



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Evaluación de herramientas de análisis de datos espectrales para la identificación y cuantificación de la madurez temprana en papa

William Alfonso Leon Rueda

Universidad Nacional de Colombia

Facultad de Agronomía

Bogotá D.C, Colombia

2023

Evaluación de herramientas de análisis de datos espectrales para la identificación y cuantificación de la madurez temprana en papa

William Alfonso Leon Rueda

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título de:

Magister en Geomática

Director (a):

Ph.D. Joaquín Guillermo Ramírez Gil

Codirector (a):

Ph.D. Sandra Gómez Caro

Línea de Investigación:

Tecnologías Geoespaciales

Grupo de Investigación:

Biogénesis, Código: COL0066561, Clasificación de Colciencias: A1

Universidad Nacional de Colombia

Facultad de Agronomía

Bogotá D.C, Colombia

2023

*No importa cuánto deformemos la realidad.
Afortunadamente siempre habrá teorías,
estudios y datos que corroboran nuestro punto
de vista.*

John Kenneth Galbraith

Declaración de obra original

Yo declaro lo siguiente:

He leído el Acuerdo 035 de 2003 del Consejo Académico de la Universidad Nacional. «Reglamento sobre propiedad intelectual» y la Normatividad Nacional relacionada al respeto de los derechos de autor. Esta disertación representa mi trabajo original, excepto donde he reconocido las ideas, las palabras, o materiales de otros autores.

Cuando se han presentado ideas o palabras de otros autores en esta disertación, he realizado su respectivo reconocimiento aplicando correctamente los esquemas de citas y referencias bibliográficas en el estilo requerido.

He obtenido el permiso del autor o editor para incluir cualquier material con derechos de autor (por ejemplo, tablas, figuras, instrumentos de encuesta o grandes porciones de texto).

Por último, he sometido esta disertación a la herramienta de integridad académica, definida por la universidad.

William Leon

William Alfonso Leon Rueda

Fecha 05/06/2023

Agradecimientos

Este documento condensa el resultado de un ambicioso proyecto en el cual participaron de manera directa e indirecta muchas personas, a todas ellas muchas gracias por pertenecer y aportar a esta investigación. Me gustaría dar las gracias a mi familia, mi novia y amigos por su inquebrantable apoyo y ánimo en los momentos difíciles de mi investigación. Me gustaría expresar mi más profunda gratitud a mi director de tesis, Joaquín Guillermo Ramírez Gil, por su inestimable orientación, apoyo y aliento a lo largo de mi proceso de formación. También estoy muy en deuda con la profesora Sandra Gómez Caro y el profesor Camilo Alexander Leon Sánchez por sus críticas constructivas y valiosas sugerencias. Debo agradecer a todo grupo de trabajo del grupo, en especial a Luis Alberto Mendoza por su gran aporte a la investigación. Por último, me gustaría agradecer el apoyo de la Universidad Nacional de Colombia, FEDEPAPA y el Fondo Nacional para el Fomento de la papa por proporcionar el apoyo financiero que hizo posible esta investigación.

Resumen General

Evaluación de herramientas de análisis de datos espectrales para la identificación y cuantificación de la madurez temprana en papa

El cultivo de papa es afectado por diferentes enfermedades que disminuyen su rendimiento, entre ellas, los problemas asociados a madurez temprana (MT) causada por *Verticillium* spp. han cobrado importancia en Colombia. La falta de estrategias de manejo y en especial herramientas de diagnóstico y detección temprana ha generado la necesidad de identificar técnicas de detección indirecta con aplicación potencial a nivel comercial. Por lo anterior, este trabajo tuvo como objetivo evaluar herramientas de análisis de datos espectrales para la identificación y cuantificación de MT asociada a *Verticillium* spp. en cultivos de papa. El trabajo se dividió en dos fases en busca de caracterizar a nivel espectral plantas sanas y enfermas, además de hacer una aproximación a la cuantificación indirecta de distintos niveles de severidad de la enfermedad. En primer lugar, se compararon firmas espectrales adquiridas mediante un espectro radiómetro fijo bajo condiciones controladas con el fin de identificar bandas e índices espectrales contrastantes por su capacidad para la detección y cuantificación indirecta de esta patología. Posteriormente, en dos áreas de producción comercial se generaron clasificaciones utilizando algoritmos de aprendizaje automático (Bosques aleatorios, Máquinas de soporte vectorial, Redes neuronales y Adaboost), seleccionando aquellos de mejor comportamiento mediante parámetros de rendimiento por su capacidad para la identificación de plantas sanas y enfermas. Adicionalmente, se realizó una aproximación a la cuantificación de la severidad usando datos multiespectrales adquiridos por medio de un dron. Los resultados indican que los algoritmos usados no tuvieron diferencias significativas entre la capacidad de clasificación usando como predictoras firmas espectrales de plantas sanas y enfermas. Igualmente, las regiones del rojo y el borde rojo fueron las que presentaron mayor importancia en los clasificadores, conllevando a que los índices espectrales RECI, NDRE y GRVI presentaron mayor capacidad discriminativa. En cuanto a los lotes comerciales, se observó que las clasificaciones alcanzaron niveles aceptables de exactitud, los cuales están directamente relacionados con las variables de intensidad de la enfermedad. Por otra parte, se resalta que en esta propuesta se hace un vínculo entre firmas espectrales e imágenes multiespectrales adquiridas bajo condiciones controladas y tomados en cultivos de condición comercial campo, hallando regiones e índices espectrales informativos con un alto potencial para el desarrollo de sensores ópticos de bajo costo que permitan la detección indirecta de la MT en el cultivo de papa.

Palabras clave: Métodos de clasificación, sensores remotos, aprendizaje automático, bandas espectrales informativas, detección indirecta.

Abstract

Evaluation of spectral data analysis tools for the identification and quantification of early maturity in potato

Potato crop is affected by different diseases that reduce yield, among them, problems associated with early maturity (MT) caused by *Verticillium* spp. have gained importance in Colombia. The lack of management strategies, especially diagnostic and early detection tools, has generated the need to identify indirect detection techniques with potential commercial application. Therefore, the objective of this work was to evaluate spectral data analysis tools for the identification and quantification of MT associated with *Verticillium* spp. in potato crops. The work was divided into two phases in order to characterize healthy and diseased plants at the spectral level, as well as to make an approximation to the indirect quantification of different levels of disease severity. First, spectral signatures acquired by means of a fixed radiometer spectrum were compared under controlled conditions in order to identify contrasting spectral bands and indices for their capacity for the detection and indirect quantification of this pathology. Subsequently, in two commercial production areas, classifications were generated using machine learning algorithms (Random Forests, Support Vector Machines, Neural Networks and Adaboost), selecting those with the best performance parameters for their ability to identify healthy and diseased plants. Additionally, a severity quantification approach was performed using multispectral data acquired from a drone. The results indicate that the algorithms used had no significant differences between the classification capability using spectral signatures of healthy and diseased plants as predictors. Likewise, the red and red-edge regions were those that presented the greatest importance in the classifiers, leading to the RECI, NDRE and GRVI spectral indices presenting greater discriminatory capacity. As for the commercial lots, it was observed that the classifications reached acceptable levels of accuracy, which are directly related to the variables of disease intensity. On the other hand, it is highlighted that in this proposal a link is made between spectral signatures and multispectral images acquired under controlled conditions and taken in commercial field condition crops, finding regions and informative spectral indices with a high potential for the development of low-cost optical sensors that allow the indirect detection of MT in potato crops.

Keywords: Classification methods, remote sensing, machine learning, informative spectral bands, indirect detection.

Contenido

| | Pág. |
|---|-------------|
| Resumen General | IX |
| Lista de figuras | XIII |
| Lista de tablas | XVI |
| Organización de la tesis | 17 |
| 1. Consideraciones generales | 18 |
| 1.1 Introducción general..... | 18 |
| 1.2 Planteamiento del problema..... | 20 |
| 1.3 Justificación..... | 21 |
| 1.4 Preguntas de investigación | 22 |
| 1.5 Objetivos | 22 |
| 1.5.1 Objetivo general..... | 22 |
| 1.5.2 Objetivos específicos | 22 |
| 1.6 Marco conceptual | 23 |
| 1.6.1 Madurez temprana en cultivos de papa | 23 |
| 1.6.2 Diferencia de reflectancia en las plantas..... | 24 |
| 1.6.3 Uso de índices espectrales a partir de imágenes multiespectrales | 26 |
| 1.6.4 Modelos de clasificación de imágenes..... | 27 |
| 1.6.5 Enfoque de clasificación basado en píxeles..... | 29 |
| 1.6.6 Cuantificación de enfermedades en cultivos a partir de imágenes capturadas con VANT..... | 31 |
| 1.6.7 Evaluación de resultados de clasificación en imágenes..... | 33 |
| 1.7 Estado del arte | 35 |
| 1.7.1 Uso de imágenes multiespectrales en identificación de alteraciones en cultivos 35 | |
| 1.7.2 Modelación de datos de imágenes multiespectrales enfocados a clasificación en agricultura | 36 |
| 1.7.3 Desempeño de modelos aplicados a detección y cuantificación de alteraciones en cultivos con imágenes multiespectrales..... | 37 |
| 1.7.4 Desempeño de modelos aplicados a detección y cuantificación de alteraciones en cultivos con imágenes multiespectrales en cultivos de papa | 39 |
| 1.8 Bibliografía | 39 |
| 2. Conexión entre el laboratorio y el campo en la detección de madurez temprana de la papa: de las firmas espectrales a los índices de vegetación obtenidos con cámaras espectrales acopladas a drones | 47 |

| | | |
|-----------|--|--------------------------------------|
| 2.1 | Resumen | 47 |
| 2.2 | Introducción | 48 |
| 2.3 | Materiales y métodos | 51 |
| 2.3.1 | Localización de los experimentos | 51 |
| 2.3.2 | Adquisición de datos | 52 |
| 2.3.2.1 | Datos en invernadero | 52 |
| 2.3.2.2 | Datos en campo | 53 |
| 2.3.3 | Análisis de datos | 53 |
| 2.3.3.1 | Firmas espectrales | 55 |
| 2.3.3.2 | Cámara Multiespectral | ¡Error! Marcador no definido. |
| 2.3.3.3 | Comparación de datos de espectro radiómetro y datos de cámara multiespectral..... | 56 |
| 2.4 | Resultados..... | 56 |
| 2.4.1 | Análisis de firmas espectrales | 57 |
| 2.4.2 | Determinación de bandas informativas para discriminar entre planta sana y enferma | 63 |
| 2.4.3 | Comparación de firmas espectrales y datos de cámara multiespectral..... | 65 |
| 2.5 | Discusión | 68 |
| 2.6 | Conclusiones | 70 |
| 2.7 | Bibliografía..... | 70 |
| | | |
| 3. | Propuesta metodológica para la detección y cuantificación de la severidad asociada a madurez temprana en cultivos de papa a partir de imágenes multiespectrales capturadas con VANT | 83 |
| 3.1 | Resumen | 83 |
| 3.2 | Introducción | 84 |
| 3.3 | Materiales y métodos | 86 |
| 3.4 | Resultados..... | 92 |
| 3.5 | Discusión | 102 |
| 3.6 | Conclusiones | 105 |
| 3.7 | Bibliografía..... | 106 |
| 4. | Discusión general | 118 |
| 5. | Recomendaciones | 122 |
| 6. | Bibliografía | 123 |

Lista de figuras

| | Pág. |
|---|------|
| Figura 1. Espectro electromagnético en relación con los procesos generados por las plantas. Ajustado de: (Sarić et al., 2022). | 19 |
| Figura 2. Algoritmos de clasificación explorados en estudios para la detección de enfermedades de las plantas. Ajustado de: (Vishnoi et al., 2021). | 20 |
| Figura 3. Respuesta espectral en diferentes fuentes de datos en relación con los componentes estructurales de las plantas. Ajustado de: (Segarra et al., 2020). | 25 |
| Figura 4. Ubicación de las áreas de estudio en condiciones de cultivo comercial e invernadero, mostrando las zonas de captura de imágenes ubicadas en Subachoque y Mosquera (Cundinamarca). | 51 |
| Figura 5. Flujo de trabajo de la investigación realizada para determinar bandas e índices espectrales contrastantes en la detección de MT de la papa. | 54 |
| Figura 6. Desarrollo de síntomas de marchitez temprana en plantas de papa Var. Diacol Capiro con diferentes grados de severidad. A. Plantas inoculadas con <i>Verticillium</i> spp. bajo condiciones de invernadero. B. Plantas en cultivo comercial ubicado en Subachoque. | 57 |
| Figura 7. Comparativo de valores medios de las firmas espectrales capturadas en plantas de papa Var. Diacol Capiro inoculadas con <i>Verticillium</i> y con síntomas de madurez temprana bajo invernadero. A. Plantas sanas y enfermas. B. Niveles de severidad de la enfermedad. | 58 |
| Figura 8. Comparativo de valores medios de las firmas espectrales capturadas en plantas de papa Var. Diacol Capiro inoculadas con <i>Verticillium</i> en diferentes hojas verdaderas. A. Hoja cuatro. B. Hoja siete. | 59 |
| Figura 9. Comparativo de valores medios de las firmas espectrales capturadas en plantas de papa Var. Diacol Capiro inoculadas con <i>Verticillium</i> en diferentes momentos de captura. 1. 62 dds 2. 70 dds 3. 77 dds. | 60 |
| Figura 10. Resultados del análisis PCA aplicado a sets de datos. A. Hoja cuatro–DGS B. Hoja siete–DGS. | 60 |
| Figura 11. Resultados de exactitud de clasificación de modelos aplicados a los sets de datos. A. Hoja cuatro B. Hoja siete. | 61 |
| Figura 12. Métricas de evaluación de modelos generados usando BA sobre datos capturados en la hoja cuatro (H4) y siete (H7) usando el set DGS. A. Presencia B. Severidad. | 62 |

| | |
|---|-----|
| Figura 13. Importancia de vía múltiple de variables de clasificación usando BA aplicado al set DGS. A. Presencia - Hoja cuatro B. Presencia - Hoja siete C. Severidad - Hoja cuatro D. Severidad - Hoja siete. | 63 |
| Figura 14. Gráfico de importancia de variables de clasificación usando BA aplicado a set de datos de índices de vegetación calculados con datos de hoja cuatro. A. Presencia B. Severidad..... | 64 |
| Figura 15. Comportamiento de los índices espectrales de importancia para la discriminación entre plantas sanas y enfermas por la madurez temprana de la papa Var. Diacol Capiro causada por <i>Verticillium</i> a partir de las firmas espectrales. | 65 |
| Figura 16. Bandas informativas respecto a clasificación realizada para firmas espectrales de plantas sanas de papa Var. Diacol Capiro y con síntomas de madurez temprana con el algoritmo BA. A. Bandas con significancia. B. Comparativo de bandas importantes respecto a los espectros de la cámara Parrot Sequoia. C. Comportamiento espectral en áreas de importancia para la discriminación entre plantas de papa Var. Diacol Capiro sanas y afectadas por la MT de la papa causada por <i>Verticillium</i> | 66 |
| Figura 17. Comparativo de métricas de evaluación de BA aplicados a datos de firmas e imágenes espectrales. A. Presencia de MT. B. Severidad de MT..... | 67 |
| Figura 18. Índices espectrales informativos respecto a clasificación de plantas de papa Var. Diacol Capiro sanas y con síntomas de madurez temprana con el algoritmo BA. A. Índices a partir de bandas espectrales. B. Índices a partir de imágenes multiespectrales. | 68 |
| Figura 19. Ubicación de las áreas de estudio, mostrando las zonas de colecta de imágenes ubicadas en Subachoque y Mosquera (Cundinamarca)..... | 87 |
| Figura 20. Diagrama de flujo de proceso metodológico utilizado..... | 89 |
| Figura 21. Desarrollo temporal de NDVI y NDRE en lotes de evaluación. Las áreas rojas corresponden a puntos de comparación del cambio en las imágenes. A. Mosquera. B. Subachoque..... | 93 |
| Figura 22. Resultados de segmentación de imágenes utilizando el algoritmo Multiotsu con cinco niveles. Se presenta de izquierda a derecha: Imagen original, histograma de valores, resultados de segmentación multiotsu e imagen segmentada. A. Mosquera. B. Subachoque..... | 94 |
| Figura 23. Desarrollo temporal de lotes de evaluación respecto a la segmentación realizada utilizando multiotsu. Los puntos de color morado corresponden a las plantas seleccionadas para la evaluación en campo. A. Mosquera. B. Subachoque..... | 95 |
| Figura 24. Matrices de confusión extraídas de los modelos desarrollados para las variables presencia/severidad a partir de datos extraídos de imágenes multiespectrales. A. ADA - Presencia. B. BA – Presencia. C. ADA - Severidad. D. BA – Severidad. | 97 |
| Figura 25. Importancia de variables tras la permutación usadas como predictores en el entrenamiento de los algoritmos usando la variable severidad. A. ADA. B. BA..... | 99 |
| Figura 26. Resultados de clasificación de imágenes multiespectrales con respecto a la presencia de síntomas de MT usando ADA. A. Mosquera. B. Subachoque..... | 100 |

| | |
|--|-----|
| Figura 27. Matrices de confusión comparativas entre datos de campo y valores de presencia obtenidos a partir del flujo de trabajo propuesto en esta investigación. A. Presencia. B. Severidad - Niveles 1 y 2. C. Severidad - Niveles 3 y 4..... | 100 |
| Figura 28. Comportamientos comparativos de valores de severidad calculada a partir de procesamiento de imágenes multiespectrales con respecto a datos de campo. A. Comportamiento de variables. B. Matriz de confusión respecto a datos de campo. | 101 |
| Figura 29. Comportamiento de valores de AUDPC generados a partir de procesamiento de imágenes multiespectrales con respecto a datos de campo. | 102 |

Lista de tablas

| | Pág. |
|---|------|
| Tabla 1. Índices de vegetación con potencial para la detección de madurez temprana de la papa causada por <i>Verticillium</i> spp. | 26 |
| Tabla 2. Resumen de las técnicas de clasificación de imágenes de teledetección (Li et al., 2014; Vishnoi et al., 2021)..... | 28 |
| Tabla 3. Matriz de confusión binaria. | 33 |
| Tabla 4. Índices de vegetación relacionados con los componentes estructurales de las plantas usados en la detección de MT de la papa..... | 56 |
| Tabla 5. Índices de vegetación utilizados para el procesamiento de imágenes multiespectrales para la detección de MT en cultivos de papa..... | 90 |
| Tabla 6. Métricas de evaluación de modelos desarrollados a partir de datos extraídos de imágenes multiespectrales en cultivos de papa afectados con madurez temprana. | 96 |
| Tabla 7. Importancia de variables usadas como predictores en el entrenamiento de los algoritmos usando la variable presencia. | 98 |

Organización de la tesis

Según la normatividad de la Universidad Nacional de Colombia, el formato propuesto por SINAB y en particular la reglamentación establecida para presentación de tesis, el documento final se puede organizar como capítulos, en los cuales se presentan los resultados en formato de artículos científicos. Debido a que cada revista requiere formatos diferentes, es posible que algunos artículos pueden diferir de otros. Sin embargo, se ha buscado que sean presentados con las siguientes secciones: introducción, materiales y métodos, resultados y discusión, seguidos de la lista de referencias. Este trabajo de investigación se encuentra organizado en cuatro capítulos, los cuales tienen el siguiente contenido:

El capítulo uno corresponde a una revisión de temáticas involucradas en el proceso de investigación, donde se podrá encontrar una introducción general, justificación, planteamiento del problema, objetivos, y el estado del arte de la presente investigación, haciendo visible la necesidad investigativa en relación con madurez temprana causada por *Verticillium* spp. en el cultivo de papa y la necesidad de contar con nuevas herramientas que permitan una detección temprana.

El segundo capítulo se enfoca en el uso y comparación del rendimiento de algunos métodos tradicionales y de aprendizaje automático con el fin de identificar longitudes de onda que contrastan entre plantas sanas y con sintomatologías asociadas a madurez temprana en cultivos establecidos bajo dos condiciones productivas a partir de dos fuentes de datos espectrales. Igualmente, se hace una conexión entre datos espectrales obtenidos bajo infección artificial en condiciones controladas e infección natural en campo y el uso de equipos hiperespectrales y multiespectrales respectivamente.

El tercer capítulo muestra el desarrollo metodológico del uso y comparación del rendimiento de algunos algoritmos de aprendizaje automático, con el fin de clasificar imágenes multiespectrales capturadas con VANT teniendo como objetivo la identificación y cuantificación de sintomatologías asociadas a madurez temprana en cultivos comerciales de papa.

El cuarto capítulo presenta la discusión general de los resultados mostrando el impacto de la investigación realizada.

1. Consideraciones generales

1.1 Introducción general

La papa es una planta que se cultiva en todo el mundo, por lo cual se considera un cultivo alimenticio importante debido a su riqueza nutricional (FAOSTAT, 2020). Los países líderes en cuanto a producción son China, India y Rusia (FAOSTAT, 2020). En Colombia, se siembran alrededor de 130.000 hectáreas (Agronet, 2018), con mayor producción en el departamento de Cundinamarca. El rendimiento del cultivo está por debajo del potencial debido a la brecha tecnológica en el manejo de plagas y enfermedades (Lizarazo Peña, 2020). Recientemente se ha identificado y reportado un aumento de sintomatologías asociadas a la madurez temprana (MT) causada por *Verticillium* spp. en zonas productoras de papa en Cundinamarca (Nieto, 1988; Ramirez Gil et al., 2019), causando impactos de hasta del 50% en el rendimiento del cultivo (Klosterman et al., 2009; Powelson & Rowe, 1993). A pesar de ser una enfermedad relevante, en Colombia se considera poco importante y existe poca investigación sobre su impacto y manejo.

Las medidas usadas para evaluar la intensidad de una enfermedad en campo incluyen, incidencia (cantidad de individuos enfermos en una población) y severidad (grado de enfermedad de los individuos) (Arneson, 2001; Mundt, 2019), sin embargo, los resultados de evaluación pueden tener un nivel de sesgo considerable debido a que comúnmente dependen de la capacidad del evaluador (Bock et al., 2010). Aunque existen métodos para detectar directamente enfermedades en el cultivo de papa, basados en las medidas mencionadas previamente, se requiere un tiempo considerable para implementar prácticas de manejo oportunas basadas en los datos generados con esta metodología de evaluación. Debido a esto la utilización de sensores (proximales y remotos) se ha convertido en una herramienta para la identificación rápida y precisa de algunas condiciones fitosanitarias (Behmann et al., 2015; Mahlein et al., 2012) que pueden favorecer la toma de decisiones en el momento adecuado conllevando a reducir los daños causados por distintas alteraciones en los cultivos.

En la actualidad, distintos tipos de sensores acoplados a drones tienen un impacto importante en la agricultura, ya que permiten la captura de datos de alta resolución que ayudan a identificar problemas en los cultivos (Kuang et al., 2012; Sarić et al., 2022; Singh et al., 2020). La teledetección aplicada a la vegetación comúnmente se basa en la información de reflectancia de ondas electromagnéticas obtenidas mediante sensores pasivos, pero su interpretación cuantitativa es compleja (Jasiński et al., 2010). En el caso de las plantas (Figura 1), los espectros de luz sobre los cuales se basan los análisis son: (i) la región ultravioleta (UV), que va de 10 a 380 nm; (ii) los espectros visibles, que se componen de las regiones de longitud de onda azul (450–495 nm), verde (495–570 nm) y roja (620–750 nm); y (iii) la banda del infrarrojo cercano y medio (850-1700 nm) (Kuang et al., 2012; Sarić et al., 2022; Singh et al., 2020).

