

Implementación de un Sistema De Alertas Tempranas Para Prevenir La Propagación De La Enfermedad Sigatoka Negra En Cultivos De Plátano Y Banano En El Municipio De Apartadó (Urabá).

Aldemar de Jesús Correa Hernández ^{1(*)}; Amada Tatiana Naranjo Diaz ²; Joel Enrique Guerrero Urango ³
Amhed Alejandro Cardona Mesa.

¹ *Institución Universitaria Digital de Antioquia, Facultad de Ingeniería, Medellín, Colombia*

³ *Institución Universitaria Digital de Antioquia, Facultad de Administración, Medellín, Colombia*

Resumen: La Sigatoka Negra, provocada por el hongo *Mycosphaerella fijiensis* Morelet, constituye una seria problemática para la producción de banano y plátano en Colombia, impactando considerablemente desde su primera detección en 1983. Esta enfermedad foliar no solo compromete la fotosíntesis de las plantas, disminuyendo la calidad y cantidad del fruto, sino que también eleva los costos de producción agrícola debido a la necesidad imperativa de utilizar fungicidas para su control. La relevancia de este problema se intensifica al considerar la posición central de la región de Urabá en la economía agrícola del país, reconocida por su significativa contribución a la industria bananera nacional.

Ante este panorama, el presente estudio propone la implementación de un sistema de alerta temprana, fundamentado en la aplicación de técnicas avanzadas de Machine Learning y Redes Neuronales Artificiales. El objetivo principal de esta iniciativa es analizar minuciosamente los datos fisicoquímicos de las plantas junto con las condiciones climáticas de la región, identificando patrones y variables críticas como la temperatura, humedad, precipitaciones y velocidad del viento. Estos factores son determinantes en la propagación de la enfermedad y, por ende, en la adopción de estrategias de gestión más efectivas y menos dependientes de químicos.

La recopilación y análisis de datos climáticos abarcan el periodo comprendido entre 2010 y 2019, proporcionando una base sólida para el pronóstico y prevención de la Sigatoka Negra. A través de este enfoque, se pretende no solo mitigar el impacto negativo de la enfermedad en la productividad agrícola, sino también promover prácticas más sostenibles y respetuosas con el medio ambiente. Con ello, se busca una transformación en la gestión de los cultivos de banano y plátano, orientada hacia la sostenibilidad, eficiencia y responsabilidad ambiental.

Palabras clave: clima, especies invasivas, género musa, *mycosphaerella fijiensis*, propagación, variables meteorológicas, Impacto ambiental de fungicidas

Recibido: 18 de enero de 2024. Aceptado: 2 de septiembre de 2024

Received: January 18th, 2024. Accepted: September 2nd, 2024

Implementation of an Early Warning System to Prevent the Spread of Black Sigatoka Disease in Banana and Plantain Crops. Apartadó (Urabá).

Abstract: Black Sigatoka, caused by the fungus *Mycosphaerella fijiensis* Morelet, is a serious problem for banana and plantain production in Colombia and has had a considerable impact since its first detection in 1983. This foliar disease not only compromises plant photosynthesis, reducing fruit quality and quantity, but also increases agricultural production costs due to the imperative need to use fungicides for its control. The relevance of this problem is intensified when considering the central position of the Urabá region in the agricultural economy of the country, recognized for its significant contribution to the national banana industry.

Given this scenario, this study proposes the implementation of an early warning system, based on the application of advanced Machine Learning and Artificial Neural Networks techniques. The main objective of this initiative is to thoroughly analyze the physicochemical data of the plants together with the climatic conditions of the region, identifying patterns and critical variables such as temperature, humidity, rainfall and wind speed. These factors are determinants in the spread of the disease and, therefore, in the adoption of more effective and less chemical-dependency management strategies.

The collection and analysis of climate data covers the period from 2010 to 2019, providing a solid basis for forecasting and prevention of Black Sigatoka. Through this approach, the aim is not only to mitigate the negative impact of the disease on agricultural productivity, but also to promote more sustainable and environmentally friendly practices. The aim is to transform the management of banana and plantain crops, with a focus on sustainability, efficiency and environmental responsibility.

