



**UNIVERSIDAD POLITÉCNICA SALESIANA**  
**SEDE GUAYAQUIL**

**TRABAJO DE GRADO PREVIO A LA OBTENCIÓN DEL TÍTULO DE:**

**INGENIERO DE SISTEMAS**

**CARRERA:**

**INGENIERÍA DE SISTEMAS**

**TEMA:**

**“ESTUDIO COMPARATIVO DE LAS TÉCNICAS DE INTELIGENCIA  
ARTIFICIAL PARA EL DIAGNÓSTICO DE ENFERMEDADES EN LA  
AGRICULTURA”**

**AUTOR:**

**Joseline Alfonsina Valdivieso  
Duarte**

**TUTOR:**

**Miguel Ángel Quiroz Martínez Msg.**

**Abril 2021**

**GUAYAQUIL-ECUADOR**

## DECLARATORIA DE RESPONSABILIDAD

Yo, **Joseline Alfonsina Valdivieso Duarte**, declaro que los conceptos y análisis desarrollados y las conclusiones del presente trabajo son de exclusiva responsabilidad del/los autor/es.



**Firma del autor**

**Nombre: Joseline Alfonsina Valdivieso Duarte**  
**CI. 0951613090**



**Firma:**  
**(Tutor): Miguel A. Quiroz Martínez**  
**C.I.: 0922799655**

# ESTUDIO COMPARATIVO DE LAS TÉCNICAS DE INTELIGENCIA ARTIFICIAL PARA EL DIAGNÓSTICO DE ENFERMEDADES EN LA AGRICULTURA

Miguel Angel Quiroz Martinez<sup>1[0000-0002-8369-1913]</sup> and Joseline Alfonsina Valdivieso Duarte<sup>1[0000-0003-0372-7224]</sup>

<sup>1</sup> Department of Computer Science, Universidad Politécnica Salesiana Sede Guayaquil, Ecuador, Chamber 227 y 5 de junio  
mquiroz@ups.edu.ec, jvaldiviesod@est.ups.edu.ec

**Resumen.** El proceso de diagnóstico mediante criterios y métodos complementarios es un arte muy complejo aplicado a la identificación de la enfermedad responsable del padecimiento o la estimación del riesgo de las complicaciones. El diagnóstico, tanto humano como animal y vegetal, es una tarea que requiere precisión, dada la importancia que puede tener una decisión equivocada. Gracias al desarrollo de las tecnologías de la información y la comunicación y a los inagotables avances de la informática, el diagnóstico fitosanitario en la agricultura, en la actualidad, se basa en las aplicaciones de la inteligencia artificial, que ve como referencia en varias de sus principales técnicas, así como en los sistemas expertos, la lógica difusa, las redes neuronales, la minería de datos. Por ello, actualmente se está llevando a cabo un importante estudio de las técnicas de inteligencia artificial, frecuentemente utilizadas para el diagnóstico, con el fin de seleccionar la técnica que mejor se adapte al diagnóstico fitosanitario en la agricultura a partir de los datos almacenados en las bases de datos

**Palabras Clave:** Diagnostico Fitosanitario, Inteligencia Artificial, Redes Neuronales, Sistemas Expertos, Minería de Datos, Bases de Datos.

## 1 Introducción

### 1.1 La Inteligencia Artificial y los Diagnósticos Fitosanitarios.

El diagnóstico, tanto humano como animal y vegetal, es una actividad que realizan especialistas con pericia en el ámbito en que se realiza el proceso de diagnóstico. La Inteligencia Artificial, trata de emular la habilidad natural que el ser humano tiene para tomar decisiones de cualquier arquetipo, simulando en su forma de aprender como la forma en la que se fundamenta esa instrucción para llegar a la toma de decisiones [1]. Siendo el sector agrícola uno de los sectores más importantes globalmente hablando, sin embargo, ha sido víctima de pérdidas debido a enfermedades, tomando en consideración que personas con problemas de pobreza viven en estas zonas, lo que hace que este grupo de agricultores sea muy vulnerable de ser interrumpido en el aprovisionamiento de productos alimenticios derivados de agentes patógenos [2][3]. Para este fin se han empleado diversas técnicas de Inteligencia Artificial, incluyendo las Redes Neuronales, Sistemas Expertos (ya antes mencionados), Data Mining y los Agentes Inteligentes. En las últimas décadas se han realizado algunos esfuerzos para aplicar el análisis predictivo a los sistemas de salud y para activar sistemas de aprendizaje automático que faciliten el diagnóstico de enfermedades [4].