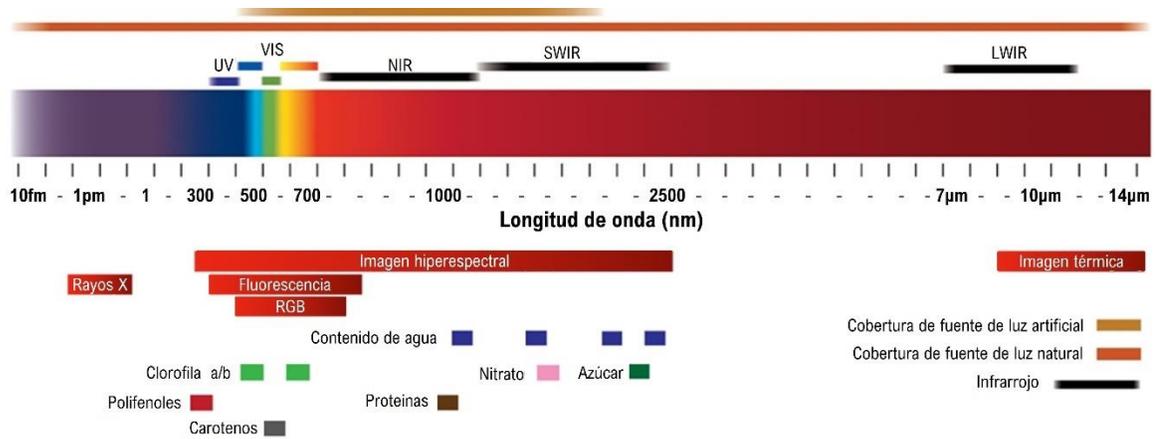


Figura 1. Espectro electromagnético en relación con los procesos generados por las plantas. Ajustado de: (Sarić et al., 2022).

Los datos capturados con sensores requieren categorización (Hamylton et al., 2020), lo cual causa que la mayoría de las técnicas de clasificación en percepción remota utilicen el píxel como unidad básica de análisis, enfocándose en etiquetar cada píxel con una sola clase (Li et al., 2014). Se han desarrollado diferentes metodologías de clasificación, las cuales se pueden catalogar como no supervisadas, supervisadas y clasificaciones híbridas (Figura 2) (Belgiu & Drăgu, 2016; Mountrakis et al., 2011; Vishnoi et al., 2021). Cuando se aplican estos enfoques a regiones heterogéneas se presentan limitaciones, ya que el tamaño de un objeto puede ser mucho más pequeño que el tamaño de un píxel (Li et al., 2014), lo cual dificulta la caracterización de un fenómeno. A partir de esto, se identifica la necesidad de incorporar estrategias de preprocesamiento como la segmentación de imágenes, las cuales permitan comparar algoritmos y múltiples aspectos técnicos disminuyendo el sesgo, logrando utilizar los datos obtenidos bajo estos procedimientos de manera eficiente (Gibson-Poole et al., 2017; León-Rueda et al., 2022; Rodríguez et al., 2021; Shi et al., 2022). Lo anterior, para lograr resultados que sean tanto confiables como oportunos, permitiendo crear estrategias de manejo para las alteraciones evaluadas en cada sistema de producción.

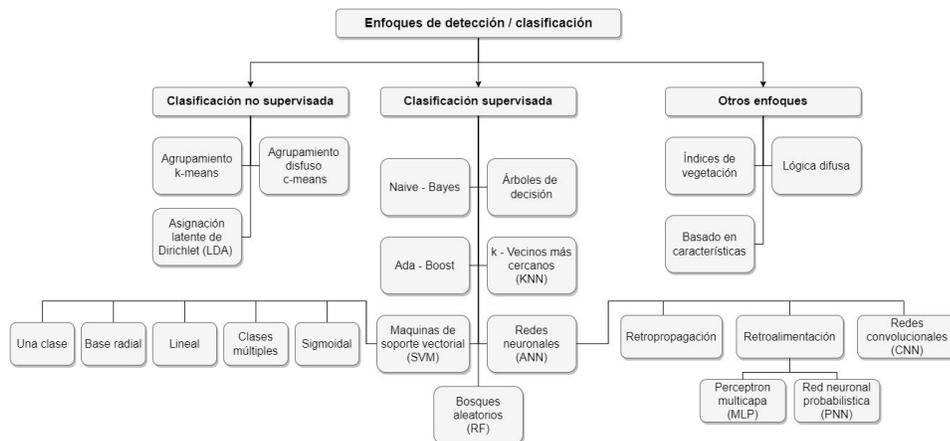


Figura 2. Algoritmos de clasificación explorados en estudios para la detección de enfermedades de las plantas. Ajustado de: (Vishnoi et al., 2021).

Los algoritmos de aprendizaje automático (AA) se utilizan cada vez más en aplicaciones de detección remota (Galieni et al., 2021; Singh et al., 2020), pero su desempeño en comparación con los enfoques de mapeo de vegetación tradicionales en términos de clasificación y rendimiento computacional sigue siendo poco conocido, en especial en el cultivo de papa (Gibson-Poole et al., 2017; León-Rueda et al., 2022; Rodríguez et al., 2021; Shi et al., 2022). Comúnmente, la evaluación del rendimiento de los algoritmos de clasificación se realiza mediante una matriz de confusión, y a partir de ella se obtienen medidas como la exactitud global y la exactitud por clases, las cuales pueden ser métricas de comparación de algoritmos que proveen información acerca de enfoques con mayor capacidad de clasificación (Bekkar et al., 2013; Müller & Guido, 2016). Este enfoque de evaluación es útil en aplicaciones agrícolas puesto que permite comparar los niveles de enfermedad calculados a partir de procesamientos de imágenes con respecto a los datos de campo, lo cual facilita la evaluación del rendimiento de las metodologías en la identificación y cuantificación de alteraciones en los cultivos de papa.

La mayoría de investigaciones que se enfocan en la detección indirecta de enfermedades en plantas de papa, realizan procesamiento de datos espectrales capturados con sensores remotos, sin embargo, existe un conocimiento limitado acerca del rendimiento que se puede obtener al aplicar estos métodos en cultivos comerciales de papa (Gibson-Poole et al., 2017; Rodríguez et al., 2021; Shi et al., 2022; Shin et al., 2023), y esto se aplica aún más cuando se busca estimar la interacción de los datos generados por diferentes sensores en relación con mediciones tradicionales de campo. Sin embargo, la evaluación de esta interacción puede resultar beneficiosa al facilitar los procesos de detección. Recientemente, se han desarrollado investigaciones que involucran técnicas espectrales (Análisis de componentes principales) y de análisis de imagen (Clasificación por píxeles) de manera individual como herramienta en la detección indirecta de MT en el cultivo de papa (León-Rueda et al., 2022; Lizarazo et al., 2023; Shin et al., 2023), mostrando resultados prometedores.

La presente investigación está enfocada en la comparación de herramientas de análisis de para la selección y clasificación de datos espectrales obtenidos mediante el uso de espectro radiómetros fijos y sensores remotos acoplados a drones para la identificación y cuantificación de la afectación denominada madurez temprana en plantas de papa.

1.2 Planteamiento del problema

La madurez temprana causada por *Verticillium* spp. en papa es una enfermedad de suelo que puede causar pérdidas en rendimiento de hasta el 50% (Klosterman et al., 2009; Powelson & Rowe, 1993). En ciclos recientes de producción esta alteración ha sido reportada en zonas productoras de papa en Cundinamarca (Ramirez Gil et al., 2019), sin embargo se evidencia un bajo nivel de información relacionada con su impacto y manejo

(Ramirez Gil et al., 2019), creando la necesidad de generar procesos de investigación en relación con su detección, epidemiología y manejo.

Los sensores proximales y remotos han cobrado importancia por su capacidad para la identificación de una condición específica del estado del cultivo, de una forma rápida y no invasiva (Behmann et al., 2015; Mahlein et al., 2012). Sin embargo, el manejo de los datos de sensores requiere su categorización para obtener una representación apropiada de los objetos de estudio (Hamylton et al., 2020). Este proceso se puede lograr mediante la aplicación de algoritmos de clasificación de imágenes usando enfoques de aprendizaje automático, destacándose los árboles de decisión, máquinas de soporte vectorial o redes neuronales, entre otros.

Estos algoritmos se utilizan cada vez más en aplicaciones de detección remota enfocada a enfermedades y fisiopatologías en plantas, sin embargo, se conoce poco sobre su desempeño en comparación con los enfoques tradicionales de medición y cuantificación respecto a la madurez temprana en cultivos de papa. En el momento la información relacionada con métricas de evaluación es limitada, por ello se busca identificar aspectos que permitan seleccionar el mejor algoritmo en función de significancia, complejidad y performance, para evitar la selección de una técnica incorrecta. No disponer de una herramienta adecuada en este sentido para la madurez temprana de la papa, conlleva a un análisis deficiente de la información, lo cual dificulta su uso y aplicación en la toma de decisiones.

1.3 Justificación

Con el fin de mitigar las afectaciones de los cultivos con la implementación oportuna de prácticas de manejo, la detección temprana entendida como la identificación de síntomas visibles en las primeras etapas del desarrollo de la enfermedad (Rocío Calderón et al., 2015), es necesaria para lograr un manejo adecuado. Sin embargo, aunque en la actualidad en el cultivo de papa se cuentan con algunos métodos que permiten la detección directa (Fang & Ramasamy, 2015), se tiene un bajo conocimiento de métodos indirectos.

Los sensores ópticos y acoplados a drones pueden ser una posible solución, ya que con el actual desarrollo tecnológico brindan una oportunidad para la captura de datos de alta resolución que permiten la identificación de alteraciones presentes en campo (Pourazar et al., 2019). Además, pueden contribuir al manejo de enfermedades, disminuyendo el riesgo de afectar la rentabilidad del cultivo (Garavito, 2018). A partir de esto, se identifica la necesidad de comparar métodos de adquisición de datos y algoritmos para su procesamiento que permitan utilizar de manera eficiente la información obtenida. Esto para lograr resultados que sean tanto confiables como oportunos, permitiendo implementar estrategias de manejo para las alteraciones observadas en el cultivo. Igualmente, generar relaciones entre datos hiperespectrales y multiespectrales adquiridos bajo condiciones diferenciales (invernadero frente a campo), puede contribuir a determinar la estabilidad y capacidad informativa independiente de la forma de adquisición de la información y condición ambiental.

1.4 Preguntas de investigación

A partir de la síntesis de las necesidades del sector, la información teórica-práctica existentes y las herramientas tecnológicas disponibles en la actualidad y su potencial uso en el sistema de producción de papa en Colombia, se generan las siguientes preguntas de investigación:

- ¿Es posible crear vínculos de relación y reproducibilidad entre datos hiperespectrales adquiridos con espectroradiómetros fijos sobre plantas con infección artificial y bajo condiciones controladas y bandas multiespectrales adquiridas mediante sensores multiespectrales acoplados a VANT para la captura de datos bajo condiciones de infección natural en campo?
- ¿Qué métodos de análisis aplicados sobre datos espectrales adquiridos con sensores ópticos permiten generar resultados con el mayor rendimiento por su capacidad en la detección, clasificación y cuantificación de la madurez temprana causada por *Verticillium* spp.? en diferentes etapas de desarrollo en cultivos de papa en Cundinamarca?
- ¿Es posible que al incrementar el preprocesamiento de los datos capturados con sensores multiespectrales acoplados a VANT basados en técnicas de análisis a nivel de píxel y objeto como base para aumentar el rendimiento de distintos algoritmos de clasificación usados para la detección y cuantificación de la madurez temprana causada por *Verticillium* spp. en cultivos de papa?

1.5 Objetivos

1.5.1 Objetivo general

Evaluar herramientas de análisis de datos espectrales para la identificación y cuantificación de madurez temprana asociada a *Verticillium* spp. en cultivos de papa.

1.5.2 Objetivos específicos

- Comparar el rendimiento de distintos algoritmos de análisis de datos espectrales por su capacidad para la identificación y cuantificación de madurez temprana causada por *Verticillium* spp. en cultivos de papa.
- Evaluar la reproducibilidad y relación entre datos espectrales obtenidos mediante un espectroradiómetro fijo y una cámara multiespectral acoplada a VANT por su capacidad para la identificación y cuantificación de madurez temprana causada por *Verticillium* spp. en cultivos de papa.

- Identificar técnicas de procesamiento de imágenes que permitan la identificación y cuantificación de alteraciones asociadas a madurez temprana causada por *Verticillium* spp. en el cultivo de papa a partir de datos espectrales.
- Validar los resultados con cada una de las técnicas de clasificación respecto a los mecanismos tradicionales de detección y cuantificación de la madurez temprana causada por *Verticillium* spp. en el cultivo de papa.

1.6 Marco conceptual

1.6.1 Madurez temprana en cultivos de papa

En el cultivo de papa, existen diversos organismos como bacterias, hongos, entre otros que pueden causar síntomas asociados a madurez temprana en plantas de papa. Algunos hongos como *Fusarium oxysporum* f. sp. *tuberosi* y *Verticillium* spp., inducen taponamiento del haz vascular al bloquear los elementos del xilema impidiendo el movimiento del agua, generando retraso en el crecimiento, senescencia temprana y muerte de la planta, síntomas asociados a la madurez temprana (Manici & Cerato, 1994; Stevenson et al., 2001).

La madurez temprana provocada por *Verticillium* spp. en papa es una enfermedad limitante de suelo que genera reducción en la calidad y el número de tubérculos, con pérdidas reportadas entre 10 y 50% (Johnson et al., 2010; Stevenson et al., 2001). Este patógeno genera marchitez vascular al bloquear los elementos del xilema con abundantes conidios que son translocados a través del sistema vascular impidiendo el movimiento de agua y por ende los nutrientes para la planta (Powelson & Rowe, 1993; Rowe & Powelson, 2002). Las pérdidas causadas por la madurez temprana de la papa dependen de las condiciones ambientales, siendo severas bajo estrés por temperaturas elevadas y altas tasas de evapotranspiración (Stevenson et al., 2001). Esta enfermedad, puede ser provocada por diferentes especies del hongo, entre ellas *Verticillium dahliae* Kleb, *Verticillium albo-atrum* Reinke & Berthold, además de *Verticillium tricorpus* I. y *Verticillium nigrescens* Pethybr las cuales pueden generar síntomas de marchitez en papa y otras plantas, sin embargo, se consideran especies no patogénicas, poco agresivas y poco frecuentes (Jing et al., 2018; Johnson et al., 2010).

La infección por *Verticillium* spp. puede darse en etapas tempranas del cultivo, sin embargo, los síntomas se desarrollan de manera tardía, siendo visibles en la etapa de llenado de tubérculos (Johnson et al., 2010). En el cultivo la enfermedad se distribuye en focos, caracterizados por la presencia de clorosis intervenal en hojas del tercio inferior, posteriormente se marchitan y necrosan de forma acropétala desde la base del tallo (Rowe & Powelson, 2002). Generalmente los síntomas de clorosis en hojas pueden ser unilaterales. Los tallos en las plantas afectadas se vuelven necróticos, presentan senescencia temprana y pueden mantenerse en posición vertical (Johnson et al., 2010;

Rowe & Powelson, 2002). En los haces vasculares se presenta una coloración marrón cerca de la base del tallo y en los tubérculos se desarrolla un pardeamiento vascular (Dung et al., 2012; Johnson et al., 2010).

Las especies mayormente reportadas son *Verticillium albo-atrum* y *Verticillium dahliae*, las cuales son patógenos monocíclicos (Jing et al., 2018). La severidad causada en el hospedero por estas especies, está relacionada directamente con la cantidad de inóculo inicial, viabilidad del mismo y condiciones ambientales (Rowe & Powelson, 2002). La enfermedad se transmite en tubérculos semilla, y el patógeno tiene un número alto de plantas hospederas y puede sobrevivir en el suelo por varios años. Debido a esto, las medidas de manejo deben estar encaminadas a disminuir el inóculo inicial del patógeno, utilizando variedades resistentes, semilla sana, rotación con cultivos no susceptibles por periodos de 3 a 5 años, eliminación de malezas y residuos vegetales (Nieto, 1988), solarización y/o aplicación de agroquímicos al suelo y abonos verdes antes de siembra (Larkin et al., 2011) principalmente.

En Colombia, *V. albo-atrum* se ha reportado asociado a marchitez y madurez temprana en los departamentos de Antioquia, Boyacá, Nariño Norte de Santander y Cundinamarca (Buriticá, 1999; Nieto, 1988). Por su parte, Nieto (1988) asoció las sintomatologías a *V. dahliae* en los departamentos de Boyacá, Nariño y Cundinamarca. Este autor reporta la presencia de estas dos especies en el país, mostrando esta alteración como una enfermedad de difícil predicción por su estrecha dependencia de la temperatura y la humedad. Algunas publicaciones recientes muestran la presencia de sintomatologías asociada a la enfermedad en cultivos ubicados en Cundinamarca (León-Rueda et al., 2022; Lizarazo et al., 2023; Ramirez-Gil et al., 2019).

1.6.2 Diferencia de reflectancia en las plantas

Cada objeto refleja la radiación electromagnética de manera selectiva, la intensidad de esta radiación en diferentes rangos del espectro se conoce como respuesta espectral (Jasiński et al., 2010). Las plantas interactúan con todo el espectro de la luz solar (Figura 3), sin embargo, la radiación electromagnética emitida por el sol puede seguir tres vías: (i) ser transmitida, (ii) reflejada o (iii) absorbida según la longitud de onda observada. La radiación electromagnética que reflejan las plantas contiene información sobre su composición biofísica y su estado fisiológico (Segarra et al., 2020).

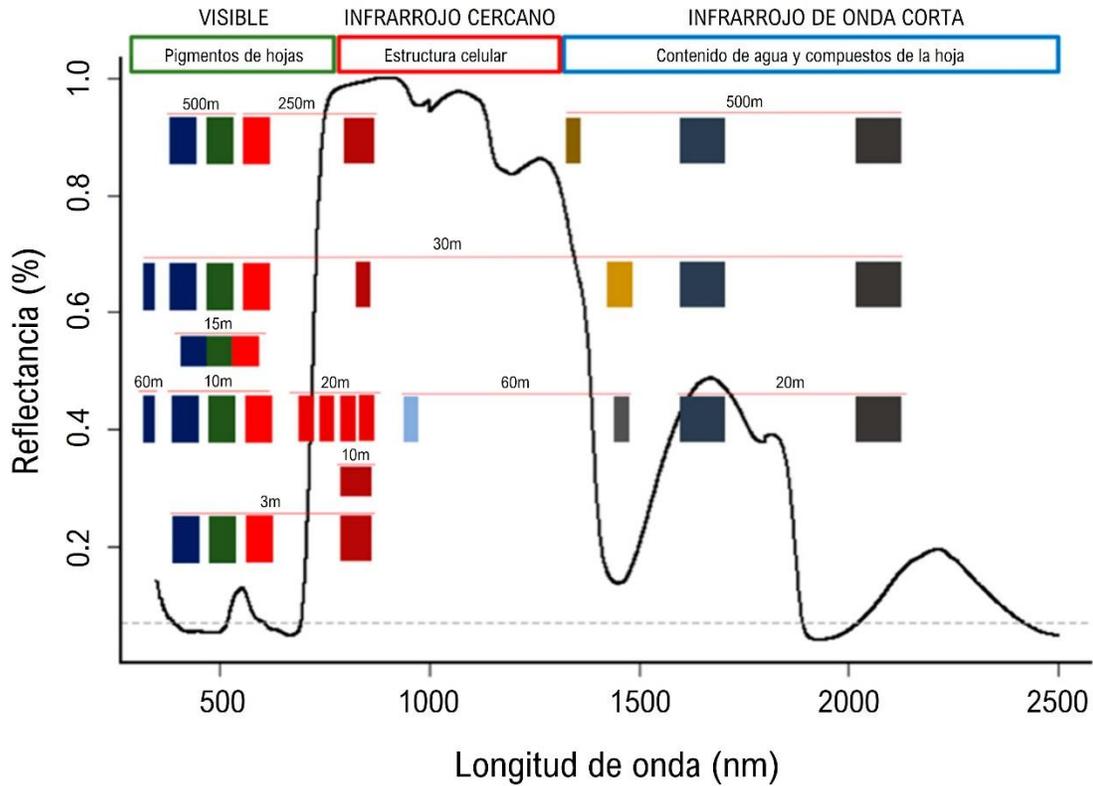


Figura 3. Respuesta espectral en diferentes fuentes de datos en relación con los componentes estructurales de las plantas. Ajustado de: (Segarra et al., 2020).

En los espectros visibles, los pigmentos de clorofila presentes en las hojas verdes absorben fuertemente en la región visible (VIS) del espectro (400-700 nm), especialmente en las longitudes de onda azul y roja, donde se capta la energía para la fotosíntesis (Sarić et al., 2022; Segarra et al., 2020; Singh et al., 2020). Por otra parte, en el infrarrojo cercano (NIR), de aproximadamente 700 a 1300 nm, las hojas exhiben altos valores de reflectancia y transmisión, principalmente relacionados con las propiedades estructurales de la hoja y la biomasa, y absorben menos radiación en esta región espectral (Sarić et al., 2022; Segarra et al., 2020). Además, la estructura del dosel de la planta y el área foliar son también rasgos fundamentales relacionados con los patrones de reflectancia del dosel y son parámetros claves para el seguimiento del crecimiento (Segarra et al., 2020; Singh et al., 2020). En lo que respecta a la región infrarroja de onda corta (SWIR), de aproximadamente 1300 a 2500 nm, la absorción de la radiación está dominada en gran medida por el agua, seguida de otros componentes bioquímicos presentes en las hojas (Segarra et al., 2020).

1.6.3 Uso de índices espectrales a partir de imágenes multispectrales

En vegetación las técnicas de teledetección se aplican principalmente mediante la obtención de la información de reflectancia de ondas electromagnéticas de los doseles utilizando sensores pasivos (Singh et al., 2020; Xue & Su, 2017). Sin embargo, se ha evidenciado que la reflectancia de los espectros de luz de las plantas cambia con el tipo de planta, el contenido de agua dentro de los tejidos y otros factores intrínsecos (Liu et al., 2016), lo cual es determinado por las características morfológicas y químicas de la superficie de las hojas (Zhang & Kovacs, 2012).

Las aplicaciones de las imágenes multispectrales en diferentes áreas del conocimiento comúnmente dependen de los picos de reflectividad o matices para compuestos específicos dentro de las regiones visible e infrarroja cercana / media de los espectros de luz (Singh et al., 2020; Xue & Su, 2017). Muchos estudios han limitado esta interpretación al extraer información de la vegetación utilizando bandas de espectros de luz individuales o un grupo de bandas individuales para el análisis de datos (Xue & Su, 2017). Por lo tanto, la combinaciones de estas bandas, traducidas en índices espectrales pueden ser utilizados como indicadores del estado hídrico de la planta y los niveles de estrés abiótico / biótico (Oerke et al., 2014).

