



Revista Internacional de Investigación e Innovación Tecnológica

Página principal: www.riit.com.mx

Sistema difuso Takagi-Sugeno para predecir el riesgo de propagación de Sigatoka Negra *Mycosphaerella fijiensis* en el cultivo de plátano

Takagi-Sugeno fuzzy system to predict propagation risk of Black Sigatoka *Mycosphaerella fijiensis* in banana crop

Rosales-Manzo, D., García-Díaz, N., Ruiz-Tadeo, A., García-Virgen, J., Farías-Mendoza, N.

Tecnológico Nacional de México / I.T. Colima, Av. Tecnológico No. 1, Colonia Liberación, C.P. 28976, Villa De
Álvarez, Colima, México.

g1846015@itcolima.edu.mx, ngarcia@itcolima.edu.mx, aruiz@itcolima.edu.mx, jgarcia@itcolima.edu.mx,
nfarias@itcolima.edu.mx

Innovación tecnológica: Aplicación de Lógica Difusa para la detección y predicción de patógenos en cultivos de plátano.

Áreas de aplicación industrial: Ciencias de la Computación, Computación inteligente, Inteligencia Artificial.

Enviado: 26 agosto 2019.

Aceptado: 11 marzo 2020.

Abstract

Banana plantation are the fourth most important crop worldwide and the most important tropical fruit. Their cultivation is carried out in more than 120 countries, producing approximately 100 million tons per year. México is one of the principal banana producers and exporters. However, its quality is affected by diseases such as black sigatoka, which, since its first appearance in the country in 1981, has been the disease that generates the greatest economic losses, because it has not been able to eradicate due to the climatic conditions in which it spreads. The principal variables that affect black sigatoka's presence are temperature and relative humidity; and if it is not controlled, the pathogen can reduce up to 50 % the bunch weight and causes losses up to 100 % of the production. This research paper proposes a fuzzy inference system Takagi-Sugeno type, with a constant output, to determine the risk of black sigatoka proliferation in banana crops, through the analysis of temperature (13-38 °C) and relative humidity (0-100 %). The fuzzy system was

developed in two applications, 1) MATLAB fuzzy logic tool and, 2) the library JFuzzyLogic of JAVA language. For testing, historical data of monthly average of temperature and relative humidity were used, from January 2015 to June 2019, in Manzanillo, one of the cities with the greatest banana production in Colima state, México, obtaining similar results with both applications. For the system validation the determination coefficient (r^2) was applied, with results greater than 0.9, demonstrating that the predictive model is acceptable. This research presents an innovative approach using a Takagi-Sugeno diffuse system with constant output that will help to prevent the risk of black sigatoka proliferation, allowing banana crop growers to have a tool to effectively fight the pathogen.

Key Words: fuzzy logic, pathogens, fuzzy inference system.

Resumen

La plantación de plátano representa el cuarto cultivo más importante a nivel mundial y la fruta tropical de mayor importancia, su cultivo se realiza en más de 120 países, produciendo aproximadamente 100 millones de toneladas al año. México es uno de los principales países productores y exportadores de plátano. Sin embargo, su calidad se ve afectada por enfermedades tales como la sigatoka negra, que ha sido la enfermedad que genera mayores pérdidas económicas, puesto que no se ha logrado controlar debido a las condiciones climáticas en las que se propaga. Las principales variables que influyen en la aparición de la sigatoka negra son la temperatura y la humedad relativa; y si no se controla, el agente patógeno puede reducir hasta en 50 % del peso del racimo y causar pérdidas de hasta 100 % de la producción. Este trabajo de investigación propone un sistema de inferencia difuso tipo Takagi-Sugeno, con salida constante, para determinar el riesgo de proliferación de la sigatoka negra en cultivos de plátano, por medio del análisis de la temperatura (13-38 °C) y la humedad relativa (0-100 %). El sistema difuso se desarrolló en dos aplicaciones; siendo éstas, la herramienta de lógica difusa de MATLAB y la librería JFuzzyLogic del lenguaje JAVA; para las pruebas se utilizaron datos históricos del promedio mensual de temperatura y humedad relativa, desde enero de 2015 hasta junio de 2019, en Manzanillo, uno de los municipios de mayor producción de plátano del estado de Colima, obteniendo resultados similares con ambas aplicaciones. Para la validación del sistema se aplicó el coeficiente de determinación (r^2), debido a que esta métrica ha sido utilizada en trabajos previos de investigación, con resultados mayores a 0.9, demostrando que el modelo predictivo es aceptable. Esta investigación presenta un enfoque innovador utilizando un sistema de inferencia difuso tipo Takagi-Sugeno con salida constante que contribuye a prevenir el riesgo de proliferación de la sigatoka negra, permitiendo a los productores de cultivos de plátano tener una herramienta para combatir eficazmente el agente patógeno.

Palabras clave: lógica difusa, agentes patógenos, sistema de inferencia difuso.

I. Introducción

El cultivo de plátano es una actividad agrícola con gran importancia a nivel mundial, puesto que es una buena fuente de ingresos. Los plátanos son el cuarto cultivo más importante a nivel mundial y el fruto tropical más

importante por su consumo internacional (Manzo-Sánchez et al., 2014). El cultivo de plátano se realiza en más de 120 países, produciendo aproximadamente 100 millones de toneladas al año. Éste es el principal alimento de al menos 400 millones de

personas, ya que cuenta con carbohidratos, vitaminas y minerales (FAO, 2018).