Keywords: climate, invasive species, musa genus, *mycosphaerella fijiensis*, propagation, weather variables, environmental impact of fungicides, environmental impact of fungicides

1. INTRODUCCIÓN

La Sigatoka negra, causada por el hongo *Mycosphaerella fijiensis* Morelet, es una enfermedad foliar destructiva que afecta principalmente a plantas del género *Musa*, incluyendo cultivos de banano y plátano. La sigatoka negra es considerada una de las enfermedades más limitantes en la producción de plátano y banano a nivel mundial, con un impacto significativo en el rendimiento y la calidad de los cultivos (Cedeño-Zambrano et al, 2021). En Colombia, la enfermedad se reportó por primera vez en 1983 y desde entonces se ha extendido rápidamente por todo el país (Manabí-El Carmen, 2023). La Sigatoka negra representa una amenaza importante para la industria agrícola, ya que los cultivos de plátano y banano son esenciales para el sustento de millones de personas en Colombia (Rojas, 2021).

El estado actual y la propagación de la Sigatoka Negra en Colombia es motivo de preocupación. Se estima que la enfermedad afecta aproximadamente al 70% de los cultivos de banano y plátano en el país (Barrera, Barraza, & Campo, 2016). La rápida propagación de la Sigatoka en Colombia ha resultado en importantes pérdidas económicas para los agricultores y la industria agrícola en general.

En el caso colombiano el hongo se localizó en la zona del Urabá- Antioqueño por primera vez en el año de 1981, inicialmente no generó mayor daño, pero posteriormente en el año 1986 se hallaron alrededor de 600.000 cajas de banano invadidas del hongo, luego de esto la plaga se trasladó al Magdalena, siendo esta enfermedad el mayor problema de pérdida de la cosecha bananera de exportación. Para el caso de la Sigatoka Negra, obedece a causas bióticas y abióticas, los cuales están regidos por condiciones de humedad, temperatura y el desarrollo de la afección, sugiere la existencia de una dependencia con los factores climáticos, los cuales limitan la repercusión y el rigor de la enfermedad. Cabe resaltar que esta plaga muestra una dinámica estacional establecida por los cambios de la temperatura y lluvias durante el año. (Forero, Pira neque Gamba sica, & Menjívar Flores, 2012)

Desafortunadamente, la sigatoka negra puede causar una disminución significativa en la producción de plátanos y bananos. Las hojas afectadas por la enfermedad se marchitan prematuramente, lo que reduce la capacidad de la planta para realizar la fotosíntesis y producir nutrientes necesarios para el desarrollo adecuado de los frutos, además los plátanos y bananos infectados por el patógeno pueden presentar una calidad inferior. Las manchas y lesiones causadas por la enfermedad pueden afectar la apariencia y el sabor de los frutos, lo que reduce su valor comercial, asimismo, el control y manejo de la sigatoka negra requiere el uso de fungicidas y medidas de manejo cultural, lo que implica un mayor costo de producción para los agricultores, eso sin contar con las implicaciones del el impacto ambiental negativo que tiene el uso de fungicidas, provocando contaminar el suelo y el agua, afectando la salud de los ecosistemas locales. Por tal razón se plantea el desarrollo de un sistema de alertas tempranas para prevenir la Propagación de la enfermedad Sigatoka Negra en cultivos de plátano y Banano en la región de Urabá, a partir de determinar las condiciones meteorológicas y fisicoquímicas de

las plantas, las cuales nos permitirán conocer a qué temperatura y humedad se puede desarrollar el patógeno, luego de esto se hará el análisis de datos utilizando técnicas estadísticas y de inteligencia artificial y para finalizar se validará la eficiencia de los algoritmos y su precisión con el fin de evaluar datos recolectados en los cultivos de plátano y banano.

