

Modelo de estimación para relacionar factores de suelo asociados con la presencia y ausencia de *Fusarium oxysporum* Schltld en el cultivo de uchuva *Physalis peruviana* L

Estimation model to relate soil factors associated with the presence and absence of *Fusarium oxysporum* Schltld in the cape gooseberry crop *Physalis peruviana* L

Modelo de estimativa para relacionar fatores do solo associados à presença e ausência de *Fusarium oxysporum* Schltld na cultura de groselha-cabeleira *Physalis peruviana* L.

Cruz-Castiblanco, Ginna; Pérez-Caro, Wilmer; Martínez-Lemus, Erika; Sandoval-Cáceres, Yuly; Wilches-Ortiz, Wilmar; Villa-Triana, Alba

**Ginna Cruz-Castiblanco**

gcruz@agrosavia.co  
Agrosavia, Colombia

**Wilmer Pérez-Caro**  
wilmer9108@gmail.com  
Agrosavia, Colombia

**Erika Martínez-Lemus**  
emartinezl@agrosavia.co  
Agrosavia, Colombia

**Yuly Sandoval-Cáceres**  
ysandoval@agrosavia.co  
Agrosavia, Colombia

**Wilmar Wilches-Ortiz**  
wwilches@agrosavia.co  
Agrosavia, Colombia

**Alba Villa-Triana**  
avilla@agrosavia.co  
Agrosavia, Colombia

**Revista Científica Dékamu Agropec**

Universidad Nacional Intercultural Fabiola Salazar Leguía de Bagua, Perú  
ISSN: 2709-3190  
ISSN-e: 2709-3182  
Periodicidad: Semestral  
vol. 3, núm. 2, 2022  
dekamuagropec@unibagua.edu.pe

Recepción: 01 Agosto 2022  
Aprobación: 28 Octubre 2022

URL: <http://portal.amelica.org/ameli/journal/744/7444294004/>

**Resumen:** El patógeno *Fusarium oxysporum* es la mayor limitante en la producción del cultivo de uchuva *Physalis peruviana*, a causa de la inexperiencia de los productores para identificarlo y manejarlo. En ese sentido el objetivo de esta investigación fue identificar la relación entre las características químicas del suelo, con la presencia y ausencia de *Fusarium oxysporum*. La recolección de muestras de suelo fue de 100 unidades productoras uchuva. Este proceso fue realizado en parcelas con plantas sanas y plantas afectadas por el patógeno *Fusarium oxysporum* Schltld. Se empleó los análisis descriptivos, correlaciones de Pearson, componentes principales (APC) y modelos Machine Learning para analizar la información asociada a los elementos químicos del suelo, de fincas productoras de uchuva. El modelo Decision Tree Classifier mostró el mejor rendimiento predictivo con métricas de Accuracy de 0.58, Recall de 0.57, y el F1 Score de 0.51, permitiendo establecer que la presencia de *F. oxysporum* está asociada a elementos como: Ca, K, Capacidad de intercambio catiónico efectiva (CICE), pH y % Arena. Los hallazgos en esta investigación son de utilidad para perfilar modelos predictivos y que se podrían incluir en los planes de manejo de esta enfermedad.

**Palabras clave:** APC, árbol de decisiones, factores predisponentes, modelos supervisados.

**Abstract:** The pathogen *Fusarium oxysporum* is the major limiting factor in the production of the cape gooseberry crop *Physalis peruviana*, due to the inexperience of growers to identify and manage it. The objective of this research was to identify the relationship between the chemical characteristics of the soil and the presence and absence of *Fusarium oxysporum*. Soil samples were collected from 100 cape gooseberry production

Copyright UNIFSLB, 2022

Esta obra está bajo una Licencia Creative Commons Atribución-  
NoComercial 4.0 Internacional.

units. This process was carried out in plots with healthy plants and plants affected by the pathogen *Fusarium oxysporum* Schltdl. Descriptive analysis, Pearson correlations, principal components (PCA) and Machine Learning models were used to analyze the information associated with the chemical elements of the soil of cape gooseberry farms. The Decision Tree Classifier model showed the best predictive performance with Accuracy metrics of 0.58, Recall of 0.57, and F1 Score of 0.51, allowing to establish that the presence of *F. oxysporum* is associated with elements such as: Ca, K, Effective Cation Exchange Capacity (ETC), pH and % Sand. Finally, the development of this work is intended to outline predictive models as a tool that can be included in management plans for this disease.