A menudo se combinan los datos de las bandas del infrarrojo cercano y del rojo de diferentes formas de acuerdo con el objetivo de cada estudio (Xue & Su, 2017). Estos tipos de combinaciones presentan muchas desventajas (por ejemplo, falta de sensibilidad) al utilizar un grupo de bandas único o limitado para detectar, por ejemplo, la biomasa de la vegetación (Xue & Su, 2017). Estas limitaciones son particularmente evidentes cuando se intenta aplicar estos tipos de índices de vegetación (IV) en áreas heterogéneas como zonas con una combinación mixta de suelos, malezas, cultivos de cobertura en el interior de la hilera y plantas de variedades diferentes. Esta situación, hace que las regiones de discriminación y la extracción de valores de índice (VI) sea muy difícil, específicamente, cuando la vegetación tiene diferentes valores en los VI debido a la variabilidad espacial, o los VI corresponden a otra vegetación (malezas y cultivos de cobertura), que pueden ser similares a las de interés (Mahlein et al., 2012; Xue & Su, 2017). Esto ha conllevado a que actualmente se planteen algunas combinaciones nuevas debido al avance de los sensores espectrales en términos de alta resolución, número de bandas obtenidas y que el ancho de banda sea cada vez más estrecho (Honkavaara et al., 2013). En la Tabla 1, se muestran las fórmulas de algunos índices de interés para la investigación:

Tabla 1. Índices de vegetación con potencial para la detección de madurez temprana de la papa causada por *Verticillium* spp.

| Nombre | Estimación | Referencia |
|---|---|----------------------|
| Normalized difference vegetation index (NDVI) | $\frac{RNIR - RRED}{RNIR + RRED}$ (Ecuación 1) | (Rouse et al., 1974) |

| | | | |
|--|---------------|--|---|
| Soil-adjusted vegetation index (SAVI) | | $\frac{(RNIR - RRED)(1 + L)}{RNIR + RRED + L}$ | (Huete, 1988) |
| | (Ecuación 2) | | |
| Modified Soil-adjusted vegetation index (MSAVI) | | $\frac{2 * RNIR + 1 - \sqrt{(2 * RNIR + 1)^2 - 8 * (RNIR - RRED)}}{2}$ | (Qi et al., 1994) |
| | (Ecuación 3) | | |
| Enhanced Vegetation Index (EVI2) | | $G * \left(\frac{RNIR - RRED}{(RNIR + (C1 * RRED) + 1)} \right)$ | (Jiang et al., 2008) |
| | (Ecuación 4) | | |
| Green Normalized difference vegetation index (GNDVI) | | $\frac{RNIR - RGREEN}{RNIR + RGREEN}$ | (Yang et al., 2007) |
| | (Ecuación 5) | | |
| Green-Red Vegetation Index (GRVI) | | $\frac{RGREEN - RRED}{RGREEN + RRED}$ | (Motohka et al., 2010; Yeom et al., 2019) |
| | (Ecuación 6) | | |
| Modified Green-Red Vegetation Index (MGRVI) | | $\frac{RGREEN^2 - RRED^2}{RGREEN^2 + RRED^2}$ | (Yeom et al., 2019) |
| | (Ecuación 7) | | |
| Green Chlorophyll Index (GCI) | | $\frac{RNIR^2}{RGREEN} - 1$ | (Gitelson et al., 2003) |
| | (Ecuación 8) | | |
| Red Edge Chlorophyll Index (RECI) | | $\frac{RNIR}{RGREEN} - 1$ | (Gitelson et al., 2003) |
| | (Ecuación 9) | | |
| Normalized Difference Red Edge Index (NDRE) | | $\frac{RNIR - RREDEGE}{RNIR + RREDEGE}$ | (Yeom et al., 2019) |
| | (Ecuación 10) | | |

a factor de corrección del brillo del suelo = 0.5. b MSAVI usa la siguiente fórmula para calcular L, $L = 1 - 2 * s * (RNIR - RRED) * (RNIR - s * RRED) / (RNIR - RRED)$; donde s es la pendiente de la línea del suelo de una gráfica de valores de brillo rojo versus infrarrojo cercano. c G: constante = 2.5; C: coeficientes de resistencia atmosférica (C1 = 2.4); L: para ajustar el fondo = 1.

El uso de índices espectrales como fuente de información se ha incrementado debido a que la captura de los datos necesarios bajo sensores acoplados a vehículos aéreos no tripulados (VANT) cuenta con diferentes ventajas, entre ellas, la captura de datos a baja altitud (50–100 m), la cual se ve menos afectada por los factores atmosféricos durante el proceso de adquisición de datos. Tiene las ventajas de asequibilidad, operación simple, alta velocidad de generación de imágenes y altas resoluciones espaciales y temporales (Yeom et al., 2019). Debido a los rápidos avances tecnológicos, las cámaras térmicas, multiespectrales e infrarrojas son cada vez más económicas y versátiles, razones del incremento de su uso en aplicaciones agrícolas (Lowe et al., 2017; Oerke, 2020; Singh et al., 2020; Xue & Su, 2017).

1.6.4 Modelos de clasificación de imágenes

Para generar información a partir de imágenes en percepción remota a diferentes escalas, se han desarrollado técnicas de clasificación de estas desde la década de 1980 (Oerke,

2020). Durante las décadas de 1980 y 1990, la mayoría de las técnicas emplearon el píxel de la imagen como unidad básica de análisis, con el cual cada píxel se etiqueta como una sola clase (Buja et al., 2021; Li et al., 2014; Singh et al., 2020).

Sin embargo, estos métodos de clasificación de píxeles tienen limitaciones cuando se aplican a áreas heterogéneas, ya que el tamaño de los objetos puede ser mucho más pequeño que el tamaño del píxel. (Li et al., 2014; Yan et al., 2022). En respuesta a esto, la alta resolución espacial de las imágenes capturadas con VANT y su periodicidad de captura, permite la creación de grandes cantidades de conjuntos de datos en forma de imágenes aéreas que se han convertido en un enfoque de detección en diferentes sistemas productivos (Garcia-Ruiz et al., 2013; León-Rueda et al., 2022; Salamí et al., 2014). En general, las múltiples tareas de procesamiento dependen de algoritmos de visión por computadora. En la última década, las aplicaciones realizadas con algoritmos estadísticos y de AA se utilizaron principalmente en tareas de clasificación / regresión, debido a esto existe una gran cantidad de técnicas. En la Tabla 2 se listan algunos algoritmos usados según el enfoque de investigación.

Tabla 2. Resumen de las técnicas de clasificación de imágenes de teledetección (Li et al., 2014; Vishnoi et al., 2021).

| Técnicas de clasificación | Características | Algoritmos |
|----------------------------------|---|--|
| Técnicas basadas en píxeles | Cada píxel se asume individualmente y, por lo general, se etiqueta como un tipo de clase. | Sin supervisión (por ejemplo, k-means, ISODATA, SOM, agrupamiento jerárquico) |
| | | Supervisado (por ejemplo, máxima probabilidad, distancia mínima a la media, distancia de Mahalanobis, paralelepípedo, k vecinos más cercanos) |
| | | Aprendizaje automático (por ejemplo, red neuronal artificial, árbol de clasificación, bosques aleatorios, máquina de vectores de soporte, algoritmos genéticos) |
| Técnicas basadas en subpíxeles | Cada píxel se considera mixto y se estima la proporción de área de cada clase | Clasificación difusa, redes neuronales, modelado de regresión, análisis de árbol de regresión, análisis de mezcla espectral, análisis de mezcla espectral difusa |

| | | |
|-----------------------------|--|---|
| Técnicas basadas en objetos | Los objetos geográficos, en lugar de píxeles individuales, se consideran la unidad básica. | Segmentación de imágenes y técnicas de análisis de imágenes basadas en objetos (por ejemplo, E-cognition, OBIA) |
|-----------------------------|--|---|

1.6.5 Enfoque de clasificación basado en píxeles

Los métodos de clasificación por píxeles asumen que cada píxel es puro y típicamente etiquetado como un tipo de cobertura de uso único (Xu et al., 2005) (Tabla 2). Con este método, las imágenes de teledetección se consideran una colección de píxeles con información espectral y, por lo tanto, las variables espectrales y sus transformaciones (por ejemplo, componentes principales, índices de vegetación, etc.) se ingresan en clasificadores por píxel (Campbell & Wynne., 2011; Li et al., 2014; Singh et al., 2020). En general, los algoritmos de clasificación por píxeles se pueden dividir en dos grupos: (I) clasificación no supervisada y (II) clasificación supervisada (Li et al., 2014; Vishnoi et al., 2021).

Con clasificadores no supervisados, una imagen se divide en varias clases basadas en las agrupaciones naturales de los valores de la imagen, sin la ayuda de datos de entrenamiento o conocimiento previo del área de estudio (Liu, 2003; Puletti et al., 2014). En comparación, los clasificadores supervisados, se basan en sitios de muestreo representativos con tipos de clase conocidos (es decir, muestras de entrenamiento) y compara las propiedades espectrales de cada píxel en la imagen con las de las muestras de entrenamiento, luego etiqueta el píxel según el tipo de clase según reglas de decisión (Belgiu & Drăgu, 2016; Lillesand & Kiefer, 2004; Liu, 2003).

El aprendizaje automático es un enfoque eficaz tanto para la regresión como para la clasificación (supervisada o no supervisada) de sistemas no lineales. Dichos sistemas pueden ser masivamente multivariados, en los que se involucran unas pocas o múltiples variables (Lary et al., 2016). En AA, se construye un conjunto de datos de entrenamiento con ejemplos que representan la mayor parte de parámetros involucrados en la clasificación. Normalmente, se reserva un subconjunto aleatorio de datos para una validación completamente independiente (Belgiu & Drăgu, 2016). El AA es ideal para abordar aquellos problemas en los que nuestro conocimiento teórico aún es incompleto, pero para los cuales tenemos un número significativo de observaciones y otros datos (Lary et al., 2016; Singh et al., 2020). Los tipos de algoritmos comúnmente utilizados son redes neuronales artificiales (ANN, por sus siglas en inglés), máquinas de vectores de soporte (SVM, por sus siglas en inglés), mapa auto organizado (SOM, por sus siglas en inglés), árboles de decisión (DT, por sus siglas en inglés), métodos de conjunto como bosques aleatorios (RF, por sus siglas en inglés), razonamiento basado en casos, neuro-difuso (NF, por sus siglas en inglés), algoritmo genético (GA, por sus siglas en inglés), splines de regresión adaptativa multivariante (MARS, por sus siglas en inglés) (Belgiu & Drăgu, 2016;

Mountrakis et al., 2011; Seetha et al., 2008; Vishnoi et al., 2021). A continuación, se describen en detalle los algoritmos que serán usados en este estudio.

Bosques aleatorios (BA)

BA se ha utilizado en muchas aplicaciones de minería de datos, sin embargo, su potencial en datos capturados con sensores remotos ha sido explorado en diversos estudios (Belgiu & Drăgu, 2016; Lowe & Kulkarni, 2015). BA cultiva muchos árboles de clasificación y para clasificar un nuevo vector de características, el vector de entrada se clasifica con cada uno de los árboles en el bosque. Cada árbol da una clasificación, y se decide que el árbol "vote" para esa clase (Kanti et al., 2010; Lowe & Kulkarni, 2015) (Ecuación 11). El bosque elige la clasificación que tiene más votos sobre todos los árboles en el bosque. Entre las muchas ventajas de BA, las más significativas son: exactitud entre los algoritmos actuales, implementación eficiente en grandes conjuntos de datos, y una estructura fácilmente guardada para el uso futuro de árboles previamente generados (Kanti et al., 2010).

$$BA_{fii} = \frac{\sum_{j \in \text{all trees}} \text{norm}f_{ij}}{T} \quad (\text{Ecuación 11})$$

Dónde: BA_{fii} sub (i) = la importancia de la característica; $\text{norm}f_{ij}$ sub (ij) = la importancia de la característica normalizada para i en el árbol j; T = número total de árboles.

Máquinas de soporte vectorial (MVS)

En la arquitectura de MVS (Ecuación 12), se construyen los hiperplanos de separación óptimos basados en una función de núcleo (K). Todos los valores, cuyo vector de características se encuentra en un lado del hiperplano, pertenecen a la clase -1 y las demás pertenecen a la clase +1 (Thai et al., 2012). En el caso de MVS lineal la separación entre dos clases se realiza maximizando el margen de separación en el hiperplano óptimo. En el caso de la MVS no lineal, las dos clases se mapean primero con la función del núcleo en el espacio de características con una dimensión alta (Mohapatra & Mohanty, 2022).

$$\begin{cases} \text{Arquitectura} = F(X, Y) \\ \text{Peso} = G(\text{Arquitectura}) \\ \text{Minimizar } L(X, \text{Peso}, Y) \end{cases} \quad (\text{Ecuación 12})$$

Dónde: X e Y son los datos de entrada. F (·) denota la función de elección. G (·) se refiere al método de inicialización de los pesos de conexión y L (·) mide las diferencias entre etiqueta verdadera y la etiqueta predicha

Redes neuronales artificiales (RNA)

Las redes neuronales artificiales (RNA) constan de capas de entrada, ocultas y de salida con neuronas conectadas (nodos) para simular el cerebro humano (Mohseni-Dargah et al., 2022). Los modelos de RNA funcionan creando una relación no lineal entre las variables dependientes e independientes en función de un conjunto de datos experimentales

(Antunes et al., 2021). Este algoritmo puede proporcionar soluciones adecuadas para problemas que generalmente se caracterizan por vínculos no lineales, datos de sensores ruidosos, complejos, imprecisos e imperfectos o propensos a errores de alta dimensionalidad, y la falta de una solución o algoritmo matemático claramente establecido (Seetha et al., 2008; Tripathi et al., 2019). La clasificación de imágenes usando redes neuronales se realiza mediante extracción de características y luego aplicando el algoritmo de propagación inversa (Seetha et al., 2008).

AdaBoost (Adaptive Boosting) (ADA)

Es un algoritmo de aprendizaje automático que se utiliza para problemas de clasificación y regresión. Es un tipo de método de aprendizaje por conjuntos, en el que varios modelos débiles (denominados "aprendices base") se combinan para formar un modelo más sólido. El algoritmo funciona mediante el entrenamiento iterativo de los aprendices base y el ajuste de los pesos de las instancias de entrenamiento en función de los errores cometidos por los aprendices base anteriores (Friedman et al., 2000). El algoritmo ADA funciona mediante el entrenamiento iterativo de los aprendices base, donde cada aprendiz base se entrena con una versión ponderada del conjunto de entrenamiento original (Friedman et al., 2000). Los pesos se ajustan de forma que las instancias que fueron mal clasificadas por los aprendices base anteriores reciban más peso en la siguiente iteración de entrenamiento. Esto hace que los aprendices de base se centren más en las instancias difíciles de clasificar, lo que da como resultado un modelo general más sólido (Friedman et al., 2000).

1.6.6 Cuantificación de enfermedades en cultivos a partir de imágenes capturadas con VANT

Los VANT, también conocidos como sistemas aéreos no tripulados (UAS por sus siglas en inglés de Unmanned Aerial System) y/o drones, principalmente han sido adoptados en los sistemas agrícolas en el contexto de la agricultura de precisión (Barbedo, 2019; El Hoummaidi et al., 2021; Tsouros et al., 2019). Por lo tanto, los VANT se están convirtiendo rápidamente en una valiosa herramienta de apoyo en la decisiones para los agricultores e investigadores que se enfrentan a problemas agrícolas (Barbedo, 2019).

Tradicionalmente, la detección de enfermedades en los cultivos ha sido realizada visualmente por personas con alguna formación o experiencia en la detección de alteraciones de las plantas (Mishra et al., 2020; Singh et al., 2020). Como ocurre con cualquier actividad realizada por humanos, este enfoque está sujeto a fenómenos psicológicos y cognitivos que pueden provocar sesgos, ilusiones ópticas y, en última instancia, errores (Bock et al., 2010). Por lo tanto, las herramientas basadas en imágenes pueden desempeñar un papel importante en la detección y el reconocimiento de enfermedades de las plantas cuando la evaluación humana no es adecuada, no es confiable o no está disponible, especialmente con la cobertura extendida que brindan los VANT (Barbedo, 2019).

Las técnicas de imágenes multiespectrales enfocadas a la detección de enfermedades de las plantas integran algoritmos de aprendizaje y clasificación que convierten la información en datos significativos (Shruthi et al., 2019; Singh et al., 2020). Las imágenes RGB y multiespectrales son los productos preferidos para adquirir información sobre las áreas estudiadas, sin embargo, las imágenes hiperespectrales y térmicas también se han probado para distintos fines (Oerke, 2020; Tsouros et al., 2019). Barbedo, 2019 discute varios desafíos involucrados en la identificación automática de enfermedades de las plantas, los cuales son listados a continuación:

- **Fondo de la imagen.** Aislar las plantas del fondo (principalmente suelo en el caso de imágenes adquiridas por VANT) puede ser un problema difícil en sí mismo. Dependiendo de la resolución espacial de las imágenes, pueden obtenerse píxeles mixtos (planta + suelo, planta + sombras) incluso si la segmentación de la planta es exacta (Albetis et al., 2019). Los errores también se pueden minimizar haciendo la segmentación manualmente, pero esta puede ser una tarea muy laboriosa y lo que es más importante, el método resultante para la detección de enfermedades ya no será completamente automático, lo que reducirá drásticamente su aplicabilidad. En cualquier caso, la presencia de arvenses puede dificultar la delimitación de las regiones de interés y, en consecuencia, la correcta detección y cuantificación de las enfermedades (Gibson-Poole et al., 2017).
- **Condiciones de captura de imágenes.** Las preocupaciones sobre la iluminación son especialmente importantes en el campo, donde aspectos como la hora del día, la posición del sol con respecto a la hoja y las condiciones de nubosidad pueden afectar en gran medida las características de la imagen (Barbedo, 2019). En general, la recomendación es que las imágenes se capturen con condiciones nubladas o con el sol cerca del nadir (Barbedo, 2019). Además, generalmente se prefiere un ángulo de captura perpendicular para evitar problemas de perspectiva y oclusión. Vale la pena señalar que algunos autores han optado por realizar misiones de vuelo por la noche, con las plantas iluminadas por una luz polarizada diseñada específicamente para resaltar los efectos de la enfermedad objetivo (Sarkar et al., 2016).
- **Variaciones de los síntomas:** La mayoría de las enfermedades vegetales producen alteraciones fisiológicas que pueden detectarse en determinadas bandas del espectro. El problema es que esas alteraciones pueden ser muy variables dependiendo de factores distintos de la enfermedad en sí, como el cultivo (Albetis et al., 2019), la edad de la hoja (Albetis et al., 2019), la gravedad de la enfermedad (Albetis et al., 2019), las condiciones climáticas y la presencia de otros factores de estrés, entre otras (Barbedo, 2019). Diseñar experimentos que tengan en cuenta todas esas variaciones puede ser un desafío o incluso inviable, lo que puede conducir a métodos con un uso práctico limitado.
- **Otras alteraciones:** Los experimentos suelen considerar solamente las alteraciones de interés y las plantas sanas. En la práctica, hay muchos factores que pueden provocar respuestas similares a las de la enfermedad en cuestión (Albetis et al., 2019). Además, pueden presentarse múltiples alteraciones simultáneamente.

Un grado tan grande de variabilidad que se encuentra en el mundo real es muy difícil de emular en cualquier investigación. Como resultado, los métodos que funcionaron bien en experimentos controlados a menudo fallan en condiciones más realistas. Sin embargo, se plantea que el uso de información adicional, como datos históricos sobre el cultivo y los modelos digitales de superficie (DSM, por sus siglas en inglés) que revelan la altura del dosel (Gibson-Poole et al., 2017), pueden ser valiosos en este tipo de contexto, ya que pueden proporcionar respuestas que pueden resolver posibles ambigüedades.

- **Desplazamiento de covariables:** Otro problema que es muy común surge de las diferencias entre las distribuciones de los datos utilizados para entrenar el modelo y los datos sobre los que se va a aplicar el modelo, una situación que comúnmente se denomina desplazamiento de covariables (Barbedo, 2019).

1.6.7 Evaluación de resultados de clasificación en imágenes

Los resultados de procesamiento deben ser evaluados para comparar el rendimiento de los algoritmos, para de esta manera contrastar su capacidad de clasificación, para ello se utilizan diversas métricas que serán explicadas a continuación:

Curva ROC y AUC

La característica de funcionamiento del receptor (ROC) se ha utilizado para visualizar y evaluar el equilibrio entre el rendimiento de los algoritmos de tasa positiva verdadera y la tasa de falso positivo (Fawcett, 2006). Por lo tanto, la curva ROC se define como gráficos en los que el objetivo de un buen modelo es estar en la esquina superior izquierda, que indica bajos falsos positivos, con un alto recuerdo (Cortes & Mohri, 2004; Fawcett, 2006). Para comparar clasificadores, ROC puede reducirse a un solo valor escalar llamado área bajo la curva (AUC), la cual se relaciona como una medida de la calidad de la clasificación (Cortes & Mohri, 2004), esto indica que para una exactitud perfecta, ambos ejes ROC se maximizan, lo que sugiere que las áreas más grandes son superiores (Mosley, 2013).

Matriz de confusión

En el AA, una de las formas más completas de evaluar una tarea de clasificación es mediante el uso de una matriz de confusión (Bekkar et al., 2013; Müller & Guido, 2016). Como ejemplo, para una tarea de clasificación binaria, el resultado de la matriz de confusión es una matriz de dos por dos como se muestra en la Tabla 3, donde las filas corresponden a las clases verdaderas y las columnas a las clases predichas. El rendimiento de los algoritmos de clasificación se evalúa utilizando datos dentro de esta matriz, donde las entradas en la diagonal principal corresponden a clasificaciones correctas, mientras que las entradas en diagonal corresponden a clasificaciones erróneas (Müller & Guido, 2016).

Tabla 3. Matriz de confusión binaria.

| | Predicción positiva | Predicción negativa |
|--|---------------------|---------------------|
|--|---------------------|---------------------|

| | | |
|---------------|-------------------------------------|---------------------------------|
| Positivo Real | TP (Número de positivos verdaderos) | FN (Número de falsos negativos) |
| Negativo Real | FP (Número de falsos negativos) | TN (Número de falsos positivos) |

Exactitud temática

El resultado de la evaluación de la exactitud provee al usuario la Exactitud Global (EG) de la clasificación, así como de cada una de sus clases, dicho porcentaje es estimado a partir de la ecuación 13 (Ferri et al., 2009; Hasmadi et al., 2009; Mosley, 2013).

$$EG = \frac{TP+TN}{TP+FP+TN+FN} \text{ (Ecuación 13) (Tabla 3)}$$

Adicionalmente a la estimación de la EG, es posible estimar la exactitud de la clasificación para cada una de las clases, sin embargo, para este caso es posible emplear dos enfoques (Stehman & Foody, 2008).

Sensibilidad

La sensibilidad o la exactitud del usuario (EU), tasa positiva verdadera o recuerdo, es una métrica que mide la proporción de ejemplos positivos que se identificaron correctamente, cuantificando la capacidad del modelo para evitar el falso negativo (Stehman & Foody, 2008). Es estimada dividiendo el número de píxeles correctamente clasificados en cada categoría por el número total de píxeles que fueron clasificados en esa categoría (Ecuación 14).

$$EU = \frac{TP}{TP+FN} \text{ (Ecuación 14) (Tabla 3)}$$

Especificidad

La métrica de especificidad, valor predicho positivo o la exactitud del productor (EP), mide cuántas de las muestras predichas como positivas se predicen correctamente, se usa comúnmente cuando el objetivo principal es limitar el número de falsos positivos (Stehman & Foody, 2008). Se estima dividiendo el número de píxeles correctamente clasificados en una clase por el número total de píxeles (Ecuación 15).

$$EP = \frac{TN}{TN+FP} \text{ (Ecuación 15) (Tabla 3)}$$

Exactitud equilibrada

A pesar de que aún no existe un consenso sobre la implementación de la exactitud equilibrada para tareas de varias clases, autores como Brodersen et al. (2010) y Mosley

(2013) describen la exactitud equilibrada como el recuerdo de cada clase, promediado sobre el número de clases (Ecuación 16)

$$\sum l \in L \frac{TP}{TP+FP} \quad (\text{Ecuación 16})$$

dónde: "l" es la clase, mientras que "L" es el conjunto de clase.

