

See discussions, stats, and author profiles for this publication at: <https://www.researchgate.net/publication/327786463>

DSSAT: DSS Anthracnosis in Tomato Crops

Conference Paper · May 2018

DOI: 10.1109/ColComCon.2018.8466726

CITATIONS

0

READS

158

3 authors, including:



Fulvio Vivas

Universidad del Cauca

4 PUBLICATIONS 2 CITATIONS

[SEE PROFILE](#)



Oscar Mauricio Caicedo Rendon

Universidad del Cauca

75 PUBLICATIONS 454 CITATIONS

[SEE PROFILE](#)

Some of the authors of this publication are also working on these related projects:



Heavy-Hitters - Elephant Flows [View project](#)



Descubrimiento e interacción de servicios móviles ubicuos utilizando Bluetooth y WiFi [View project](#)

DSSAT: DSS Anthracnosis in Tomato Crops

Yeison Andres Urrea, Fulvio Yesid Vivas, Oscar Mauricio Caicedo

Departamento de Telemática

Universidad del Cauca

Popayán, Colombia

yaurrea,fyvivas,omcaicedo@unicauca.edu.co

Abstract— Anthracnose disease attacks tomato crops causing damage to fruit and minimizing its commercialization. Anthracnose is combated in two ways, on the one hand, the use of highly toxic fungicides combats the disease. Nonetheless, these fungicides affect the health of farmers and consumers. On the other hand, the continuous monitoring of crop conditions prevents the appearance of the disease. However, the prevention of diseases in crops presents an incomplete implementation (i.e., lack of data processing and sending alerts to farmers). Recently, precision agriculture and decision support systems (DSS) are concepts applied to crops to improve their production. In this paper, we propose a DSS to prevent the development of anthracnose in tomato crops (DSSAT). DSSAT collects agroclimatic data from the tomato crop, processes the collected data and generates alerts aimed at preventing anthracnose disease.

Keywords— Precision agriculture, DSS, Anthracnose, Tomato crops, Alerts.

I. INTRODUCCION

La Antracnosis (*Lycopersicum esculentum*) en cultivos de tomate es una enfermedad causada por el hongo *Colletotrichum gloeosporioides* que ataca los tejidos débiles (hojas, tallos y frutos). El hongo ataca el cultivo de tomate más severamente en época de floración y fructificación con humedad relativa mayor a 90% y temperatura promedio entre 27°C y 32°C [1]. La enfermedad en el fruto produce hendiduras de forma circular, color oscuro y aspecto de pudrición; generando pérdidas económicas por la baja comercialización del fruto. Una solución para combatir la enfermedad es la aplicación de fungicidas de alta toxicidad, pero perjudica la salud de cultivadores y consumidores [2]. Otra posible solución es prevenir la enfermedad antes de su aparición y en etapas tempranas, mediante mecanismos de monitorización y gestión de cultivos que busquen aumentar la producción del tomate, mejorar la calidad del fruto y evitar la aplicación de fungicidas.

En relación con mecanismos de monitorización y gestión de cultivos agrícolas tenemos la agricultura de precisión y los sistemas de soporte para la toma de decisiones. La agricultura de precisión mejora el uso de los recursos agrícolas con el propósito de hacer una gestión eficiente de los cultivos [3]. Este mecanismo se compone de tres fases: la recolección de datos en los cultivos, el procesamiento de la información recopilada, y la toma de decisiones sobre la información procesada. En esta última fase, los sistemas de soporte para la toma de decisiones (*Decision Support System* - DSS) procesan datos históricos de condiciones agroclimáticas de un

cultivo para inferir reglas de clasificación y comportamiento del cultivo [4]. Estos datos son llamados datos de entrenamiento. La inferencia de reglas usa un modelo de aprendizaje automático (Machine Learning – ML) basado en algoritmos de aprendizaje supervisado [5].

En la literatura, los trabajos [6] [7] [8] [9] [10] [11] [12] [13] han utilizado la tecnología de agricultura de precisión para gestionar cultivos agrícolas. Los sensores desplegados en los cultivos capturan variables agroclimáticas y posteriormente visualizan los datos recopilados en un centro de cómputo. Sin embargo, en estos trabajos la falta de una fase de procesamiento de datos y una toma de decisión impiden generar alertas y recomendaciones sobre los cultivos. Incluso, la presencia de condiciones favorables para la aparición de enfermedades (i.e., antracnosis en tomate) es ignorada.