**Keywords:** APC, decision tree, predisposing factors, supervised models.

**Resumo:** O patógeno *Fusarium oxysporum* é o principal fator limitante na produção da cultura de groselha-cabeleira *Physalis peruviana*, devido à inexperiência dos produtores em identificá-la e administrá-la. O objetivo desta pesquisa foi identificar a relação entre as características químicas do solo e a presença e ausência do *Fusarium oxysporum*. Foram coletadas amostras de solo de 100 unidades de produção de groselha-cabeleira. Este processo foi realizado em parcelas com plantas saudáveis e plantas afetadas pelo patógeno *Fusarium oxysporum* Schltdl. Análise descritiva, correlações de Pearson, análise de componentes principais (PCA) e modelos de aprendizagem de máquinas foram usados para analisar as informações associadas aos elementos químicos do solo das fazendas de groselha-cabeleira. O modelo Decision Tree Classifier mostrou o melhor desempenho preditivo com Métricas de Precisão de 0,58, Recall de 0,57 e F1 Score de 0,51, permitindo estabelecer que a presença de *F. oxysporum* está associada a elementos tais como: Ca, K, Capacidade de Troca Catiônica Efetiva (ETC), pH e % Sand. Finalmente, o objetivo deste trabalho é desenvolver modelos preditivos como uma ferramenta que pode ser incluída nos planos de manejo desta doença.

**Palavras-chave:** APC, árvore de decisão, fatores predisponentes, modelos supervisionados.

## INTRODUCCIÓN

La Uchuva *Physalis peruviana* Linnaeus, 1763 es un producto con propiedades antioxidantes, antiinflamatorias y anticancerígenas debido al contenido de vitaminas (A, B y C), minerales (hierro y fósforo) y ácidos grasos polinsaturados (Castro et al., 2020; Hassan et al., 2017). Es un cultivo con gran impacto en el país debido a la apertura de mercados internacionales, en Colombia se ha observado un aumento del 27% en la producción de este fruto en los últimos años (Analdex, 2021). Sin embargo, a pesar de ocurrir un aumento en el área sembrada se ha observado una disminución del área cosechada, esto debido principalmente a problemas fitosanitarios (patógenos del suelo).

Aunque los problemas fitosanitarios se posicionan como uno de los factores que más afecta la producción y el patógeno *Fusarium oxysporum* Schltdl, 1824 es la mayor causal de estos, son muy pocos los estudios enfocados a obtener herramientas que se puedan incluir en los planes de manejo de enfermedades del cultivo.

*F. oxysporum* es el agente causal del marchitamiento vascular de la uchuva, afecta seriamente la producción generando pérdidas entre el 80% y 100% en campo (Forero de La-Rotta & Quevedo, 2005; Góngora & Rojas, 2006). Es un patógeno de difícil control y su diseminación en campo puede ser facilitada por la propagación y uso de material infectado; sus clamidosporas pueden permanecer en el suelo por más de dos décadas (Haglund & Kraft, 2001).

Tiene la capacidad de propagarse con facilidad sin impulsar los mecanismos de localización y protección del huésped y de penetrar los haces vasculares ubicados en el centro de la raíz de la planta causando obstrucción (Beckman & Roberts, 1995). Estupiñán & Ossa, 2007 reportan la presencia de una especie del patógeno que infecta plantas de uchuva particularmente y no muestra patogenicidad en otras solanáceas. En campo, las plantas infectadas muestran marchitamiento, amarillamiento y en casos severos se puede llegar hasta su muerte (Góngora & Rojas, 2006).

La relación de los factores edáficos con la incidencia y severidad de *Fusarium* sp. en uchuva no ha sido estudiada ampliamente. Borges-Pérez et al. (1983) y Trujillo et al. (1983) hallaron que el pH, materia orgánica (MO), y elementos como calcio (Ca), magnesio (Mg), zinc (Zn) y relaciones Ca/Mg y K/Mg están vinculados con la ocurrencia del mal de Panamá (*Fusarium oxysporum* f.sp. cubense). Hwang, (1985) y Sun & Huang (1985), consiguieron resultados promisorios en ensayos para el manejo del mal de Panamá, haciendo uso de suelos supresivos y conductivos, y añadiendo compuestos orgánicos e inorgánicos a los suelos donde sucedieron severos ataques del patógeno. En el Estado de Bahía, Brasil, observaciones realizadas demostraron que la existencia de este hongo en el suelo disminuía el contenido de materia orgánica (EMBRAPA, 1987).

El uso de modelos de Machine Learning (ML) en la agricultura es prometedor, ya que ayuda a los agricultores y otras partes interesadas de la agricultura a tomar decisiones inteligentes. Las aplicaciones de aprendizaje automático en la agricultura mejorarán el uso optimizado de los recursos para el cultivo, además de un manejo adecuado de plagas y enfermedades que puede conducir a un aumento en la calidad de los productos agrícolas, es así, como el uso de algoritmos de ML ha permitido detectar y clasificar mediante el procesamiento de imágenes hojas sanas de enfermas en la identificación de síntomas asociados al

marchitamiento del laurel, lo que permite realizar un manejo efectivo de la enfermedad (Abdulridha et al., 2018).

Por esto, el objetivo del estudio fue identificar la relación entre las características químicas del suelo, con la presencia y ausencia de *Fusarium oxysporum*.