2. MATERIALES Y MÉTODOS

2.1 La región de estudio

La región del Urabá es fundamental para el sector bananero en Colombia, ya que allí se ubican alrededor de 65.000 hectáreas de cultivos que son importantes para el desarrollo productivo. De las aproximadamente 95.000 hectáreas de producción agrícola en Urabá, unas 35.000 son dedicadas a la producción de bananos para exportación, las cuales generan más de 25.000 empleos directos y entre 65.000 y 100.000 empleos indirectos en la zona. Además, hay unas 30.000 hectáreas de cultivos de plátano, que benefician a unas 8.000 familias. (Instituto Colombiano Agropecuario-ICA, 2021).

2.2 La Sigatoka Negra

La Sigatoka negra es una enfermedad causada por el hongo *Mycosphaerella fijiensis* Morelet, y representa el principal problema fitopatológico de los cultivos de banano y plátano en Centroamérica. Esta enfermedad afecta las hojas de las plantas, lo que provoca una rápida degradación del área foliar y disminuye la capacidad fotosintética de las mismas, afectando el crecimiento y la productividad de las plantas. Además, la Sigatoka negra también produce una disminución en la calidad del fruto. (Elizabeth Álvarez, Pantoja, Gañán, & Ceballos, 2013)

2.3 Machine Learning

El Machine Learning se basa en la idea de que las máquinas pueden aprender de los datos, identificar patrones y hacer predicciones y decisiones sin ser programadas explícitamente para cada tarea específica. Para lograr esto, los algoritmos de Machine Learning utilizan técnicas matemáticas y estadísticas avanzadas para encontrar patrones y relaciones en los datos, y luego utilizan estos patrones para hacer predicciones o tomar decisiones. (Cuadrado, 2019)

Los algoritmos de Machine Learning se pueden dividir en dos categorías principales: aprendizaje supervisado y no supervisado. En el aprendizaje supervisado, se proporciona al modelo datos etiquetados, lo que significa que se conoce la respuesta correcta para cada ejemplo en los datos. El modelo utiliza estos datos etiquetados para aprender a hacer predicciones precisas sobre nuevos datos no vistos anteriormente (Manosalva, 2019). En el aprendizaje no supervisado, el modelo recibe datos no etiquetados y tiene que encontrar patrones y relaciones en los datos por sí mismo. El objetivo principal del aprendizaje no supervisado es descubrir estructuras ocultas en los datos y agrupar los datos en

diferentes categorías o clústeres. (Instituto de Ingeniería del conocimiento, 2023)

El Machine Learning tiene una amplia variedad de aplicaciones en diferentes campos, algunas de las principales son:

- Reconocimiento de patrones: permite identificar patrones y características en los datos para su análisis y predicción en campos como la imagenología médica, el análisis de voz y texto, y el reconocimiento de objetos en imágenes.
- Análisis de datos: se utiliza para la identificación de patrones en grandes cantidades de datos para mejorar la toma de decisiones en diferentes campos como el marketing, la banca y la industria.
- Análisis predictivo: se utiliza para hacer predicciones precisas basadas en datos históricos para prever resultados futuros en áreas como la previsión del tiempo, las finanzas y el mantenimiento preventivo.
- Optimización: se utiliza para optimizar procesos y sistemas en diferentes campos, como la producción, la logística y la cadena de suministro.
- Automatización de tareas: se utiliza para automatizar tareas repetitivas y reducir la necesidad de intervención humana, como la clasificación de correos electrónicos, el etiquetado de imágenes y la detección de fraudes.

2.4 Redes Neuronales Artificiales (RNA)

Son un tipo de algoritmo de aprendizaje automático que se basa en la estructura y el funcionamiento de las redes neuronales biológicas. Las RNA están diseñadas para simular el comportamiento de las neuronas en el cerebro humano, permitiendo que las máquinas puedan aprender de forma autónoma y realizar tareas complejas de manera eficiente. (CELIS, 2008)

Una RNA se compone de una serie de nodos, llamados neuronas artificiales, que están conectados por líneas que representan las sinapsis biológicas. Cada neurona artificial recibe una entrada de información, la procesa y luego transmite una señal de salida a otras neuronas o hacia la salida de la red. La red se organiza en capas, donde cada capa se compone de un número de neuronas que procesan los datos y transmiten la información hacia la siguiente capa. La última capa de la red es la capa de salida, que proporciona la respuesta final a la tarea de aprendizaje. (Caicedo & López, 2017, págs. 17-18)