Para el diagnóstico de las enfermedades en la agricultura, la rápida y fácil integración de los contenidos que pueden sustituir al diagnóstico antiguo es una causa primordial, siendo que el diagnóstico es un proceso de gran complejidad, que no es totalmente preciso y que no puede llevarse a término sin considerar previamente otras alternativas, debido a la incertidumbre presente en el procedimiento [5] [6]. Dando como resultado de esta gran incertidumbre, las determinaciones que han sido adoptadas por los distintos especialistas en cada etapa del procedimiento de diagnóstico no son las mismas siempre, ya que cada incidente en concreto conlleva un procedimiento de decisiones distinto para cada especialista, aunque este se trate de la valoración del mismo tipo de afección. Hay maneras de identificar las condiciones de cualquier planta, tales como el examen de los tejidos de las plantas en un laboratorio equipado o la presencia de un agrónomo especialista en la materia en el sitio de la plantación; en cualquiera de los dos casos, el problema es el tiempo que se necesita para conseguir los resultados [2]. Entre las técnicas que se han empleado con mayor frecuencia para el reconocimiento de

enfermedades, destacan las siguientes: Lógica difusa (diagnóstico que se basa en la clasificación), sistemas expertos (se basa en reglas, probabilidades, basado en casos), redes neuronales (diagnóstico basado en la formación y el reconocimiento), minería de datos aplicada (diagnóstico basado mediante el reconocimiento de patrones) [1][7]. Estas técnicas tienen un potencial importante en la Inteligencia Artificial en la agricultura.


El estudio comparativo constituye el elemento que permitirá determinar cuál es la técnica de Inteligencia Artificial que mejor se adapta al diagnóstico de las afecciones en la agricultura. El análisis para la elección de la técnica de Inteligencia Artificial que mejor se ajusta al diagnóstico de las enfermedades, se hace a través del análisis de Mapas Cognitivos Difusos.

Los Mapas Cognitivos Difusos (Fuzzy Cognitive Maps) son una de las técnicas de IA más extendidas y estudiadas en los últimos años. La necesidad de hacer modelos de causalidad similares a la vida real, junto con los requerimientos de precisión e interpretabilidad han llevado a cabo un aumento de los esfuerzos para desarrollar este tipo de representaciones matemáticas[8]. Estos presentan un mecanismo para poder modelar y predecir complejos sistemas, muy poderosa por ser altamente multivariable e interpretable. La idea principal de los MCD consiste en modular el objeto de estudio, separándolo en unidades primordiales, de manera que se pueda describir la dinámica de la interacción interna entre estas unidades[9].

## 2 Materiales y métodos o metodología

La investigación adoptó un planteamiento de tipo cuantitativo. Se empleó la Teoría de la Decisión, comenzando por la identificación y definición de la problemática y finalizando con la elección de una o varias posibilidades, lo que supone un ejercicio de toma de decisiones, un procedimiento que se basa en cinco etapas esenciales. La toma de decisiones, en el trabajo presente, se enfoca en la búsqueda de la mejor técnica, comúnmente empleada para el proceso de diagnóstico de enfermedades en el agro. El proceso se inicia con la identificación y definición del problema y finaliza con la selección de una o más variantes, lo que implica el acto de tomar una decisión.

A partir de la información que esta previamente registrada en bases de datos se han determinado cinco fases para adoptar una decisión sobre la mejor técnica de inteligencia artificial, que se emplea con asiduidad en el diagnóstico de las enfermedades de agricultura. Las etapas iniciales del procedimiento para tomar decisiones consisten en la articulación del problema y las dos últimas en el análisis del mismo [10]. Se presentan las etapas para la conclusión de un incidente por medio de la adopción de decisiones (ver Fig. 1):