## MATERIALES Y MÉTODOS

### Unidad de estudio

Fue recolectada información correspondiente a 100 unidades productoras del fruto en estudio. En estas unidades seleccionadas se tomaron muestras de suelo que fueron enviadas para analizar las propiedades fisicoquímicas de los suelos. Este proceso fue realizado en parcelas con plantas sanas y plantas afectadas por el patógeno recolectando en total 221 muestras (Tabla 1).

La colecta de material biológico fue manejada bajo los lineamientos señalados en Resolución 1466 del 03 de diciembre de 2014 "Por la cual se otorga un Permiso Marco de Recolección de Especímenes de Especies Silvestres de la Diversidad Biológica con Fines de Investigación Científica No Comercial y se toman otras determinaciones.

### *Análisis de la información*

En busca de eliminar datos atípicos e identificar la distribución de las variables se realizó un análisis exploratorio usando gráficos de boxplot, histogramas y qqplot, dado que los datos cumplieron la distribución normal, algunas técnicas estadísticas pueden ser más eficientes (Gallardo y Maestre, 2008). En ese sentido, se realizó un análisis descriptivo en todas las variables de estudio, esto con el fin de resumir la información en términos de medidas de tendencia central (media y mediana) y de variabilidad (coeficiente de variación), además de algunas medidas de asimetría y curtosis, lo que permite identificar las principales características de los datos observados (Garzón et al., 2010; Kaliyadan & Kulkarni, 2019) y de esta manera observar de forma preliminar la existencia de diferencias entre los valores presentados en plantas sanas y enfermas.

Para establecer relación entre las variables de estudio se realizaron correlaciones de Pearson que permiten medir la relación lineal entre dos variables aleatorias continuas y se adopta cuando los datos siguen una distribución normal (Rovetta, 2020). Además, este análisis es fundamental para poder realizar componentes principales (PCA), ya que al observar una elevada correlación entre las variables le da sentido al análisis, ya que indica la existencia de información redundante y permite que pocos factores (o componentes principales) expliquen gran parte de la variabilidad total (Restrepo et al., 2012).

Con el fin de reducir la información redundante o excesiva asociada a los datos colectados de plantas sanas y enfermas se realizó un análisis de componentes principales (PCA), el cual tiene como propósito transformar un conjunto de variables correlacionadas en un nuevo conjunto de variables no correlacionadas que contienen un alto grado de información, es decir, lo que se pretende reducir la dimensionalidad del conjunto original, con una pérdida mínima de información (Peña, 2002; Restrepo et al., 2012). Para ello, se tendrá en cuenta la varianza acumulada por cada componente y la importancia de las variables dentro del mismo mediante el valor del Coseno cuadrado ( $\text{Cos}^2$ ), esto con el fin de conocer las variables de suelo que tienen mayor importancia sobre la presencia o ausencia de la enfermedad.

**TABLA 1**  
Descripción de las variables incluidas en los análisis químicos y físicos de las muestras de suelo tomadas en 110 fincas productoras de uchuva.

Tipo de análisis	Elemento	Nomenclatura
Químico	Materia Orgánica	MO (%)
	Fósforo	
	Azufre	P (ppm)
	Aluminio	
	Calcio	
	Magnesio	S meq/100g
	Potasio	
	Sodio	Al meq/100g
	Capacidad de Intercambio Catiónico Efectiva	
	Capacidad del suelo para conducir corriente eléctrica	Ca meq/100g
	Hierro	
	Cobre	Mg meq/100g
	Manganeso	
	Zinc	K meq/100g
	Boro	
	Relación Calcio-Magnesio	Na meq/100g
	Relación Calcio-Magnesio-Potasio	
	Relación Magnesio-Potasio	CICE (meq/100g)
	% Arena	Arena
	Textura	% Limo
% Arcilla		Arcilla

Finalmente, con las variables seleccionadas en el análisis de PCA se probaron diferentes modelos Machine Learning con el fin identificar los factores de suelo asociados a la prevalencia o no de *F. oxysporum* en el cultivo de uchuva. Los modelos probados fueron: Decision Tree Classifier, Random Forest Classifier, Light Gradient Boosting Machine y Extra Trees Classifier. Para evaluar el desempeño de los modelos y seleccionar el más adecuado, se usaron las métricas: Accuracy (exactitud) que evalúa el porcentaje de casos que el modelo ha acertado;

Recall (exhaustividad) que calcula la cantidad de valores positivos que son correctamente clasificados; Precision (Precisión) que permite medir la calidad del modelo en tareas de clasificación y F1 Score representa un promedio ponderado de los indicadores precisión y Recall, donde la puntuación de la F1 alcanza su mejor valor en 1 (precisión y exhaustividad perfectas). Las anteriores métricas permiten determinar la calidad y eficiencia del modelo (Sidey-Gibbons & Sidey-Gibbons, 2019; Bautista et al., 2021; Bhardwaj et al., 2022). Los análisis descriptivos, correlaciones y PCA se hicieron usando el programa estadístico R versión 3.4.1 (R Core Team, 2017) y los modelos binarios de machine Learning usando la librería PyCaret de Python (Ali, 2020).