2.5 Máquinas de Soporte Vectorial (SVM)

Las Máquinas de Soporte Vectorial son un algoritmo de aprendizaje supervisado utilizado en el campo del aprendizaje automático. El objetivo de las SVM es encontrar la mejor separación lineal entre dos grupos de datos, maximizando la distancia entre los puntos de cada grupo y la línea de separación. Las SVM se basan en la teoría de la optimización convexa y se utilizan para clasificación y regresión. En la clasificación, se utiliza una SVM para predecir la clase de un

objeto desconocido a partir de sus características. En la regresión, se utiliza una SVM para predecir el valor de una variable numérica a partir de un conjunto de características. (León, 2016)

Las SVM son capaces de manejar datos de alta dimensión y son efectivas en la clasificación de datos no lineales. Esto se logra mediante la aplicación de una función de kernel, que transforma los datos en un espacio de características de mayor dimensión, donde la separación lineal es posible. Los tipos de funciones de kernel comunes incluyen el kernel lineal, el kernel polinómico y el kernel radial. (Monroy Jordán & Pérez Neira, 2005)

2.6 Dataset

La zona de investigación se compone por tres fincas bananeras que se encuentran en Carepa (Antioquia), que cuentan con estaciones meteorológicas para la adquisición de datos cada diez minutos. Para esta investigación se utilizaron los promedios diarios generados del dataset. Las variables meteorológicas consideradas se presentan en la Tabla 1 con su respectiva representación en el dataset.

Tabla 1. Variables meteorológicas en el dataset

Variable	Parameter (s)
RH2M	Relative Humidity at 2 Meters (%)
PRECTOTCORR	Precipitation Corrected (mm/hour)
T2M DEW	Dew/Frost Point at 2 Meters (C)
T2M WET	Wet Bulb Temperature at 2 Meters (C)
T2M	Temperature at 2 Meters (C)
WS2M	Wind Speed at 2 Meters (m/s)
PS	Surface Pressure (kPa)

Adicionalmente, las fincas cuentan con registros del estado de la Sigatoka Negra en los cultivos, por lo tanto, se tomará el progreso de la enfermedad como variable que mide el nivel de progresión de la enfermedad. Para las pruebas, se consideran los siguientes períodos, que coinciden con la medida de progresión de la enfermedad entre 01/27/2010 y 05/22/2019.

2.7 Python y Google Colab

Python es un lenguaje de programación de alto nivel, interpretado y de propósito general que se utiliza ampliamente en la programación de sistemas, desarrollo web, inteligencia artificial, aprendizaje automático, análisis de datos y otras aplicaciones. También cuenta con una amplia biblioteca estándar que proporciona una gran cantidad de herramientas para el procesamiento de datos, redes, matemáticas, gráficos, entre otros. Además, Python es un lenguaje multiplataforma, lo que significa que se puede ejecutar en cualquier sistema operativo. (Franco, 2019)

Para el análisis de datos con Google Colab, Python es la opción preferida por la mayoría de los científicos de datos debido a su facilidad de uso y a la gran cantidad de bibliotecas y herramientas disponibles para el análisis de datos. Google Colab es un entorno de desarrollo en línea gratuito que proporciona acceso a una instancia virtual de Python y ofrece una amplia gama de bibliotecas preinstaladas, incluidas las más populares para análisis de datos como NumPy, Pandas, Matplotlib y Scikit-learn. Además, Google Colab permite el uso de GPUs y TPUs para acelerar el procesamiento de datos y modelos de aprendizaje automático.

3. METODOLOGÍA

Esta metodología se enmarcó de la siguiente manera en tres partes así:

1. La primera etapa consiste en la búsqueda en el estado del arte sobre los diferentes métodos de detección y prevención de la Sigatoka Negra en los cultivos de plátano y banano. De igual forma, se realizará la caracterización de la enfermedad y sus efectos en las plantas, además de las condiciones ambientales que se consideran como ideales para la rápida propagación del hongo en las hojas.

