

“COMPARACIÓN DE MODELOS DIFUSOS PARA PREDECIR LA COSECHA OPORTUNA EN CULTIVOS DE STEVIA”

Gutiérrez-Magaña Shanti-Maryse¹, García-Díaz Noel¹, García-Virgen Juan¹, Ruiz-Tadeo Ana-Claudia¹,
Brizuela-Ramírez Jesús-Emmanuel¹, Soriano-Equigua Leonel².

Tecnológico Nacional de México, Campus Colima. División De Estudios de Posgrado e Investigación¹.
Avenida Tecnológico No.1, Col. Liberación, Villa de Álvarez, Colima, C.P. 28976.

Teléfonos: (312) 312 6393, (312) 312 9920

Universidad de Colima, Facultad de Ingeniería Mecánica y Eléctrica².

Carretera Colima – Coquimatlán Km.9, Valle de las Huertas, 28400, Coquimatlán, Colima.

Teléfono: (312) 316 1165

{g2346013, ngarcia, jgarcia, aruiz, g2346011}@colima.tecnm.mx, lsoriano@ucol.mx

RESUMEN.

La cosecha oportuna constituye un factor fundamental en la agricultura, ya que determina la condición, estado y calidad del producto final. Diversos estudios se centran en evaluar la calidad del suelo de los cultivos sin considerar la relevancia de la calidad de la planta. En este trabajo se desarrolló un sistema de inferencia difuso con el objetivo de implementar una variable para indicar el estado de la planta y otra más para la salud del suelo, además de realizar una comparación entre un sistema Takagi-Sugeno y un Mamdani para evaluar la efectividad de ambos. El modelo Takagi-Sugeno generó un error del 1% que es inferior al 5% obtenido con el sistema Mamdani. Este modelo permite predecir si una cosecha es apta para su corte o no, simplificando el proceso de planificación y toma de decisiones de los agricultores, así como la optimización de recursos.

Palabras Clave: Cosecha Oportuna, Agricultura, Sistema de Inferencia Difuso.

ABSTRACT.

Timely harvesting is a fundamental factor in agriculture because it determines the condition, state and quality of the final product. Several studies focus on evaluating the soil quality of crops, without considering the quality of the plant. In this work, a fuzzy inference system was developed with the objective of implementing a variable to indicate plant status and another one for soil health. In addition, a comparison was made between a Takagi-Sugeno and Mamdani model to evaluate their effectiveness. The Takagi-Sugeno models generated an error of 1% lower than the 5% obtained with the Mamdani model. This model makes it possible to predict whether a crop is suitable for cutting or not, simplifying the planning and decision-making process for farmers, as well as optimizing resources.

Key words: Timely Harvest, Agriculture, Fuzzy Inference System.

INTRODUCCIÓN

1.1 Antecedentes

La agricultura es una actividad humana donde se cultiva la tierra con el objetivo de producir alimentos para la sociedad [1]. De igual manera, esta labor resulta fundamental para el desarrollo

económico [2]. En México, la agricultura es una función del sector primario que ha desempeñado un papel fundamental en el país, y en la actualidad, es la rama que brinda mayores oportunidades de obtener recursos económicos [3]. Entre las actividades que integran a la agricultura se encuentra la cosecha, la cual involucra la división de la planta madre y la parte vegetal de valor comercial [4]. Cosechar a tiempo es sustancial para prevenir pérdidas [5], además, la cosecha oportuna (CO) asegura beneficios como la reducción en la expectativa de plagas, enfermedades e infecciones por aflatoxinas, también existe un riesgo menor de pérdida por robo o daño causado por animales, así mismo, garantiza semillas de alta calidad y mejor rendimiento económico [6].

Para enfrentar los retos que experimentan los agricultores, como no conocer con precisión cuándo un cultivo es óptimo para su cosecha, tecnologías como la inteligencia artificial (IA) presentan soluciones significativas. No obstante, es necesario que estas herramientas sean más robustas y accesibles para alcanzar el impacto positivo buscado. La IA facilita la protección del rendimiento de los cultivos mediante el uso de diversas herramientas [7]. Existen diferentes técnicas para el uso de la IA, dentro de las cuales se encuentra la lógica difusa (LD) [8]. La LD es una metodología que ofrece un sistema sencillo para derivar conclusiones de datos ambiguos, imprecisos, ruidosos o incompletos [9]. La LD se caracteriza por su capacidad para evaluar el grado de veracidad o falsedad de una proposición de manera cuantitativa. Además, este análisis implica la clasificación de los valores de una variable en categorías lingüísticas, asignándoles valores que reflejan su grado de pertenencia a una categoría mediante funciones de membresía [10]. La LD es una herramienta que se aplica en diferentes áreas con diversos propósitos, una de estas ramas es la agricultura, donde el uso de esta técnica puede causar múltiples beneficios en los cultivos.