## RESULTADOS

La Tabla 2, muestra las variables Mg, K, Ca, B y Cu que presentaron mayor asimetría hacia la derecha. Las variables MO, Ca y Limo tienen una distribución mesocúrtica y el pH sigue una distribución platicúrtica

y variables como S, Cu y Mg/K son de tipo leptocúrtica. Con respecto a los análisis de suelo en plantas sanas y enfermas se encontró un pH moderadamente ácido (5.4), contenido de materia orgánica alto con valores promedio de 14%; con valores de fósforo y azufre altos; además, las bases intercambiables Ca y K se presentan niveles altos en plantas sanas y bajos en enfermas, mientras que para Mg los valores son medios. En cuanto al CE, para los dos tipos de muestra se observan valores de 2.1 dS/m y una Capacidad efectiva de intercambio catiónico moderada. La mayoría de las variables presentaron desviaciones estándar altos debido a la heterogeneidad de los suelos.

TABLA 2  
Análisis descriptivo del estado de la planta con relación a la concentración de los elementos químicos disponible en el suelo

pH= Potencial de Hidrógeno, MO= Materia orgánica, P=Fósforo, S= Azufre, Al=Aluminio, Ca= Calcio, Mg= Magnesio, K=Potasio, Na= Sodio, CICE= Capacidad efectiva de intercambio catiónico, CE=Conductividad eléctrica, Fe= Hierro, Cu= Cobre, Mn= Manganeso, Zn= Zinc, B= Boro, DE= Desviación estándar

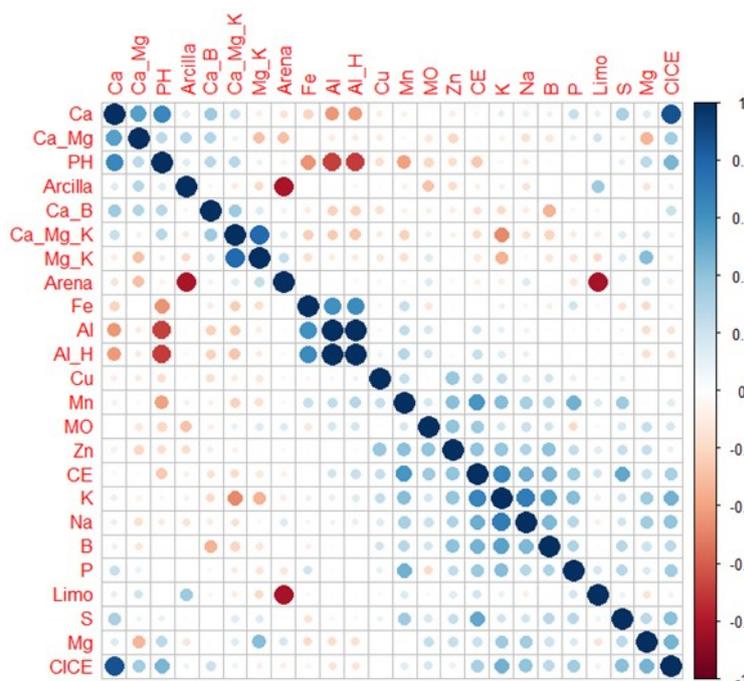


FIGURA 1  
Correlación de Pearson entre las variables analizadas

Mediante la técnica de componentes principales (ACP), la información de plantas sanas y enfermas se resumió en dimensiones con el fin de agrupar conjuntos de variables (por afinidad) y entender la relación entre estas. La varianza explicada fue del del 71.5% para plantas sanas y 73.4% para plantas enfermas, en plantas sanas los componentes de suelo más importantes fueron: CE, Na, K, Ca, pH, % Arena y Ca/Mg (Figura 2a); mientras que para plantas enfermas fueron: K, Ca, CE, pH, CICE y Mg (Figura 2b). La elección de estas variables permite la construcción de modelos Machine Learning como herramienta para clasificar el estado de una planta en relación con las características químicas del suelo.

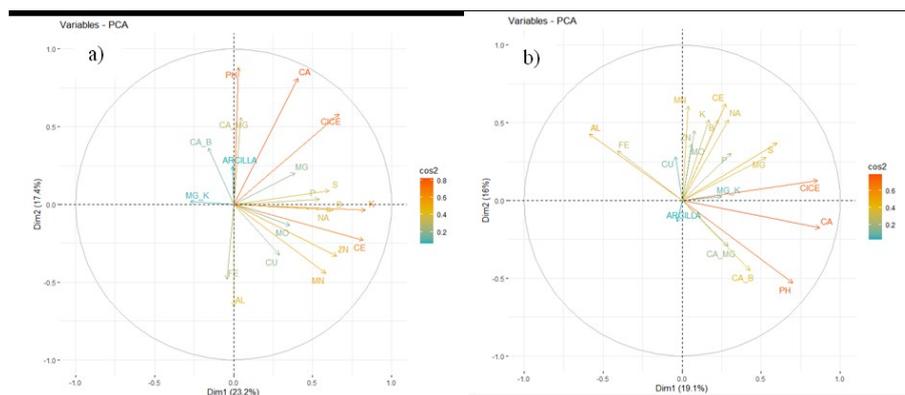


FIGURA 2

Mapa de Factores de los elementos del suelo encontrados en plantas sanas y enfermas. El Cos2, indica el grado de importancia de la variable dentro del componente. a) Plantas sanas, b) Plantas enfermas