En este trabajo proponemos un DSS para prevenir el desarrollo de la Antracnosis en cultivos de tomate (DSSAT). DSSAT recolecta datos agroclimáticos (temperatura y humedad relativa) del cultivo de tomate, procesa los datos recopilados junto con datos climatológicos históricos por medio de un modelo de aprendizaje supervisado previamente establecido y genera alertas y recomendaciones encaminadas a prevenir la enfermedad de antracnosis.

El resto del artículo se encuentra organizado de la siguiente manera. La sección II presenta el trabajo relacionado con esta investigación. La sección III describe el modelado de la enfermedad y la selección de un algoritmo de clasificación para generar dicho modelo. La sección IV expone la arquitectura propuesta para el DSSAT. La sección V muestra la implementación de la arquitectura por medio de un caso de estudio y finalmente las conclusiones y trabajos futuros en la sección VI.

II. TRABAJO RELACIONADO

A continuación se menciona el trabajo relacionado en las categorías de agricultura de precisión y DSS.

Los trabajos [6] y [7] realizaron la captura de datos climáticos (temperatura y humedad relativa) por medio de sensores y los datos recopilados son visualizados en pantallas LCD. En [8] los autores almacenaron los datos recolectados en una base de datos y posteriormente grafican las condiciones del cultivo. No obstante, falta la fase de procesamiento de los datos y la generación de alertas preventivas en el desarrollo de los cultivos. En [9] los autores propusieron un modelo de alertas y monitoreo de cultivos. Sin embargo, la implementación usa un ambiente simulado.

En [10] los autores diseñaron un DSS de bajo costo, orientado a cultivos localizados en la zona rural para mejorar la producción agrícola en tierras áridas. Sin embargo, falta la implementación en un ambiente real. En [11] los autores desarrollaron un DSS para mejorar la producción de semillas en invernadero pero no cuenta con mecanismos de generación de alertas. En [12] los autores enumeraron algunas tecnologías utilizadas en DSS y en [13] los autores calcularon la dosis diaria de agua en un sistema de riego en invernadero mediante un software utilizando datos históricos del clima y simulaciones del sistema. Aun así, falta evidencia de una arquitectura de referencia que especifique la captura de datos por medio de una red de sensores, siendo necesaria para conocer la condición actual del cultivo agrícola.

En [14] los autores implementaron un DSS aplicado al control de la roya en un cultivo de café. Este trabajo utiliza el conocimiento de un experto e información climática de una zona para tomar decisiones. Las decisiones evidencian la posibilidad de presencia de la enfermedad y su grado de afectación en el cultivo utilizando como algoritmo supervisado los árboles de decisión. Sin embargo, el trabajo está restringido en la recolección de datos por medio de sensores en cultivos agrícolas de cielo abierto (e.g., café); razón por la cual, no es aplicable al cultivo de tomate que usa un invernadero con un microclima diferente a las condiciones externas.

Finalmente, los trabajos consultados tienen aportes significativos en la monitorización y gestión de cultivos agrícolas. Sin embargo, faltan mecanismos (e.g., procesamiento de datos, toma de decisiones, generación de alertas y recomendaciones) que ayuden en la prevención de enfermedades. Además, ningún trabajo describe una arquitectura de referencia, ni están orientados a la prevención de antracnosis en tomate. Por tal motivo, DSSAT es una herramienta que resuelve la mayoría de estas limitaciones.

III. MODELADO DE LA ENFERMEDAD

La caracterización de la enfermedad de antracnosis brinda el conocimiento necesario para obtener un modelo general basado en estudios de laboratorio y datos históricos de la enfermedad. Dicho conocimiento establece algunas reglas para identificar casos de favorabilidad de aparición de la enfermedad haciendo uso de algoritmos de aprendizaje supervisado.

En este trabajo, el proceso de modelado de la enfermedad de antracnosis usa el modelo de minería de datos CRISP-DM [15] cuyas fases principales son: comprensión del negocio, comprensión de los datos, preparación de los datos, modelado y evaluación.