Globalmente, el plátano es una de las frutas más populares. Su valor nutricional incluye un bajo contenido en grasa y azúcar, pero mayor contenido en minerales, fibra y vitaminas hace que el plátano sea popular entre los consumidores. En 2018, las exportaciones mundiales de plátano alcanzaron un récord de 19.2 millones de ton. La Unión Europea, los Estados Unidos y Rusia son los principales importadores de plátano, debido a que su clima no es adecuado para su cultivo. Por lo tanto, la mayoría de los plátanos se importan de países tropicales y subtropicales como Ecuador, Colombia, Costa Rica y Filipinas (Wang et al., 2020).

México es uno de los principales países productores y exportadores de plátano, ocupando el sexto lugar de los países exportadores en América Latina con aproximadamente 500 mil ton de plátano (FAO, 2018). De acuerdo con la FAO (2018), en el 2018 en México se estableció una intención de cosecha de 2.3 millones de ton, de las cuales en el estado de Colima se estimaron aproximadamente 206 mil ton, ubicándolo en el 4^{to} lugar a nivel nacional a pesar de la reducida superficie, en comparación con los otros estados productores.

La calidad del cultivo de plátano se ve afectada por la presencia de plagas y enfermedades tal como la sigatoka negra (SN), siendo ésta la enfermedad que más presencia tiene en los cultivos de plátano del estado de Colima, la cual fue detectada por primera vez en el año 1989, ocasionando pérdidas y aumentando los costos en la producción, debido al uso de agroquímicos para el tratamiento y control de la enfermedad (Vázquez Castrejón et al., 2005).

En el estado de Colima, los cultivos se han visto afectados por la SN desde su primera aparición, puesto que no se ha logrado controlar completamente debido a que las condiciones climáticas para que se desarrolle la planta de plátano, son similares a las que propician que se propague el patógeno. Por ello, a lo largo de los años en la geografía del estado se han generado mermas de aproximadamente del 50 % dentro de los cultivos (Vázquez Castrejón et al., 2005).

Por medio de investigación de campo y experiencia de los investigadores, se observaron casos en que los productores de plátano prefieren dejar morir el cultivo y perder toda la producción de plátano, para evitar gastos innecesarios, que no se recuperan. Asimismo, estas situaciones son peligrosas para los cultivos aledaños, debido a que el hongo puede transportarse fácilmente hacia otras plantaciones de plátano cuando el foco de infestación se encuentra cercano.

La SN es causada por el hongo *Mycosphaerella fijiensis* Morelet, ocasionando que los racimos y los frutos tengan menor peso e incluso ocasionando la madurez prematura del fruto. La presencia de la enfermedad se puede reconocer con la aparición de rayas o estrías de color amarillo o marrón en las hojas (Álvarez et al., 2013). Además, al ser un hongo que se transmite sexualmente mediante esporas, puede moverse de una planta infectada a una planta sana.

Con información obtenida de la Álvarez et al. (2013), la principal causa de la aparición de la SN es la condición de las variables de temperatura y humedad relativa, aunque hay trabajos relacionados en los que se incluyen la variable precipitación tales como Ramírez et al. (2012) y Torrado-Jaime & Castaño-Zapata (2008). Asimismo, estos autores hacen énfasis en que esta variable es más importante en las épocas lluviosas, por tal

motivo en ese trabajo solo se incluyeron las variables climáticas de temperatura y humedad relativa, las cuales son las que más influyen en la proliferación de la Sigatoka durante toda la época del año.

Por otra parte, la sigatoka amarilla (SA) es ocasionada por el hongo *Mycosphaerella musicola* (Villalobos Arámbula et al., 2019), teniendo como similitud con la SN la propagación por medio del viento, afectación a las hojas, madurez prematura de los frutos y pérdida de la producción de la cosecha del plátano. A diferencia de la SN, la SA se presenta con manchas pequeñas amarillas y a los pocos días aumentan. Además, las condiciones climáticas entre ambas tienen una variación, como se muestra en la Tabla 1.

Tabla 1. Condiciones climáticas de la SN y SA.

Tipo de sigatoka	Temperatura	Humedad
Negra	23-28 °C	80-100 %
Amarilla	Media 25 °C o mayores	90-100 %

Fuente: (Álvarez et al., 2013) (Contreras & Tenaglia, 2015).

Consultando con productores de la región, se descubrió que la SN tiene más presencia en el estado de Colima, debido a que abarca mayor rango de las condiciones climáticas que propician su aparición, además de ser más agresiva y fácil de propagarse que la SA.

La humedad relativa es una variable importante para el crecimiento del plátano, debido a que el cultivo de plátano requiere de humedad constante, ya que la planta está constituida por 85 % de agua (Álvarez et al., 2013). De acuerdo con Cárdenas-Valdovinos et al. (2017), la humedad relativa es la expresión porcentual de la cantidad de vapor de agua presente en el aire con respecto a la máxima posible para unas condiciones dadas de presión y temperatura y su medición es de 0 a 100 %.

La temperatura es la magnitud física que expresa el grado o nivel de calor del ambiente (Cárdenas-Valdovinos et al., 2017). El plátano requiere de temperaturas relativamente altas que varían de 20 a 30 °C, de lo contrario, puede sufrir daños y su desarrollo es más lento.

Por lo cual, el monitoreo de dichas variables (temperatura y humedad relativa) es una pieza fundamental para la prevención y detección de la enfermedad. De acuerdo con INTAGRI (2018) e Interempresas Media (2019), las condiciones climáticas de temperatura y humedad relativa pueden ocasionar afectaciones al cultivo de plátano; si la temperatura es menor a 13 °C el crecimiento de la fruta se detiene, además, puede presentar decoloración de la parte exterior, pedúnculo pálido, los tejidos de la subepidermis forman rayas marrón-oscuros, fallan en la maduración, y, en algunos casos, se broncea la pulpa; si la humedad es menor a 90 % la fruta pierde agua por las zonas rozadas más rápidamente y el color pasa desde marrón a negro.