Como medida de rendimiento, la exactitud equilibrada evalúa la calidad del rendimiento del modelo, que primero se mide para cada clase de forma independiente y luego se agrega. En un escenario de caso desequilibrado, si la exactitud general descrita anteriormente es alta porque está sesgada debido al buen desempeño del modelo en la clase mayoritaria, el uso de la métrica de precisión equilibrada balanceará el puntaje (Brodersen et al., 2010).

1.7 Estado del arte

1.7.1 Uso de imágenes multiespectrales en identificación de alteraciones en cultivos

Los experimentos enfocados a enfermedades de plantas que involucran procesos de detección con sensores remotos y proximales han ido en aumento (Fang & Ramasamy, 2015; Oerke, 2020; Singh et al., 2020; Tsouros et al., 2019), sin embargo, se evidencia dificultad con su desarrollo en campo ya que las plantas afectadas pueden hacer que la enfermedad se propague a áreas vecinas (Barbedo, 2019). Para evitar un brote de enfermedad real, algunos experimentos han utilizado sustitutos de la enfermedad real (por ejemplo, herbicidas) para causar estrés fisiológico y simular la aparición de síntomas (Dash et al., 2017). Es importante enfatizar, sin embargo, que si bien este tipo de enfoque es útil si el objetivo es una prueba de concepto general, si se apunta a enfermedades específicas, sus detalles deben investigarse explícitamente en experimentos prácticos (Barbedo, 2019).

La mayoría de los experimentos indican que las resoluciones espaciales más altas conducen a mejores resultados, ya que se puede extraer información más significativa cuando las plantas y las estructuras respectivas se pueden analizar individualmente. Sin embargo, hay algunas excepciones, Dash y col. (2017) observaron que existe un aumento de la exactitud cuando se redujeron las muestras de las imágenes multiespectrales originales utilizadas para la detección de estrés por enfermedad en pinos. Se ha planteado que el aumento en la sensibilidad de los índices espectrales podría ser un producto del proceso de remuestreo, que potencialmente puede actuar como un filtro que aumenta la relación señal-ruido cuando el fenómeno del sujeto es igual o mayor que el tamaño del píxel (Dash et al., 2017). Debido a esto, los autores señalaron que este resultado no debe interpretarse como una evidencia directa de que una imagen de menor resolución espacial tiene una mayor utilidad para el monitoreo del estrés.

Para que sea útil, en la mayoría de los casos, la detección de enfermedades debe realizarse lo antes posible para evitar pérdidas importantes (Barbedo, 2019; Mahlein et al., 2017). Sin embargo, los síntomas de la enfermedad tienden a ser muy leves al comienzo de la infección, lo que dificulta la detección incluso cuando se utilizan imágenes proximales con resoluciones espaciales y espectrales muy altas (Barbedo, 2019). De hecho, se ha demostrado que la correlación entre las clasificaciones manuales y derivadas de los vehículos aéreos no tripulados para la marchitez del tomate aumenta constantemente a medida que avanza el desarrollo del cultivo, lo que puede explicarse tanto por el aumento de las áreas infectadas como por el mayor impacto de la enfermedad en el tamaño del dosel y su salud (Patrick et al., 2017). Otros autores han informado de altas tasas de error al intentar detectar enfermedades en plantas con bajos niveles de infección (Albetis et al., 2019).

Se sabe que algunas enfermedades producen simultáneamente diferentes tipos de cambios morfológicos y bioquímicos en las plantas. Esta situación da lugar a que algunos autores combinen diferentes dominios espectrales para abordar el problema de detección de enfermedades de manera más sistémica. Por ejemplo, Calderón et al. (2014) combinó índices de las regiones del espectro visible, del borde rojo, del infrarrojo cercano y del espectro térmico para detectar el mildiú veloso en plantas de amapola. Si bien esta estrategia puede mejorar significativamente las capacidades de detección, es importante considerar que requiere múltiples sensores, lo que aumenta los costos de operación y la carga útil que debe transportar el VANT (Barbedo, 2019).

Algunos estudios utilizaron imágenes térmicas para detectar cambios en el contenido de agua como un signo indirecto de la presencia de ciertas enfermedades (Calderón et al., 2014). Por esta razón, las características experimentales y los desafíos que enfrentan estos estudios están estrechamente relacionados con la detección de características relacionadas con disminución en la cantidad de agua presente en la planta.

1.7.2 Modelación de datos de imágenes multiespectrales enfocados a clasificación en agricultura

Con el uso de sensores especializados, los VANT pueden adquirir información para diversas características de las áreas de cultivos agrícolas. Sin embargo, todavía no existe un flujo de trabajo estandarizado o técnicas bien establecidas a seguir para analizar y visualizar la información adquirida (Tsouros et al., 2019). Las técnicas de aprendizaje automático se aplican a menudo en la agricultura de precisión para explotar la información de la gran cantidad de datos adquiridos por los VANT. Las técnicas de AA son capaces de estimar algunos parámetros relacionados con la tasa de crecimiento del cultivo, detectar enfermedades o incluso identificar / discriminar objetos en las imágenes (Tsouros et al., 2019).

Teniendo en cuenta la gran cantidad de datos recopilados de los campos agrícolas, el AA se puede aplicar para mejorar el rendimiento de los sistemas basados en VANT para la

agricultura de precisión (AP), extrayendo conocimiento para varios parámetros de la vegetación. Se están explotando tanto las técnicas de aprendizaje supervisadas como no supervisadas, mediante métodos de agrupación, clasificación y regresión. Los métodos de regresión se utilizan ampliamente en aplicaciones VANT para AP para una variedad de propósitos. La regresión se ha utilizado para estimar los índices de vegetación espectral mediante el análisis de los datos adquiridos a partir de imágenes RGB (Lu et al., 2019), presentando en general buenos resultados. En una comparación de diferentes algoritmos de regresión, para estimar el contenido de nitrógeno de las hojas, BA presenta los mejores resultados entre 14 algoritmos, con un coeficiente de determinación (R^2) de hasta 0,79 (Zheng et al., 2018). Los métodos de regresión también se utilizan para predecir el estado hídrico de los cultivos, en este contexto, las RNA presentan generalmente buenos resultados (R^2 hasta 0.87 usando información de algunas bandas espectrales) (Tsouros et al., 2019).

Actualmente, las técnicas de clasificación más populares y exactas son la familia de RNA (AlAfandy et al., 2019; Thai et al., 2012) y BA (Lu et al., 2019; Rodríguez et al., 2021; Wan et al., 2018). Estos algoritmos utilizan directamente las bandas correspondientes al RGB, la intensidad, la información espectral u otras características derivadas de la imagen adquirida. En algunos casos, también se consideran los datos sobre la vecindad de cada píxel. Además de los datos anteriores, los algoritmos de clasificación también pueden utilizar índices de vegetación como características en el modelo para lograr una mayor precisión. En general, las RNA presentan una mayor exactitud en comparación con otros algoritmos de clasificación, que alcanza hasta el 99% para el mapeo de malezas en algunos casos (Tsouros et al., 2019).

Dentro del AA, el uso de Deep Learning (DL) en aplicaciones de agricultura de precisión es una técnica reciente, moderna y prometedora, que goza de una popularidad creciente. Las técnicas de aprendizaje profundo amplían el aprendizaje automático típico al agregar más complejidad a los modelos derivados (Tsouros et al., 2019). Las técnicas de DL transforman los datos utilizando diversas funciones que permiten la representación de datos de forma jerárquica, a través de varios niveles de abstracción (Pourazar et al., 2017). Los avances y las aplicaciones del DL en otros dominios indican su gran potencial (Tsouros et al., 2019).

1.7.3 Desempeño de modelos aplicados a detección y cuantificación de alteraciones en cultivos con imágenes multiespectrales

En la actualidad se han usado técnicas de análisis de imágenes sobre mosaicos generados a partir de imágenes capturadas con VANT en diferentes casos. En este sentido, Tetila et al. (2017) usaron el método de segmentación *clustering* iterativo lineal simple para detectar hojas de plantas de soya en las imágenes y algunos de sus atributos como el color, la textura y la forma. Los resultados experimentales mostraron que los atributos de color y textura conducen a tasas de clasificación más altas (Tetila et al., 2017), logrando una

precisión del 98.34%. Pourazar et al. (2017) aplicaron redes neuronales convolucionales (RNC) para detectar enfermedades en un viñedo (moho), escarabajos de papa y malezas (en campos de lechuga, zanahoria y cebolla) obteniendo que la aplicación de la técnica de aprendizaje profundo presentó una tasa de éxito de más del 90%, lo que demuestra el potencial de este enfoque (Pourazar et al., 2017). Rahman et al. (2017) compararon diferentes algoritmos de aprendizaje automático como MVS, BA y RNA para clasificar hojas de sorgo, cítricos y repollo con respecto a plantas saludables y no saludables. Llegaron a la conclusión de que el uso de características basadas en el color, junto con el uso de un clasificador no paramétrico como el bosque aleatorio, proporcionó una buena combinación de procedimientos para distinguir dichos eventos (Rahman et al., 2017). Además, García-Ruiz et al. (2013), compararon dos plataformas diferentes de imágenes aéreas para la identificación de Huanglongbing (HLB) en cítricos, utilizando diferentes algoritmos de clasificación, como análisis discriminante lineal, análisis discriminante cuadrático, máquinas de vectores de soporte lineales y no lineales. En este estudio, los autores encontraron precisiones en el rango entre 67% - 85%, donde las máquinas de vectores de soporte kernelizadas superaron a los otros clasificadores.

Algunos trabajos comparan algoritmos de clasificación obteniendo resultados variables dependiendo de la afectación (Blekos et al., 2021; Calderón et al., 2015; Cockerton et al., 2019; Garcia-Ruiz et al., 2013; Rahman et al., 2017), sin embargo las metodologías de muestreo son diferenciales por lo que su comparación se ve limitada. Crockerton et al. (2019) evaluaron la afectación de *V. dahliae* en plantas de fresa utilizando como base el cálculo el índice de vegetación normalizada (NDVI), de ello obtuvieron que existe una fuerte correlación entre las mediciones de campo y las calculadas a partir de valores del índice. Calderón et al. (2015), aplicaron métodos de clasificación de análisis discriminante lineal (LDA) y MVS para clasificar la severidad de *V. dahliae* utilizando imágenes térmicas e hiperespectrales. Estos autores encontraron que LDA alcanzó una precisión general del 59,0% y un valor kappa de 0,487 mientras que MVS obtuvo una precisión general más alta, 79,2% con una κ similar, 0,495. Sin embargo, LDA clasificó mejor los árboles en niveles de severidad inicial y baja, alcanzando precisiones de 71.4 y 75.0%, respectivamente, en comparación con el 14.3% y 40.6% obtenido por el MVS. Se descubrió que la temperatura normalizada del dosel, la fluorescencia de la clorofila, los índices estructurales, de xantofila, de clorofila, de carotenoides y de enfermedades son los mejores indicadores para la infección en estadio temprano y avanzado por *V. dahliae*. Estos resultados indican aproximaciones sobre el trabajo que se desea abordar, sin embargo, se considera que existe una limitación en la cantidad de información asociada a la problemática a estudiar. Por su parte, en una investigación reciente Blekos et al. (2021) planteó el uso de Redes neuronales convolucionales (CNN) para evaluar el potencial uso de bandas de cámaras multispectrales en el desarrollo de modelos predictivos, a partir de esto se encontraron exactitudes mayores al 83%, mostrando el potencial de estas herramientas de detección, sin embargo, no se expresa claramente la evaluación comparativa con respecto a datos de campo.

1.7.4 Desempeño de modelos aplicados a detección y cuantificación de alteraciones en cultivos con imágenes multiespectrales en cultivos de papa

A nivel mundial el uso de herramientas de teledetección en cultivos de papa se ha incrementado causando mayor impacto en relación con la detección de enfermedades, para ello se han usado diferentes enfoques de análisis (Gibson-Poole et al., 2017; Gold, Townsend, Larson, et al., 2020; Shi et al., 2022; Sugiura et al., 2016). En Colombia diversos autores reportan el uso de sensores acoplados a VANT en la detección de enfermedades en cultivos de papa con resultados bastante prometedores (Duarte-Carvajalino et al., 2018; León-Rueda et al., 2022; Lizarazo et al., 2023; Rodríguez et al., 2021). Duarte-Carvajalino et al. (2018) presentaron una predicción cuantitativa de la gravedad de la enfermedad causada por *P. infestans* en cultivos de papa utilizando algoritmos de aprendizaje automático como el perceptrón multicapa, redes neuronales convolucionales, MVS y BA. Sus resultados indican que las redes neuronales convolucionales, los bosques aleatorios y el perceptrón multicapa pueden predecir el nivel de afectación de *P. infestans* en cultivos de papa con una exactitud aceptable. Recientemente, la investigación de Rodríguez et al. (2022) evaluó la presencia de tizón tardío en el cultivo de papa con imágenes capturadas con VANT en dos momentos de desarrollo del cultivo. Como resultados, se evidenció la necesidad de aplicar un algoritmo que remueva pixeles que causan ruido en los datos usados para entrenar los algoritmos, planteando una alternativa con el uso de segmentación sobre las imágenes. Sin embargo, se encontraron problemas en cuanto a la identificación de valores de ajuste apropiados para la separación de clases en momentos de desarrollo del cultivo. Además de esto, se encontró que los algoritmos con mejor desempeño de clasificación fueron MVS y BA, lo cual plantea bases para la investigación futura. Como conclusión, fue evidente que la metodología planteada puede ser usada en la evaluación de enfermedades en el cultivo dada la relación entre lo obtenido en clasificación contra lo evaluado en campo, sin embargo, se recomienda evaluar la posibilidad de tener aplicaciones en escenarios de detección temprana. Por su parte, León-Rueda et al. (2022) evaluaron datos multiespectrales adquiridos con VANT para detectar la marchitez vascular de papa causada por *Verticillium* spp., el estrés por encharcamiento y síntomas de una fisiopatología de origen desconocido. La exactitud osciló entre el 37,5 y el 82,5%, según el experimento, mostrando que la herramienta tiene potencial para la detección y diferenciación de enfermedades y desórdenes fisiológicos en cultivos comerciales de papa.

1.8 Bibliografía

- Agronet. (2018). Agronet. <http://www.agronet.gov.co/estadistica/Paginas/default.aspx>
- AlAfandy, K. A., Omara, H., Lazaar, M., & Al Achhab, M. (2019, October 23). Artificial neural networks optimization and convolution neural networks to classifying images in remote sensing: A review. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3372938.3372945>
- Albetis, J., Jacquin, A., Goulard, M., Poilvé, H., Rousseau, J., Clenet, H., Dedieu, G., &

- Duthoit, S. (2019). On the potentiality of UAV multispectral imagery to detect Flavescence dorée and Grapevine Trunk Diseases. *Remote Sensing*, 11(1). <https://doi.org/10.3390/rs11010023>
- Antunes, E., Vuppaladadiyam, A. K., Sarmah, A. K., Varsha, S. S. V., Pant, K. K., Tiwari, B., & Pandey, A. (2021). Application of biochar for emerging contaminant mitigation. In *Advances in Chemical Pollution, Environmental Management and Protection* (Vol. 7, pp. 65–91). Elsevier. <https://doi.org/10.1016/bs.apmp.2021.08.003>
- Arneson, P. A. (2001). Plant Disease Epidemiology. *The Plant Health Instructor*, <https://www.apsnet.org/edcenter/disimpactmngmnt/to>. <https://doi.org/10.1094/PHI-A-2001-0524-01>
- Barbedo, J. G. A. (2019). A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses. *Drones*, 3(2), 1–27. <https://doi.org/10.3390/drones3020040>
- Behmann, J., Mahlein, A. K., Rumpf, T., Römer, C., & Plümer, L. (2015). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. In *Precision Agriculture*. <https://doi.org/10.1007/s11119-014-9372-7>
- Bekkar, M., Djemaa, H. K., & Alitouche, T. A. (2013). Evaluation Measures for Models Assessment over Imbalanced Data Sets. *Journal of Information Engineering and Applications*.
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Blekos, K., Tsakas, A., Xouris, C., Evdokidis, I., Alexandropoulos, D., Alexakos, C., Katakis, S., Makedonas, A., Theoharatos, C., & Lalos, A. (2021). Analysis, Modeling and Multi-Spectral Sensing for the Predictive Management of Verticillium Wilt in Olive Groves. *Journal of Sensor and Actuator Networks*, 10(1), 15. <https://doi.org/10.3390/jsan10010015>
- Bock, C. H., Poole, G. H., Parker, P. E., & Gottwald, T. R. (2010). Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Critical Reviews in Plant Sciences*, 29(2), 59–107. <https://doi.org/10.1080/07352681003617285>
- Brodersen, K. H., Ong, C. S., Stephan, K. E., & Buhmann, J. M. (2010). The balanced accuracy and its posterior distribution. *Proceedings - International Conference on Pattern Recognition*. <https://doi.org/10.1109/ICPR.2010.764>
- Buja, I., Sabella, E., Monteduro, A. G., Chiriaco, M. S., De Bellis, L., Luvisi, A., & Maruccio, G. (2021). Advances in Plant Disease Detection and Monitoring: From Traditional Assays to In-Field Diagnostics. *Sensors* (Basel, Switzerland), 21(6), 1–22. <https://doi.org/10.3390/S21062129>
- Buriticá, P. (1999). Directorio de patógenos y enfermedades de las plantas de importancia económica en Colombia. <http://www.buritica-antioquia.gov.co/presentacion.shtml>
- Calderón, R., Montes-Borrego, M., Landa, B. B., Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2014). Detection of downy mildew of opium poppy using high-resolution multi-spectral and thermal imagery acquired with an unmanned aerial vehicle. *Precision Agriculture*, 15(6), 639–661. <https://doi.org/10.1007/s11119-014-9360-y>
- Calderón, Rocío, Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2015). Early detection and quantification of verticillium wilt in olive using hyperspectral and thermal imagery over large areas. *Remote Sensing*. <https://doi.org/10.3390/rs70505584>
- Campbell, J. B., & Wynne, R. H. (2011). Introduction to Remote Sensing FIFTH EDITION. In *Uma ética para quantos?* <https://doi.org/10.1007/s13398-014-0173-7.2>
- Cockerton, H. M., Li, B., Vickerstaff, R. J., Eyre, C. A., Sargent, D. J., Armitage, A. D.,

- Marina-Montes, C., Garcia-Cruz, A., Passey, A. J., Simpson, D. W., & Harrison, R. J. (2019). Identifying *Verticillium dahliae* resistance in strawberry through disease screening of multiple populations and image based phenotyping. *Frontiers in Plant Science*. <https://doi.org/10.3389/fpls.2019.00924>
- Cortes, C., & Mohri, M. (2004). AUC optimization vs. Error rate minimization. *Advances in Neural Information Processing Systems*.
- Dash, J. P., Watt, M. S., Pearse, G. D., Heaphy, M., & Dungey, H. S. (2017). Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 1–14. <https://doi.org/10.1016/j.isprsjprs.2017.07.007>
- Duarte-Carvajalino, J. M., Alzate, D. F., Ramirez, A. A., Santa-Sepulveda, J. D., Fajardo-Rojas, A. E., & Soto-Suárez, M. (2018). Evaluating late blight severity in potato crops using unmanned aerial vehicles and machine learning algorithms. *Remote Sensing*. <https://doi.org/10.3390/rs10101513>
- Dung, J. K. S., Ingram, J. T., Cummings, T. F., & Johnson, D. A. (2012). Impact of seed lot infection on the development of black dot and verticillium wilt of potato in Washington. *Plant Disease*. <https://doi.org/10.1094/PDIS-01-12-0061-RE>
- El Hoummaidi, L., Larabi, A., & Alam, K. (2021). Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*, 7(10). <https://doi.org/10.1016/j.heliyon.2021.e08154>
- Fang, Y., & Ramasamy, R. P. (2015). Current and prospective methods for plant disease detection. In *Biosensors*. <https://doi.org/10.3390/bios5030537>
- FAOSTAT. (2020). FAOSTAT: Statistical database. FAOSTAT: Statistical Database. <https://www.fao.org/faostat/es/#home>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Ferri, C., Hernández-Orallo, J., & Modroiu, R. (2009). An experimental comparison of performance measures for classification. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2008.08.010>
- Friedman, J., Hastie, T., & Tibshirani, R. (2000). Additive logistic regression: A statistical view of boosting. *Annals of Statistics*, 28(2), 337–407. <https://doi.org/10.1214/AOS/1016218223>
- Galieni, A., D'Ascenzo, N., Stagnari, F., Pagnani, G., Xie, Q., & Pisante, M. (2021). Past and Future of Plant Stress Detection: An Overview From Remote Sensing to Positron Emission Tomography. In *Frontiers in Plant Science* (Vol. 11, p. 1975). *Frontiers Media S.A.* <https://doi.org/10.3389/fpls.2020.609155>
- Garcia-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2012.12.002>
- Gibson-Poole, S., Humphris, S., Toth, I., & Hamilton, A. (2017). Identification of the onset of disease within a potato crop using a UAV equipped with un-modified and modified commercial off-the-shelf digital cameras. *Advances in Animal Biosciences*, 8(2), 812–816. <https://doi.org/10.1017/s204047001700084x>
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gold, K. M., Townsend, P. A., Larson, E. R., Herrmann, I., & Gevens, A. J. (2020). Contact reflectance spectroscopy for rapid, accurate, and nondestructive phytophthora infestans clonal lineage discrimination. *Phytopathology*, 110(4), 851–862.