2. La segunda etapa se enfoca en revisar las condiciones meteorológicas a través de literatura y por parte de un experto en el área para determinar cuál es la temperatura ideal, los niveles relativos de humedad, las precipitaciones y la velocidad del viento.

3. La tercera etapa está enfocada en el análisis y recopilación de los datos meteorológicos de las cuatro variables climáticas de temperatura, humedad relativa, precipitaciones de lluvia y velocidad del viento y la posibilidad de incorporación de la tecnología basada en inteligencia artificial como alternativa de solución frente a la problemática de dicha enfermedad foliar.

4. RESULTADOS

El desarrollo de un sistema de alerta temprana utilizando técnicas de Machine Learning es crucial para predecir la propagación de la enfermedad de la Sigatoka Negra en cultivos de banano en la región de Urabá en Colombia. La recopilación y el análisis de datos son los primeros pasos de este proceso.

4.1 Condiciones meteorológicas

Con la revisión de literatura y validación por parte de expertos en el área, se determina que el banano crece mejor en un rango de temperatura entre 27°C y 32°. Si bien requiere calor para prosperar debido a su naturaleza tropical, temperaturas superiores a 35 °C pueden ser perjudiciales, reduciendo el crecimiento y el rendimiento. Por lo tanto, es crucial mantener una temperatura constante dentro del rango óptimo para asegurar un crecimiento saludable. Los niveles relativos de humedad también son importantes para el cultivo y el rango ideal para los cultivos de banano es del 75 al 85%. La sigatoka

negra puede dañar gravemente los cultivos y crece cuando hay altos niveles de humedad. Por lo tanto, mantener niveles de humedad adecuados es importante para evitar la aparición de la sigatoka y garantizar un crecimiento saludable del banano.

Las precipitaciones y la velocidad del viento también son cruciales para el cultivo del banano y la aparición de la sigatoka. Las precipitaciones anuales de entre 1.500 y 2.000mm son ideales para los cultivos. Pero las precipitaciones abundantes pueden causar inundaciones y tener un impacto en el crecimiento y el rendimiento de los frutos. La velocidad del viento también es importante porque los vientos fuertes pueden dañar las plantas. Además, las esporas de la sigatoka se pueden propagar por el viento, lo que aumenta el riesgo de brotes de la enfermedad.

4.2 Análisis inicial de los datos

En el contexto del proyecto de investigación, se llevaron a cabo análisis de los datos meteorológicos correspondientes al periodo entre 2010 y 2019, con el propósito de examinar la variable temperatura. Los resultados obtenidos indican que el promedio de temperatura registrado durante dicho periodo fue de 25.48 grados Celsius. Además, se identificó un valor mínimo de 19.45 grados Celsius y un valor máximo de 37.75 grados Celsius. La desviación estándar de la variable temperatura en este periodo fue de 2.15 grados Celsius, lo que señala la presencia de una moderada variabilidad en los registros de temperatura. El promedio de temperatura se calculó sumando todas las temperaturas registradas durante el periodo de estudio y dividiendo entre el número total de observaciones. El valor mínimo y máximo de temperatura se obtuvieron a partir de los registros más bajos y más altos, respectivamente, documentados en el periodo estudiado. Por otro lado, la desviación estándar es una medida estadística que indica la variabilidad de un conjunto de datos en relación a su media (Figura 1).

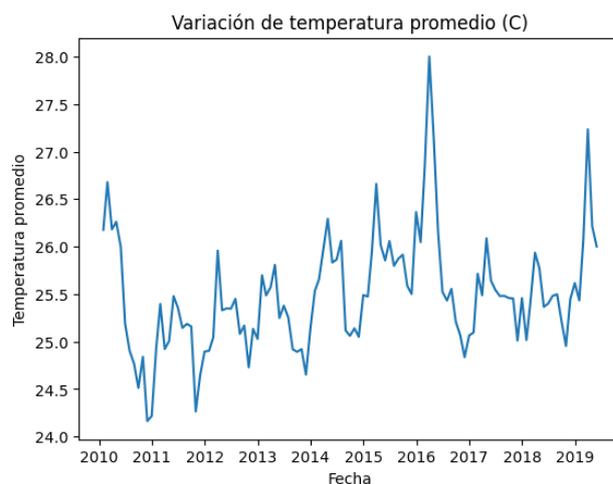


Figura 1. Variación de temperatura promedio en el periodo 2010 a 2019.