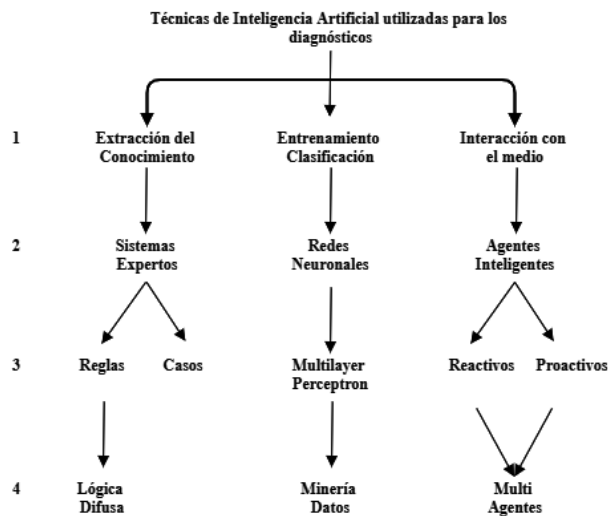


**Fig. 1.** Fases para la resolución de un problema a través de la toma de decisiones.

La etapa de investigación del procedimiento para tomar decisiones puede adoptar dos formatos principales: el cualitativo y el cuantitativo. El análisis cualitativo es el que se basa en el razonamiento y la práctica de la entidad que ha tomado la decisión; incluye la impresión intuitiva que tiene del problema. Al emplear el enfoque cuantitativo, el analizador se centra en los datos o factores que se relacionan con la incidencia y conlleva a desarrollar las expresiones de las ciencias exactas que describen los propósitos, las limitaciones y las interacciones del problema[11]. Luego, utilizando los métodos cuantitativos, es posible ofrecer una sugerencia basándose en los componentes cuantitativos del problema.

En este sentido, deseamos conocer cuál es la mejor forma de evaluar, a fin de determinar qué técnica de Inteligencia Artificial se adapta mejor al diagnóstico de las enfermedades en la agricultura, considerando las peculiaridades de cada técnica que se muestra en (ver Fig. 2):

- 1) Primera etapa (A): Se lleva a cabo de manera continua sobre las ventajas de las prácticas de IA empleadas en los diagnósticos, en los que los profesionales de la fitopatología tienen un rol de experticia en la obtención de los conocimientos.
- 2) Segunda etapa (B): Se realiza la evaluación de las técnicas de IA, presentándose estudios de casos para realizar comparativas, prevalece el criterio de expertos, y la comparación con datos almacenados en Bases de Datos.
- 3) Tercera etapa (C): Los agrónomos o fitopatólogos (expertos), tienen la posibilidad de plantear y resolver problemáticas que se relacionan con su ámbito e implican el conocimiento edificado durante el tiempo determinado de la presencia de síntomas de enfermedades.



**Figura 2.** Técnicas de Inteligencia Artificial utilizadas para los Diagnósticos Fitosanitarios.

Leyenda:

- 1) Principio general (Basadas en).
- 2) Rama específica de la Inteligencia Artificial.
- 3) Clasificación dentro de la rama de Inteligencia Artificial.
- 4) Aplicación.

Para poder seleccionar la técnica que mejor se ajuste al proceso de diagnóstico de enfermedades en la agricultura, se recomienda tener en cuenta el principio de cada técnica (ver Fig.2).

1. (1-Sistema Expertos), sobre la base de la obtención de los conocimientos.
2. (2- Redes Neuronales), basadas en entrenamiento y clasificación.
3. (3- Agentes Inteligentes), basándose en la interrelación con el entorno.

Establecer la mejor forma de evaluar los diagnósticos con los casos previamente almacenados en las bases de datos en la agricultura y al establecer los mapas cognitivos difusos ya que forma una globalización de los Mapas Cognitivos, ambos son gráficos dirigidos, cuyos vértices representan conceptos y sus bordes representan relaciones causales entre estos conceptos [12]. La diferencia entre ambos está en los valores asignados a los bordes que significan el grado de relación entre los vértices. En los Mapas Cognitivos estos valores son -1, 1, que suponen una correlación invertida o directa, respectivamente, entre los conceptos. Mientras que los Mapas Cognitivos Difusos toman valores en el rango [-1, 1], donde se incluye una escala entre las diferencias de los conceptos [13].

## 2.1 Pasos a seguir para aplicar el método de Mapas Cognitivos Difusos

Se trata de gráficos direccionados que utilizan unos vértices para representar los conceptos o las variables en un ámbito. Mientras que los bordes son los que señalan las relaciones de causalidad positivas, negativas o nulas entre los términos representados por los vértices. Los Mapas Cognitivos Difusos (MCD) extienden los Mapas Cognitivos al dominio difuso en el intervalo  $[-1,1]$  para determinar la fuerza en las relaciones causales [14]. Los MCD perfeccionan a los mapas cognitivos, que describen la fuerza conjunta por medio del uso de los datos difusos en el intervalo  $[-1,1]$  [15].