Actualmente, existen muy pocos sistemas comerciales para el monitoreo de cultivos de plátano y detección de la SN, a pesar de la gran cantidad de trabajos relacionados, la mayoría se centra en la detección cuando la enfermedad está presente en el cultivo. Algunos trabajos como el propuesto por Cárdenas-Valdovinos et al. (2017), quienes construyeron un módulo de censado de humedad relativa y temperatura, permite examinar variables por medio de lógica difusa utilizando un sistema de inferencia tipo Mamdani para la detección del riesgo de proliferación. Por otro lado, Subert-Semanat (2018) implementó una casa meteorológica, para la recolección de datos temperatura, intensidad y duración de las lluvias y evaporación, analizó los datos por medio del método Stover para la detección y realizó la

correlación entre los datos y la gravedad de la enfermedad para la predicción del patógeno.

En cambio, Nagaraju & Shankar (2017) realizaron una red de sensores inalámbricos para obtener la temperatura, humedad relativa, humedad del suelo y lluvia, elaboraron un análisis para encontrar patrones basados en el contexto para el cultivo, comparando los datos obtenidos por medio de los sensores con los valores almacenados en una base de datos para determinar la gravedad de la SN. Cuevas-Gutiérrez et al. (2015) en su trabajo de investigación presentaron un sistema de adquisición y análisis de información para determinar la severidad de la SN en el cultivo de plátano, por medio de una aplicación móvil para realizar muestreos de la enfermedad, basándose en el método de Stover, permitiendo conocer el estado fitosanitario de la huerta.

Por otro lado, Taghoy & Flores Villaverde (2018) implementaron un sistema automatizado para determinar la vida útil de una fruta de plátano mediante lógica difusa. En la cual elaboraron una cámara donde colocan la fruta recolectando datos por medio del sensor de gas etileno MQ3 y el sensor de humedad y temperatura DHT22, y los analizaron utilizando la herramienta de lógica difusa de MATLAB para determinar la vida útil de la fruta. Flores-Gallegos et al. (2017) presentaron el modelado de un sistema difuso de inferencia tipo Mamdani, elaborado con la caja de herramientas de lógica difusa de MATLAB, para monitorear la temperatura y humedad relativa en macro túneles de enraizamiento de esquejes en viveros, aumentando la productividad al obtener un incremento en el índice de sobrevivencia de esquejes.

García et al. (2017) utilizaron otra rama de Inteligencia Artificial (redes neuronales) para procesar imágenes e identificar plagas en cultivos de plátano. Estos autores tomaron

fotos por medio de drones aéreos y las resolvieron utilizando imágenes procesadas mediante el software de simulación MATLAB empleando técnicas de redes neuronales y de patrón de binario local; sin embargo, y a pesar de la visión innovadora, solo se enfocaron en la detección cuando la enfermedad estaba ya presente en el cultivo.

Varios de los estudios presentados utilizan el método Stover (Cuevas-Gutiérrez et al., 2015; Subert-Semanat, 2018). De acuerdo con Orozco-Santos et al., 2013, el método Stover se basa en la cuantificación del estado de desarrollo de la enfermedad, según los síntomas que causa en las plantas afectadas tales como el tipo y número de lesiones, número de hojas afectadas, porcentaje de área foliar afectada, hoja más joven infectada y número de hojas funcionales, cual no ayuda en la prevención de la enfermedad, pero detecta cuando la planta ha sido infectada. Nagaraju & Shankar, 2017 y Subert-Semanat, 2018 involucran variables que no influyen significativamente en la presencia del agente patógeno. Solo un estudio emplea lógica difusa, pero utilizando un sistema de inferencia difuso tipo Mamdani para determinar el riesgo de proliferación (Cárdenas-Valdovinos et al., 2017), sin realizar uso de métrica para validar sus resultados, tal como se llevó a cabo en el presente artículo. Por lo anteriormente descrito, en este trabajo se propone un sistema difuso (SD) Takagi-Sugeno para monitoreo de humedad y temperatura de cultivos de plátano con la finalidad de identificar el riesgo de proliferación de la SN en el municipio de Manzanillo, Colima, México.

II. Materiales y equipos

Se utilizó la herramienta de lógica difusa de MATLAB empleando el SD Takagi-Sugeno con salida constante. La otra herramienta con la que se realizó el SD propuesto es con el

lenguaje JAVA utilizando la librería JFuzzyLogic.

III. Métodos experimentales

La investigación se realizó en la División de Estudios de Posgrado e Investigación (DEPI) en el Instituto Tecnológico de Colima, ubicado en la ciudad de Villa de Álvarez, Colima, México.

3.1. Lógica Difusa

De acuerdo con Zadeh (1965), un conjunto difuso es una clase de objetos que poseen un grado continuo de membresía, permitiendo las nociones de inclusión, unión, intersección, complemento, entre otras en el contexto de conjuntos difusos. La lógica difusa, como su nombre lo indica, es la lógica subyacente a los modos de razonamiento que son aproximados en lugar de exactos. La importancia de la lógica difusa se deriva del hecho de que la mayoría de los modos de razonamiento humano, y especialmente la razón de sentido común, son de naturaleza aproximada (Zadeh, 1996).

La lógica difusa representa modelos o conocimiento utilizando la lógica IF-THEN en la forma de “si X entonces Y” (“if X then Y”). Generalmente existen dos tipos de Sistemas de Inferencia Difusa (SID o por sus siglas en inglés FIS), Mamdani y Takagi-Sugeno.