Un cultivo perteneciente a la familia “Asterácea” es la Stevia. Las hojas de la Stevia son una fuente rica de glucósidos dulces, por lo que uno de sus usos principales es como endulzante. De manera relevante, se conoce que los compuestos químicos extraídos de la Stevia se consideran una alternativa valiosa en comparación al azúcar convencional. La Stevia es una planta que se cultiva con fines comerciales en diversas regiones de Brasil,

Paraguay, Tailandia, Corea del Sur, América Central, China e India [11]; por su parte, en México se observan zonas con condiciones agrícolas favorables para el cultivo de la Stevia, destacándose estados como Yucatán, Chiapas, Quintana Roo, Veracruz, Oaxaca, Campeche, Michoacán y Jalisco [12]. Colima es otro estado en donde se lleva a cabo la producción de la Stevia. En Colima se localiza el municipio de Cuauhtémoc; en él se encuentra la empresa productora y comercializadora de Stevia “Rancho Tajeli”. Los agricultores del rancho están en constante revisión y aprendizaje sobre los cultivos de Stevia, por lo que al fundamentarse en su juicio experto fueron elegidas las variables pH y grados Brix (BD, por sus siglas en inglés Brix Degree), ya que además de encontrarse estrechamente relacionadas con la variable dependiente CO, son las dos variables que más influyen para lograr el crecimiento adecuado del cultivo. Por una parte, el pH del suelo es un factor clave que influye en la disponibilidad de nutrientes esenciales y variables ambientales, además puede causar deficiencias o toxicidades en un cultivo e influir en la fertilidad del suelo cuando no se encuentra en niveles adecuados [13-18], si el suelo en el que se cultiva no presenta un nivel de pH adecuado, la planta no logrará un desarrollo óptimo, lo que resultará en un crecimiento deficiente del cultivo, calidad inferior del producto final y, en consecuencia, pérdidas significativas de tiempo y recursos materiales. El pH del suelo se mide utilizando la escala que se muestra en la Fig.1.



Figura 1. Escala de pH para suelos de cultivos [18].

Los valores específicos de pH para el suelo de un cultivo de Stevia oscilan entre 5.5 y 7, como se presenta en la Tabla 1.

Tabla 1. Niveles de pH para cultivos de Stevia [19].

Variable	Nivel	Indicador
pH	Bajo: <5.5	Ácido
	Óptimo: 5.5 – 7	Neutro
	Alto: >7	Alcalino

Por otro lado, la selección de la variable BD se justifica porque indica la capacidad edulcorante de un producto [20], lo que se considera un indicador de calidad; además, los niveles de azúcar en un cultivo reflejan su estado de salud: a mayor concentración de azúcar, más saludable será la planta [21]. La Tabla 2 muestra el nivel de BD establecidos con base en el juicio experto de los

productores de ‘Rancho Tajeli’ para poder llevar a cabo la cosecha del cultivo.

Tabla 2. Nivel de BD adecuado para cosechar (Fuente propia).

Nivel de BD	Cosecha
<22	No apto para corte
>=22	Apto para corte

1.2 TRABAJOS RELACIONADOS

Diversos trabajos han utilizado el SID como método principal de predicción, por lo que se recopilaron y analizaron investigaciones que utilizan este enfoque.

Por ejemplo, en [22] implementaron un SID tipo Mamdani para predecir el rendimiento de un cultivo vegetal, este modelo destinó 3 variables como independientes y 1 como dependiente, que se trataba como tal del rendimiento del plantío. En [23] se elaboró un SID tipo Mamdani para la predicción de la gravedad de enfermedades en cultivos de algodón, se utilizaron 6 variables climatológicas como independientes y de salida se emplearon 2 variables, la incidencia de la enfermedad y el porcentaje de intensidad de la enfermedad, el modelo trabajó con un histórico de datos de 4 años y logró una precisión de predicción del 90% y un resultado de F1 score del 88%. En [24] aplicaron un SID Mamdani para predecir el rendimiento del maíz, considerando la fase de crecimiento del cultivo, usando 1 variable dependiente y 5 independientes. El sistema fue evaluado con la métrica MRE. En [25] emplearon un SID tipo Mamdani para predecir precipitaciones, en este trabajo implementaron 3 variables, 2 de ellas independientes y 1 dependiente, además, para entrenar su SID usaron un dataset equivalente a 3 meses de información.