A. Comprensión del Negocio

La Antracnosis en tomate es causada por el hongo *Colletotrichum gloeosporioides*, el cual ingresa por las hojas, pasa por los tallos, y finalmente afecta el fruto [1]. Las condiciones favorables en la incubación del hongo son lesiones en tallos, hojas muertas, altos niveles de humedad relativa (>90%) y temperatura entre los 27°C a 32°C. Además, el periodo durante el cual las condiciones deben mantenerse lo

determina el periodo de incubación de la enfermedad entre 12 y 24 días [16].

B. Comprensión de los Datos

Los datos recolectados de diferentes estudios están relacionados con las condiciones favorables y desfavorables para el cultivo de tomate y el desarrollo de antracnosis.

Los datos de antracnosis provienen de estudios realizados en [17], [18] y [19], los cuales consideran variables como temperatura, humedad relativa y periodo de incubación.

Los datos sobre el cultivo de tomate provienen de estudios [20], [21] y [22] los cuales recopilan variables de temperatura y humedad relativa.

C. Preparación de los Datos

Los atributos de temperatura (TEMP), humedad relativa (HR) y nivel de Antracnosis (ANTRAC) son obtenidos mediante los datos recolectados en la fase de comprensión de datos y los resultados hallados en el trabajo [9]. ANTRAC es el atributo clase y tiene cuatro categorías: A0 que indica que no hay condiciones favorables para desarrollar la enfermedad (probabilidad < 20%), A1 indica una leve favorabilidad (probabilidad entre 20% y 50%), A2 indica una favorabilidad media (probabilidad entre 50% y 70%) y A3 indica una alta favorabilidad (probabilidad > 70%). Cada uno de los datos recolectados es llamado instancia y todo el conjunto es llamado datos de entrenamiento o aprendizaje.

D. Modelado

Para el modelado utilizamos la herramienta WEKA (Waikato Environment for Knowledge Analysis), la cual implementa algoritmos de aprendizaje supervisado que son evaluados para determinar cuál algoritmo es el más adecuado en la identificación de casos de favorabilidad de aparición de la enfermedad. Según [23], el trabajo concluye que los algoritmos de aprendizaje supervisado más utilizados en la agricultura son de dos tipos: árbol de decisión y redes bayesianas. En algoritmos de árbol de decisión utilizamos J48 (C4.5) y para algoritmos de redes bayesianas usamos *Naive Bayes*. Por tal razón vamos a evaluar estos dos algoritmos.

El modelo de clasificación del algoritmo J48 (Fig. 1) a partir de los datos de entrenamiento HR y TEMP genera una clasificación en cuatro categorías (A0, A1, A2, A3).




Fig. 1. Árbol de decisión algoritmo J48.

Los resultados de desempeño del algoritmo Naive Bayes (Fig. 2) muestran algunas variables estadísticas (media y desviación estándar) de los atributos HR y TEMP con respecto a ANTRAC.

Naive Bayes Classifier

Attribute	Class			
	A3 (0.2)	A2 (0.25)	A1 (0.25)	A0 (0.31)
=====				
HR				
mean	95.9375	85.5	83	77
std. dev.	3.0714	5.7663	6.2849	4
weight sum	16	20	20	25
precision	1	1	1	1
TEMP				
mean	26.9866	30.6429	26.4107	23.1857
std. dev.	3.578	3.0756	4.2355	2.889
weight sum	16	20	20	25
precision	1.0714	1.0714	1.0714	1.0714

Fig. 2. Variables estadísticas algoritmo Naive Bayes.

Para la categoría A3 la media de los datos de HR se encuentra en 95.9% y de TEMP en 26.9°C. Esto indica que alrededor de esos valores el nivel de antracnosis es clasificado en la categoría A3. Para la categoría A2 la media de HR está en 85.5% y para TEMP está en 30.6°C. Del mismo modo para la categoría A1, la media de HR está en 83% y de TEMP está en 26.4°C. Finalmente, para la clase A0 la media de HR está en 77% y de TEMP está en 23°C.

E. Evaluación

La evaluación del modelo J48 y Naive Bayes genero los resultados de la Tabla I. *iii)* el error relativo absoluto representa el porcentaje de error de predicción de un clasificador.