- <https://doi.org/10.1094/PHYTO-08-19-0294-R>
- Hamylton, S. M., Morris, R. H., Carvalho, R. C., Roder, N., Barlow, P., Mills, K., & Wang, L. (2020). Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation and machine learning approaches. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2020.102085>
- Hasmadi, I., Pakhriazad, H., & Shahrin, M. (2009). Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Geografia - Malaysian Journal of Society and Space*.
- Honkavaara, E., Saari, H., Kaivosoja, J., Pölönen, I., Hakala, T., Litkey, P., Mäkynen, J., & Pesonen, L. (2013). Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. *Remote Sensing*, 5(10), 5006–5039. <https://doi.org/10.3390/rs5105006>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Jasiński, J., Pietrek, S., Walczykowski, P., & Orych, A. (2010). Acquisition of spectral reflectance characteristics of land cover features based on hyperspectral images . January.
- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112(10), 3833–3845. <https://doi.org/10.1016/j.rse.2008.06.006>
- Jing, R., Li, H., Hu, X., Shang, W., Shen, R., Guo, C., Guo, Q., & Subbarao, K. V. (2018). Verticillium wilt caused by *verticillium dahliae* and *v. Nonalfalfae* in potato in northern China. *Plant Disease*, 102(10), 1958–1964. <https://doi.org/10.1094/PDIS-01-18-0162-RE>
- Johnson, D. A., Jeremiah, K., & Dung, S. (2010). Verticillium wilt of potato - The pathogen, disease and management. *Canadian Journal of Plant Pathology*. <https://doi.org/10.1080/07060661003621134>
- Kanti, M., Pradhan, R., & Sushan, S. (2010). Decision Tree Classification of Remotely Sensed Satellite Data using Spectral Separability Matrix. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2010.010516>
- Klosterman, S. J., Atallah, Z. K., Vallad, G. E., & Subbarao, K. V. (2009). Diversity, pathogenicity, and management of verticillium species. *Annual Review of Phytopathology*, 47, 39–62. <https://doi.org/10.1146/annurev-phyto-080508-081748>
- Kuang, B., Mahmood, H. S., Quraishi, M. Z., Hoogmoed, W. B., Mouazen, A. M., & van Henten, E. J. (2012). Sensing soil properties in the laboratory, in situ, and on-line. A review. In *Advances in Agronomy* (1st ed., Vol. 114, Issue October 2017). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-394275-3.00003-1>
- Larkin, R. P., Honeycutt, C. W., & Olanya, O. M. (2011). Management of Verticillium Wilt of Potato with Disease-Suppressive Green Manures and as Affected by Previous Cropping History. *Plant Disease*. <https://doi.org/10.1094/pdis-09-10-0670>
- Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3–10. <https://doi.org/10.1016/j.gsf.2015.07.003>
- León-Rueda, W. A., León, C., Caro, S. G., & Ramírez-Gil, J. G. (2022). Identification of diseases and physiological disorders in potato via multispectral drone imagery using machine learning tools. *Tropical Plant Pathology*, 47(1), 152–167. <https://doi.org/10.1007/s40858-021-00460-2>
- Li, M., Zang, S., Zhang, B., Li, S., & Wu, C. (2014). A review of remote sensing image

- classification techniques: The role of Spatio-contextual information. *European Journal of Remote Sensing*, 47(1), 389–411. <https://doi.org/10.5721/EuJRS20144723>
- Lillesand, T. M., & Kiefer, R. W. (2004). Remote sensing and image interpretation. In *Remote sensing and image interpretation*. <https://doi.org/10.2307/634969>
- Liu, C., Sun, P. Sen, & Liu, S. R. (2016). A review of plant spectral reflectance response to water physiological changes. *Chinese Journal of Plant Ecology*, 40(1), 80–91. <https://doi.org/10.17521/cjpe.2015.0267>
- Liu, X. (2003). *Supervised Classification and Unsupervised Classification*. Cfa.Harvard.Edu.
- Lizarazo, I., Rodriguez, J. L., Cristancho, O., Olaya, F., Duarte, M., & Prieto, F. (2023). Identification of symptoms related to potato *Verticillium* wilt from UAV-based multispectral imagery using an ensemble of gradient boosting machines. *Smart Agricultural Technology*, 3, 100138. <https://doi.org/https://doi.org/10.1016/j.atech.2022.100138>
- Lizarazo Peña, P. A. (2020). Desarrollo , crecimiento y rendimiento de cultivares de papa diploide en ambientes contrastantes por altitud. In Universidad Nacional de Colombia. <https://repositorio.unal.edu.co/bitstream/handle/unal/78234/1022359762.2020.pdf?sequence=1&isAllowed=y>
- Lowe, A., Harrison, N., & French, A. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. In *Plant Methods*. <https://doi.org/10.1186/s13007-017-0233-z>
- Lowe, B., & Kulkarni, A. (2015). Multispectral Image Analysis Using Random Forest. *International Journal on Soft Computing*. <https://doi.org/10.5121/ijsc.2015.6101>
- Lu, N., Zhou, J., Han, Z., Li, D., Cao, Q., Yao, X., Tian, Y., Zhu, Y., Cao, W., & Cheng, T. (2019). Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. *Plant Methods*, 15(1), 17. <https://doi.org/10.1186/s13007-019-0402-3>
- Mahlein, A. K., Kuska, M. T., Thomas, S., Bohnenkamp, D., Alisaac, E., Behmann, J., Wahabzada, M., & Kersting, K. (2017). Plant disease detection by hyperspectral imaging: from the lab to the field. *Advances in Animal Biosciences*. <https://doi.org/10.1017/s2040470017001248>
- Mahlein, A. K., Oerke, E. C., Steiner, U., & Dehne, H. W. (2012). Recent advances in sensing plant diseases for precision crop protection. In *European Journal of Plant Pathology*. <https://doi.org/10.1007/s10658-011-9878-z>
- Manici, L. M., & Cerato, C. (1994). Pathogenicity of *Fusarium oxysporum* f.sp. *tuberosi* isolates from tubers and potato plants. *Potato Research*, 37(2), 129–134. <https://doi.org/10.1007/BF02358713>
- Mishra, P., Polder, G., & Vilfan, N. (2020). Close Range Spectral Imaging for Disease Detection in Plants Using Autonomous Platforms: a Review on Recent Studies. *Current Robotics Reports*, 1(2), 43–48. <https://doi.org/10.1007/s43154-020-00004-7>
- Mohapatra, S. K., & Mohanty, M. N. (2022). Big data classification with IoT-based application for e-health care. *Cognitive Big Data Intelligence with a Metaheuristic Approach*, 147–172. <https://doi.org/10.1016/B978-0-323-85117-6.00014-5>
- Mohseni-Dargah, M., Falahati, Z., Dabirmanesh, B., Nasrollahi, P., & Khajeh, K. (2022). Machine learning in surface plasmon resonance for environmental monitoring. In *Artificial Intelligence and Data Science in Environmental Sensing* (pp. 269–298). Academic Press. <https://doi.org/10.1016/B978-0-323-90508-4.00012-5>
- Mosley, L. S. D. (2013). A balanced approach to the multi-class imbalance problem. In *ProQuest Dissertations and Theses*.
- Motohka, T., Nasahara, K. N., Oguma, H., & Tsuchida, S. (2010). Applicability of Green-Red Vegetation Index for remote sensing of vegetation phenology. *Remote Sensing*,

- 2(10), 2369–2387. <https://doi.org/10.3390/rs2102369>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Müller, A. C., & Guido, S. (2016). Introduction to Machine Learning with Python: a guide for data scientists. In *Journal of Chemical Information and Modeling*. <https://doi.org/10.1017/CBO9781107415324.004>
- Mundt, C. C. (2019). The Study of Plant Disease Epidemics. *HortScience*, 44(7), 2065b – 2065. <https://doi.org/10.21273/hortsci.44.7.2065b>
- Nieto, L. E. (1988). La Madurez Prematura de la Papa Causada por *Verticillium* spp. en Colombia. *Revista ICA*, 4, 334–340.
- Oerke, E. C. (2020). Remote Sensing of Diseases. *Annual Review of Phytopathology*, 58, 225–252. <https://doi.org/10.1146/annurev-phyto-010820-012832>
- Oerke, E. C., Mahlein, A. K., & Steiner, U. (2014). Proximal sensing of plant diseases. In *Detection and Diagnostics of Plant Pathogens* (pp. 55–68). Springer Netherlands. https://doi.org/10.1007/978-94-017-9020-8_4
- Patrick, A., Pelham, S., Culbreath, A., Corely Holbrook, C., De Godoy, I. J., & Li, C. (2017). High throughput phenotyping of tomato spot wilt disease in peanuts using unmanned aerial systems and multispectral imaging. *IEEE Instrumentation and Measurement Magazine*, 20(3), 4–12. <https://doi.org/10.1109/MIM.2017.7951684>
- Pourazar, H., Samadzadegan, F., Dadrass Javan, F., Giacomo, R., David, G., Gilbertson, J. K., Forum, P. O., Bouroubi, Y., Bugnet, P., Nguyen-xuan, T., Gosselin, C., Bélec, C., Longchamps, L., Vigneault, P., Ji, S., Zhang, C., Xu, A., Shi, Y., Duan, Y., ... Gore, M. A. (2017). Pest Detection on UAV Imagery using a Deep Convolutional Neural Network. *Remote Sensing*, 52(19), 17–31. <https://doi.org/10.3390/rs11192209>
- Powelson, M. L., & Rowe, R. C. (1993). Biology and management of early dying of potatoes. In *Annual Review of Phytopathology* (Vol. 31, pp. 111–126). Annual Reviews Inc. <https://doi.org/10.1146/annurev.py.31.090193.000551>
- Puletti, N., Perria, R., & Storchi, P. (2014). Unsupervised classification of very high remotely sensed images for grapevine rows detection. *European Journal of Remote Sensing*, 47(1), 45–54. <https://doi.org/10.5721/EuJRS20144704>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Rahman, H. ur, Jabbar Ch, N., Manzoor, S., Najeef, F., Siddique, M. Y., & Khan, R. A. (2017). A comparative analysis of machine learning approaches for plant disease identification. *Advancements in Life Sciences*, 4(4), 120–126.
- Ramirez-Gil, J., Navas, J., & Gómez, S. (2019). Epidemiología e importancia económica de una alteración de origen desconocido en papa en la sabana occidente de Cundinamarca. XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS, 205–205.
- Ramirez Gil, J., Garcia, C., Navas, J., Leon, J., & Gómez, S. (2019). Implicaciones epidemiológicas y económicas de *Verticillium* sp., en una región productora de papa en Cundinamarca. XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS, 206–207.
- Rodríguez, J., Lizarazo, I., Prieto, F., & Angulo-Morales, V. (2021). Assessment of potato late blight from UAV-based multispectral imagery. *Computers and Electronics in Agriculture*, 184, 106061. <https://doi.org/10.1016/j.compag.2021.106061>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS proceeding. *Third Earth Reserves Technology*

- Satellite Symposium, Greenbelt: NASA SP-351, 30103017, 317. <https://ui.adsabs.harvard.edu/abs/1974NASSP.351..309R/abstract>
- Rowe, R. C., & Powelson, M. L. (2002). Potato early dying: Management challenges in a changing production environment. In *Plant Disease* (Vol. 86, Issue 11, pp. 1184–1193). The American Phytopathological Society. <https://doi.org/10.1094/PDIS.2002.86.11.1184>
- Salamí, E., Barrado, C., & Pastor, E. (2014). UAV flight experiments applied to the remote sensing of vegetated areas. In *Remote Sensing* (Vol. 6, Issue 11, pp. 11051–11081). MDPI AG. <https://doi.org/10.3390/rs61111051>
- Sarić, R., Nguyen, V. D., Burge, T., Berkowitz, O., Trtílek, M., Whelan, J., Lewsey, M. G., & Čustović, E. (2022). Applications of hyperspectral imaging in plant phenotyping. In *Trends in Plant Science* (Vol. 27, Issue 3, pp. 301–315). Elsevier Current Trends. <https://doi.org/10.1016/j.tplants.2021.12.003>
- Sarkar, S. K., Das, J., Ehsani, R., & Kumar, V. (2016). Towards autonomous phytopathology: Outcomes and challenges of citrus greening disease detection through close-range remote sensing. *Proceedings - IEEE International Conference on Robotics and Automation, 2016-June*, 5143–5148. <https://doi.org/10.1109/ICRA.2016.7487719>
- Seetha, M., Muralikrishna, Deekshatulu, B. L., Malleswari, B. L., Nagaratna, & Hegde, P. (2008). *Artificial Neural Networks and Other Methods of Image Classification. Theoretical and Applied Information Technology*.
- Segarra, J., Buchailot, M. L., Araus, J. L., & Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5), 1–18. <https://doi.org/10.3390/agronomy10050641>
- Shi, Y., Han, L., Kleerekoper, A., Chang, S., & Hu, T. (2022). Novel CropdocNet Model for Automated Potato Late Blight Disease Detection from Unmanned Aerial Vehicle-Based Hyperspectral Imagery. *Remote Sensing*, 14(2), 396. <https://doi.org/10.3390/rs14020396>
- Shin, M. Y., Gonzalez Viejo, C., Tongson, E., Wiechel, T., Taylor, P. W. J., & Fuentes, S. (2023). Early detection of *Verticillium* wilt of potatoes using near-infrared spectroscopy and machine learning modeling. *Computers and Electronics in Agriculture*, 204, 107567. <https://doi.org/10.1016/J.COMPAG.2022.107567>
- Shruthi, U., Nagaveni, V., & Raghavendra, B. K. (2019). A Review on Machine Learning Classification Techniques for Plant Disease Detection. 2019 5th International Conference on Advanced Computing and Communication Systems, ICACCS 2019, 281–284. <https://doi.org/10.1109/ICACCS.2019.8728415>
- Singh, V., Sharma, N., & Singh, S. (2020). A review of imaging techniques for plant disease detection. In *Artificial Intelligence in Agriculture* (Vol. 4, pp. 229–242). KeAi Communications Co. <https://doi.org/10.1016/j.aiaa.2020.10.002>
- Stehman, S. V., & Foody, G. M. (2008). Accuracy Assessment. In *The SAGE Handbook of Remote Sensing*. <https://doi.org/10.4135/9780857021052.n21>
- Stevenson, W., Loria, R., Franc, G., & Weingartner, D. (2001). *Compendium of Potato Diseases, Second Edition*. Phytopathological Society. <https://doi.org/10.1046/j.1365-3059.2002.06934.x>
- Sugiura, R., Tsuda, S., Tamiya, S., Itoh, A., Nishiwaki, K., Murakami, N., Shibuya, Y., Hirafuji, M., & Nuske, S. (2016). Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering*. <https://doi.org/10.1016/j.biosystemseng.2016.04.010>
- Tetila, E. C., Brandoli Machado, B., Belete, N. A. D. S., Guimaraes, D. A., & Pistori, H. (2017). Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. *IEEE Geoscience and Remote Sensing Letters*.

- <https://doi.org/10.1109/LGRS.2017.2743715>
- Thai, L. H., Hai, T. S., & Thuy, N. T. (2012). Image Classification using Support Vector Machine and Artificial Neural Network. *International Journal of Information Technology and Computer Science*. <https://doi.org/10.5815/ijitcs.2012.05.05>
- Tripathi, K., Vyas, R. G., & Gupta, A. K. (2019). Document Classification Using Artificial Neural Network. *Asian Journal of Computer Science and Technology*, 8(2), 55–58.
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. *Information (Switzerland)*, 10(11). <https://doi.org/10.3390/info10110349>
- Vishnoi, V. K., Kumar, K., & Kumar, B. (2021). Plant disease detection using computational intelligence and image processing. In *Journal of Plant Diseases and Protection* (Vol. 128, Issue 1, pp. 19–53). Springer. <https://doi.org/10.1007/s41348-020-00368-0>
- Wan, L., Li, Y., Cen, H., Zhu, J., Yin, W., Wu, W., Zhu, H., Sun, D., Zhou, W., & He, Y. (2018). Combining UAV-based vegetation indices and image classification to estimate flower number in oilseed rape. *Remote Sensing*, 10(9), 1484. <https://doi.org/10.3390/rs10091484>
- Xu, M., Watanachaturaporn, P., Varshney, P. K., & Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322–336. <https://doi.org/10.1016/j.rse.2005.05.008>
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. In *Journal of Sensors*. Hindawi Limited. <https://doi.org/10.1155/2017/1353691>
- Yan, Z., Ma, L., He, W., Zhou, L., Lu, H., Liu, G., & Huang, G. (2022). Comparing Object-Based and Pixel-Based Methods for Local Climate Zones Mapping with Multi-Source Data. *Remote Sensing*, 14(15). <https://doi.org/10.3390/rs14153744>
- Yang, C. M., Cheng, C. H., & Chen, R. K. (2007). Changes in spectral characteristics of rice canopy infested with brown planthopper and leafhopper. *Crop Science*. <https://doi.org/10.2135/cropsci2006.05.0335>
- Yeom, J., Jung, J., Chang, A., Ashapure, A., Maeda, M., Maeda, A., & Landivar, J. (2019). Comparison of vegetation indices derived from UAV data for differentiation of tillage effects in agriculture. *Remote Sensing*, 11(13). <https://doi.org/10.3390/rs11131548>
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. In *Precision Agriculture* (Vol. 13, Issue 6, pp. 693–712). Springer. <https://doi.org/10.1007/s11119-012-9274-5>
- Zheng, H., Li, W., Jiang, J., Liu, Y., Cheng, T., Tian, Y., Zhu, Y., Cao, W., Zhang, Y., & Yao, X. (2018). A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, 10(12). <https://doi.org/10.3390/rs10122026>

2. Conexión entre el laboratorio y el campo en la detección de madurez temprana de la papa: de las firmas espectrales a los índices de vegetación obtenidos con cámaras espectrales acopladas a drones

En este capítulo se presenta un enfoque teórico y metodológico, el cual busca dar cumplimiento a los siguientes objetivos específicos del presente trabajo de tesis:

- Comparar el rendimiento de distintos métodos de análisis de datos espectrales por su capacidad para la identificación y cuantificación de madurez temprana causada por *Verticillium* spp. en cultivos de papa.
- Evaluar la reproducibilidad y relación entre datos espectrales obtenidos mediante un espectro radiómetro fijo y una cámara multiespectral acoplada a VANT por su capacidad para la identificación y cuantificación de madurez temprana causada por *Verticillium* spp. en cultivos de papa.

2.1 Resumen

Los sistemas de producción de papa presentan diferentes problemas fitosanitarios con alta implicación en términos de pérdidas en cantidad y calidad conllevando a un impacto económico. En este sentido, la madurez temprana de la papa asociada a *Verticillium* spp., es una de las patologías que ha presentado una mayor relevancia en los últimos años. Esta enfermedad es de difícil detección en estados iniciales y la expresión visual de los síntomas se da en fases fenológicas críticas del cultivo. El uso de datos espectrales para la detección indirecta de enfermedades en cultivos agrícolas es cada vez más común y la

aplicación de métodos de aprendizaje automático ha generado la posibilidad de extraer información para tomar decisiones acertadas en función de la detección temprana. Este trabajo tuvo como objetivo el uso y comparación del rendimiento de algunos métodos tradicionales para el análisis de datos espectrales en la clasificación de plantas de papa sanas y afectadas por madurez temprana y su nivel de severidad. Igualmente, se propone un método para lograr vincular datos espectrales obtenidos bajo condiciones controladas y en campo. Se usaron firmas e imágenes multispectrales capturadas en plantas de papa bajo condiciones de invernadero y de producción comercial, al igual que datos asociados a la cuantificación de nivel de la enfermedad en las plantas. Se implementaron métodos tradicionales como el análisis de componentes principales (PCA) y de aprendizaje automático como bosques aleatorios (BA), vectores de soporte de maquina (MVS) y redes neuronales artificiales (RNA) por su capacidad de detectar bandas espectrales informativas. Como resultado se encontró que todos los algoritmos aplicados tuvieron valores de exactitud mayores a 60% sin importar la fuente de datos, sin embargo, la capacidad de identificación de bandas fue sobresaliente en los métodos de aprendizaje automático, en especial BA aplicados a firmas espectrales. Las longitudes de onda relacionadas al rojo y borde rojo, en especial desde 710 a 735 nm mostraron mayor importancia repetidamente para los algoritmos utilizados. El uso de índices espectrales permitió la comparación y validación de su uso en la detección de la enfermedad usando dos fuentes de datos distintas, mostrando que el RECI, NDRE, VWI y GRVI tienen alto potencial en la discriminación de los síntomas de esta alteración en plantas de papa. Estas longitudes de onda identificadas pueden aplicarse en el diseño de sensores ópticos que sumados al uso de algoritmos de aprendizaje automático presenta un alto potencial para la detección remota de la madurez temprana causada por *Verticillium* spp. en cultivos de papa.

Palabras clave: Herramientas de teledetección, aprendizaje automático, espectro radiómetro, cámara espectral, dron

2.2 Introducción

La papa (*Solanum tuberosum* L.), después del arroz, el trigo y el maíz es el cuarto cultivo más importante del mundo (Zhang et al., 2017). Cerca de 1.4 mil millones de personas consumen este tubérculo como alimento básico y su producción anual supera los 300 millones de toneladas métricas (FAOSTAT, 2020). Sin embargo, el rendimiento, calidad, productividad y sostenibilidad de este cultivo se han visto reducidos por la presencia de diversas alteraciones, entre ellas la enfermedad conocida como madurez temprana de la papa (MT) causada por *Verticillium* spp. (Haiyuan Li et al., 2019). Se ha reportado que la MT puede generar hasta un 50% de pérdidas en rendimiento (Johnson et al., 2010; Shattock, 2002). Las principales especies dentro del género *Verticillium* asociadas con MT son *Verticillium dahliae* Kleb. (Vd) y *Verticillium albo-atrum* Reinke & Berthold, 1879 (Johnson & Cummings, 2015), las cuales causan taponamiento del haz vascular,

marchitamiento, clorosis y necrosis de las hojas y finalmente la muerte temprana de las plantas (Johnson et al., 2010).

El estado de salud de las plantas se ha relacionado con características morfológicas, fisiológicas, bioquímicas, estructurales o fenológicas medibles, que se consideran indicadores de la respuesta de la planta frente a factores de estrés biótico o abiótico (Ramegowda & Senthil-Kumar, 2015; Suzuki et al., 2014). El seguimiento a estos rasgos se ha utilizado como una alerta frente a este tipo de eventos (Kollist et al., 2019). Para esto, las técnicas espectrales, termografía e imágenes de fluorescencia proporcionan una alternativa para la detección y monitoreo indirecto del estado fitosanitario de un cultivo (Galieni et al., 2021; Kuska & Mahlein, 2018; Oerke, 2020). Lo anterior, debido a su capacidad para detectar cambios en las características de las plantas en respuesta a los diferentes tipos de estrés (Aasen et al., 2018; Buja et al., 2021; Mahlein, 2016).

Habitualmente, la detección de enfermedades en plantas se realiza con base en evaluaciones visuales que identifican cambios en el color de las hojas, el patrón y distribución de las lesiones a nivel de hoja, tallo y planta (Liu et al., 2020). Sin embargo, dichas evaluaciones pueden estar influenciadas por el conocimiento del observador por lo cual pueden llegar a ser subjetivas (Mishra et al., 2020; Singh et al., 2020). Junto con esto, a medida que aparecen otras alteraciones, la detección puede verse limitada por la poca diferenciación que puede existir entre las sintomatologías asociadas a cada alteración (León-Rueda et al., 2022; Lu et al., 2018; Reddy et al., 2022). Por su parte, las técnicas moleculares y bioquímicas son bastante sensibles y detectan con exactitud las enfermedades, sin embargo, son metodologías destructivas que consumen tiempo considerable, requieren personal capacitado y en muchas ocasiones presentan un alto costo (Ali et al., 2019; Baldi & La Porta, 2020; Buja et al., 2021). En contraste, los cambios en las respuestas espectrales de las plantas podrían permitir una detección rápida e indirecta a partir de muestras *in vivo* (Kong et al., 2018; Mahlein, 2016; Marín-Ortiz et al., 2020).

En el caso de la detección de enfermedades de plantas mediante datos espectrales, comúnmente se utilizan dos fuentes de datos, las firmas e imágenes espectrales (Couture et al., 2018; Singh et al., 2020). Respecto a las firmas espectrales, los métodos de detección se han enfocado en la identificación de bandas que sean más significativas y se relacionen con la enfermedad evaluada (Imanian et al., 2021; Lu et al., 2018; Mahlein, 2016). Por su parte, a partir de las imágenes multiespectrales se genera información por píxel, que puede ser transformada en índices de vegetación, índices de enfermedad, mapas de calor y mapas de falso color. Adicionalmente, también es posible identificar áreas espectrales asociadas a reflectancias que se pueden relacionar con la presencia y cuantificación de una determinada alteración (Agilandeewari et al., 2022; Sami et al., 2020). En cualquier caso, se genera un volumen de datos de alta dimensión, lo que plantea un desafío a la hora de realizar análisis que permitan la identificación de longitudes de

onda informativas que estén relacionadas directamente con el estado de salud de las plantas (Wei et al., 2021).