3.1.1. FIS Mamdani

Las reglas en sistemas difusos estándares tienen la forma:

R_i : SI x_1 es A_1^i & ... & x_n es A_n^i ENTONCES y es B^j

Donde:

- R_i denota la i -ésima regla;
- $i = 1, \dots, N_r$, donde N_r es el número de reglas;
- x_n es la n -ésima entrada del sistema difuso;
- A_n^j y B^j son conjuntos difusos descritos por funciones de membresía (FM) (Mamdani, 1976).

3.1.2. FIS Takagi-Sugeno

Las reglas en SD funcionales tienen la forma:

R_i : SI x_1 es A_1^i & ... & x_n es A_n^i ENTONCES y es $f_j(x)$

Donde:

- R_i es la i -ésima regla;
- x_1 y hasta x_n son las entradas del sistema;
- A_n^1 y hasta A_n^j son conjuntos difusos;
- $f_j(x)$ es un valor constante con base a las variables de entrada, en lugar de una proposición difusa (Takagi & Sugeno, 1985).

Para este trabajo de investigación se implementó el FIS tipo Takagi-Sugeno para el SD propuesto.

3.2. Variables

Para la creación del SD se definieron las variables de entrada, siendo estas la temperatura y la humedad relativa, permitiendo determinar la variable de salida, riesgo de proliferación de la SN. De acuerdo con Álvarez et al. (2013), se especifica que las condiciones óptimas para el crecimiento de la SN se ocasionan cuando las condiciones de humedad y temperatura se encuentran entre los valores mostrados en la Tabla 1.

3.2.1. Variables de entrada

Las variables de entrada del SD son las variables climáticas que influyen en la aparición de la SN, temperatura y humedad relativa.

Humedad Relativa

La Tabla 2 muestra los valores utilizados en el SD propuesto para la humedad, con base en los rangos de medición (0-100 %) y en el rango de humedad para la SN mostrado en la Tabla 1.

Tabla 2. Rangos de la humedad relativa.

FM	Rango
Poca	0 a 35 %
Media	22.5 a 77.5 %
Mucha	65 a 100 %

De acuerdo con López-Martin et al. (2008), las FM trapezoidales tienen cuatro parámetros, donde a corresponde al ángulo inferior izquierdo, b al ángulo superior izquierdo, c al ángulo superior derecho y finalmente d al ángulo inferior derecho y se definen como:

$$FM(x) = 0 \text{ si } -\infty < x \leq a$$

$$FM(x) = 1 \text{ si } b \leq x \leq c$$

$$FM(x) = 0 \text{ si } d \leq x < \infty$$

Como se muestra en la Figura 1 se optó por emplear FM trapezoidales para la variable de entrada humedad relativa, debido a que son las FM que mejor se adaptan por su forma geométrica, al rango de humedad que propicia la aparición de la SN, como se puede observar en la Tabla 1.




Figura 1. FM de la humedad relativa.

Los valores de pertenencia de las funciones de membresía de la humedad relativa fueron obtenidos con base al valor de la humedad para la SN en la Tabla 1 y fueron ajustados de manera empírica (con base en la observación de los hechos in situ). Además, al utilizar FM trapezoidales se definen 4 valores por cada una, como se muestran en la Tabla 3.

Tabla 3. Valores de pertenencia de la humedad relativa.

FM	a	b	c	d
Poca	0	0	20	35
Media	22.5	42.5	57.5	77.5
Mucha	65	80	100	100

Temperatura

La Tabla 4 muestra los rangos utilizados en el SD para la temperatura, con base en el rango de la temperatura para la SN mostrado en la Tabla 1.

Tabla 4. Rangos de la temperatura.

FM	Rango
Baja	13 a 24 °
Media	18 a 33 °
Alta	27 a 38 °

Para la variable de entrada temperatura, se utilizaron FM gaussianas, como se muestra en la Figura 2, puesto que se ajustan al rango de temperatura que favorece la proliferación de SN, mostrado en la Tabla 1. Las FM gaussianas tienen dos parámetros, uno de

ellos (k) determina la curvatura y el otro (m) corresponde al punto central de la curva y se definen como (López-Martin et al., 2008):

$$FM(x) = e^{-k(x-m)^2}$$




Figura 2. FM de la temperatura.

Los valores de pertenencia de las funciones de membresía de la temperatura fueron obtenidos con base al valor de la temperatura para la SN en la Tabla 1, estos se ajustaron de manera empírica (con base en la observación de los hechos in situ). Al emplear FM gaussianas se requieren 2 valores por cada una, como se muestran en la Tabla 5.

Tabla 5. Valores de pertenencia de la temperatura.

FM	k	m
Baja	4	13
Media	2	25.5
Alta	4	38

Tabla 7. Reglas del SD.

Humedad/ Temperatura	Poca (0 – 35 %)	Media (22.5 - 77.5 %)	Mucha (65 – 100 %)
Baja (13 – 24 °)	Bajo	Bajo	Medio
Media (18 – 33 °)	Medio	Medio	Alto
Alta (27 – 38 °)	Bajo	Bajo	Medio

3.4. Pruebas

Para realizar pruebas de ambas herramientas, tanto el de MATLAB como el de JAVA, se utilizaron datos históricos del promedio mensual de la temperatura y humedad relativa en el municipio de Manzanillo, Colima, México, desde Enero de 2015 hasta Junio de

3.2.2. Variable de Salida

La principal característica de la lógica difusa tipo Takagi-Sugeno, es que la salida es una constante, en lugar de una FM. La Tabla 6 muestra los valores de salida dados para el riesgo de proliferación, tomando como base el grado de pertenencia de un conjunto difuso, el cual está en el rango de 0 a 1.