De los trabajos referenciados se observa que los resultados obtenidos son significativamente buenos, sin embargo, ninguno de ellos cubre en su totalidad todas las fortalezas que lograron desarrollarse en este estudio. Principalmente, en este trabajo se busca la mejor precisión mediante la comparación de dos técnicas de LD, equiparando un SID Mamdani y un TSK. Además, otras de las fortalezas distintivas es la variable dependiente CO, la cuál es un área de alta trascendencia en la agricultura, especialmente en los aspectos relacionados a la gestión eficiente de recursos materiales y económico, la mejora de la calidad de los cultivos y los productos derivados de estos. También, se destaca el cultivo objeto de estudio: la Stevia, debido a que es una planta de creciente interés comercial y ofrece múltiples beneficios nutricionales, así mismo, sirve como alternativa al azúcar convencional. Finalmente, el trabajo desarrollado ofrece una herramienta a los agricultores para efectuar una mejor planificación y toma de decisiones, de la misma manera, les brinda una herramienta que facilite conocer el momento óptimo de recolección de Stevia.

2. DESARROLLO

2.1 Modelo difuso

La LD es un área extensa que engloba una variedad de métodos y técnicas, entre los que sobresalen los SID Mamdani y TSK.

En el método Mamdani, cada regla representa una implicación que tiene un antecedente y un consecuente. Por otro lado, el SID TSK funciona de manera similar al de Mamdani, con la diferencia de que la salida del sistema es una constante o una ecuación lineal en lugar de un conjunto difuso [26]. En este trabajo se expone la comparación de estos dos SID con el objetivo de demostrar la precisión de cada uno al momento de realizar una predicción para saber si el cultivo de Stevia es apto o no apto para cosecha, utilizando como variables de entrada el nivel de BD de la planta y el pH del suelo agrícola. Para desarrollar los SID Mamdani y TSK se utilizó el software Matlab en su versión R2020a, particularmente se trabajó con el toolbox especializado en LD. En las Figs. 2 y 3 se observan las estructuras creadas para el SID Mamdani y el TSK.




Figura 2. SID Mamdani (Fuente propia).




Figura 3. SID TSK (Fuente propia).

2.2 Dataset

El dataset o conjunto de datos utilizado para los SID consta de 180 datos recopilados directamente de los cultivos de Stevia.

2.2.1 Variables de entrada

Para la obtención de la primera variable de entrada correspondiente a los BD se utilizó un refractómetro digital de bolsillo modelo 300053 Sper Scientific ATC 0-95%, el cual se ilustra en la Fig. 4:



Figura 4. Refractómetro utilizado para la obtención de BD.

Así mismo, se tomaron muestras de las hojas de los cultivos en el área de estudio con el objetivo extraerles el jugo con ayuda de un mortero de grado alimentario y posteriormente, medir el nivel de BD con el refractómetro mostrado en la Figura 4. Las imágenes de este proceso se muestran de manera secuencial en la Fig. 5.



Figura 5. Proceso para obtención de BD de las muestras del cultivo (Fuente propia).

Por otro lado, para adquirir los datos correspondientes al pH del suelo, se utilizó el detector de suelo portátil JXBS-3001-SCY-PT y el sensor integrado para suelo que se muestra en la Fig. 6.



Figura 6. Detector de suelo utilizado para obtención de datos de pH.

2.2.2 Variable de salida

Para el SID Mamdani, así como el TSK, la variable dependiente o de salida corresponde a la cosecha, específicamente a si la cosecha es oportuna o no. Se optó por una salida binaria debido a la naturaleza de los datos, ya que las características de las mediciones obtenidas de las variables pH y BD proporcionan datos que oscilan entre umbrales que determinan de manera clara si es adecuado o no cosechar; además la simplicidad de una salida de dos estados facilita su interpretación y como

consecuencia, favorece la toma de decisiones para los agricultores.

2.3 Funciones de membresía (FM)

Las FM son conjuntos difusos que miden el grado en que los elementos pertenecen a esos conjuntos, cumpliendo características definidas de manera imprecisa. Estas funciones pueden plasmarse de diversas maneras, siendo las configuraciones más usuales las triangulares, trapezoidales y gaussianas [27]. En este caso, para desarrollar los SID Mamdani y TSK se recurrió al uso de funciones triangulares y trapezoidales, aprovechando las virtudes de ambos tipos.