TABLA 3

Modelos de Machine Learning estimados para clasificar el estado de la planta (sana o enferma) con relación a la concentración de los elementos químicos disponible en el suelo

Modelo	Accuracy	Recall	Precision	F1 Score
Decision Tree Classifier	0.59	0.51	0.54	0.51
Random Forest Classifier	0.53	0.38	0.49	0.43
Light Gradient Boosting Machine	0.49	0.53	0.49	0.51
Extra Trees Classifier	0.52	0.39	0.45	0.41

La Figura 3, permite analizar que los elementos Ca, K, la CICE, el pH y el % arena son lo más determinantes en la presencia o ausencia de la enfermedad en plantas de uchuva, además, se estableció que a mayor % de partículas arena en el suelo, hay una disminución de la presencia de la enfermedad en las plantas; con relación a los elementos Ca y K se evidenció al haber una menor concentración de estos elementos en el suelo aumenta la probabilidad de que las plantas sean afectadas por el patógeno, además una baja Capacidad de Intercambio Catiónico aumentó el riesgo de infección por *F. Oxysporum* en plantas de uchuva

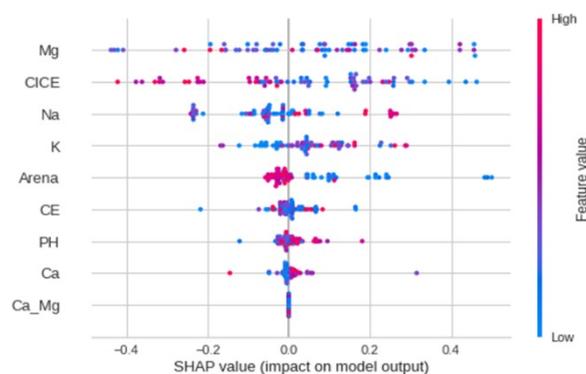


FIGURA 3

Interpretación del modelo: Shap Value, de plantas sanas y enfermas con relación a variables físicas y químicas del suelo

## DISCUSIÓN

El modelo basado en árboles de decisión “Decision Tree Classifier” fue el que mejor rendimiento predictivo presento, dado a que éste se basa en la división de criterios con una estructura de árbol en la que las instancias se clasifican según los valores asociados a una característica, cada nodo en un árbol de decisión representa una instancia destinada a la clasificación y cada rama del nodo simboliza la etiqueta de clase, lo que lo hace un método muy eficiente de clasificación (Bansal et al., 2022; Panigrahi & Borah, 2018).

Las métricas de rendimiento predictivo del modelo seleccionado permitieron evaluar el ajuste entre la salida del modelo y los datos, además de comparar entre diferentes modelos y seleccionar el modelo que mejor permite clasificar las plantas sanas y enfermas en relación con la concentración y textura del suelo (Gupta & Sehgal, 2021; Somogyi, 2021).

Tandera et al. (2017) resaltan las ventajas del uso de algoritmos de clasificación, indicando que son fáciles y rápidos de realizar y que no se requiere de grandes colecciones de datos para lograr el entrenamiento, además los resultados obtenidos son relativamente favorables para realizar clasificaciones. Sin embargo Prieto & Téllez (2021) señalan que si bien los resultados conseguidos para estos modelos de clasificación son altamente promisorios, se hace necesario tener en cuenta que estos pueden verse afectados por diversos factores como el manejo agronómico del cultivo, lo cual genera variación en los datos y conllevaría a la no obtención de resultados idénticos al momento de poner a prueba el modelo con nuevos datos que no tengan la misma naturaleza de los datos con los que se realizó el entrenamiento del modelo.

Se ha demostrado que la adición de Ca al suelo suprime el marchitamiento por *Fusarium* en una amplia variedad de plantas hospedantes y condiciones del suelo (Orr & Nelson, 2018), además ayuda a estabilizar la estructura celular, acumulándose en la pared celular y la lámina media (Hawkesford et al., 2011), un aumento de la concentración de calcio en la pared celular ayuda a reducir la pérdida de compuestos citoplasmáticos en caso de penetración celular de hongos que pueden inhibir el ataque de hongos parásitos (como *F. oxysporum*) al inhibir las enzimas diseñadas para degradar la lámina media (Huber et al., 2012).