Tabla I. RESULTADOS PRUEBA DE ALGORITMOS

	Resultados de los algoritmos J48 y Naive Bayes		
	Medida de Desempeño	J48	Naive Bayes
1	Instancias Correctamente Clasificadas	79	67
2	Porcentaje Instancias Correctas	97.5%	82.7%
3	Instancias Incorrectamente Clasificadas	2	14
4	Porcentaje Instancias Incorrectas	2.4%	17.2%
5	Estadística Kappa	0.9668	0.7681
6	Error Medio Absoluto	0.0185	0.1615
7	Error Relativo Absoluto	4.97 %	43.4%
8	Numero de Instancias Total	81	81

Los resultados de la Tabla I. concluyen que el algoritmo de Árbol de Decisión (J48) clasificó un 97.5% de manera correcta las instancias, y el Algoritmo de Naive Bayes apenas llego al 82.7%. El error medio absoluto para J48 es mucho menor, indicando una mejor aproximación. El error relativo absoluto para J48 es de 4.97% (muy bajo) y para Naive Bayes es de 43.4% (significativamente alto). Además, Los algoritmos de árbol de decisión son los más utilizados en la agricultura y los que mejor clasifican las enfermedades corroborando lo dicho en el artículo [23]. De esta manera el modelo seleccionado es el generado por el algoritmo de árbol de decisión (J48).

IV. ARQUITECTURA

La arquitectura del DSSAT (Fig. 3) usa el modelo propuesto por Siemens y consta de cuatro capas: Datos, Base de Datos, Modelos y Presentación.




Fig. 3. Arquitectura en capas del DSSAT.

Capa de Datos: capa encargada de interactuar con el medio ambiente. La batería alimenta de potencia los sensores para capturar las variables climáticas, luego los datos recopilados pasan a una etapa de filtrado donde limpia los datos capturados para evitar errores y posteriormente una etapa de transmisión envía los datos para almacenarlos en una base de datos.

Capa de Base de datos: esta capa almacena datos correspondientes a variables agroclimáticas. Está dividida en dos partes, Base de datos de aprendizaje y base de datos recolectados. la primera es la base de información utilizada como referencia para generar los modelos de aprendizaje. Y la segunda es la información generada por los sensores.

Capa de Modelos: capa basada en algoritmos de clasificación y datos históricos. Presenta modelos para la clasificación de nivel de antracnosis y los compara con datos capturados por el sistema generando la decisión de alerta de antracnosis para prevenir la enfermedad.

Capa de Presentación: Encargada de presentar al usuario final, las diferentes condiciones climáticas del cultivo y las posibles alertas de Antracnosis generadas y presentadas en forma de notificaciones.

V. IMPLEMENTACION DE LA ARQUITECTURA

El prototipo (Fig. 4) está dividido en dos partes el Nodo y el Procesador Central.




Fig. 4. Prototipo General.

El Nodo: Está directamente relacionado con la capa de Datos (Fig. 5). Es el encargado de capturar los datos agroclimáticos para enviarlos al Procesador Central. Está compuesto por el sensor de temperatura y humedad relativa DHT22. Una tarjeta Arduino Mega encargada de la conversión análogo digital y la interfaz de comunicación mediante el módulo Bluetooth HC05 (Fig. 6).




Fig. 5. Componentes del Nodo.




Fig. 6. Prototipo Nodo.

El Procesador Central: Relacionado con las capas de Base de Datos, Modelo y Presentación (Fig. 7). El Procesador Central recibe los datos enviados por el nodo, los almacena, los procesa y muestra las alertas. El procesador utiliza la tarjeta Raspberry Pi 3 modelo 2, con el sistema operativo Raspbian que es una distribución Debian (Linux). La base de datos almacena archivos de texto plano (extensión csv). El modelo usa una librería WEKA implementada en el lenguaje de programación Python y la visualización implementada en una aplicación de escritorio y programada en Python (Fig. 9)




Fig. 7. Componentes del Procesador Central.

Finalmente, la evaluación del sistema se llevo a cabo por medio de un caso de estudio en dos invernaderos (distanciados 100 metros uno del otro) localizados en la vereda La Paz del municipio de Sotará Cauca, Colombia. Para este caso se utilizó la variedad chonto (Lycopersicon esculentum Mili) la cual es más resistente a las enfermedades.