Los resultados revelan que el promedio de humedad relativa registrado en dicho lapso fue de 91.00%, indicando una condición de alta humedad en general. Se identificó un valor mínimo de 35.25%, lo que sugiere situaciones de baja humedad relativa en ciertos momentos, y un valor máximo de

100.0%, reflejando condiciones de alta humedad máxima alcanzada. Además, se calculó una desviación estándar de 9.53%, lo que señala una variabilidad moderada en los registros de humedad relativa. Estos datos son fundamentales para comprender y caracterizar los patrones climáticos en la región durante el periodo analizado (Figura 2).

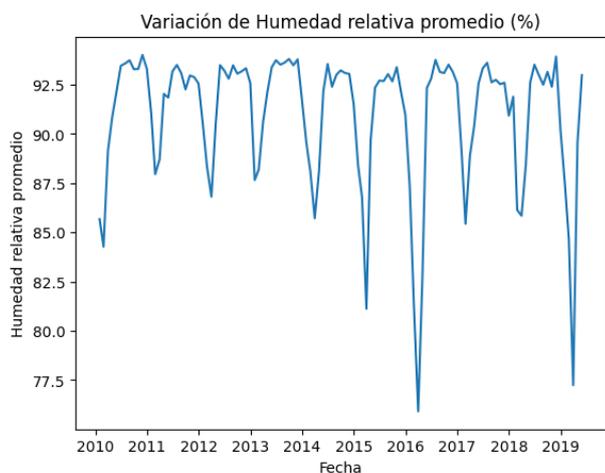


Figura 2. Variación de humedad relativa promedio en el período 2010 a 2019.

Los resultados obtenidos muestran que el promedio de precipitaciones registrado durante ese lapso fue de 0.34 milímetros. Se identificó un valor mínimo de 0.0 milímetros, indicando periodos sin lluvia, y un valor máximo de 25.78 milímetros, señalando episodios de lluvias intensas. La desviación estándar de 0.78 milímetros revela una variabilidad significativa en los registros de precipitaciones. Estos datos son esenciales para comprender y analizar los patrones climáticos de lluvia en la región durante el periodo de estudio (Figura 3).

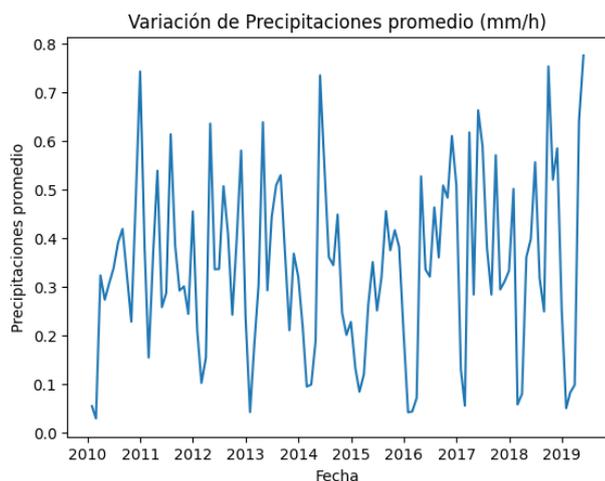


Figura 3. Variación de precipitaciones de lluvia promedio en el período 2010 a 2019.

Los resultados obtenidos indican que la velocidad promedio del viento registrada durante dicho periodo fue de 0.35 metros por segundo. Se identificó un valor mínimo de 0.0 metros por segundo, lo que sugiere momentos de calma en los que no se registraron vientos significativos. Por otro lado, se encontró un valor máximo de 1.34 metros por segundo, indicando

episodios de viento más intenso. La desviación estándar de 0.18 metros por segundo señala una variabilidad moderada en los registros de velocidad del viento. Estos datos son fundamentales para comprender y caracterizar los patrones climáticos de viento en la región durante el periodo analizado (Figura 4).