Por su parte Orr & Nelson (2018) señalan que cuanto menor sea el suministro de Hierro o Manganeseo biodisponible en el suelo, más exitosas serán las plantas hospedantes y las bacterias beneficiosas en presencia de *F. oxysporum*; además se ha demostrado que los agentes quelantes con alta estabilidad de quelato (K) inducen la supresión de *F. oxysporum*.

Estudios realizados por Domínguez-Hernández et al. (2010) demostraron un efecto significativo respecto al aumento en la concentración de potasio en suelos sin enfermedad (suelos supresores) y con enfermedad (suelos propicios) afectados por *Fusarium* naturalmente, siendo los valores de K mayores en áreas sin enfermedad; Sanogo & Yang (2001) en un estudio realizado sobre el desarrollo del síndrome de muerte súbita de la soya *Glycine max* Merrill, 1917, causado por *F. solani* f. sp. *glicinas*, demostraron que la severidad de la enfermedad disminuyó cuando el suelo se modificó con KCl. Lo anterior se debe a que el Potasio disponible en el suelo (factor abiótico) puede ejercer una influencia indirecta sobre los mecanismos biológicos de expresión de la enfermedad.

La implementación de herramientas de Machine Learning en la agricultura ha ido aumentando en los últimos años y su uso para la detección de plantas afectadas por diferentes patógenos ha tomado gran relevancia lo que ha permitido desarrollar estrategias de prevención en campo (Aworka et al., 2022; Pujari et al. 2016).

## CONCLUSIONES

El análisis de componentes principales identificó que los factores que mayor influencia tienen sobre la presencia o ausencia de la enfermedad en las plantas fueron Mg, Na, CE, Ca, K, CICE, Ca/Mg, pH y % Arena.

El modelo con mejor desempeño predictivo fue Decision Tree Classifier el cual permitió establecer que en suelos donde se presenten porcentajes altos

de Arena, bajas concentraciones de Ca y K, y un bajo CICE pueden tener mayor probabilidad de presentar de plantas enfermas por *F. oxysporum*

## AGRADECIMIENTOS

Al Ministerio de Agricultura y Desarrollo Rural de Colombia - MADR, por la financiación y a la Corporación Colombiana de Investigación Agropecuaria (Agrosavia), por la ejecución del proyecto “Desarrollo integral de modelos productivos sostenibles para el cultivo de la uchuva en Colombia”

## REFERENCIAS BIBLIOGRÁFICAS

- Ali, M. (2020). PyCaret: An open source, low-code machine learning library in Python. PyCaret version, 2.
- Abdulridha, J., Ampatzidis, Y., Ehsani, R. y de Castro, A. I. (2018). Evaluating the performance of spectral features and multivariate analysis tools to detect laurel wilt disease and nutritional deficiency in avocado. *Computers and Electronics in Agriculture*, 155, 203–211. <https://doi.org/https://doi.org/10.1016/j.compag.2018.10.016>
- Aworka, R., Cedric, L. S., Adoni, W. Y. H., Zoueu, J. T., Mutombo, F. K., Kimpolo, C. L. M., Nahhal, T. y Krichen, M. (2022). Agricultural decision system based on advanced machine learning models for yield prediction: Case of East African countries. *Smart Agricultural Technology*, 2, 100048. <https://doi.org/https://doi.org/10.1016/j.atech.2022.100048>
- Asociación Nacional de Comercio Exterior (ANALDEX). (2021). Exportaciones de uchuva 2016. En línea: <http://www.analdex.org/wp-content/uploads/2017/02/Informe-Uchuva-2017-SE.pdf>.
- Asociación Nacional de Comercio Exterior (ANALDEX). (2021). Mercado de la uchuva. En línea: <http://www.analdex.org/2018/02/26/mercado-de-la-uchuva/>.
- Bansal, M., Goyal, A. y Choudhary, A. (2022). A comparative analysis of K-Nearest Neighbor, Genetic, Support Vector Machine, Decision Tree, and Long Short Term Memory algorithms in machine learning. *Decision Analytics Journal*, 3, 100071. <https://doi.org/https://doi.org/10.1016/j.dajour.2022.100071>
- Bansal, M., Prince, Yadav, R. y Ujjwal, P. K. (2020). Palmistry using Machine Learning and OpenCV. 2020 Fourth International Conference on Inventive Systems and Control (ICISC), 536–539. <https://doi.org/10.1109/ICISC47916.2020.9171158>
- Bautista, E., Quirama, J. y Bautista, E. (2021). Modelo predictivo del progreso en el aprendizaje de los estudiantes de uniminuto aplicando técnicas de machine learning. *Conrado*, 17(83), 305-310. Epub 10 de diciembre de 2021. Recuperado en 15 de octubre de 2022, de [http://scielo.sld.cu/scielo.php?script=sci\\_arttext&pid=S1990-86442021000600305&lng=es&tlng=es](http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1990-86442021000600305&lng=es&tlng=es).
- Beckman, C., and E. Roberts. (1995). On the nature and generic basis for resistance and tolerance to wilt diseases of plants. *Advanced Botanical Research* 24(3): 35-77.
- Borges-Pérez, A., Trujillo, J. D. C., Gutiérrez Jerez, F. y Angulo Rodríguez, D. (1983). Estudio sobre el Mal de Panamá en las Islas Canarias. II. Influencia de los desequilibrios nutritivos P-Zn y K-Mg del suelo, en la alteración de los mecanismos de resistencia de la platanera (Cavendish enana) al Mal de Panamá.
- Calvo Vélez, P., Reymundo Meneses, L. y Zúñiga Dávila, D. (2008). Estudio de las poblaciones microbianas de la rizósfera del cultivo de papa (*Solanum tuberosum*) en zonas altoandinas. *Ecología Aplicada*, 7(1-2), 141-148.
- Castro León, J. A., Penagos Díaz, L. y Salgado Úsuga, S. T. (2020). Estudio de viabilidad para exportar uchuva hacia Estados Unidos.
- Domínguez-Hernández, J. D., Negrín-Medina, M. A. y Rodríguez-Hernández, C. M. (2010). Potassium Selectivity in Transported Volcanic Soils (Sorribas) under Banana Cultivation in Relation to Banana-Wilt Expression Caused