Caso 1: Invernadero 1 con DSSAT implementado en un cultivo de tomate.

Caso 2: Invernadero 2 sin DSSAT implementado en el cultivo de tomate.

Para el caso 1 (Fig. 8), los datos son recolectados mediante el Nodo enviando un valor de temperatura y humedad relativa cada quince (15) minutos durante cuatro (4) meses (duración del cultivo).



Fig. 8. Caso 1: invernadero con DSSAT.

En la Fig. 9 apreciamos algunas alertas y recomendaciones que el sistema notifica en la interfaz gráfica. Las alertas muestran la fecha y el nivel de probabilidad de desarrollar la enfermedad de antracnosis, además de brindar la recomendación que el usuario debe seguir.

DSS Antracnosis			
Temp:	20 C	ver temp	
HR:	80 %	ver HR	
		ver Antrac	
Alertas de Antracnosis			
Fecha	Alerta	Temp HR	Recomendacion
12/12	Nivel A0	Baja media	Ninguna
13/12	Nivel A1	Baja alta	Apertura de ventanas laterales
14/12	Nivel A2	alta alta	colocar polisombra y Utilizar coberturas plásticas en el suelo

Fig. 9. Notificaciones de alertas DSSAT.

Al terminar la cosecha, en ambos invernaderos realizamos una inspección manual, haciendo un balance de la cantidad de frutos producidos y cuantos de estos estaban infectados con antracnosis (Tabla II).

Tabla II. COMPARACION CULTIVO CON Y SIN DSSAT

Resultados Caso de Estudio DSSAT			
	Valores	Caso 1	Caso 2
1	Numero de plantas	30	30
2	Promedio numero de frutos por planta	55	42
3	Aproximado total frutos	1700	1300

Resultados Caso de Estudio DSSAT			
	Valores	Caso 1	Caso 2
4	Frutos infectados	64	116
5	Porcentaje numero de frutos infectados	3.7%	8.9%
6	Numero de plantas infectadas (al menos un fruto infectado)	7	14

Los resultados del caso de estudio resalta que al utilizar el DSSAT (caso 1) no solo se presenta una disminución de la presencia de antracnosis en el fruto (3.7 % contra 8.9%) sino también un aumento en el número de frutos por planta (55 contra 42). De esta manera, el DSSAT logra una reducción de la aparición de la enfermedad de antracnosis en los cultivos de tomate.

VI. CONCLUSIONES

Los algoritmos de árboles de decisión clasificaron de manera correcta el nivel de posible desarrollo de antracnosis en tomate. Con un 97.5% contra un 82.7% del algoritmo de *Naive Bayes*. Razón por la cual se eligen para el modelado de la antracnosis.

El DSSAT redujo un 5.2 % la aparición de antracnosis en los frutos de tomate en comparación cuando no se utilizó ningún sistema pasando de 8.9% a 3.7%. Además, el DSSAT incrementó en 13 unidades el número de frutos producidos por una planta pasando de 42 a 55 frutos por planta. Por lo tanto, el DSSAT es importante para la prevención de antracnosis en tomate.

Para trabajos futuros se plantea desplegar mayor número de nodos para aumentar la precisión en la medida de las condiciones climáticas de todo el invernadero. Además, aumentar el número de plantas a estudiar y cambiar la variedad de tomate utilizada.

REFERENCIAS

- [1] S. Freeman, T. Katan, and E. Shabi, "Characterization of Colletotrichum Species Responsible for Anthracnose Diseases of Various Fruits," *Plant Disease*, vol. 82, no. 6, pp. 596–605, 1998.
- [2] M. Agricultura, "Antracnosis, importancia y manejo integrado en el cultivo. Prevención: la mejor alternativa," 2014.
- [3] F. Y. Vivas, J. C. Corrales, and G. Ramírez-gonzález, "Aproximación a un modelo contextual para calidad de datos en agricultura de precisión," *Revista Ingenierías Universidad de Medellín*, vol. 15, no. 29, pp. 99–112, 2016.
- [4] R. C. Seem, "Decision Support Systems: Quenching the Thirst," *Plant Disease*, vol. 86, no. 1, pp. 2–14, 2002.
- [5] T. M. Mitchell, *Machine Learning*. U.K: McGraw-Hill, 1997.
- [6] M. Mancuso, "A Wireless Sensors Network For Monitoring Environmental Variables in a Tomato Greenhouse," *Sensicast Systems*, vol. 1, no. 1, pp. 74–85, 2009.
- [7] G. Galandé, "Greenhouse Microclimatic Real-Time Monitoring Embedded WSN Used in Agriculture," *International Journal of Engineering*, vol. 3, no. 3, pp. 1328–1333, 2015.
- [8] A. Jimenez, "Sistema de adquisición, almacenamiento y análisis de información de fenológica para el manejo de plagas y enfermedades de un duraznero mediante tecnologías de agricultura de precisión," *Tecnura*, vol. 14, no. 27, pp. 41–51, 2010.