Tabla 6. Valores del riesgo de proliferación de la enfermedad de SN en el cultivo de plátano.

Conjunto Difuso	Valor
Bajo	0
Medio	0.5
Alto	1

3.3. Reglas

Las reglas del SD se crearon basándose en las condiciones climáticas que propician la aparición de SN, presentadas en la Tabla 1. Los cambios hechos en la entrada afectan a la salida. Las combinaciones de las reglas establecidas se muestran en la Tabla 7.

2019, los cuales se obtuvieron de Meteored (2019); Tutiempo Network, S.L. (2019), con un conjunto total de 54 datos. Esto permitió tener un conjunto de datos que representan las condiciones mes con mes de las variables climáticas que influyen en la aparición de la SN.

IV. Discusión de Resultados

Como resultado se obtuvo el modelado, simulación y validación del SD tipo Takagi-Sugeno, a partir de las variables climáticas de temperatura y humedad relativa, obteniendo el riesgo de proliferación de la SN. En la Figura 3 se observa el modelado del SD propuesto, con las dos variables climáticas de entrada (Temperatura y Humedad) y la variable de salida (Riesgo).




Figura 3. Modelado del SD para predecir la proliferación de SN.

Este sistema fue simulado con MATLAB, obteniendo la relación de las variables de entrada para determinar la variable de salida. Como se aprecia en la Figura 4, se puede observar que el mayor riesgo de proliferación respecto a la variable humedad se concentra en la parte alta, mientras que en la variable temperatura se concentra en la parte central. Por otra parte, se puede apreciar que a menor humedad menor riesgo de proliferación, en cambio, el menor riesgo de proliferación en relación con la variable temperatura se ubica en los extremos inferior y superior.

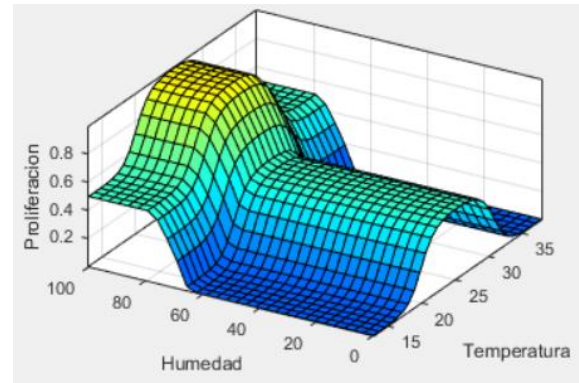


Figura 4. Simulación del SD.

Cabe mencionar que este SD fue implementado tanto en la herramienta de MATLAB como en JFuzzyLogic, para saber si existe alguna diferencia en el coeficiente de determinación con ambas herramientas. En la Figura 5 se puede observar el análisis que realiza MATLAB para determinar el riesgo, colocando el valor de las variables de entrada en sus respectivas FM, obteniendo la variable de salida.

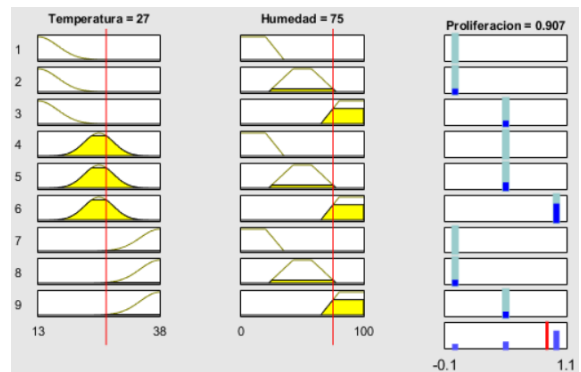


Figura 5. Resultados obtenidos del riesgo de proliferación en MATLAB.

Mientras que JAVA solo muestra el resultado del riesgo y los valores de la variable de salida establecidos, como se puede observar en la Figura 6.




Figura 6. Resultados obtenidos del riesgo de proliferación en JAVA.

Los resultados obtenidos (Tabla 8), son muy similares en ambas herramientas, con pequeñas variaciones; sin embargo, existen algunos datos atípicos, remarcados en negritas, donde la diferencia es más notoria (una variación del 10 %); esto puede deberse a cómo la herramienta utilizada determina la salida, puesto que en ambas se configuraron los mismos rangos y condiciones.

Tabla 8. Implementación del SD.

Temperatura	Humedad	MATLAB	JAVA
27	54	0.484	0.485
26	60	0.492	0.494
26	57	0.492	0.494
27	66	0.536	0.533
29	63	0.365	0.366
30	64	0.185	0.185
31	59	0.047	0.048
31	60	0.047	0.048
30	74	0.572	0.420
30	78	0.685	0.685
30	76	0.639	0.508
29	73	0.717	0.633
27	66	0.536	0.533
27	72	0.799	0.790
26	68	0.640	0.638
26	73	0.843	0.839
28	77	0.940	0.911
29	74	0.752	0.645
30	72	0.500	0.420
30	74	0.572	0.420
29	75	0.786	0.662
30	75	0.606	0.433
28	75	0.876	0.830
27	75	0.905	0.895
26	72	0.806	0.803
25	73	0.843	0.839
26	76	0.945	0.941
25	76	0.945	0.941
25	80	0.992	0.994
29	80	0.865	0.866
30	74	0.572	0.420
30	80	0.685	0.685