Uno de los métodos comúnmente usado en el análisis de datos espectrales para detectar cambios en las plantas es el uso de índices de vegetación (IV) (Abdulridha et al., 2020; Mahlein et al., 2013; Meng et al., 2020). Sin embargo, a pesar de que se han encontrado relaciones positivas entre los fenómenos evaluados y los IV, se ha demostrado la baja sensibilidad y especificidad que pueden tener para discriminar problemas que presentan síntomas y cambios similares en la planta (Al-Saddik et al., 2017; Mahlein et al., 2013). Por lo anterior, se ha optado por el desarrollo de índices a partir de áreas espectrales identificadas mediante diferentes métodos, las cuales se relacionan directamente con la alteración evaluada (Ashourloo et al., 2016; Su et al., 2022).

Para lograr una identificación de bandas espectrales e índices informativos se usan métodos de extracción y de selección de características/bandas para la reducción dimensional y la eliminación de la redundancia espectral (Sun & Du, 2019), por ejemplo, componentes principales (Lu et al., 2018; Wei et al., 2021). En los últimos años, se ha incrementado el uso de métodos de aprendizaje automático (AA) en los sistemas de producción de cultivos, para la selección de bandas y posterior predicción y clasificación de diferentes alteraciones (Sun & Du, 2019; Wei et al., 2021). Una de las ventajas de estos métodos es que permiten conservar el significado espectral de las longitudes de onda seleccionadas (Sun & Du, 2019; Wei et al., 2021). Distintos enfoques de ML han sido utilizados para este fin, debido a su alta tasa de reconocimiento y exactitud en los resultados, robustez y su perspectiva no paramétrica (Junges et al., 2020; Lu et al., 2018; Wei et al., 2021). De ellos se destacan, los vectores de soporte de maquina MVS (Mountrakis et al., 2011; Wei et al., 2021), bosques aleatorios (BA) (León-Rueda et al., 2022; Meng et al., 2020; Rodríguez et al., 2021; Shammi et al., 2022), y redes neuronales artificiales (RNA) (Imanian et al., 2021; Seetha et al., 2008).

Con base en lo anterior, y sumado al limitado número de investigaciones que usan datos espectrales enfocadas a MT causada por *Verticillium* spp. en papa, el enfoque de este trabajo fue usar métodos tradicionales y de aprendizaje automático con el fin de identificar longitudes de onda que contrasten entre plantas sanas y con sintomatologías asociadas a la enfermedad a partir de dos fuentes de datos espectrales. Los objetivos específicos fueron (i) comparar el desempeño de diferentes métodos de aprendizaje automático para la clasificación de plantas de papa sanas y con síntomas de madurez temprana en diferentes etapas de desarrollo de la enfermedad usando firmas espectrales y datos extraídos de imágenes multiespectrales, (ii) identificar las longitudes de onda con mayor importancia en la discriminación de plantas sintomáticas a partir de diferentes métodos de análisis usando firmas espectrales y datos extraídos de imágenes multiespectrales, (iii) desarrollar y aplicar índices espectrales y de enfermedad a partir de las longitudes de onda seleccionadas como mecanismo de comparación de las firmas espectrales y datos extraídos de imágenes multiespectrales y (iv) comparar resultados de clasificación con respecto a modelos generados a partir de datos de firmas e imágenes espectrales,

capturados en dos condiciones de desarrollo de la madurez temprana causada por *Verticillium* spp.

2.3 Materiales y métodos

2.3.1 Localización de áreas experimentales

Los datos fueron generados a partir de plantas de papa desarrolladas bajo dos condiciones contrastantes: (i) condiciones semicontroladas (invernadero) y cultivos de producción comercial (Figura 4). En el primer caso, se sembraron plantas de la variedad Diacol Capiro en materas de 5 kg de suelo en un invernadero ubicado en la Facultad de Ciencias Agrarias de la Universidad Nacional de Colombia en Bogotá (4°38'12.58"N, 74° 5'18.12"O). El suelo se mantuvo húmedo a partir de riegos constantes según los requerimientos de las plantas y se realizó un manejo acorde a la etapa de desarrollo del cultivo. Durante el periodo de desarrollo de las plantas, la temperatura promedio fue 15,1°C y la humedad relativa osciló entre 80 y 85%. Se utilizaron dos aislamientos del patógeno previamente identificados como pertenecientes al género *Verticillium* usando dos métodos de inoculación. Como referencia, el primer aislamiento del patógeno (*Verticillium albo-atrum*) fue proporcionado la Corporación Colombiana de Investigación Agropecuaria (Agrosavia) y el segundo fue obtenido a partir de plantas de papa var. Diacol Capiro afectadas por marchitez temprana en el municipio Funza, Cundinamarca durante el semestre 2 del 2020.

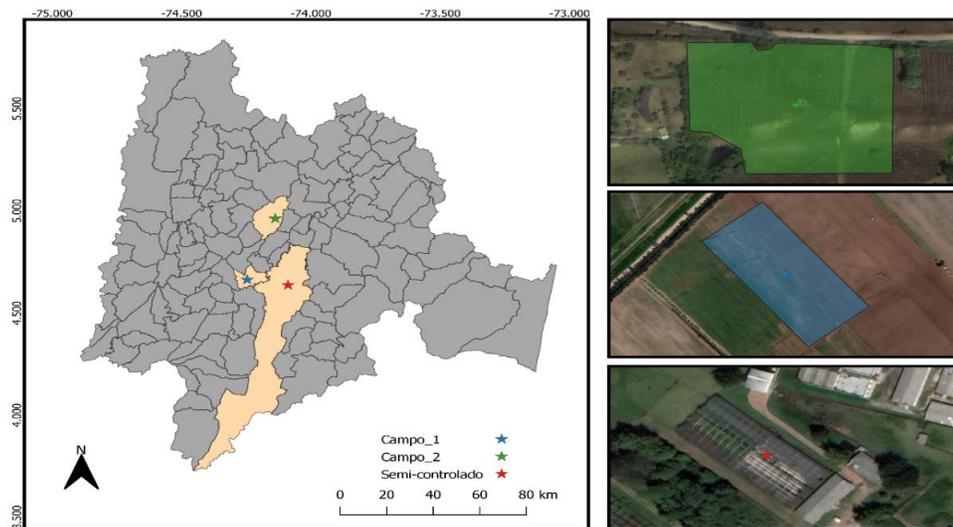


Figura 4. Ubicación de las áreas de estudio en condiciones de cultivo comercial e invernadero, mostrando las zonas de captura de imágenes ubicadas en Subachoque y Mosquera (Cundinamarca).

La multiplicación del patógeno en laboratorio se realizó en arroz cocido estéril a 21°C según el protocolo ajustado por el laboratorio de Sanidad Vegetal de la Facultad de Ciencias Agrarias. Las conidias de cada aislamiento fueron recogidas en agua destilada estéril ocho días después de la siembra y se ajustó una suspensión de 1×10^7 conidias ml^{-1} (Ashraf et al., 2012). Para la siembra se utilizaron tubérculos certificados de papa sembrados en suelo previamente autoclavado. Se sembraron 15 tubérculos para asegurar la presencia de plantas con diferentes niveles de severidad de la enfermedad. Del total de plantas evaluadas, seis fueron inoculadas por drench 49 días después de siembra (dds) y los seis restantes fueron inoculados al momento de la siembra ubicando el sustrato (arroz) con el patógeno alrededor del tubérculo semilla; como controles se usaron tres plantas sin inocular.

Para el estudio bajo condiciones de campo, se evaluaron plantas de la misma variedad con el manejo comercial del cultivo en dos lotes de producción ubicados en los municipios de Subachoque (4°57'44.52"N, 74° 8'14.44"O) y Mosquera (4°39'40.58"N, 74°14'53.46"O) (Cundinamarca). Las zonas de estudio se caracterizaron por presentar temperaturas diarias promedio en el rango entre 12 y 15°C, precipitación acumulada anual entre 600 y 1000 mm con distribución bimodal, altitud entre 2550 y 2750 msnm y humedad relativa entre 80 y 85%. Bajo esta condición, la fuente de inóculo correspondió a la presencia natural del patógeno en el suelo de los lotes seleccionados para el estudio, en los cuales fue reportada la afectación por MT ocasionada por *Verticillium* en ciclos de cultivo previos.

2.3.2 Adquisición de datos

Tanto en invernadero como en campo, la severidad de la enfermedad se evaluó de manera visual a partir de una escala descriptiva propuesta por Hunter et al., 1968 con cinco niveles correspondientes a 0: sin síntomas; 1: clorosis intervenal en las hojas inferiores; 2: necrosis moderada y defoliación de las hojas inferiores; 3: necrosis y defoliación severas de las hojas, retraso en el crecimiento; y 4: defoliación severa acompañada de atrofia pronunciada, clorosis y necrosis de las hojas restantes y planta muerta.

2.3.2.1 Datos en invernadero

Bajo condiciones controladas, se realizaron tres muestreos sobre el total de plantas (15) cada 8 días a partir de los 62 dds. Se capturaron firmas espectrales usando un espectroradiómetro fijo FieldSpec 4 Standar-Res® (Analytical Spectral Devices Inc. Boulder, CO, USA), con rango de evaluación entre 350 y 2500 nm, resolución espectral de 3 nm de 350 a 700 nm y de 10 nm entre 1400 y 2100 nm, intervalo de muestreo de 1.4 nm de 350 a 1050 nm y de 2 nm de 1000 a 2500 nm y un tiempo de integración de 34 ms.

En las plantas sanas e inoculadas se realizaron mediciones de la reflectancia en los folíolos laterales de las hojas número cuatro (Mauromicale et al., 2006) y siete totalmente expandidas a los 62, 70 y 77 dds. En cada momento de evaluación se tomaron cinco firmas

espectrales por foliolo, donde cada una correspondía a 24 promedios para un total de 120. Los datos fueron obtenidos mediante el uso del clip de hoja en cinco partes de cada foliolo, ubicando el haz de la hoja frente a la fuente de luz. Luego de cada 100 firmas capturadas, el equipo fue calibrado con un panel polytetrafluoroethylene con 99% de reflectancia (Analytical Spectral Devices Inc. Boulder, CO, USA). Se garantizó que las unidades experimentales evaluadas presentaran diferentes estados de severidad con el fin de comparar los cambios en el área foliar afectada para cada una de las hojas seleccionadas para la captura de firmas espectrales.

2.3.2.2 Datos en campo

Para la evaluación de la enfermedad en campo, se realizaron siete muestreos cada 8 días entre los 60 dds y 115 dds, en los cuales se seleccionaron 30 puntos evaluando 15 plantas por sitio, para un total de 450 individuos. Se realizó un muestreo sistemático en grilla de 15 x 20 m, distribuido en una hectárea del lote sin incluir los bordes. Cada uno de los puntos fue georreferenciado usando un dispositivo GPS Reach RS2® (EMLID, HU). En cada uno de los lotes (Mosquera y Subachoque) se evaluó la incidencia de la MT determinada como el número de plantas enfermas sobre el total de plantas evaluado. Adicionalmente, en cada punto de muestreo se determinó la severidad de la MT de cada planta según la escala descrita anteriormente. De los valores obtenidos, se tomó cualquier número mayor a 0 como caso positivo para el posterior entrenamiento de los algoritmos.

En los dos lotes seleccionados se capturaron datos multiespectrales en cuatro momentos cada 8 días a partir de los 77 dds, abarcando la fase de floración y llenado del tubérculo. Se realizaron vuelos con un dron DJI Phantom 4 al cual se le acopló el sensor multiespectral Parrot Sequoia (Parrot®), con GPS integrado y panel de reflectancia. Las imágenes fueron capturadas a una altura de 27 m, con solapamiento mayor al 70%. Se obtuvieron datos en las bandas verde-G (550 nm centro, 40 nm de ancho de banda), rojo-R (660 nm centro, 40 nm de ancho de banda), borde rojo-RE (735 nm centro, 10 nm de ancho de banda) e infrarrojo cercano-NIR (790 nm centro, 40 nm de ancho de banda) con un tamaño de píxel de 2.8 cm. Para corregir radiométricamente las imágenes, se capturaron datos sobre un panel de calibración, al inicio y final de cada vuelo. Para el postproceso de los datos y la generación de los orto mosaicos, se empleó el software Agisoft Meta Shape 1.6.1 (Agisoft™).

2.3.3 Análisis de datos

El proceso de análisis de datos fue desarrollado utilizando el software libre R (versión 4.1.2). El esquema básico de todo el proceso se ilustra en la Figura 5. Todos los modelos desarrollados fueron comparados respecto a su rendimiento de clasificación según las diferentes fuentes de datos, el estado de desarrollo de los síntomas de MT por *Verticillium*

presentes en plantas de papa según la escala de severidad mencionada anteriormente y las firmas e imágenes espectrales capturadas.

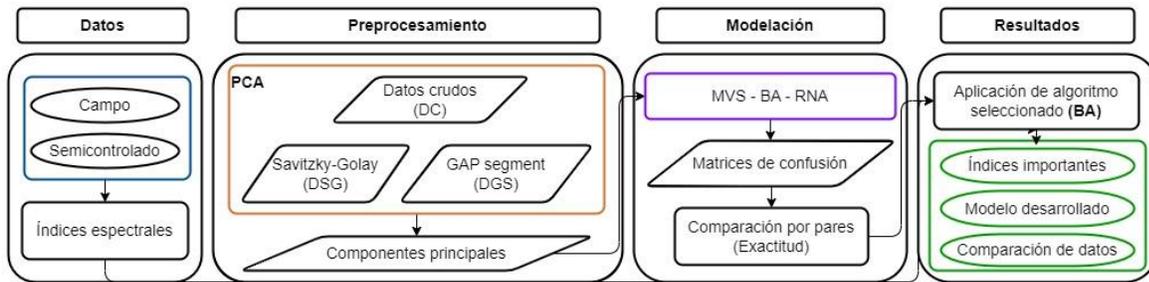


Figura 5. Flujo de trabajo de la investigación realizada para determinar bandas e índices espectrales contrastantes en la detección de MT de la papa.

El análisis se dividió en tres partes: (i) comparación de las clasificaciones respecto a firmas espectrales capturadas en diferentes hojas de la planta, esto con el fin de conocer la capacidad de discriminación de los síntomas e identificar el algoritmo con mejor rendimiento de clasificación, el cual sería usado en los análisis posteriores; (ii) identificación de bandas contrastantes respecto a la clasificación de firmas espectrales de plantas sanas y enfermas y (iii) generación de índices espectrales y de enfermedad para la posterior clasificación respecto a su uso como variables predictoras con las dos fuentes de datos capturadas. Para el punto i, se usaron los modelos BA, MVS (base lineal: MVS_l; radial: MVS_r) y RNA. Respecto a los resultados de la comparación de tasa de clasificación (Figura 11), se utilizó BA para los análisis de los puntos ii y iii.

Los algoritmos (BA, MVS y RNA) fueron seleccionados dado que utilizan enfoques de aprendizaje distintos. El primero BA utiliza el aprendizaje de conjuntos (Ren et al., 2016), el segundo MVS utiliza hiperplanos de separación (Gholami & Fakhari, 2017) y el último RNA utiliza el enfoque de redes neuronales tradicionales (Wang et al., 2021). Todos los conjuntos de datos se dividieron en grupos de entrenamiento y prueba basados en una proporción de 70:30. Los algoritmos fueron optimizados con parámetros de ajuste de cada modelo (BA = mtry, MVS = cost y loss, RNA = size y decay), se usó la librería caret (classification and regression training) para el entrenamiento y predicción de los modelos generados (Kuhn, 2008).

El rendimiento de los modelos se evaluó en dos momentos. En la fase de entrenamiento se utilizó una validación cruzada de 10 veces para cada modelo de clasificación. Posteriormente, se comparó el rendimiento de cada modelo para clasificar las clases de presencia y severidad, usando la exactitud de clasificación como métrica de comparación de los modelos en las pruebas no paramétricas. Adicionalmente, se compararon las métricas de sensibilidad y especificidad calculadas con la función confusionMatrix del paquete R caret (Kuhn, 2008). Además de esto, todos los modelos fueron evaluados en comparación por pares (métrica: exactitud) utilizando pruebas t con corrección de Bonferroni (nivel de confianza = 0,95) y la función diff en el paquete R caret (Kuhn, 2008).

2.3.3.1 Firmas espectrales

Los archivos generados a partir del espectro radiómetro fueron exportados en formato .asd, por lo cual se utilizó la librería asdreader versión (0.1-3) para su posterior lectura. Cada archivo fue organizado respecto al número de planta para luego asignar el grado de severidad de la enfermedad, respecto a las evaluaciones de los síntomas realizadas en cada uno de los muestreos.

La primera fase del análisis de datos se basó en comparar la capacidad de los modelos generados para la predicción de plantas sanas y enfermas, usando las bandas espectrales como variables predictoras. Para este proceso se utilizó un análisis multietapas, usando datos crudos y preprocesados. Se generaron tres bases de datos: (i) datos crudos (DC); (ii) datos preprocesados usando el filtro Savitzky-Golay (Savitzky & Golay, 1964), segunda derivada (DSG) con un ancho de banda de trece unidades, un polinomio de tercer y una derivada de segundo grado respectivamente y (iii) datos con filtro Gap segment (Hopkins, 2001) y segunda derivada (DGS) con un ancho de banda de trece unidades, con un intervalo gap de diez unidades y una derivada de segundo grado. Los sets de datos fueron procesados con librería prospectr (Stevens & Ramirez Lopez, 2014).

A cada set de datos se le realizó análisis de componentes principales (PCA) usando la librería FactoMineR (Lê et al., 2008). Los componentes generados fueron utilizados como variables predictoras para optimizar el proceso de modelación y comparación inicial de la tasa de clasificación. Esto permitió identificar el algoritmo y el set de datos a usar para seleccionar las longitudes de onda con mayor importancia, las cuales fueron aplicadas posteriormente en el cálculo de índices espectrales.

En la segunda fase del análisis de las firmas espectrales, se generaron modelos con el fin de identificar las longitudes de onda con mayor importancia y comparar la tasa de clasificación de plantas sanas y enfermas con respecto a la hoja en la cual se realizaron las mediciones. El algoritmo usado fue BA, utilizando el set DGS dividido respecto a la hoja de medición, se usaron los parámetros de optimización y las métricas de comparación anteriormente descritas.

2.3.3.2 Imágenes multiespectrales

A partir de las imágenes multiespectrales capturadas y los puntos de muestreo para cada una de las fechas, se extrajeron los valores de los píxeles asociados a cada planta, generando un set de cuatro bandas y los valores asociados a la evaluación de los síntomas de la enfermedad. Con los valores de las bandas se calcularon 13 índices, presentados en las tablas 1 y 4, incluido un índice de enfermedad propuesto a partir de las bandas contrastantes encontradas respecto a los análisis previos realizados sobre las firmas espectrales (Ecuación 19). Posteriormente se generaron modelos de clasificación respecto

a incidencia y severidad usando el algoritmo BA bajo las parametrizaciones descritas anteriormente.

Tabla 4. Índices de vegetación relacionados con los componentes estructurales de las plantas usados en la detección de MT de la papa.

| Nombre | | Ecuación | Referencia |
|--------------------------|-------------|---|-------------------------|
| Anthocyanin Index (ARI) | Reflectance | $\frac{1}{R_{GREEN}} - \frac{1}{R_{REDEGDE}}$ (Ecuación 17) | (Gitelson et al., 2001) |
| Anthocyanin Index (CARI) | Reflectance | $\frac{R_{REDEGDE}}{R_{GREEN}} - 1$ (Ecuación 18) | (Zhou et al., 2019) |
| Verticillium (VWI) | Wilt Index | $\frac{\sqrt{NIR - REDEGDE}}{(NIR - REDEGDE)^2}$ (Ecuación 19) | Índice propuesto |

2.3.3.3 Comparación de datos de espectro radiómetro y datos de cámara multiespectral

A partir de la identificación de las bandas importantes desarrollada en una fase previa y con el fin de establecer una relación de contraste entre los datos generados en las firmas e imágenes multiespectrales, se calculó la media de los valores de reflectancia obtenidos en las firmas espectrales utilizando el set DC. Lo anterior, debido a que no se modificaron los valores de reflectancia en los intervalos de captura de las bandas de la cámara multiespectral teniendo en cuenta su variación específica (ancho de banda). Se generaron diversas combinaciones de los valores asociados a las bandas NIR, R y RE, para evaluar su capacidad estimativa con respecto a la presencia de los síntomas de MT, seleccionando el índice llamado *Verticillium Wilt Index* (VWI) (Ecuación 19). Posteriormente se calcularon los índices espectrales listados en las tablas 1 y 4 los cuales fueron usados como variables predictoras en las clasificaciones posteriores. Se generaron comparaciones por pares de los diferentes modelos desarrollados a partir de las dos fuentes espectrales usadas mediante el mismo flujo de evaluación presentado anteriormente.

2.4 Resultados

Bajo condiciones de invernadero, las plantas de papa inoculadas con los dos aislamientos de *Verticillium* desarrollaron síntomas de madurez temprana (Figura 6A). Los primeros síntomas se observaron entre los 60 y 65 dds y corresponden a pérdida de turgencia y decoloración de las hojas bajas. Posteriormente, se presentó clorosis, necrosis y

marchitamiento de las hojas de forma ascendente y por último las hojas marchitas permanecieron adheridas al tallo (Figura 6A).

Bajo condiciones comerciales en los lotes de Mosquera y Subachoque se encontraron síntomas asociados con MT de la papa sobre los 70 dds. Las sintomatologías correspondieron a clorosis intervenal, necrosis y marchitamiento de las hojas las cuales permanecieron adheridas a los tallos (Figura 6B). Los síntomas observados en campo coincidieron con lo encontrado en las plantas inoculadas bajo invernadero.

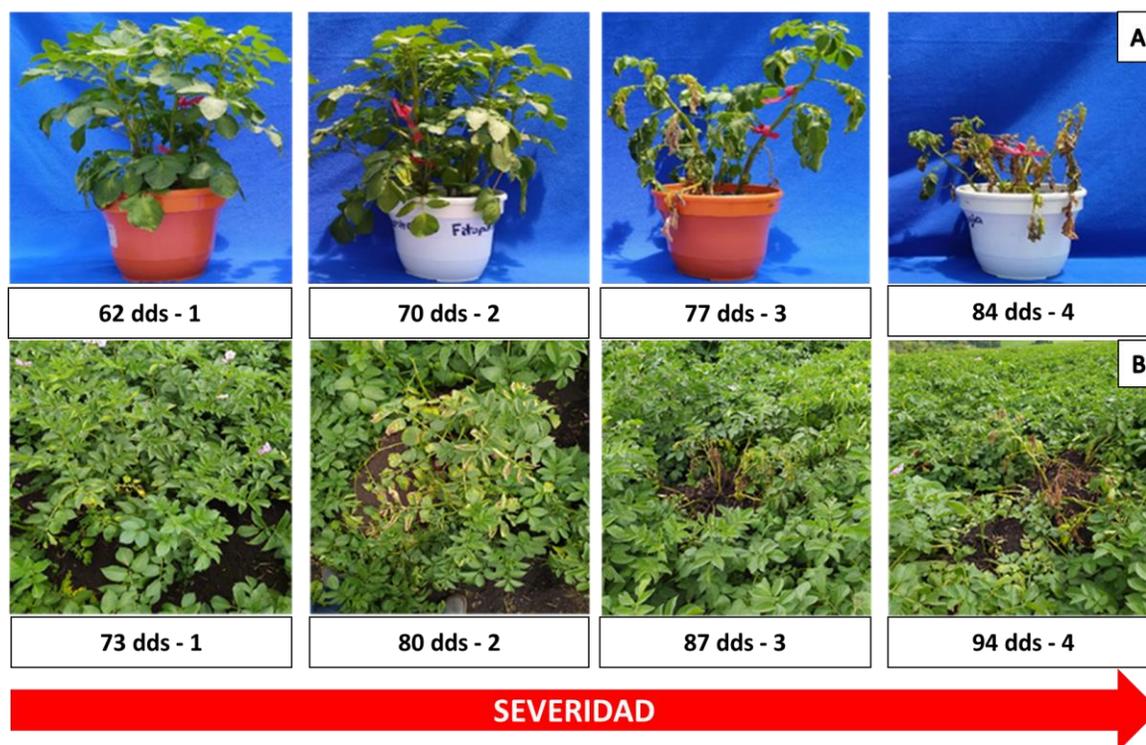


Figura 6. Desarrollo de síntomas de marchitez temprana en plantas de papa Var. Diacol Capiro con diferentes grados de severidad. **A.** Plantas inoculadas con *Verticillium* spp. bajo condiciones de invernadero. **B.** Plantas en cultivo comercial ubicado en Subachoque.