Los mapas cognitivos nos ayudan a manifestar las interrelaciones causales entre las variables, donde cada borde se relaciona con un valor de peso en el conjunto, siendo el 0 el que indica que no hay relación causal entre las variables, -1 significa que la relación de causalidad es inversa (si una variable aumenta y la otra disminuye), y 1 significa que hay una relación de causalidad totalmente directa (ambas variables van en aumento o ambas disminuyen) [16]. Estos factores no cubren la incertidumbre que hay en estas relaciones de causalidad, lo que provoca que surjan los Mapas Cognitivos Difusos, en los que se logra introducir una clasificación en el conjunto anterior de ponderaciones que se define en el intervalo continuo  $[-1,1]$ .

Hay tres clases de posibles relaciones de causalidad entre los conceptos en los MCD:

1. La causalidad es positiva ( $W_{ij} > 0$ ): Existe una causalidad directamente proporcional entre los conceptos  $C_i$  y  $C_j$ , es decir, el incremento (disminución) en el valor de  $C_i$  llevan a incrementar (disminuir) el valor de  $C_j$ .
2. La causalidad es negativa ( $W_{ij} < 0$ ): Existe una causalidad inversamente proporcional valores de  $C_i$  y  $C_j$ , es decir, el aumento (descenso) del valor de  $C_i$  conduce a la disminución (aumento) en el valor de  $C_j$ .
3. La inexistencia de relaciones ( $W_{ij} = 0$ ): Indica la no existencia de una correlación causal entre  $C_i$  y  $C_j$ .

Proponemos en este estudio basado en mapas cognitivos para la toma de decisiones el siguiente algoritmo:

1. La selección de los causales más relevantes.
2. Una vez ya seleccionados los causales más relevantes se modelará la causalidad entre ellos con ayuda de un Mapa Cognitivo Difuso.
3. Análisis estático[16]. Las medidas siguientes se valoran para los resultados absolutos de la matriz adyacente:
  - Outdegree, que se identifica con  $od(v_i)$ , siendo la suma para cada fila de los valores absolutos de una variable en la matriz adyacente difusa. Es una medida de la fuerza acumulada de las relaciones existentes de la variable.
  - Indegree, que se identifica con  $id(v_i)$ , es la suma de cada columna de los resultados absolutos de una de las variables de la matriz difusa adyacente. Esta mide la fuerza de entrada acumulada de la variable.
  - La centralidad o el grado de totalidad de la variable es la sumatoria de  $od(v_i)$ , donde  $id(v_i)$ , de la manera que sigue:  $td(v_i) = od(v_i) + id(v_i)$ .


Al final, estas variables se logran clasificar acorde al criterio a continuación, según autores [17]:

- a) Las variables de transmisión son las que contienen  $od(v_i) > 0$  e  $id(v_i) = 0$ .
- b) Las variables receptoras son aquellas con  $od(v_i) = 0$  y  $id(v_i) > 0$ .
- c) Las variables comunes u ordinarias cumplen con  $od(v_i) \neq 0$  y  $id(v_i) \neq 0$ .

Se logran ordenar de manera ascendente de acuerdo al grado de la centralidad.

Debido a la utilidad significativa de los Mapas Cognitivos Difusos, han sido reconocidos para poder modelar varios escenarios. Siendo así, que logramos encontrar extensiones basadas en intervalos, lógica difusa intuicionista [17], entre otras ampliaciones.

Un Mapa Cognitivo Difuso puede ser representativo por un dígrafo (ver Fig. 3.) mediante el cual, estos nodos logran representar los criterios y luego los arcos nos muestran en vínculo de causalidad.



**Fig 3.** Mapa cognitivo difuso

Cuando un grupo de expertos ( $k$ ) participa, la matriz adyacente se logra formular por medio de un operario de agregación, como es la media aritmética. La táctica más sencilla es hallar la media en cada conexión por cada competente.

Para ( $k$ ) individuos, la matriz adyacente final de los MCD ( $E$ ) se obtiene como [18]:

$$E = \frac{(E_1 + E_2 + \dots + E_k)}{k}$$

Esta facilidad en la agregación nos permite crear modelos colectivos mentales con relativa simplicidad. Este método nos permite esquemas lo más apegados a la realidad posible para la representación del conocimiento. Entre los factores que nos facilitan una interpretación lo más real posible del conocimiento, está la oportunidad de representación de los ciclos, la vaguedad y la ambigüedad, presentes; asimismo, una gran facilidad de uso para la obtención de conocimientos por parte de los agricultores.