- by *Fusarium oxysporum* f. sp. Cubense. Communications in Soil Science and Plant Analysis, 41(14), 1674–1692. <https://doi.org/10.1080/00103624.2010.489133>
- EMBRAPA (Centro Nacional de Pesquisa de Mandioca e Fruticultura Tropical). (1987). Relatório técnico do Centro Nacional de Pesquisa de Mandioca e Fruticultura – 1986. Cruz das Almas, Brasil. en: [https://www.agronet.gov.co/Documents/39-UCHUVA\\_2017.pdf](https://www.agronet.gov.co/Documents/39-UCHUVA_2017.pdf). (con acceso 07/09/2022).
- Estupiñán Rodríguez, H. y Ossa Canencio, J. A. (2007). Efecto del agente causal de la marchitez vascular de la uchuva (*Physalis peruviana* L.) el hongo *Fusarium oxysporum* schlecht, sobre algunas solanáceas y otras especies cultivadas afectadas por formas especiales del microorganismo. En: <https://repository.javeriana.edu.co/handle/10554/8319>.
- Forero de La-Rotta y Quevedo. (2005). Marchitamiento vascular en uchuva (*Physalis peruviana* L.) ocasionada por *Fusarium oxysporum*. En: resúmenes XXVI congreso de ASCOLFI. Bogotá octubre 5-7. 70p.
- Gallardo Correa, A. (2006). Geostadística. Ecosistemas, Vol. 15, n. 3 (sept.-dic. 2006); pp. 48-58.
- Garzón, C., Cortés, C. A., y Camacho-Tamayo, J. H. (2010). Variabilidad espacial de algunas propiedades químicas en un Entisol. Revista UDCA Actualidad y Divulgación Científica, 13(1), 87-95.
- Góngora Salgado, A. C. y Rojas Gracia, P. (2006). Incidencia de las enfermedades en uchuva *Physalis peruviana* L., por estado fenológico y de acuerdo con la ubicación en los diferentes estratos de la planta, en el departamento de Cundinamarca. Trabajo de grado Microbiología Agrícola y Veterinaria. Fac. Ciencias Biológicas, Pontificia Universidad Javeriana, Bogotá. 87p.
- Gupta, P. y Sehgal, N. K. (2021). Introduction to Machine Learning in the Cloud with Python: Concepts and Practice. In Introduction to Machine Learning in the Cloud with Python. Springer International Publishing. <https://doi.org/10.1007/978-3-030-71270-9>
- Haglund, W. y J. Kraft (2001). Fusarium wilt. p. 14-16. In: Kraft, J.M. and Pflieger, F.L. (eds.). Compendium of pea diseases and pests. The American Phytopathological Society Press, Minnesota, USA. 84 p.
- Hassan, H. A., Serag, H. M., Qadir, M. S. y Ramadan, M. F. (2017). Cape gooseberry (*Physalis peruviana*) juice as a modulator agent for hepatocellular carcinoma-linked apoptosis and cell cycle arrest. Biomedicine y Pharmacotherapy, 94, 1129-1137.
- Hawkesford, M., Horst, W., Kichey, T., Lambers, H., Schjoerring, J., Møller, I. S. y White, P. (2011). Functions of Macronutrients. In Marschner's Mineral Nutrition of Higher Plants: Third Edition (pp. 135–189). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-384905->
- Huber, D., Römheld, V. y Weinmann, M. (2011). Relationship between Nutrition, Plant Diseases and Pests. In Marschner's Mineral Nutrition of Higher Plants: Third Edition (pp. 283–298). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-384905-2.00010-8>
- Hwang, S. (1985). Ecology and control of fusarial wilt of banana. Plant Protection Bulletin 27(3): 233-245.
- Kaliyadan, F. y Kulkarni, V. (2019). Types of Variables, Descriptive Statistics, and Sample Size. Indian Dermatology Online Journal, 10(1). [https://journals.lww.com/idoj/Fulltext/2019/10010/Types\\_of\\_Variables,\\_Descriptive\\_Statistics,\\_and.19.aspx](https://journals.lww.com/idoj/Fulltext/2019/10010/Types_of_Variables,_Descriptive_Statistics,_and.19.aspx)
- Jhuria, M., Kumar, A. y Borse, R. (2013). Image processing for smart farming: Detection of disease and fruit grading. 2013 IEEE Second International Conference on Image Information Processing (ICIIP-2013), 521–526. <https://doi.org/10.1109/ICIIP.2013.6707647>.
- Ochoa Fuentes, Y. M., Cerna Chávez, E., Gallegos Morales, G., Landeros Flores, J., Delgado Ortiz, J. C., Hernández Camacho, S. y Olalde Portugal, V. (2012). Identificación de especies de *Fusarium* en semilla de ajo en Aguascalientes, México. Revista mexicana de micología, 36, 27-32.
- Orr, R. y Nelson, P. N. (2018). Impacts of soil abiotic attributes on Fusarium wilt, focusing on bananas. Applied Soil Ecology, 132, 20–33. <https://doi.org/https://doi.org/10.1016/j.apsoil.2018.06.019>
- Panigrahi, R. y Borah, S. (2018). Rank Allocation to J48 Group of Decision Tree Classifiers using Binary and Multiclass Intrusion Detection Datasets. Procedia Computer Science, 132, 323–332. <https://doi.org/https://doi.org/10.1016/j.procs.2018.05.186>