29	83	0.865	0.866
30	79	0.685	0.685
30	78	0.685	0.685
27	74	0.871	0.862
26	75	0.913	0.908
27	76	0.938	0.927
26	76	0.945	0.941
25	76	0.945	0.941
29	76	0.813	0.690
29	77	0.850	0.798
31	74	0.435	0.316
30	77	0.670	0.614
30	77	0.670	0.614
29	80	0.865	0.866
27	80	0.984	0.985
27	74	0.871	0.862
27	73	0.836	0.827
25	75	0.913	0.908
26	74	0.879	0.875
25	75	0.913	0.908
26	77	0.977	0.972
29	74	0.752	0.645

En su trabajo Jeng-Fung & Quang Hung (2014), mencionaron que existen diferentes métricas para evaluar el desempeño de los modelos difusos, neuro-difusos y de redes neuronales, utilizados para comparar los valores estimados y los valores reales. Para evaluar el desempeño del SD elaborado en este trabajo se usó el coeficiente de determinación (r^2). De acuerdo con Humphrey (1995), se considera aceptable un modelo predictivo cuando $r^2 \geq 0.5$. Esta misma métrica se ha utilizado en otros trabajos de investigación en los que involucran las variables de temperatura y

humedad, aplicados a modelos difusos y/o neuro-difusos (López-Cruz & Hernández-Larragoiti, 2010).

4.1. Resultados obtenidos de MATLAB

El coeficiente de determinación obtenido con MATLAB es:

$$R - \text{cuadrada} = 0.903$$

La Tabla 9 muestra el análisis de varianza de los resultados obtenidos en el SD elaborado con MATLAB.

Tabla 9. Análisis de varianza de los resultados de MATLAB.

Fuente	Suma de cuadrados	GI	Cuadrado Medio	Razón-F	Valor-P
Modelo	2.4192	2	1.2096	238.06	0.0000
Residuo	0.25913	51	0.00508098		
Total (Corr.)	2.67833	53			

Ya que el valor-P de la tabla de análisis de varianza (Tabla 9) para este modelo es menor a 0.05, existe una relación estadísticamente

significativa entre las variables con un nivel de confianza del 95.0%.

Tabla 10. Análisis de las variables de entrada del modelo en MATLAB.

Parámetro	Estimación	Error		Estadístico	
		Estándar	T	Valor-P	
CONSTANTE	0.781639	0.181356	4.30996	0.0001	
Temperatura	-0.0722901	0.00513534	-14.077	0.0000	
Humedad	0.0267834	0.00156833	17.0777	0.0000	

Con base en el análisis de las variables de entrada (Tabla 10), podemos determinar si el modelo puede simplificarse, note que el valor-P en ambas variables independientes es 0.0000. Puesto que el valor-P es menor que 0.05, ambos términos son estadísticamente significativos con un nivel de confianza del 95.0 %. Consecuentemente, no es conveniente eliminar ninguna variable del modelo.

Tabla 11. Prueba de normalidad de los valores obtenidos en MATLAB.

Prueba	Estadístico	Valor-P
Estadístico W de Shapiro-Wilk	0.876699	0.000008197

La Tabla 11 muestra la prueba de normalidad realizada a los valores obtenidos con MATLAB.

Debido a que el valor-P más pequeño de las pruebas realizadas, mostrado en la Tabla 11, es menor a 0.05, se puede rechazar la idea de que las estimaciones hechas en MATLAB provienen de una distribución normal con 95 % de confianza. La Figura 7 muestra la gráfica de probabilidad normal para el conjunto de datos MATLAB.




Figura 7. Gráfico de probabilidad normal de los datos obtenidos con MATLAB.

4.2. Resultados obtenidos de JAVA

El coeficiente de determinación obtenido con JAVA es:

La Tabla 12 muestra el análisis de varianza de los resultados conseguidos con el SD realizado en JAVA.

$$R - cuadrada = 0.901$$

Tabla 12. Análisis de varianza de los resultados de JAVA.

Fuente	Suma de cuadrados	GI	Cuadrado Medio	Razón-F	Valor-P
Modelo	2.71358	2	1.35679	234.08	0.0000
Residuo	0.295612	51	0.00579631		
Total (Corr.)	3.00919	53			

Puesto que el valor-P en la tabla de análisis de varianza (Tabla 12) es menor que 0.05, existe una relación estadísticamente significativa entre las variables con un nivel de confianza del 95.0 %.

Tabla 13. Análisis de las variables de entrada del modelo en JAVA.

Parámetro	Estimación	Error	Estadístico	Valor-P
		Estándar	T	
CONSTANTE	1.23612	0.193702	6.38156	0.0000
Temperatura	-0.0865657	0.00548493	-15.7825	0.0000
Humedad	0.0255571	0.0016751	15.2571	0.0000


Con base en el análisis de las variables de entrada (Tabla 13), podemos determinar si el modelo puede simplificarse, note que el valor-P en ambas variables independientes es 0.0000. Puesto que el valor-P es menor que 0.05, ambos términos son estadísticamente significativos con un nivel de confianza del 95.0 %. Consecuentemente, no es conveniente eliminar ninguna variable del modelo.

La Tabla 14 muestra la prueba de normalidad realizada a los valores obtenidos con JAVA.

Tabla 14. Prueba de normalidad de los valores obtenidos en JAVA.

Prueba	Estadístico	Valor-P
Estadístico W de Shapiro-Wilk	0.904191	0.000205984

Debido a que el valor-P más pequeño de las pruebas realizadas (Tabla 14) es menor a 0.05, se puede rechazar la idea de que las estimaciones obtenidas por medio de JAVA provienen de una distribución normal con 95 % de confianza. La Figura 8 muestra la gráfica de probabilidad normal del conjunto de datos JAVA.