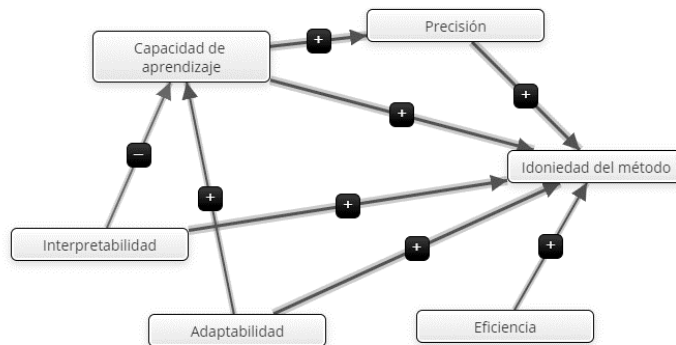
### 3 Resultados y discusión

Para obtener los resultados sobre la problemática planteada, es necesario elaborar el siguiente modelo, tomando en consideración cada criterio que ha sido utilizado con frecuencia para el diagnóstico de enfermedades en la agricultura mediante revisión bibliográfica (ver Figura 4).

Se consideraron en el modelo los siguientes criterios de evaluación en cada una de las técnicas de inteligencia artificial planteadas anteriormente:

- Precisión
- Capacidad de aprendizaje
- Interpretabilidad
- Adaptabilidad
- Eficiencia

Donde la idoneidad del método es el factor que evalúa las tres técnicas de inteligencia artificial para poder elegir la mejor de estas.



**Figura 4.** Modelo de Mapa Cognitivo Difuso.

Iniciaremos con la descripción en las próximas tablas las técnicas de inteligencia artificial, y sus correspondientes criterios, para después representarlas gráficamente por medio de una tangente hiperbólica y luego presentar el resultado del método empleado por medio de Mapas Cognitivos Difusos.

A continuación, en la siguiente tabla (Tabla 1) ubicamos los valores de los criterios de la técnica de Sistemas Expertos:

Criterios	+/-
Capacidad de Aprendizaje	0.5
Interpretabilidad	0.77
Adaptabilidad	0.17
Precisión	0.7
Eficiencia	0.32
Idoneidad del método	

**Tabla 1.** Tabla de evaluación de criterios Sistemas Expertos.

Se grafica mostrándonos el resultado de 0.89 en el criterio de Idoneidad del Método (ver Fig. 5):



**Figura 5.** Tangente Hiperbólica Sistemas Expertos.

La siguiente tabla (Tabla 2) hace referencia a los valores de los criterios de la técnica Redes Neuronales:

Criterios	+/-
Capacidad de Aprendizaje	1
Interpretabilidad	0.25
Adaptabilidad	0.96
Precisión	1
Eficiencia	0.89
Idoneidad del método	

**Tabla 2.** Tabla de evaluación de criterios Redes Neuronales.

Se grafica mostrándonos el resultado de 0.98 bajo el criterio de Idoneidad del Método en la técnica de Redes Neuronales (ver Fig. 6):





**Figura 6.** Tangente Hiperbólica Redes Neuronales.

La tabla (Tabla 3) siguientes nos hace referencia a los valores de los criterios de la técnica Sistemas Multiagentes:

Criterios	+/-
Capacidad de Aprendizaje	0.3
Interpretabilidad	0.25
Adaptabilidad	0.51
Precisión	0.62
Eficiencia	0.25
Idoneidad del método	

**Tabla 3.** Tabla de evaluación de criterios Sistemas Multiagentes.

Se grafica mostrándonos el resultado de 0.81 en el criterio de Idoneidad del Método de la técnica de Sistemas Multiagentes (ver Fig. 7):



**Figura 7.** Tangente Hiperbólica Sistemas Multiagentes.

Finalmente mostraremos en la siguiente tabla (Tabla 4) las medidas de centralidad basadas en el valor absoluto de la matriz de adyacencia donde el resultado de la centralidad  $td(v_i) = od(v_i) + id(v_i)$ , es la suma total de los valores de los criterios de indegree y outdegree