- Prieto Morante, J. S. y Trelles Prieto, R. L. (2021). Clasificación de hojas de tomate con plagas o enfermedades usando una máquina de soporte vectorial (SVM). Tomado de [https://pirhua.udep.edu.pe/bitstream/handle/11042/4940/T\\_IME\\_2103.pdf?sequence=1](https://pirhua.udep.edu.pe/bitstream/handle/11042/4940/T_IME_2103.pdf?sequence=1) (2019).
- Pujari, D., Yakkundimath, R. y Byadgi, A. S. (2016). SVM and ANN based classification of plant diseases using feature reduction technique. *IJIMAI*, 3(7), 6-14.
- R Core Team (2017) R: a language and environment for statistical computing. R Foundation for Statistical Computing, <https://www.R-project.org/>.
- Restrepo, L., Posada, S. y Noguera, R. (2012). Application of the principal-component analysis in the evaluation of three grass varieties. *Revista Colombiana de Ciencias Pecuarias*, 25, 258–266. [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0120-06902012000200011&nrm=iso](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-06902012000200011&nrm=iso)
- Rodríguez - Molina, M. C., Medina, I., Torres - Vila, L. M. y Cuartero, J. (2003). Vascular colonization patterns in susceptible and resistant tomato cultivars inoculated with *Fusarium oxysporum* f. sp. *lycopersici* races 0 and 1. *Plant Pathology*, 52(2), 199-203.
- Rovetta, A. (2020). Raiders of the Lost Correlation: A Guide on Using Pearson and Spearman Coefficients to Detect Hidden Correlations in Medical Sciences. *Cureus*. <https://doi.org/10.7759/cureus.11794>
- Roveda, G., Peñaranda, A., Ramírez, M., Baquero, I. y Galindo, R. (2012). Diagnóstico de la fertilidad química de los suelos de los municipios de Granada y Sylvania para la producción de uchuva en Cundinamarca. In *Revista Corpoica-Ciencia y Tecnología Agropecuaria* (Vol. 13, Issue 2)
- Sanogo, S. y Yang, X. B. (2001). Relation of sand content, pH, and potassium and phosphorus nutrition to the development of sudden death syndrome in soybean. *Canadian Journal of Plant Pathology*, 23(2), 174–180. <https://doi.org/10.1080/07060660109506927>
- Sidey-Gibbons, J. A. M. y Sidey-Gibbons, C. J. (2019). Machine learning in medicine: a practical introduction. *BMC Medical Research Methodology*, 19(1), 64. <https://doi.org/10.1186/s12874-019-0681-4>
- Somogyi, Z. (2021). The Application of Artificial Intelligence: Step-by-Step Guide from Beginner to Expert. In *The Application of Artificial Intelligence*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-60032-7>
- Sun, S. y Huang, V. (1985). Formulated soil amendment for controlling *Fusarium* wilt and other soil-borne diseases. *Plant Disease* 69(11): 917-920.
- Tandera, T., Suhartono, D., Wongso, R. y Prasetio, Y. L. (2017). Personality prediction system from facebook users. *Procedia computer science*, 116, 604-611.
- Trujillo, I., Gutierrez, F. y Borges, A. (1983). Estudio sobre el mal de Panamá en las Islas Canarias. III. Relaciones entre parámetros físicos y químicos de los suelos. *Fruits* 38(11): 759-764.