2.3.1 FM: Variables de entrada.

Los rangos utilizados para las FM de las variables de entrada se establecieron acorde a los siguientes parámetros: En el caso de BD se utilizó de referencia el histórico de 2 años, correspondiente al registro de corte que tienen los agricultores en Rancho Tajeli, donde los BD mínimos con los que han llevado a cabo una cosecha son 22 (Cosecha 1: 19 de abril del 2021) y el máximo 34 (Cosecha 6: 26 de septiembre de 2022), por otro lado, para establecer los rangos de pH se utilizó de referencia la escala de la Fig. 1 considerando a su vez los datos específicos de la Tabla 2. La Tabla 3 presenta las propiedades que caracterizan a cada una de las FM empleadas.

Tabla 3. Propiedades de las FM para las entradas de los SID (Fuente: Propia).

Variable	Rango	Indicador		
pH	0 – 14	ácido [0 2.17 4.34 6.51]	neutro [5.5 6.47 7.44 8.41]	alcalino [7.1 9.4 11.7 14]
Grados Brix	0 – 46	no_maduro [0 12 24]	maduro [22 26 30 34]	exceso_maduro [33 39.5 46]

Las Figs. 7 y 8 corresponden a cada una de las estructuras de las FM.




Figura 7. FM para pH (Fuente propia).




Figura 8. FM para BD (Fuente propia).

2.3.2 FM: Variables de salida.

En el caso de las salidas de los SID, para Mamdani se utilizaron dos FM de tipo trapezoidal, ambas con etiquetas lingüísticas para definir si una cosecha es apta o no apta para su cultivo; para TSK se utilizó una función constante, a la cual, de igual manera, se le asignaron dos etiquetas lingüísticas. En la Tabla 4 se muestran los parámetros establecidos para las salidas de los SID.

Tabla 4. Propiedades de las FM para la salida de los SID (Fuente: Propia).

Variable	SID	Indicador	
Cosecha [0 1]	Mamdani	no_corte (0 0.25 0.5]	corte [0 0.45 1)
	TSK	no_corte [0]	corte [1]

En el SID Mamdani se utilizaron dos FM etiquetadas como se muestra en la tabla 5, mientras que para el modelo TSK, la salida se establece a través de una función constante la cual, de la misma manera que en Mamdani está establecida en un rango de 0-1. Las Figs. 9 y 10 corresponden a la salida de los SID Mamdani y TSK respectivamente.




Figura 9. Salida SID Mamdani (Fuente propia).

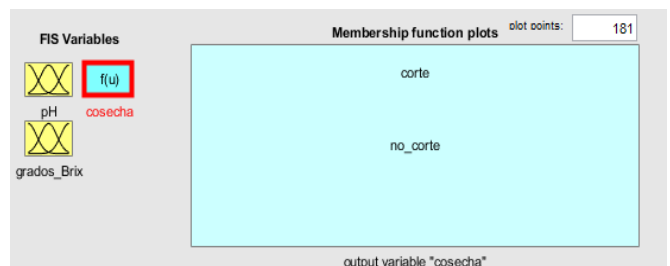


Figura 10. Salida SID TSK (Fuente propia).

2.4 Reglas difusas

En un SID las reglas difusas (RD) permiten establecer un mecanismo de razonamiento cualitativo, estableciendo relaciones entre conjuntos difusos de entrada y conjuntos difusos de salida. Las RD se componen de dos partes: la sección que define la condición se denomina ‘antecedente’ mientras que la sección que determina la consecuencia o resultante se conoce como ‘consecuente’. Debido a que el antecedente de una regla difusa suele incluir dos condiciones, se emplean operadores difusos (OD) para definir las relaciones entre los conjuntos difusos que conforman el antecedente. Los operadores difusos más utilizados son AND (intersección), OR (unión) y NOT (complemento) [28]. El conjunto de RD utilizado para los SID consiste en 9 reglas, las cuales se exponen en la Tabla 5.

Tabla 5. Reglas difusas de los SID (Fuente: Propia).