**Figura 8.** Gráfico de probabilidad normal de los datos obtenidos con JAVA.

4.3 Selección de prueba para comparar muestras

Para seleccionar la prueba se obtuvo la diferencia de los datos obtenidos con MATLAB y JAVA, con un rango desde -0.002 hasta 0.173. Posteriormente se realizó la prueba de probabilidad normal al conjunto obtenido, mostrado en la Tabla 15.

Tabla 15. Prueba de normalidad de la diferencia.

Prueba	Estadístico	Valor-P
Estadístico W de Shapiro-Wilk	0.684925	2.26485E-14

A causa de que el valor-P más pequeño de las pruebas realizadas es menor a 0.05, indica que el conjunto de la diferencia entre los datos de MATLAB y JAVA no proviene de una distribución normal. Por tal motivo, se aplicó la prueba de Wilcoxon (también conocida como Mann-Whitney), la cual se construye combinando las dos muestras, ordenando los datos de menor a mayor, y comparando los rankeos promedio de las dos muestras en los datos combinados, dando como resultado:

$$\text{valor} - P = 0.406652.$$




Figura 9. Gráfico de caja y bigotes de los datos obtenidos con MATLAB y JAVA.

Debido a que el valor-P es mayor o igual que 0.05 y, como se puede observar en la Figura 9, no hay diferencia estadísticamente

significativa entre las medianas con un 95.0 % de confianza.

V. Conclusiones

Con base en los resultados obtenidos se concluye:

- De acuerdo con el modelo propuesto en este trabajo, la utilización de un SD tipo Takagi-Sugeno resulta apropiado para la detección del riesgo de proliferación de la SN, contribuyendo a la detección y control del patógeno.
- El modelo con ambas herramientas es aceptable, debido a que en ambos casos el coeficiente de determinación supera ampliamente el 0.5.
- Con base en el análisis de varianza de los resultados con ambas herramientas, la relación entre las variables es estadísticamente significativa, con una confianza del 95 %.
- La utilización de herramientas puede variar en los resultados obtenidos, aunque la diferencia no es considerable. En este caso, MATLAB obtuvo el mejor (mayor) coeficiente de determinación que JAVA, aunque la diferencia entre ambos es de 0.002, la cual es mínima.

VI. Trabajo a futuro

Una vez elaborado el SD se propone como trabajo a futuro:

- Agregar la variable Viento, debido a que es muy importante para predecir la propagación del patógeno ya que sus estructuras reproductivas son transportadas fácilmente por el mismo.
- Replicar este trabajo con un sistema difuso Mamdani y hacer el comparativo con el presente trabajo, para ver cual tiene más precisión.

- Construir una red de sensores para la recolección de datos.
- Integración y pruebas del SD con el módulo de recolección de datos, para utilizar condiciones climáticas reales.
- Modificar el SD para la detección de un rango más amplio de plagas en distintos cultivos.
- Utilizar otras técnicas de Inteligencia Artificial y comparar resultados.

VII. Agradecimientos

Los autores de este trabajo agradecen al Consejo Nacional de Ciencia y Tecnología (CONACYT), al Instituto Tecnológico de Colima, así como al Programa para el Desarrollo Profesional Docente (PRODEP) por su apoyo brindado para la elaboración de este trabajo.

VIII. Referencias

1. Manzo-Sánchez, G., Orozco-Santos, M., Martínez-Bolaños, L., Garrido-Ramírez E. & Canto-Canche, B. (2014) «*Enfermedades de importancia cuarentenaria y económica del cultivo de banano*» Revista mexicana de fitopatología, vol. 32, n° 2, pp. 89-107.
2. FAO (2018) «*Situación del mercado del banano. Resultados preliminares relativos a 2017*» [En línea]. Disponible: http://www.fao.org/fileadmin/templates/est/COMM_MARKET. [Último acceso: 29 Noviembre 2018].
3. Wang, Z., Erasmus, S. W., Dekker, P., Guo, B., Stoorvogel, J. J. & van Ruth, S. M. (2020) «*Linking growing conditions to stable isotope ratios and elemental compositions of Costa Rican bananas (Musa spp.)*» *Food Research International*, vol. 129, 2020.
4. Vázquez Castrejón, R., Romero Cadena, A. & Figueroa Viera, J. (2005) «*ge tecnológico para el cultivo de plátano*» [En línea]. Disponible: <http://www.campocolima.gob.mx/paginaOEIDRUS/paquete%20tecnologico%20del%20platano.pdf>. [Último acceso: 12 Diciembre 2018].
5. Álvarez, E., Pantoja, A., Gañán, L. & Ceballos, G. (2013) «*La Sigatoka negra en plátano y banano. Guía para el reconocimiento y manejo de la enfermedad, aplicado a la agricultura familiar*» [En línea]. Disponible: <http://www.fao.org/docrep/019/as089s/as089s.pdf>. [Último acceso: 12 Diciembre 2018].
6. Ramírez, C., Castaño, J., Villegas, B., & Aristizábal, M. (2012) «*Efecto de inductores de resistencia sobre las sigatokas negra (Mycosphaerella Fijiensis Morelet) y amarilla (Mycosphaerella Musicola Leach) en plátano*» Revista U.D.C.A Actualidad & Divulgación Científica, 15(12), 363-371.
7. Torrado-Jaime, M., & Castaño-Zapata, J. (2008). «*Incidencia y severidad de las sigatokas negra (Mycosphaerella fijiensis Morelet) y amarilla (Mycosphaerella musicola Leach et Mulder) del plátano según los estados fenológicos*» Agronomía Colombiana, 26(3), 435-442.
8. Villalobos Arámbula, V. M., Trujillo Arriaga, F. J., Ramírez y Ramírez, F. & López Buenfil, J. A. (2019) «*Ficha Técnica Mycosphaerella musicola (Leach)*». [En línea]. Available: https://www.gob.mx/cms/uploads/attachment/file/472513/Ficha_tcnica_Mycosphaerella_musicola.pdf. [Último acceso: 5 Marzo 2020].