Criterios	Indegree	Outdegree	Centralidad
Capacidad de Aprendizaje	0.47	1.25	1.72
Interpretabilidad	0	0.89	0.89
Adaptabilidad	0	0.92	0.92
Precisión	0.69	0.59	1.27999
Eficiencia	0	0.31	0.31
Idoneidad del método	2.8	0	2.8

**Tabla 4.** Tabla Matriz de resultados adyacentes.

Según el análisis efectuado y de acuerdo con los resultados que se visualizan en la matriz total de los resultados adyacentes, el valor del criterio más cualificado es la idoneidad del método, consiguiendo la técnica de Inteligencia Artificial con valor más alto las Redes Neuronales, dando como resultado que las Redes Neuronales es la técnica que mejor se ajusta para el diagnóstico de enfermedades en la agricultura tomando en consideración los criterios con los que ha sido evaluado en este estudio mediante revisión bibliográfica y aplicando Mapas Cognitivos Difusos.

Resultado que se verifica al relacionar y poner en práctica los diagnósticos en la agricultura basados en técnicas de Inteligencia Artificial, y en particular utilizando datos almacenados en Bases de Datos. En este sentido, se destaca que las Redes Neuronales son una de las más poderosas herramientas de Inteligencia Artificial. Cuentan con la disposición de aprendizaje de un grupo de matrices y datos de ponderación estructural para la representación del aprendizaje de los diferentes modelos [19].

Las Redes Neuronales, están ajustadas para el diagnóstico de enfermedades en el agro, ya que se componen de numerosas unidades de procesamiento, simulando la funcionalidad del propio cerebro y la forma de desempeñar las funciones como un ser vivo [20]. Las Redes Neuronales se han aplicado con frecuencia en varias aplicaciones de Diagnóstico Fitosanitario, obteniendo resultados muy favorables y con un mayor grado de certeza que otras técnicas de Inteligencia Artificial, que proporcionan en los Diagnósticos Fitosanitarios [21].

## 4 Conclusiones

Se analizó las diferentes herramientas que se aplica en la inteligencia artificial, para la detección de enfermedades fitosanitarias en la agricultura, cada una de ellas ha sido de gran importancia, este proceso apoyado por la Inteligencia Artificial a través de la evolución de la historia, ha sido capaz de representar resultados precisos mediante el empleo de las mismas, específicamente en el área de la agricultura se han desarrollado diagnósticos disímiles de enfermedades[22].

En este estudio realizado se verificaron bibliográficamente, las siguientes técnicas de inteligencia artificial, Redes Neuronales, Sistemas Expertos, y Sistemas Multiagentes, considerando el principio de cada técnica, basándonos en mapas cognitivos difusos para la toma de decisiones en algoritmos.

Se evaluó cada una de las características de las técnicas de inteligencia artificial, obteniendo así, la más eficiente a través de la instrumentalización de las preferencias revisadas bibliográficamente mediante Mapas Cognitivos Difusos, que llevó, a considerar la segunda alternativa, Redes neuronales, ya que esta técnica es la más robusta en cuanto los criterios calificados de los datos almacenados en bases de datos.

## ACKNOWLEDGMENT

This work has been supported by the GIAR research group and the Salesian Polytechnic University of Guayaquil.