RD	Antecedente	OD	Consecuente	Cosecha
1	pH is acido		DB is no_maduro	no_corte
2	pH is acido		DB is maduro	no_corte
3	pH is acido	A	DB is exceso_maduro	no_corte
4	pH is neutro		DB is no_maduro	no_corte
5	pH is neutro	N	DB is maduro	corte
6	pH is neutro		DB is exceso_maduro	no_corte
7	pH is acido	D	DB is no_maduro	no_corte
8	pH is acido		DB is maduro	no_corte
9	pH is acido		DB is exceso_maduro	no_corte

3. RESULTADOS

3.1 SID

Para visualizar el comportamiento de ambos SID se generaron los modelos 3D. Las gráficas permitieron apreciar la influencia de las variables de entrada sobre la variable dependiente, facilitando la interpretación de correlaciones y patrones subyacentes. La Fig. 11 muestra dichas gráficas, donde se aprecia las características de ambos SID, así como el comportamiento que tiene la variable de salida ‘cosecha’, la cual alcanza un valor cercano a 1, es decir, ‘apto’ cuando los valores de pH se encuentran entre 6 – 8 y los valores de BD oscilan en un rango de 24 – 34.




Figura 11. Gráficas 3D de comportamiento de los SID (Fuente propia).

3.2 Métricas de evaluación

Se implementó la métrica de Absolutos Residuales (AR) para examinar los SID desarrollados. AR es una métrica que ha sido

ampliamente utilizada para la evaluación de resultados en trabajos como [29,30,31]; AR se define por la ecuación 1.

$$AR_i = |(\text{Esfuerzo actual})_i - (\text{Esfuerzo estimado})_i| \quad (1)$$

Para cada observación ‘i’ donde se estima la aptitud de la cosecha, se calcula un valor AR. La ecuación 2 muestra cómo se puede obtener un valor AR promedio (MAR) para un conjunto de observaciones (N) sumando los valores AR individuales y dividiendo por el número de observaciones.

$$MAR = \left(\frac{1}{N}\right) \sum_1^N AR_i \quad (2)$$

A menor valor de MAR, mayor precisión de la técnica de predicción. Esto significa que un MAR bajo indica que las predicciones realizadas por la técnica son más cercanas al valor real [29].

3.3 Evaluaciones de desempeño

La evaluación de los SID se desarrolló en Python. Se utilizó un conjunto de 180 datos, del cual se realizaron 3 particiones (90/10, 80/20, 70/30 : Entrenamiento/Validación) con base en el método Hold Out [32], cabe resaltar que los datos fueron particionados aleatoriamente mediante el método ‘random’ del mismo software. Así mismo, se aplicó la métrica de evaluación mencionada a cada conjunto de datos, obteniendo los resultados mostrados en la Tabla 6:

Tabla 6. Resultados obtenidos (Validación) (Fuente: Propia)

Partición	Mamdani	TSK
90/10	0.0556	0.0185
80/20	0.1111	0.0278
70/30	0.1111	0.0556

En los resultados obtenidos se observa que la partición que brinda el mejor resultado es la 90/10, esto se debe a que el ajuste abarca la mayoría del conjunto de datos, permitiendo que el modelo difuso ajuste mejor sus parámetros y tenga un mayor conocimiento de los datos analizados. En la Tabla 7 se muestra los datos con los que se evaluaron el modelo Mamdani y TSK, así como su resultado.

Tabla 7. Datos evaluados. Mamdani (M), resultado (R) (Fuente: Propia)

Conjunto de datos		1	2	3	4	5	6	7	8	9
M	pH	6.47	6.84	7	6.53	6.75	6.51	6.59	7.26	6.77
	BD	30.2	30.5	34.1	24.7	30	28	30	34.9	29
	R	1	1	0	1	1	1	1	0	1
TARGET		1	1	1	1	1	1	1	1	1
T	pH	6.68	6.64	5	6.57	6.77	7	6.74	6.69	6.47
S	BD	30.2	29.7	16	28	27.1	30	30.1	28.2	30.2
K	R	1	1	0	1	1	1	1	1	1
TARGET		1	1	0	1	1	1	1	1	1
Conjunto de datos		10	11	12	13	14	15	16	17	18

M	pH	6.49	6.5	6.51	7.16	6.74	8.06	6.44	6.52	6.56
	BD	27.4	30.2	30	35	29	40	23.8	28	27.1
	R	1	1	1	0	1	0	1	1	1
	TARGET	1	1	1	1	1	0	1	1	1
T	pH	6.6	6.57	7.17	6.61	6.22	6.24	6.66	6.56	4.3
	BD	29	30.5	31	27.1	24.7	28	25.4	27.1	42
	R	1	1	1	1	1	1	1	1	0
	TARGET	1	1	1	1	0	1	1	1	0

Con la partición 90/10 el SID Mamdani reportó un error del 5% mientras que TSK generó un error de 1% siendo acreedor a una atribución de mayor confiabilidad. El SID TSK es conocido por su amplia aplicación en el área de la agricultura, brindando resultados precisos y confiables en múltiples estudios como [33-36]. Su implementación ha contribuido y favorecido significativamente el avance de la agricultura, impulsando su progreso hacia la sustentabilidad y promoviendo un desarrollo tecnológico que optimiza y facilita sus procesos productivos.