9. Contreras, G. B. & Tenaglia G. C. (2015) «Alerta para el control de Sigatoka amarilla en el área productora de banana de la provincia de Formosa,» [En línea]. Available: <https://inta.gob.ar/documentos/alerta-para-el-control-de-sigatoka-amarilla-en-el-area-productora-de-banana-de-la-provincia-de-formosa>. [Último acceso: 5 Marzo 2020].
10. Cárdenas-Valdovinos, E., García-Díaz, N., García-Virgen J. & Flores-Gallegos, E. (2017) «Modelo difuso para predecir la proliferación de plaga “Sigatoka Negra” en el cultivo» Revista de Ingeniería Eléctrica, vol. 1, n° 1, pp. 16-21.
11. INTAGRI (2018) «Requerimientos de Clima y Suelo para el Cultivo de Banano» Serie Frutales , n° 33.
12. Interempresas Media, S.L. (2019) «Plátano, *Musa sp. / Musaceae*» Frutas y Hortalizas, [En línea]. Available: <https://www.frutas-hortalizas.com/Frutas/Poscosecha-Platano.html>. [Último acceso: 1 Noviembre 2019].
13. Subert-Semanat, A. (2018) «Poster: Wireless Sensor Network to Predict Black Sigatoka in Banana Cultivations» Smart Industry & Smart Education, pp. 159-164. DOI: https://doi.org/10.1007/978-3-319-95678-7_18.
14. Nagaraju, B. & Shankar, P. (2017) «Precision Agriculture for Banana Using Wireless Sensor Network» de 2017 International Conference on Computing, Communication, Control and Automation, India. DOI: <https://doi.org/10.1109/ICCUBEA.2017.8464007>.
15. Cuevas-Gutiérrez, J., Flores-Cortés C. & Guerrero, J. (2015) «Evaluación de un sistema de apoyo para el diagnóstico de Sigatoka Negra» Research in Computing Science, vol. 108, n° 1, pp. 73-80.
16. Taghoy, D. M. & Flores Villaverde, J. (2018) «A Fuzzy Logic Approach for the Determination of Cavendish Banana Shelf Life» de TENCON 2018 - 2018 IEEE Region 10 Conference, Korea (South). DOI: <https://doi.org/10.1109/TENCON.2018.8650454>.
17. Flores-Gallegos, E., Farías-Mendoza, N., Silos-Espino, H., García-Díaz, N. & Vargas-González, C.O. (2017) «Procesamiento de imágenes aplicadas a la identificación de agentes patógenos en el cultivo de plátano» Revista Internacional de Investigación e Innovación Tecnológica, vol. 5, n° 29.
18. García, J., Farias, N., Benavides-J, R. & Escobar, E. (2017) «Procesamiento de imágenes aplicadas a la identificación de agentes patógenos en el cultivo de plátano» Revista de las Tecnologías de la Información, vol. 4, n° 13, pp. 23-31.
19. Orozco-Santos, M., García-Mariscal, K., Manzo-Sánchez, G., Guzmán, S., Martínez Bolaños, L., Beltran-García, M., Garrido-Ramirez, E., Torres-Amezcuca, J. & Canto Canche, B. (2013) «La Sigatoka negra y su manejo Integrado en banano» Pacífico Centro: INIFAP. ISBN: 978-607-37-0019-1.
20. Zadeh, L. (1965) «Fuzzy Sets» Information and Control, pp. 338-353. DOI: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X).

21. Zadeh, L. (1996) «*Fuzzy Sets, Fuzzy Logic, and Fuzzy Systems*» de World Scientific, New York. DOI: <https://doi.org/10.1142/2895>.
22. Mamdani, E. (1976) «*Advances in the linguistic synthesis of fuzzy controllers*» International Journal of Man-Machine Studies, p. 669–678. DOI: [https://doi.org/10.1016/S0020-7373\(76\)80028-4](https://doi.org/10.1016/S0020-7373(76)80028-4)
23. Takagi, T. & Sugeno, M. (1985) «*Fuzzy Identification of Systems and its Application to Modeling and Control*» IEEE Transactions on Systems, Man and Cybernetics, pp. 116-132. DOI: <https://doi.org/10.1109/TSMC.1985.6313399>.
24. López-Martín, C., Yáñez-Márquez, C. & Gutiérrez-Tornés, A. (2008) «*Predictive accuracy comparison of fuzzy models for software development effort of small programs*» The journal of systems and software, pp. 949-960. DOI: <https://doi.org/10.1016/j.jss.2007.08.027>
25. METEORED (2019) «*Histórico del clima en Manzanillo*» METEORED. [En línea]. Available: <https://www.meteored.mx/manzanillo/historico>. [Último acceso: 26 Junio 2019].
26. Tutiempo Network, S.L. (2019) «*Clima Manzanillo*» Tutiempo Network, S.L. [En línea]. Available: <https://www.tutiempo.net/clima/ws-766540.html>. [Último acceso: 26 Junio 2019].
27. 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° 5, pp. 2551-2561. DOI: <https://doi.org/10.3233/IFS-141229>.
28. Humphrey, W. S. (1995) «*A Discipline for Software Engineering*» Addison-Wesley Professional. ISBN: 978-0201546101.
29. López-Cruz, I. L. & Hernández-Larragoiti, L. (2010) «*Modelos neuro-difusos para temperatura y humedad del aire en invernaderos tipo cenital y capilla en el centro de México*» Agrociencia, vol. 44, n° 7, pp. 791-805.