung, D. (2014) «A cooperative Cuckoo Search - hierarchical adaptive neuro-fuzzy inference system approach for predicting student academic performance» *Journal of Intelligent and Fuzzy Systems*, vol. 27, n.º 5, pp. [19]2551-2561. DOI: <https://doi.org/10.3233/IFS-141229>.

[18] Humphrey, W. S. (1995) «A Discipline for Software Engineering» Addison Wesley Professional. ISBN: 978- 0201546101.

[19] "Stevia Regaber". Regaber. <https://regaber.com/stevia/#:~:text=La%20stevia%20es%20una,templadas,%20entre%205%20y%2030%C>. (accedido el 21 de junio de 2023).

[20] "Hold-out Method for Training Machine Learning Models - Data Analytics". Data Analytics. <https://vitalflux.com/hold-out-method-for-training-machine-learning-model/> (accedido el 22 de junio de 2023).

[21] Accedido el 22 de junio de 2023. [Imagen]. Disponible: <https://vitalflux.com/wp-content/uploads/2020/12/Hold-out-method-for-model-evaluation.png>