4. TRABAJO FUTURO

Las investigaciones futuras derivadas de este estudio se centrarán en el desarrollo de un modelo neuro-difuso, con especial énfasis en la utilización de la arquitectura ANFIS. La elección de ANFIS, en combinación con el algoritmo de particionamiento GRID, se fundamenta en su excelente desempeño en sistemas con un número de variables independientes igual o menor a cinco. Además, esta arquitectura hace uso del modelo TSK, el cual, en el presente trabajo demostró un error significativamente bajo (1%), posicionándose como el más preciso. Entre los desafíos anticipados en la implementación de ANFIS se incluyen la adquisición del dominio completo de su estructura y la realización de una evaluación exhaustiva de todos los tipos de FM y sus parámetros correspondientes a través de diversas pruebas, con el propósito de identificar el modelo que garantice la mejor precisión; además, se prevé la expansión del conjunto de datos.

5. CONCLUSIONES

La incorporación de una variable de entrada que refleja el estado de la planta (BD), junto con un parámetro que evalúa la salud del suelo (pH), demostraron ser variables altamente correlacionadas para determinar la cosecha oportuna. Al aplicar la métrica MAR a ambos SID y evaluarlos mediante tres particiones, se obtuvo que la partición que brinda mejor precisión es la 90/10, ya que proporciona valores de error de 0.0185 y 0.0556 para TSK y Mamdani, respectivamente. El SID TSK presenta resultados más confiables para la predicción y la toma de decisiones informadas, ubicándose por encima de Mamdani en este aspecto. Finalmente, el desarrollo de los SID ofrece múltiples beneficios para los agricultores, incluyendo la planificación de la cosecha, mejora en la toma de decisiones y la optimización de recursos.

Referencias

[1] Food and Agriculture Organization. “¿Qué es la Agricultura?”. FAO. Accedido el 20 de mayo de 2024. [En

línea].

Disponible: <https://openknowledge.fao.org/#:~:text=“La%20agricultura%20es%20una%20actividad,alimentos%20para%20la%20poblaci%20n%20humana.”>

[2] Grupo Banco Mundial. “Agricultura y alimentos”. World Bank. Accedido el 20 de mayo de 2024. [En línea].

Disponible: <https://www.bancomundial.org/es/topic/agriculture/overview>

[3] Gobierno de México. “¿Cómo beneficia la agricultura a las familias mexicanas?”. gob.mx. Accedido el 20 de mayo de 2024. [En línea].

Disponible: <https://www.gob.mx/agricultura/es/articulos/como-beneficia-la-agricultura-a-las-familias-mexicanas>

[4] Food and Agriculture Organization. “¿Qué es la cosecha?”. FAO. Accedido el 20 de mayo de 2024. [En línea]. Disponible: <https://openknowledge.fao.org/#:~:text=La%20cosecha%20es%20la%20separaci%20n,como%20el%20esp%20rrago;%20pec%20i%20los%20como>

[5] Food and Agriculture Organization. “Timely harvest | FAO”. Home | Food and Agriculture Organization of the United Nations. Accedido el 20 de mayo de 2024. [En línea]. Disponible: <https://www.fao.org/family-farming/detail/en/c/1309554/>

[6] Strengthening Partnerships, Results and Innovations in Nutrition Globally. “Good Agronomic Practices for Groundnut Production”. SPRING. Accedido el 20 de mayo de 2024. [En línea]. Disponible: https://spring-nutrition.org/sites/default/files/publications/trainingmaterials/spring_farmer_agronomic_curriculum.pdf

[7] Y. Sepúlveda, “Artificial intelligence (AI) and its applications in modern agriculture”, p. 2, 2020. Accedido el 21 de mayo de 2024. [En línea]. Disponible: <https://doi.org/10.13140/RG.2.2.17264.89603>

[8] P. Carranza, “Introducción a las técnicas de Inteligencia Artificial aplicadas a la Gestión Financiera Empresarial”, Rev. Difusion Cult. Cient. Univ. Salle En Boliv., vol. 4, n.º 4, p. 10, 2010. Accedido el 21 de mayo de 2024. [En línea]. Disponible: http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S2071-081X2010000100002

[9] C. D’Negri y E. De Vito, “Introducción al razonamiento aproximado: lógica difusa”, Rev. Am. Medicina Respir., vol. 6, n.º 3, 2006, art. n.º 1852-1630. [En línea]. Disponible: <https://www.redalyc.org/pdf/3821/382138367007.pdf>