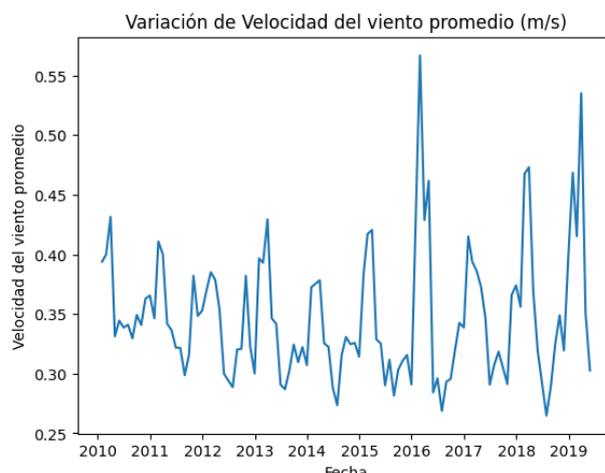


Figura 4. Variación de velocidad del viento promedio en el período 2010 a 2019.

El análisis de las cuatro variables climáticas de temperatura, humedad relativa, precipitaciones de lluvia y velocidad del viento. Los resultados revelaron que, durante el periodo entre 2010 y 2019, la temperatura promedio registrada fue de 25.48 grados Celsius, con una variabilidad moderada de 2.15 grados Celsius. La humedad relativa promedio fue de 91.00%, con una desviación estándar de 9.53%, indicando una condición general de alta humedad. En cuanto a las precipitaciones de lluvia, se observó un promedio de 0.34 milímetros, con una variabilidad significativa de 0.78 milímetros. Por último, la velocidad del viento promedio fue de 0.35 metros por segundo, con una desviación estándar de 0.18 metros por segundo.

5. CONCLUSIONES

La revisión detallada de las condiciones meteorológicas en la región de Urabá entre 2010 y 2019 revela que, en general, el promedio de temperatura se encuentra dentro del rango óptimo para el cultivo de banano, situándose entre 27°C y 32°C. Sin embargo, se destaca la presencia de variabilidad en la temperatura, indicando la necesidad de monitoreo constante para evitar extremos perjudiciales. La alta humedad relativa, con un promedio del 91%, también favorece el cultivo, aunque la variabilidad en la humedad y la presencia de lluvias intensas deben considerarse en la gestión agrícola para prevenir la propagación de la Sigatoka Negra.

El análisis de las precipitaciones revela un promedio relativamente bajo de 0.34 milímetros, indicando condiciones predominantemente secas. Sin embargo, la presencia de episodios de lluvias intensas, con un máximo de 25.78 milímetros, sugiere patrones climáticos significativos. La variabilidad en las precipitaciones, con una desviación estándar de 0.78 milímetros, resalta la importancia de comprender y gestionar los eventos climáticos extremos, ya

que pueden influir directamente en el rendimiento de los cultivos.

El análisis de la velocidad del viento indica que, en promedio, la región experimenta vientos moderados de 0.35 metros por segundo. Aunque se identifican momentos de calma, con velocidades mínimas de 0.0 metros por segundo, también se registran episodios de viento más intenso, alcanzando un máximo de 1.34 metros por segundo. La moderada variabilidad en la velocidad del viento (0.18 metros por segundo) destaca su influencia en la propagación potencial de esporas de la Sigatoka Negra y enfatiza la importancia de estrategias de manejo para mitigar posibles daños a los cultivos.