## Referencias

1. Romero, A.C., Cortes, H.H.: Machine learning en detección de enfermedades en plantas Machine learning in plant disease detection. (2019).
2. Roldán Ortega, B., Roshan Biswal, R., Sánchez Delacruz, E.: Detección de enfermedades en el sector agrícola utilizando Inteligencia Artificial. *Res. Comput. Sci.* 148, 419–427 (2019). <https://doi.org/10.13053/rcs-148-7-31>.
3. Quintero-Domínguez, L.A., Rodríguez, L.R.R., Sánchez, D.Q., Ávila, B.Y.L.: Sistema Experto para el diagnóstico presuntivo de enfermedades fúngicas en los cultivos. *Rev. Cuba. Ciencias Informáticas.* 13, (2019).
4. González, C.N., Leyva, C.M., Faggioni, K.M., Álvarez, P.J.: Estudio comparado de las técnicas de Inteligencia Artificial para el diagnóstico de enfermedades en la ganadería. CISCi 2018 - Decima Septima Conf. Iberoam. en Sist. Cibern. e Informatica, Decimo Quinto Simp. Iberoam. en Educ. Cibern. e Informatica, SIECI 2018 - Memorias. 1, 9–13 (2018).
5. Ortiz, K.A.L.: Sistema de ayuda a la decisión basado en ontologías para el diagnóstico y prevención de las enfermedades en cultivos. (2020).
6. Angel, M., Martínez, Q., Alfonsina, J., Duarte, V., Daniela, M., Rios, G.: Análisis multicriterio para seleccionar técnicas de Inteligencia Artificial para el diagnóstico de enfermedades ganaderas Multicriteria analysis to select Artificial Intelligence techniques for the diagnosis of livestock diseases. 13, 121–135 (2020).
7. Gutiérrez, M., Iñ, V., Carlos, G.-M., Olvera Olvera, C.A., Auxiliadora, M., Esquivel, A., Espinoza García, G., Bordón López, R.: Redes neuronales convolucionales para la detección y clasificación de enfermedades de plantas basadas en imágenes digitales. *Rev. Científica Biológico Agropecu. Tuxpan.* 6, 275–282 (2018).
8. Lázaro, A., Yero, A., Ching, I.S., López, R.S., Alexandra, I., Peláez, M.: Diseño de software para el modelado de sistemas discretos mediante Mapas Cognitivos Difusos. (2018).
9. Gómez Gil, P.: El reconocimiento de patrones y su aplicación a las señales digitales. 219 (2018).
10. Hugo Roche, C.V.: Analisis multicriterio en la toma de decisiones. *Univ. del Val.* 1–23 (2015).
11. Pillajo, S., Pillajo, S.: Diagnóstico inteligente de enfermedades y plagas en plantas ornamentales. 134–148 (2019).
12. Bolívar, F., Basurto, A., Vladimir, D., Mayorga, G., Washington, J., Andachi, S.: Análisis de las causas inaplicabilidad de los reglamentos generales de la Economía Popular. (2020).
13. Calle, W.C., Hidalgo, G.F.A., Navarrete, W.P.: Estudio de los criterios del estrés laboral utilizando mapas cognitivos. *Investig. Operacional.* 41, 689–698 (2020).
14. Papageorgiou, E., Hatwagner, M., Buruzs, A., Koczy, L.: A Concept Reduction Approach for Fuzzy Cognitive Map Models in Decision Making and Management. *Neurocomputing.* 232, (2016). <https://doi.org/10.1016/j.neucom.2016.11.060>.
15. Rickard, J., Aisbett, J., Yager, R.: Computing With Words in fuzzy cognitive maps. Presented at the (2015). <https://doi.org/10.1109/NAFIPS-WConSC.2015.7284135>.
16. Al-subhi, S.H., Antonio, P., Rubio, R., Piñero, P.Y., Mahdi, G.S.S.: Sistema de Apoyo a la Toma de Decisiones Basado en Mapas cognitivos Neutrosóficos para Instituciones que atienden a Embarazos con Alto Riesgo por Enfermedades Cardiovasculares Decision Making Support System Based on Neutrosophic Cognitive Maps for institu. 13, 16–29 (2019).
17. Vázquez, M.L., Smarandache, F.: Neutrosofía: Nuevos avances en el tratamiento de la incertidumbre. (2018).
18. Vera-Mora, G., Leyva-Vásquez, M., León-Acurio, J., Botto-Tobar, M.: Fuzzy Cognitive Maps for the analysis of mental models. *Espacios.* 39, (2018).
19. Hughes, D.P., Salathe, M.: An open access repository of images on plant health to enable the development of mobile disease diagnostics. (2015).
20. Ángel Omar González Frayre\*, Carlos Alejandro Guerrero Méndez, Carlos Alberto Olvera Olvera\*, Francisco Eneldo López Monteagudo, Daniela López Betancur, Valeria Maeda Gutiérrez, S.V.B.: ESTUDIO Y COMPARATIVA DE ALGORITMOS DE DETECCIÓN DE OBJETOS CON REDES NEURONALES ARTIFICIALES CONVOLUCIONALES PARA LA DETECCIÓN DE ENFERMEDADES EN HOJAS. 1–6 (2019).
21. Rangarajan, A.K., Purushothaman, R., Ramesh, A.: Tomato crop disease classification using pre-trained deep learning algorithm. *Procedia Comput. Sci.* 133, 1040–1047 (2018). <https://doi.org/10.1016/j.procs.2018.07.070>.

22. Thakre, G.: A Study on Real Time Plant Disease Diagnosis System. 3, 1118–1124 (2017).