[10] B. García, “Sistemas Neuro - Difusos Aplicados al Control Automático”, Univ. Tecnol. Boliv., Cartagena de Indias D.T. Y C., 2005. [En línea]. Disponible: <https://repositorio.utb.edu.co/bitstream/handle/20.500.12585/702/0030354.pdf?sequence=1&isAllowed=y>

[11] F. Hossain, M. Islam, M. Islam y S. Akhta, “Cultivation and uses of stevia (Stevia rebaudiana bertonii): A review”, AFR. J. Food, Agriculture, Nutrition Develop., vol. 17, n.º 04, pp. 12745–12757, noviembre de 2017. Accedido el 21 de mayo de 2024. [En línea]. Disponible: <https://doi.org/10.18697/ajfand.80.16595>

- [12] Gobierno de México. “En México la stevia conquista el mercado de los edulcorantes”. gob.mx. Accedido el 23 de mayo de 2024. [En línea]. Disponible: <https://www.gob.mx/agricultura/es/articulos/en-mexico-la-stevia-conquista-el-mercado-de-los-edulcorantes>
- [13] “¿Qué tanto sabes del pH del suelo?” gob.mx. Accedido el 6 de septiembre de 2024. [En línea]. Disponible: <https://www.gob.mx/agricultura/articulos/que-tanto-sabes-del-ph-del-suelo?idiom=es#:~:text=aplicación%20de%20cal.-,>
- [14] “¿Qué es el pH del suelo?” FAO. Accedido el 6 de septiembre de 2024. [En línea]. Disponible: <https://openknowledge.fao.org/server/api/core/bitstreams/e434293f-c9d1-4585-a799-b7c9107ea64e/content>
- [15] A. Mohd, R. Mohamad, A. S. Wan Nor y K. Daljit Singh, “The relationship between soil pH and selected soil properties in 48 years logged-over forest”, *INT. J. ENVIRONMENTAL SCI.*, vol. 4, n.º 6, 2014.
- [16] “What is the relationship between pH and temperature? | AAT Bioquest”. Home | AAT Bioquest. Accedido el 6 de septiembre de 2024. [En línea]. Disponible: <https://www.aatbio.com/resources/faq-frequently-asked-questions/what-is-the-relationship-between-ph-and-temperature>
- [17] J. L. Zarate-Valdez, “Short-term effects of moisture content on soil solution pH and soil Eh”, *Soil Sci.*, vol. 171, n.º 5, 2006. [En línea]. Disponible: https://www.researchgate.net/publication/232136380_Short-term_effects_of_moisture_content_on_soil_solution_pH_and_s_oil_Eh
- [18] E. Rivera, M. Sánchez y H. Domínguez, “pH como factor de crecimiento en plantas”, *Rev. Iniciación Cient.*, vol. 4, pp. 101–105, junio de 2018. Accedido el 27 de mayo de 2024. [En línea]. Disponible: <https://doi.org/10.33412/rev-ric.v4.0.1829>
- [19] J. Martínez, “Sistema de Inferencia Difuso para Determinar la Calidad del Suelo en un Cultivo de Stevia Morita II”, *Rev. Electro*, vol. 45, p. 191, 2023. Accedido el 27 de mayo de 2024. [En línea]. Disponible: https://itchihuahua.mx/revista_electro/2023/SUB-18_190-195.html
- [20] “Using °Brix as an Indicator of Vegetable Quality: Linking Measured Values to Crop Management”. Home | Ohioline. Accedido el 6 de septiembre de 2024. [En línea]. Disponible: <https://ohioline.osu.edu/factsheet/HYG-1651>
- [21] “Brix measurements and its role in plant nutrient management - Compo Expert South Africa”. Compo Expert South Africa. Accedido el 6 de septiembre de 2024. [En línea]. Disponible: <https://cesablog.co.za/2021/07/14/brix-measurements-and-its-role-in-plant-nutrient-management/>
- [22] S. M. Upadhya y S. Mathew, “Implementation of Fuzzy Logic in Estimating Yield of a Vegetable Crop”, *J. Phys.: Conf. Ser.*, vol. 1427, p. 012013, enero de 2020. Accedido el 3 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.1088/1742-6596/1427/1/012013>
- [23] “Fuzzy Logic Modelling for Disease Severity Prediction in Cotton Crop using Weather Parameters”, *Int. Res. J. Eng. Technol.*, vol. 10, n.º 08, pp. 801–802, 2023.