REFERENCIAS

- Barrera, J., Barraza, F., & Campo, R. (2016). Efecto del sombrío sobre la sigatoka negra (*Mycosphaerella fijiensis* Morelet) en cultivo de plátano cv hartón (*Musa AAB* Simmonds). *Revista UDCA Actualidad & Divulgación Científica*, 19(2), 317-323.
- Cedeño-Zambrano, J. R., Díaz-Barrios, E. J., de Jesús Conde-López, E., Cervantes-Álava, A. R., Avellán-Vásquez, L. E., Zambrano-Mendoza, M. E., ... & Sánchez-Urdaneta, A. B. (2021). Evaluación de la severidad de Sigatoka negra (*Mycosphaerella fijiensis* Morelet) en plátano "Barraganete" bajo fertilización con magnesio. *Revista Técnica*, 44(1), 4-12.
- Manabi-El Carmen, D. E. (2023). Análisis De La Comercialización De Banano Rojo (*Musa Acuminata*'red Dacca') En La Provincia (Doctoral Dissertation, Universidad Agraria Del Ecuador).
- Rojas Contreras, L. R. (2021). Estrategia de mercadeo para el lanzamiento del fungicida Belanty® para el combate de pseudocercospora fijiensis en el cultivo de banano en Costa Rica.
- Caicedo, E. F., & Lopez, J. (2017). UNA APROXIMACIÓN PRÁCTICA A LAS REDES NEURONALES ARTIFICIALES. Cali-: Programa Editorial Universidad del Valle.
- CELIS, J. A. (2008). UNIVERSIDAD POLITÉCNICA DE MADRID. Obtenido de https://oa.upm.es/1851/1/INVE_MEM_2008_53259.pdf
- Cuadrado, A. M. (Septiembre de 2019). UTILIZACIÓN DEL MACHINE LEARNING. Valladolid. Obtenido de <https://core.ac.uk/download/pdf/228074134.pdf>
- Elizabeth Álvarez, Pantoja, A., Gañán, L., Ceballos, G. (julio de 2013). Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO). Obtenido de Organización de las Naciones Unidas para la Alimentación y la Agricultura
- Forero, S. E., Piraneque Gambasica, N., & Menjivar Flores, J. C. (2012). Relación entre las propiedades edafoclimáticas y la incidencia de sigatoka negra (*Mycosphaerella fijiensis* Morelet) en la zona bananera del Magdalena-Colombia. Obtenido de [file:///C:/Users/Usuario/Downloads/Dialnet-RelacionEntreLasPropiedadesEdafoclimaticasYLaIncid-5344950%20\(3\).pdf](file:///C:/Users/Usuario/Downloads/Dialnet-RelacionEntreLasPropiedadesEdafoclimaticasYLaIncid-5344950%20(3).pdf)
- Franco, A. C. (julio de 2019). Universidad de Sevilla . Obtenido de Universidad de Sevilla : <https://idus.us.es/bitstream/handle/11441/90004/Centeno%20Franco%20Alba%20TFG.pdf>
- Instituto Colombiano Agropecuario-ICA . (16 de Abril de 2021). Instituto Colombiano Agropecuario. Obtenido de Instituto Colombiano Agropecuario: <https://www.ica.gov.co/noticias/ica-declaro-uraba-libre-fusarium-raza-4-tropical>
- Instituto de ingeniería del conocimiento . (2023). Machine Learning & Deep Learning. Obtenido de Machine Learning & Deep Learning: <https://www.iic.uam.es/inteligencia-artificial/machine-learning-deep-learning/>
- León, E. C. (2016). Universidad de Zaragoza. Obtenido de <https://zaguan.unizar.es/record/59156/files/TAZ-TFG-2016-2057.pdf>
- Manosalva, G. R. (30 de junio de 2019). Modelo de análisis de datos utilizando técnicas de aprendizaje supervisado y no supervisado., Trabajo de grado presentado como requisito para optar al título de Magíster en Ingeniería y Analítica de Datos. Bogotá. Obtenido de <https://expeditiorepositorio.utadeo.edu.co/bitstream/handle/20.500.12010/8502/Trabajo%20de%20grado.pdf?sequence=1&isAllowed=y>
- Monroy Jordan, E. D., & Pérez Neira, J. E. (2005). Repositorio de la Universidad Tecnológica De Bolívar . Obtenido de Repositorio de Universidad Tecnológica De Bolívar : https://repositorio.utb.edu.co/bitstream/handle/20.500.12585/295/0030352_merged%20%281%29.pdf?sequence=7&isAllowed=y