2.4.1 Análisis de firmas espectrales

A partir de las firmas espectrales capturadas bajo condiciones de invernadero, se identificaron diferencias entre los comportamientos espectrales de plantas con síntomas asociados a MT y plantas control (sana). El comportamiento diferencial basado en inspección visual se observa en las regiones del espectro ubicadas entre 475-725, 1625-1770 y 2225-2320 nm (Figura 7). En estas regiones, las plantas sanas presentaron una menor reflectancia en comparación con las plantas enfermas y los respectivos niveles de

severidad. Sin embargo, se evidencia que el grado uno de la escala de severidad (menor severidad) evaluado tiende a tener un comportamiento similar con plantas reportadas como sanas.

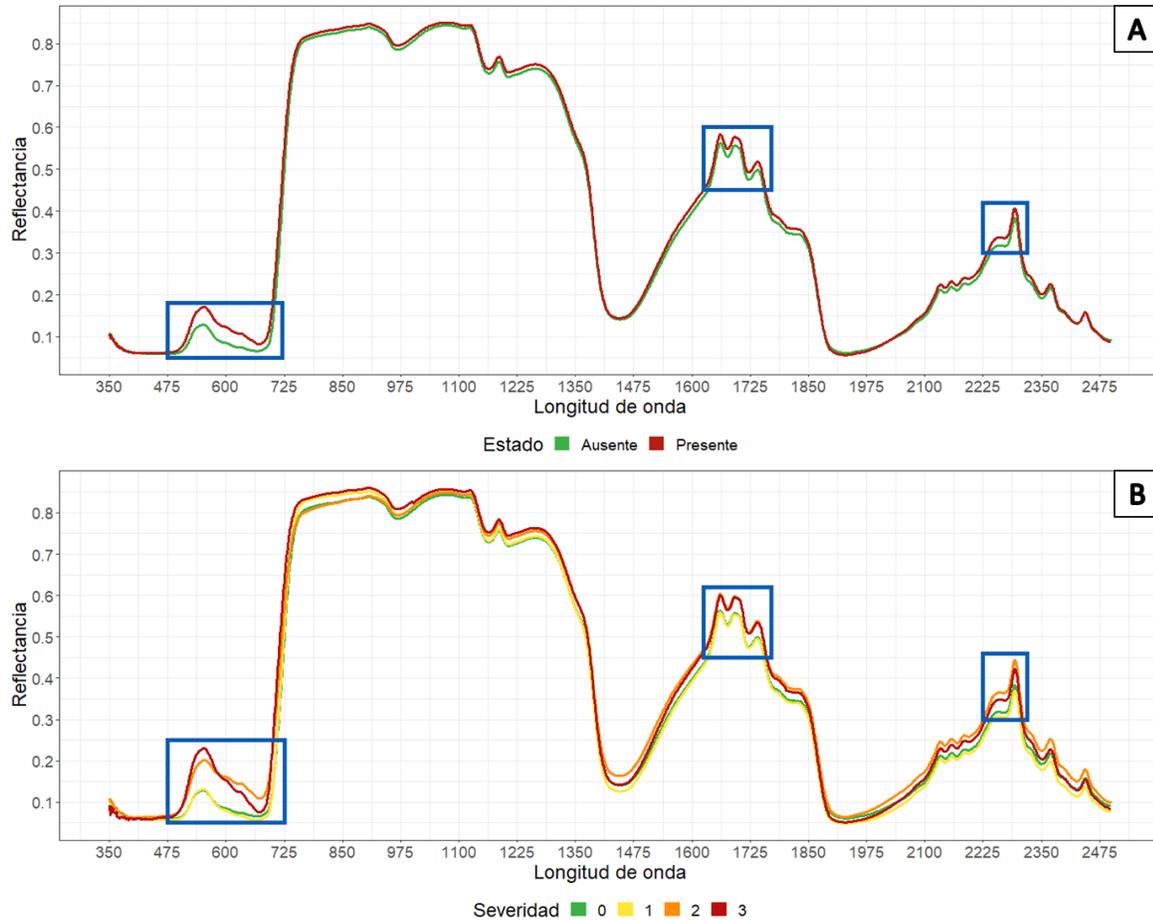


Figura 7. Comparativo de valores medios de las firmas espectrales capturadas en plantas de papa Var. Diacol Capiro inoculadas con *Verticillium* y con síntomas de madurez temprana bajo invernadero. **A.** Plantas sanas y enfermas. **B.** Niveles de severidad de la enfermedad.

Con respecto a la hoja de la planta en la que se tomó la firma espectral, se observó que en la hoja cuatro (Figura 8A) y siete (Figura 8B) se presentó un comportamiento espectral similar respecto a los diferentes grados de severidad de la enfermedad. Sin embargo, se encontró una variación en el comportamiento de las firmas con grados de severidad 3 en la hoja siete, en la cual decae la reflectancia respecto a los demás niveles de enfermedad.

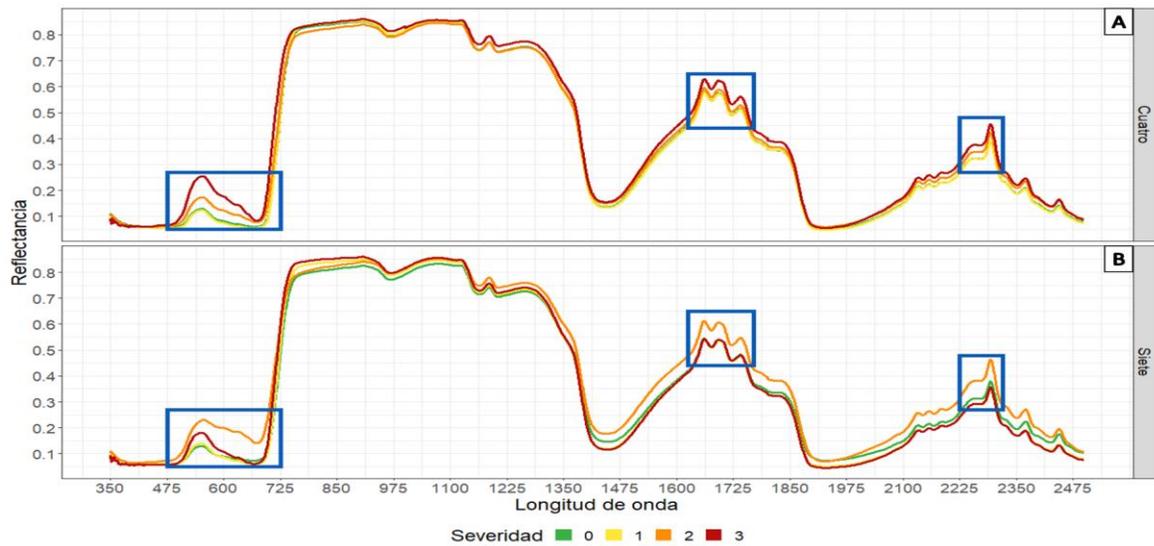


Figura 8. Comparativo de valores medios de las firmas espectrales capturadas en plantas de papa Var. Diacol Capiro inoculadas con *Verticillium* en diferentes hojas verdaderas. **A.** Hoja cuatro. **B.** Hoja siete.

Con respecto al momento de evaluación (Figura 9), se observó un aumento de la reflectancia en plantas con severidad alta (severidad 3) conforme avanza el tiempo de infección. Se identificó que la diferenciación de firmas de plantas con grados iniciales de la enfermedad (severidad 1 y 2) en el rango de los 500 a 750 nm se dificulta a los 77 dds. En contraste, a longitudes mayores a 750 nm se resalta la diferencia entre valores de reflectancia de plantas sanas y plantas que expresan algún grado de severidad de la enfermedad para el mismo momento de evaluación.

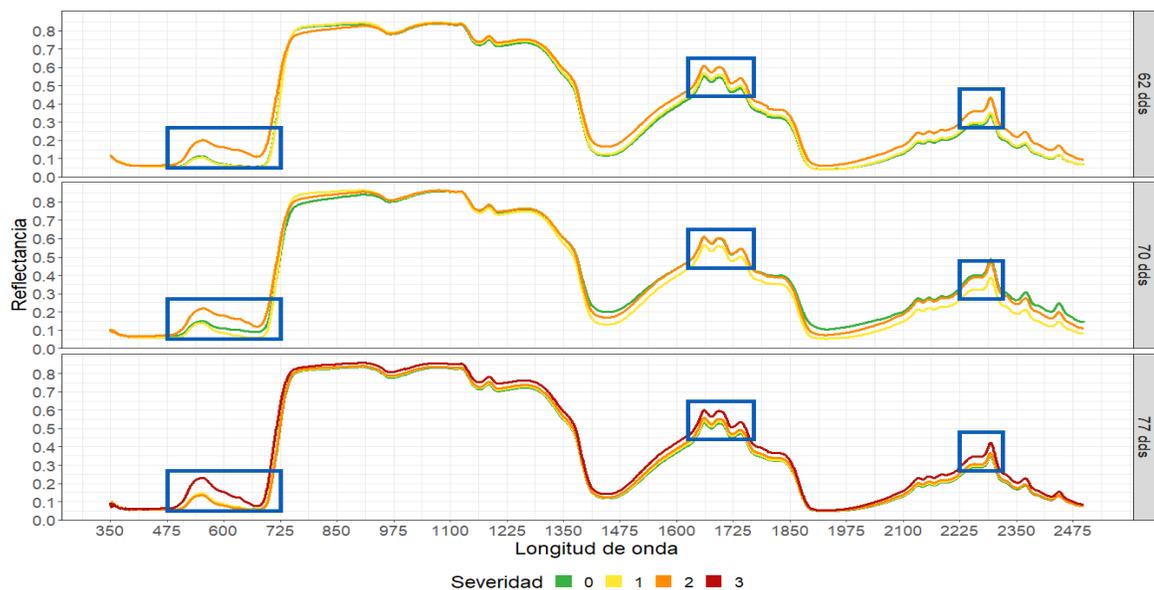


Figura 9. Comparativo de valores medios de las firmas espectrales capturadas en plantas de papa Var. Diacol Capiro inoculadas con *Verticillium* en diferentes momentos de captura. 1. 62 dds 2. 70 dds 3. 77 dds.

El análisis a partir del método de PCA aplicado sobre los diferentes sets de datos obtenidos luego del preprocesamiento, evidenció que el mejor ajuste se presentó con el set DGS ya que expresó de mejor forma la contribución de los vectores generados. Por su parte, la explicación de la variación de las dimensiones fue mayor utilizando el set DGS para la hoja cuatro, el cual logró un valor de 78.3% en la primera dimensión (Figura 10A). Sin embargo, el porcentaje de explicación fue similar para todos los sets al usar dos dimensiones para los datos capturados en este nivel de la planta. Para la hoja siete (Figura 10B), el uso de datos del set DC tuvo mayor capacidad de explicación de la varianza (87,2%), mostrando una mayor diferenciación de las respuestas espectrales en el tercio bajo de las plantas. En ambos casos, los vectores generados muestran que la mayor capacidad de discriminación de la presencia de síntomas de MT se presenta en el rango de 680 a 740 nm. Para el caso de severidad, se observa una contribución de algunos vectores ubicados en la región de 2300 a 2450 nm.

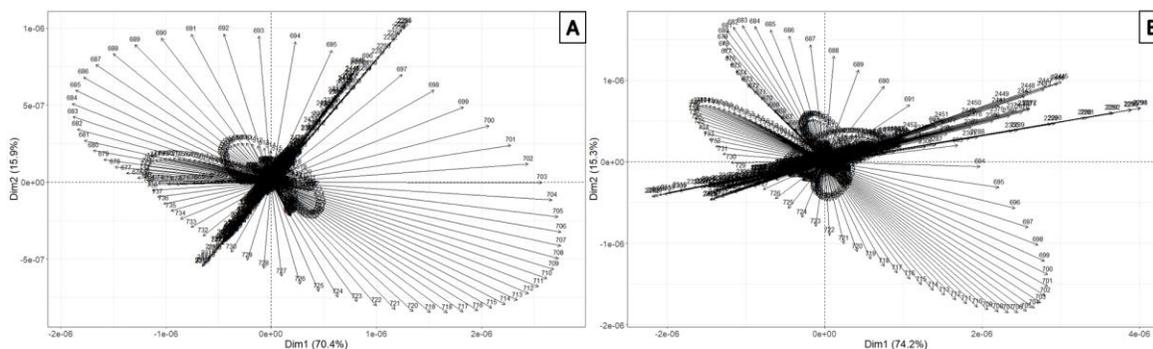


Figura 10. Resultados del análisis PCA aplicado a sets de datos. **A.** Hoja cuatro–DGS **B.** Hoja siete–DGS.

Los resultados de clasificación utilizando los tres sets de datos (Figura 11), muestran que, a partir de los valores medios de exactitud, con los datos capturados en la hoja cuatro (Figura 11A), la mayor tasa de clasificación fue obtenida utilizando el algoritmo BA con el set DGS (60.9%), sin embargo, no existen diferencias entre la tasa de clasificación de los modelos utilizados ($p\text{-value} = 0.8128$). En contraste, para la hoja siete (Figura 11B), los valores medios muestran que la mayor tasa de clasificación fue la alcanzada aplicando el modelo MVS con el set DC (72.2%). Adicionalmente, se encontraron diferencias entre clasificadores ($p\text{-value} = 1.4727e^{-10}$), separándolos en tres grupos, en los cuales se destaca que BA con cualquier set de datos donde no tuvo diferencias respecto a la tasa de clasificación presentada por MVS/DC.

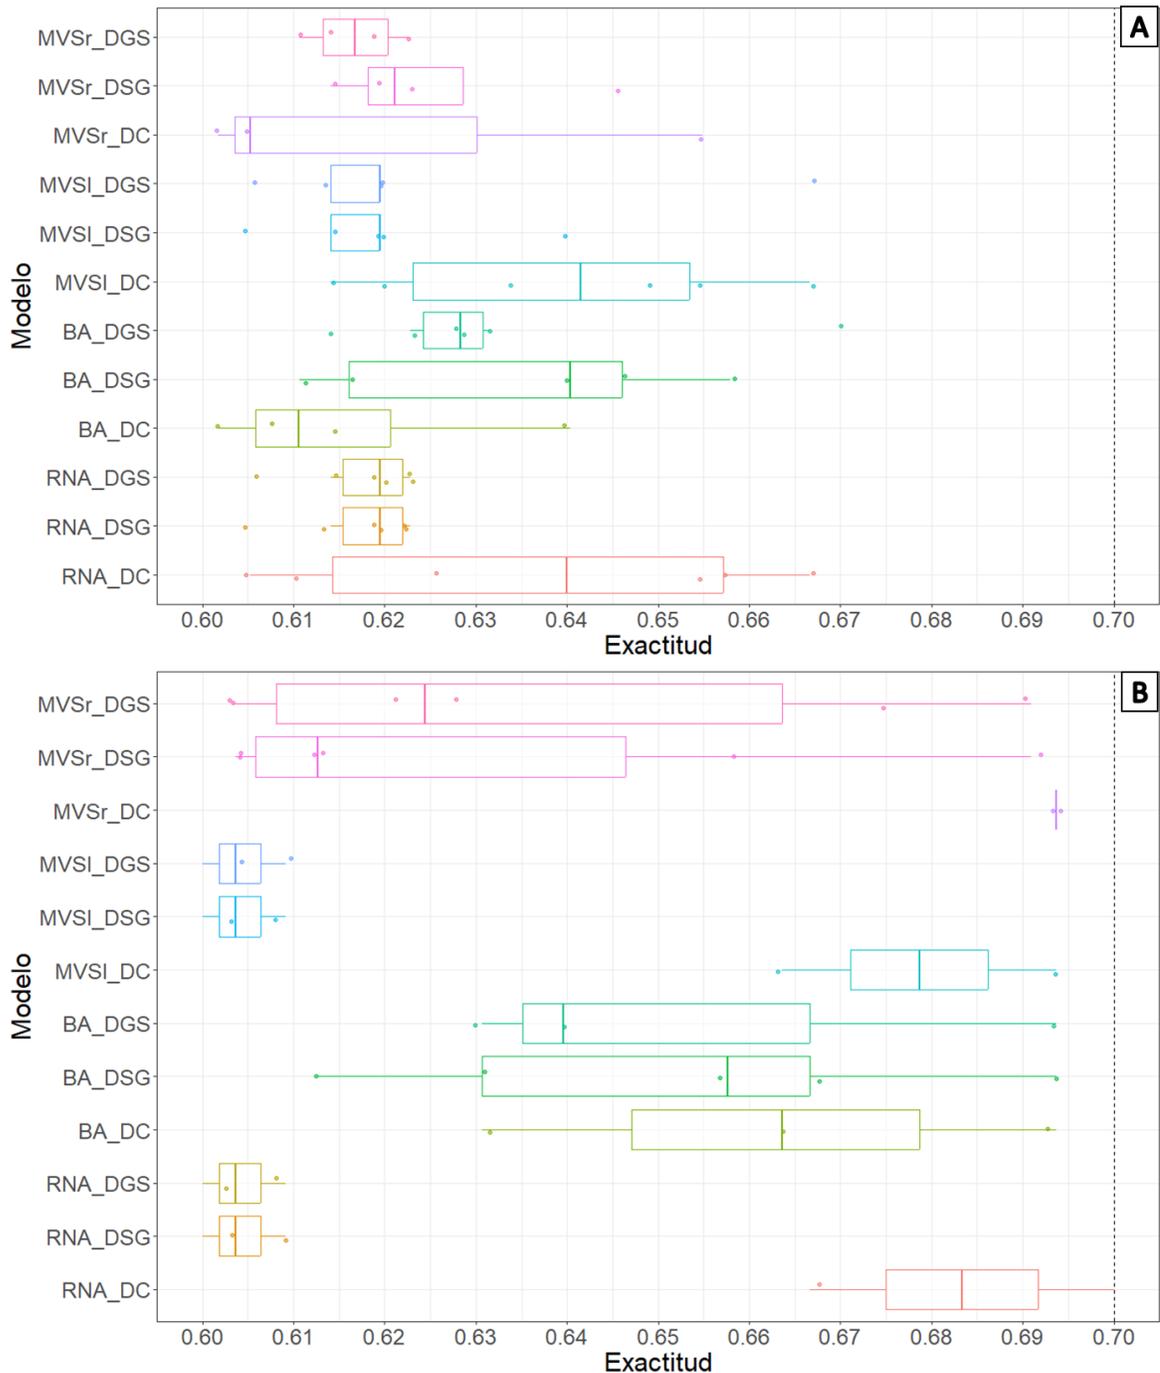


Figura 11. Resultados de exactitud de clasificación de modelos aplicados a los sets de datos. **A.** Hoja cuatro **B.** Hoja siete.

Un comportamiento similar presenta BA en su tasa de clasificación usando los sets DGS obtenidos en las diferentes hojas de la planta evaluadas. Por lo anterior, se generaron modelos usando este algoritmo, se obtuvo que existen diferencias entre las tasas de

clasificación de los modelos generados para presencia (Figura 12A) y severidad (Figura 12B) de la enfermedad según la hoja en la cual se capturaron las firmas espectrales. Los modelos presentan diferencias estadísticas ya que los valores p son cercanos a cero (p -value presencia = $1.5358e^{-06}$; p -value severidad = 0.00284). Para presencia, se obtuvieron modelos con una exactitud media de 75.3% y 89.3% para la hoja cuatro y siete respectivamente, siendo más sensibles y específicos para los datos de la hoja siete. En cuanto a severidad, el comportamiento fue similar, sin embargo, la exactitud media disminuyó en 6% para la hoja siete.

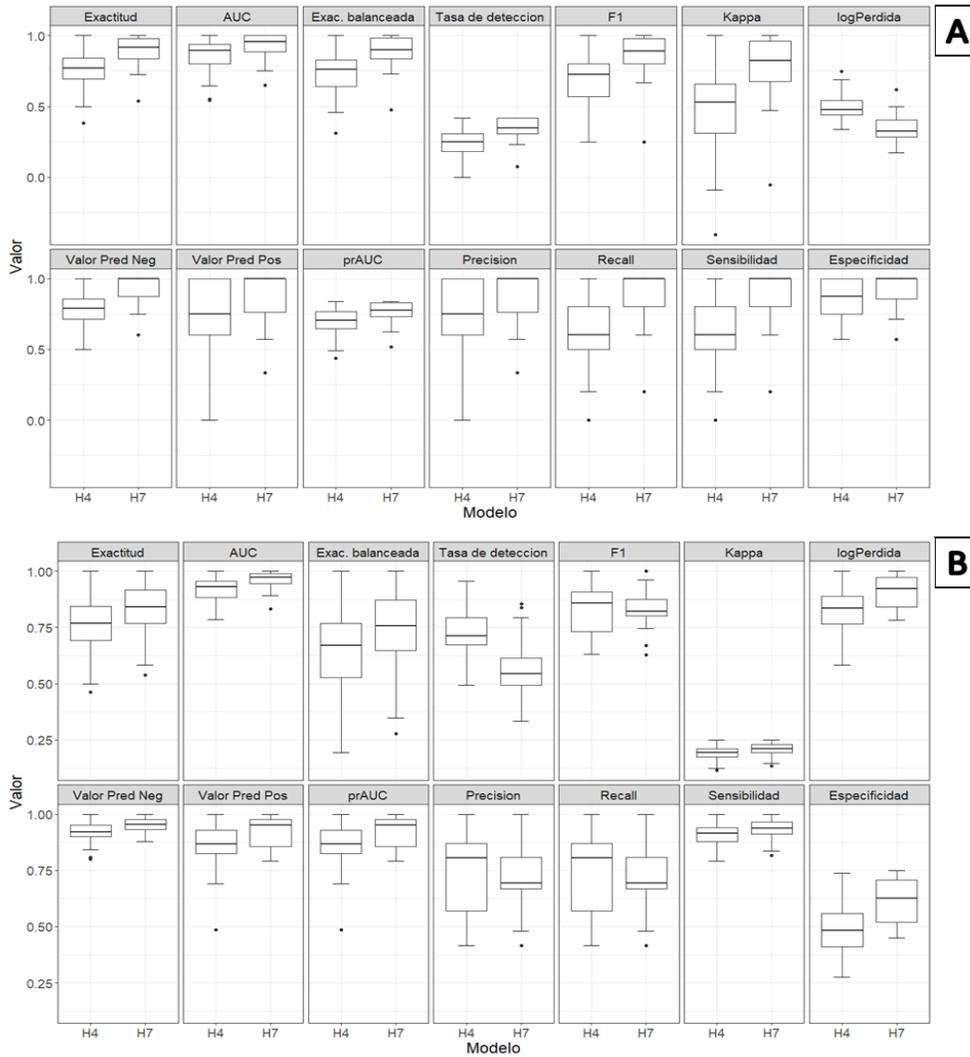


Figura 12. Métricas de evaluación de modelos generados usando BA sobre datos capturados en la hoja cuatro (H4) y siete (H7) usando el set DGS. **A.** Presencia **B.** Severidad.