- [24] J. Jinger, “Maize Yield Prediction Considering Growth Stages using Fuzzy Logic Modelling”, *INT. J. ENG. RES. & TECHNOL. (IJERT)*, vol. 09, n.º 04, pp. 8–10, 2021. [En línea]. Disponible: <https://www.ijert.org/maize-yield-prediction-considering-growth-stages-using-fuzzy-logic-modelling>
- [25] R. Janarthanan, R. Balamurali, A. Annapoorani y V. Vimala, “Prediction of rainfall using fuzzy logic”, *Mater. Today: Proc.*, julio de 2020. Accedido el 3 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.1016/j.matpr.2020.06.179>
- [26] M. Alfian Firdausy, E. Utami y A. Dwi Hartanto, “Comparison Analysis of Fuzzy Sugeno & Fuzzy Mamdani for Household Lights”, *Int. Conf. Inf. Sci. Technol. Innov. (ICoSTEC)*, vol. 1, n.º 1, pp. 30–34, febrero de 2022. Accedido el 23 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.35842/icostec.v1i1.14>
- [27] J. Cepeda, “Modelado de Sistemas Difusos de Múltiples Entradas y Salidas”, Univ. Guanaj., Salamanca, Guanajuato, 2011. [En línea]. Disponible: <https://www.aacademica.org/jcepedanegrete/7>
- [28] B. Xu, J. Su, D. S. Dale y M. D. Watson, “Cotton Color Grading with a Neural Network”, *Textile Res. J.*, vol. 70, n.º 5, pp. 430–436, mayo de 2000. Accedido el 23 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.1177/004051750007000508>
- [29] N. García-Díaz, A. Verduzco-Ramírez, J. García-Virgen y L. Muñoz, “Applying Absolute Residuals as Evaluation Criterion for Estimating the Development Time of Software Projects by Means of a Neuro-Fuzzy Approach”, *J. Inf. Syst. Eng. & Manage.*, vol. 1, n.º 4, noviembre de 2016. Accedido el 23 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.20897/lectito.201646>
- [30] C. López-Martín, Y. Villuendas-Rey, M. Azzeh, A. Bou Nassif y S. Banitaan, “Transformed k-nearest neighborhood output distance minimization for predicting the defect density of software projects”, *J. Syst. Softw.*, vol. 167, p. 110592, septiembre de 2020. Accedido el 24 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.1016/j.jss.2020.110592>
- [31] R. Silhavy, P. Silhavy y Z. Prokopova, “Using Actors and Use Cases for Software Size Estimation”, *Electronics*, vol. 10, n.º 5, p. 592, marzo de 2021. Accedido el 24 de junio de 2024. [En línea]. Disponible: <https://doi.org/10.3390/electronics10050592>
- [32] Yadav, S.; Shukla, S. Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In *Proceedings of the 2016 IEEE 6th International Conference on Advanced Computing (IACC)*, Bhimavaram, India, 27–28 February 2016; pp. 78–83.
- [33] D. Rosales, “Sistema difuso Takagi-Sugeno para predecir el riesgo de propagación de Sigatoka Negra *Mycosphaerella fijiensis* en el cultivo de plátano”, *RIIT. Rev. Int. Investig. Innovación Tecnol.*, vol. 8, n.º 44, pp. 20–24, 2020.

- [34] K. Borse y P. G. Agnihotri, "Prediction of Crop Yields Based on Fuzzy Rule-Based System (FRBS) Using the Takagi Sugeno-Kang Approach", Springer Nat. Switz., pp. 438–447, 2019. [En línea]. Disponible: https://doi.org/10.1007/978-3-030-00979-3_46
- [35] Devie Rosa Anamisa, Budi Dwi Satoto, Muhammad Yusuf, Moch. Kautsar Sophan y Fifin Ayu Mufarroha, "Application of Fuzzy Inference System Takagi-Sugeno Methods for Diagnosis of Diseases and Pests of Madura Paddy Rice Based on Symptoms", Technium: Romanian J. Appl. Sci. Technol., vol. 16, pp. 50–56, octubre de 2023. Accedido el 6 de septiembre de 2024. [En línea]. Disponible: <https://doi.org/10.47577/technium.v16i.9958>
- [36] S. Napitupulu, E. B. Nababan y P. Sihombing, "Comparative Analysis of Fuzzy Inference Tsukamoto Mamdani and Sugeno in the Horticulture Export Selling Price", IEEE, pp. 183–187, 2020. [En línea]. Disponible: <https://doi.org/10.1109/MECnIT48290.2020.916658>