- [9] A. Badage and P. Aishwarya, "Alarm System in WSN for Critical Event Monitoring: Indian Agriculture," *International Journal of Innovative*, vol. 1, no. 2, pp. 74–77, 2014.
- [10] A. J. Churi, M. R. S. Mlozi, H. Mahoo, S. D. Tumbo, and R. Casmir, "A Decision Support System for Enhancing Crop Productivity of Smallholder Farmers in Semi- Arid Agriculture," *International Journal of Information and Communication Technology Research*, vol. 3, no. 8, pp. 238–248, 2013.
- [11] M. K. Gupta, D. V. K. Samuel, and N. P. S. Sirohi, "Decision support system for greenhouse seedling production," *Computers and Electronics in Agriculture*, vol. 73, no. 2, pp. 133–145, 2010.
- [12] S. G. Karandikar, "A review of soft computing based DSS in fertilizer management in India," *YMT College of Management*, pp. 118–122, 2014.
- [13] M. Gallardo, F. Arrabal, F. M. Padilla, and R. B. Thompson, "Use of the VegSyst-DSS to calculate the irrigation and N requirements and the applied N concentration of fertigated greenhouse-grown vegetable crops," *II Simposio Nacional de Ingeniería Hortícola*, pp. 161–164, 2016.
- [14] E. Lasso, Ó. Valencia, and J. C. Corrales, "Decision Support System for Coffee Rust Control Based on Expert Knowledge and Value-Added Services," *Springer International Publishing*, vol. 2, pp. 70–83, 2017.
- [15] J. Clinton, R. Kerber, T. Khabaza, T. Reinartz, C. Shearer, and R. Wirth, *CRISP-DM 1.0 Step-by-step data mining guide*. 2000.
- [16] A. Saldarriaga, "Caracterización del Agente Causante de la Antracnosis en Tomate de Arbol, Manzano y Mora," *Revista Academia Colombiana de Ciencias*, vol. 32, no. 123, pp. 145–156, 2008.
- [17] J. Restrepo and W. Montoya, "Diagnóstico precoz de la Antracnosis (*Colletotrichum gloeosporioides*) en tomate mediante el empleo de infecciones quiescentes," *Universidad de Caldas*, vol. 15, no. 1, pp. 89–102, 2008.
- [18] B. Bernstein, "Characteristics of *Colletotrichum* from Peach, Apple, Pecan, and Others Host," *The American Phytopathological Society*, vol. 79, no. 5, pp. 478–482, 1995.
- [19] J. Moral, "Effect of Temperature , Wetness Duration , and Planting Density on Olive Anthracnose Caused by *Colletotrichum* spp .," *The American Phytopathological Society*, vol. 102, no. 10, pp. 974–981, 2012.
- [20] O. Perenguez, "Respuesta fisiológica del tomate a Diferentes Láminas de Riego y su Efecto en la Absorción de Nutrientes," Universidad Nacional de Colombia, 2011.
- [21] R. Sepúlveda, "Comportamiento de portainjertos comerciales de tomate en el valle de Illuta," *Ministerio de Agricultura Chile*, vol. 1, no. 72, pp. 1–4, 2013.
- [22] E. Avila, "Manual Tomate," *Cámara de Comercio de Bogotá*, pp. 1–56, 2015.
- [23] D. C. Corrales, J. C. Corrales, and A. Figueroa-Casas, "Towards detecting crop diseases and pest by supervised learning," *Ing Univ*, vol. 19, no. 1, pp. 207–228, 2015.