2.4.2 Determinación de bandas informativas para discriminar entre planta sana y enferma

Con base a los resultados de los modelos generados para el set DC, se identificaron bandas espectrales que tienen mayor importancia para la discriminación de plantas de papa sanas y afectadas por MT (Figura 13) y los niveles de severidad de la escala utilizada. Para los datos capturados en la hoja cuatro, la región correspondiente al espectro visible (380-780 nm) contiene las bandas de mayor importancia, en especial, la zona correspondiente al rojo (650 a 740 nm). Para la clasificación de presencia, se destacan las bandas 712, 719, 722, 726 y 727 nm; para severidad, las bandas 710, 721, 723, 728 y 730 tienen mayor importancia, lo cual concuerda con los resultados del análisis PCA generados anteriormente. Al comparar las bandas importantes por hoja, se identificó que las áreas espectrales más importantes son comunes, mostrando una mayor capacidad de discriminación en la región de 710 a 735 nm entre firmas de plantas sanas y con algún grado de la enfermedad.

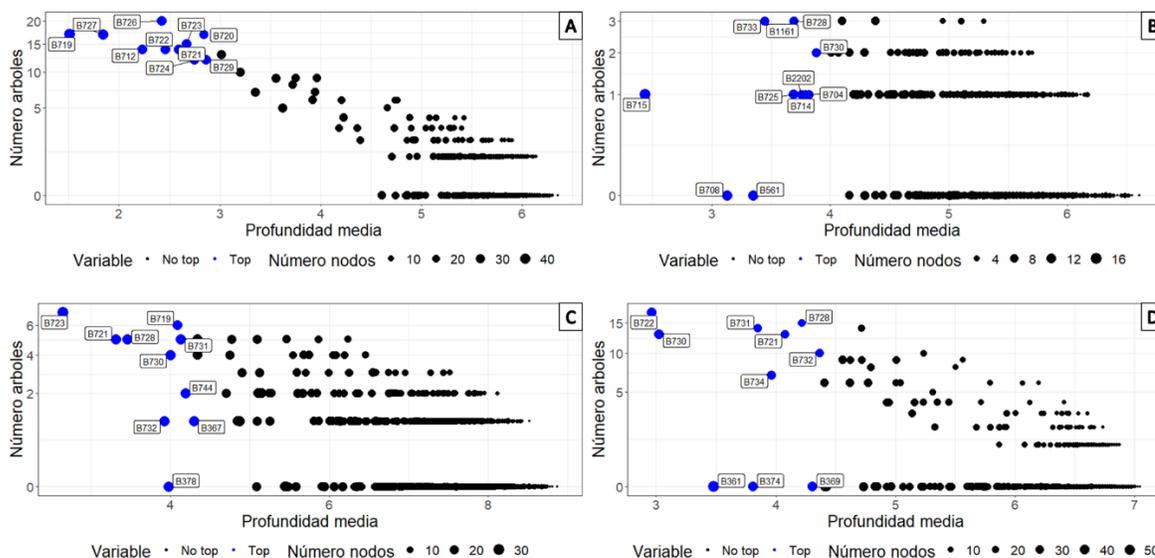


Figura 13. Importancia de vía múltiple de variables de clasificación usando BA aplicado al set DGS. **A.** Presencia - Hoja cuatro **B.** Presencia - Hoja siete **C.** Severidad - Hoja cuatro **D.** Severidad - Hoja siete.

Los resultados de los modelos generados a partir de los índices calculados con los datos de las firmas espectrales muestran tasas de clasificación de 74 y 64.8% respecto a la presencia y grado de severidad de MT en papa, respectivamente. Lo anterior indica que fueron similares al utilizar BA sobre los componentes principales, sin embargo, se identificó una disminución del tiempo de procesamiento respecto al uso del total de las longitudes de onda obtenidas en la firma espectral. Se identificaron algunos índices espectrales con mayor capacidad de diferenciación; dentro de estos se destacaron el RECI, NDRE y GRVI,

los cuales se ubican en la parte de arriba a la izquierda en la Figura 14. Se obtuvo que los índices con bandas en las áreas del espectro visible y el borde rojo fueron los más informativos para esta enfermedad, lo que se relaciona en la figura 14. El índice propuesto tuvo importancia aceptable en la clasificación de presencia y severidad mostrando su potencial al ser usado como herramienta de estimación al usar otras herramientas de captura de datos.

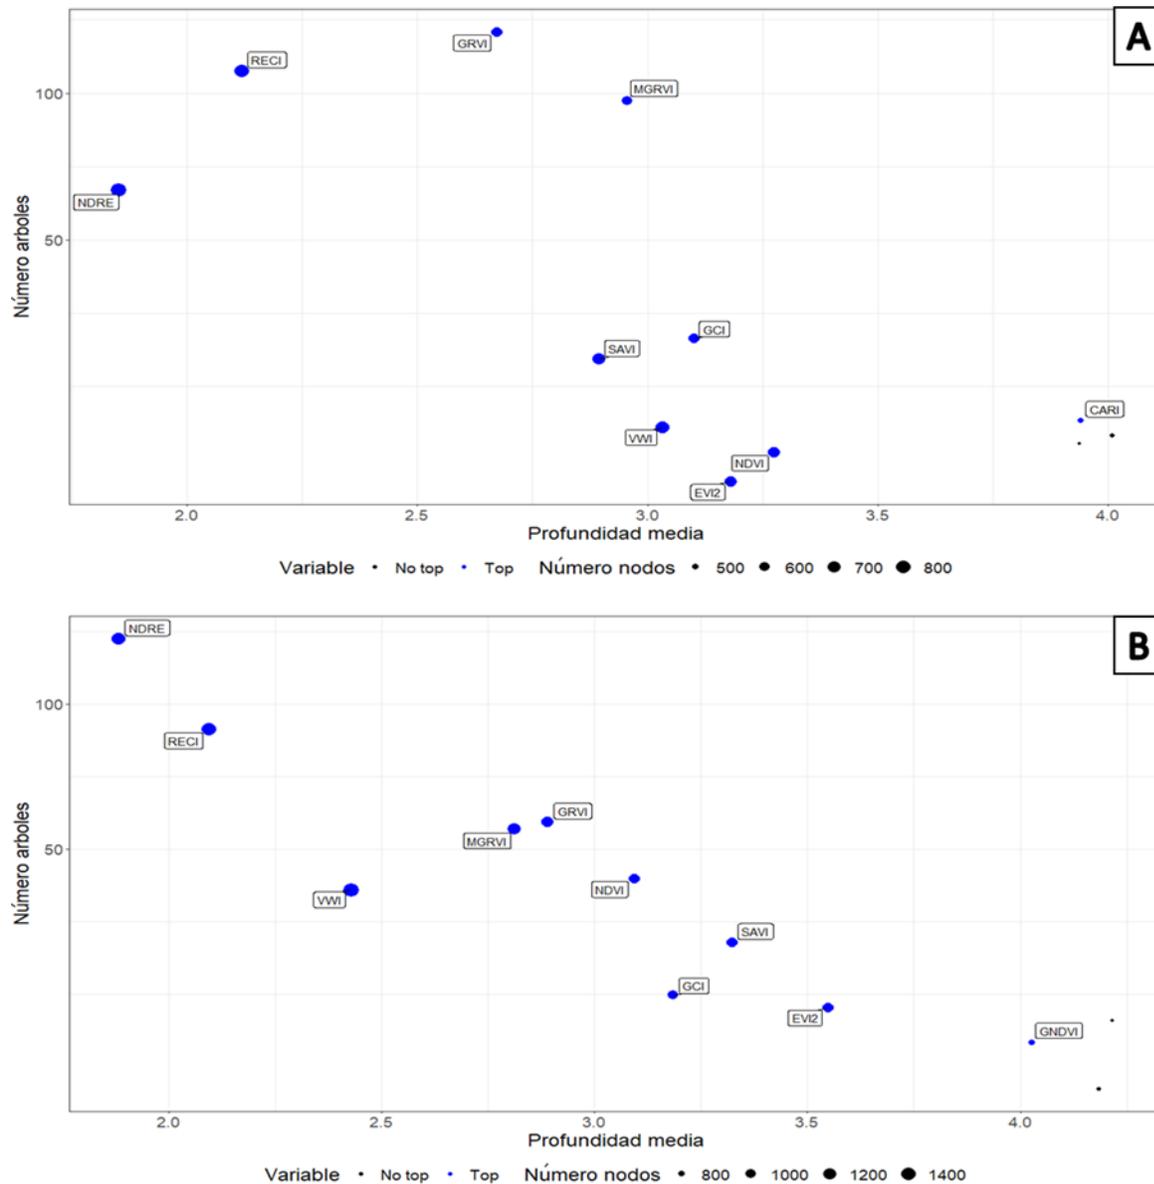


Figura 14. Gráfico de importancia de variables de clasificación usando BA aplicado a set de datos de índices de vegetación calculados con datos de hoja cuatro. Los puntos de color azul tienen mayor importancia. **A.** Presencia **B.** Severidad.

Los índices más informativos con respecto a los datos de firmas espectrales mostraron alta variación entre plantas sanas y enfermas. Los valores de GRVI en las plantas con presencia de síntomas de la alteración tienden a tener valores mayores del índice, mientras que para el RECI y NDRE las plantas enfermas tienden a los valores más bajos (Figura 15). Con respecto al índice generado por esta investigación (VWI), se identificó que los valores asociados a plantas con síntomas de la enfermedad tienden a ser menores en comparación con los demás.

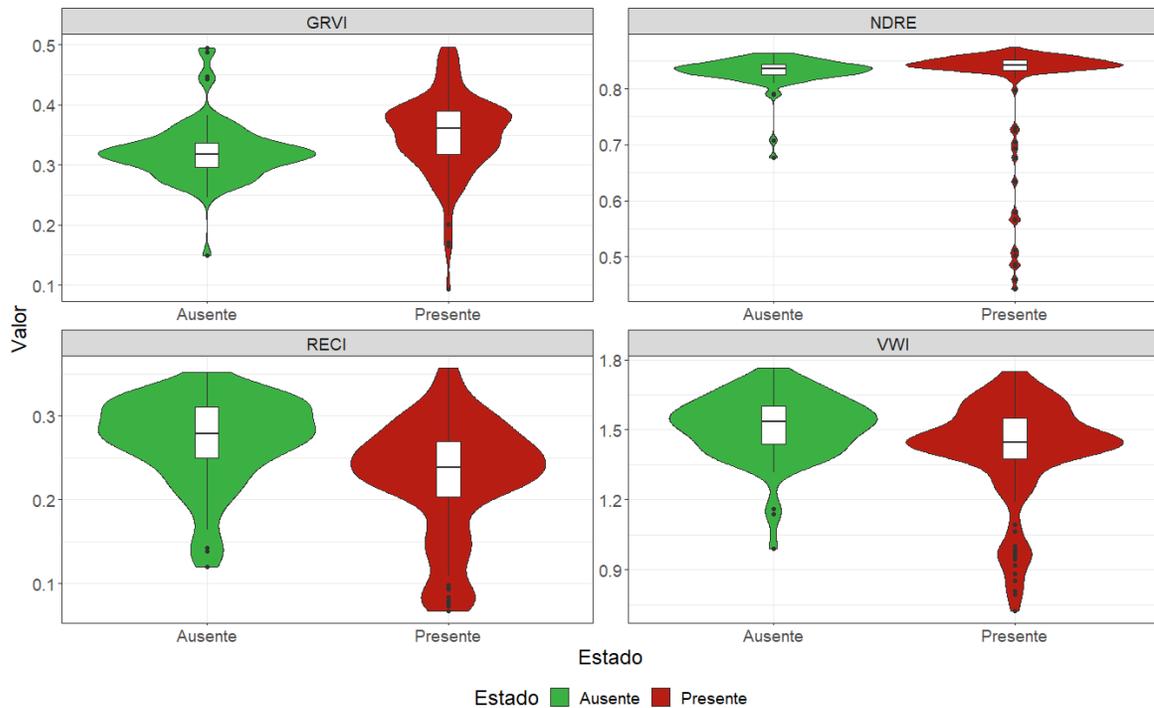


Figura 15. Comportamiento de los índices espectrales de importancia para la discriminación entre plantas sanas y enfermas por la madurez temprana de la papa Var. Diacol Capiro causada por *Verticillium* a partir de las firmas espectrales.

2.4.3 Comparación de firmas espectrales y datos de cámara multispectral

Los resultados mostraron que la región correspondiente al espectro visible (380-780 nm) contiene las bandas de mayor importancia encontradas por el algoritmo BA. Dentro de estas, la zona correspondiente al rojo incluye las bandas con mayor capacidad de discriminación (650 a 740 nm) (Figura 16A). La comparación de las bandas de la cámara multispectral respecto a las bandas más importantes en las firmas espectrales se presenta en la figura 16B. Los datos indican que 18 de las bandas informativas encontradas en la modelación de las firmas espectrales presentes en el primer cuartil respecto a su importancia, coinciden con regiones capturadas por la cámara multispectral,

donde cuatro corresponden a la región del verde, siete al rojo y siete al borde del rojo (Figura 16C).

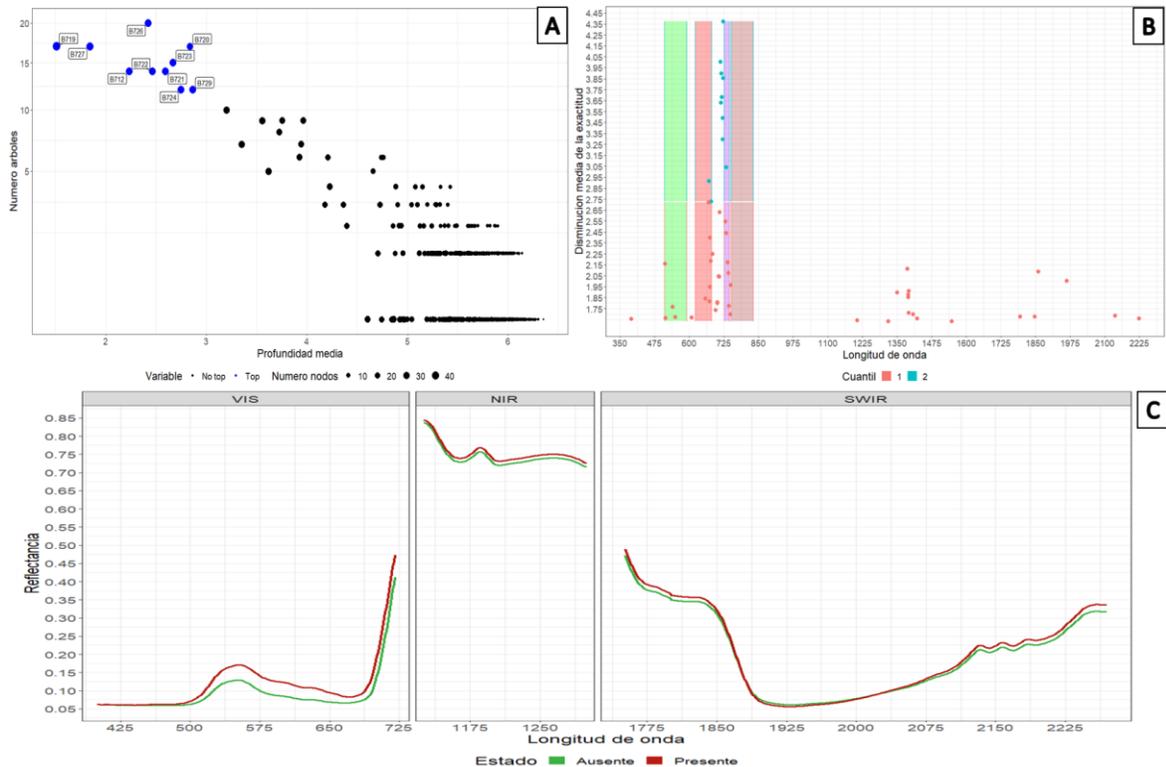


Figura 16. Bandas informativas respecto a clasificación realizada para firmas espectrales de plantas sanas de papa Var. Diacol Capiro y con síntomas de madurez temprana con el algoritmo BA. **A.** Bandas con significancia. **B.** Comparativo de bandas importantes respecto a los espectros de la cámara Parrot Sequoia. **C.** Comportamiento espectral en áreas de importancia para la discriminación entre plantas de papa Var. Diacol Capiro sanas y afectadas por la MT de la papa causada por *Verticillium*.

Los resultados indican que los modelos generados a partir de las dos fuentes de datos tienen tasas de exactitud de clasificación bastante aceptables. Esto se ve representado por valores de exactitud mayores al 80% para la clasificación de presencia de síntomas de la enfermedad. Por el contrario, para severidad las tasas fueron de 84% con datos extraídos de imágenes y 56% para firmas espectrales. BA aplicado a los índices calculados sobre los datos de las imágenes espectrales obtuvo mayor exactitud. A pesar de ello, la sensibilidad y especificidad media se vieron afectadas en la clasificación de la presencia y severidad de MT con respecto a los índices calculados a partir de datos de imágenes multiespectrales (Figura 17A). En los modelos evaluados se encontraron diferencias significativas ($P = 0.0023$) entre las clasificaciones realizadas respecto a la exactitud de clasificación. En relación con la clasificación de los diferentes grados de severidad de la enfermedad (Figura 17B) se presentaron diferencias entre los modelos generados ($p\text{-value} = 8.2700e-10$).

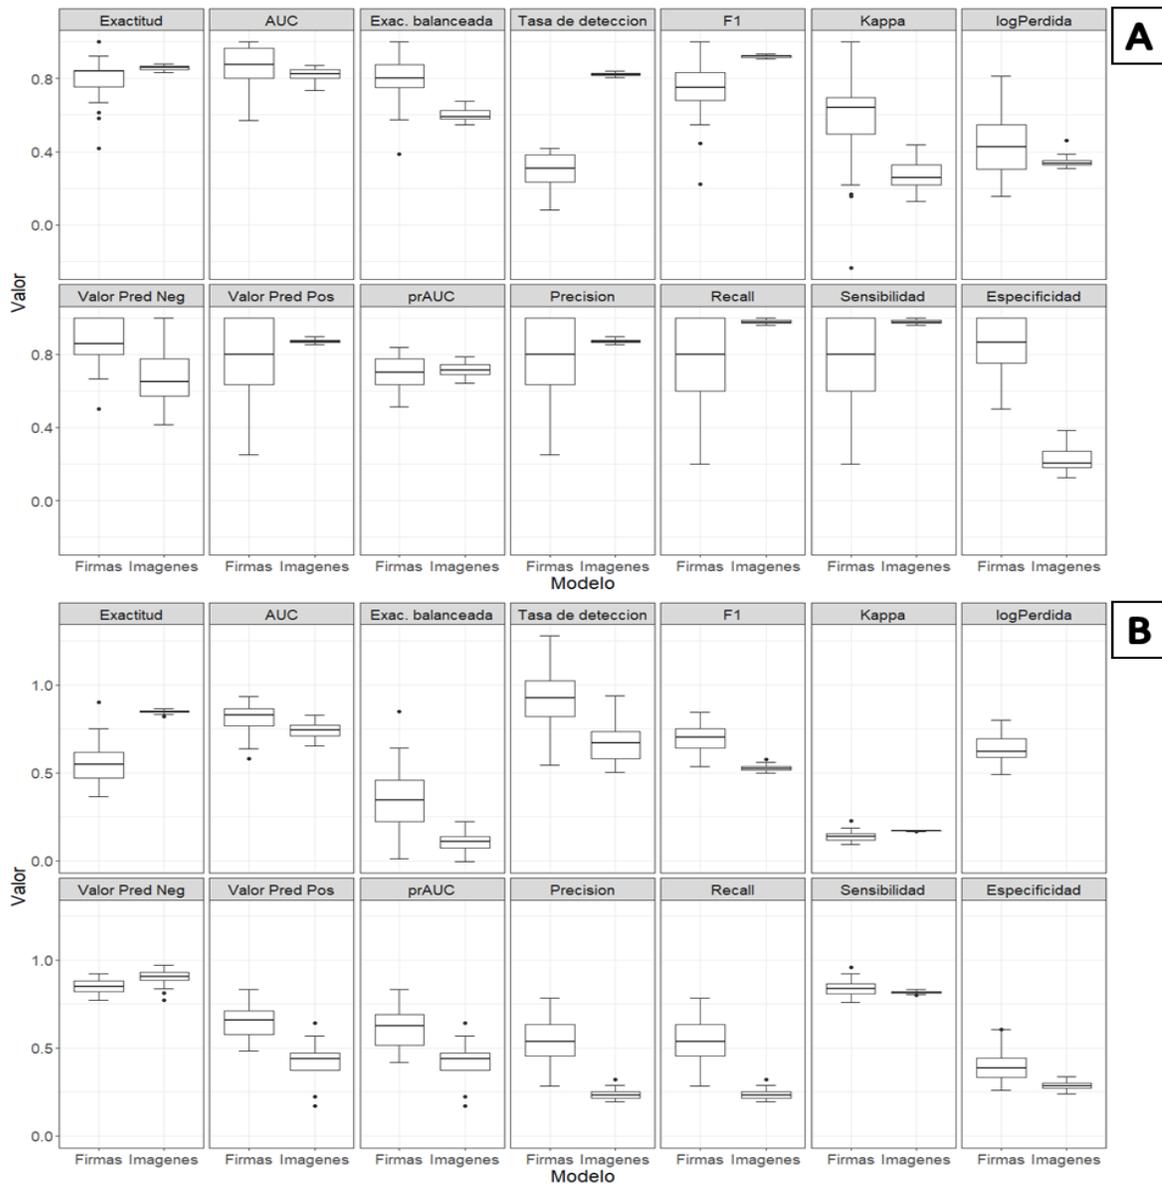


Figura 17. Comparativo de métricas de evaluación de BA aplicados a datos de firmas e imágenes espectrales. **A.** Presencia de MT. **B.** Severidad de MT.

Se identificó que los índices con bandas en las áreas del espectro visible y el borde rojo fueron los más informativos en la discriminación sin importar la fuente de los datos (Figura 18). Los índices de mayor importancia fueron RECI, NDRE y GRVI obtenidos a partir de las firmas espectrales y NDRE, RECI, VWI y GCI con las imágenes multiespectrales, sin embargo, se observó la importancia de las bandas de la cámara (Red, Green, RedEdge y NIR) como variables de predicción en los modelos. Por su parte, el índice propuesto (VWI) tuvo una importancia alta para presencia y severidad, comportándose mejor en los índices calculados para las imágenes multiespectrales.

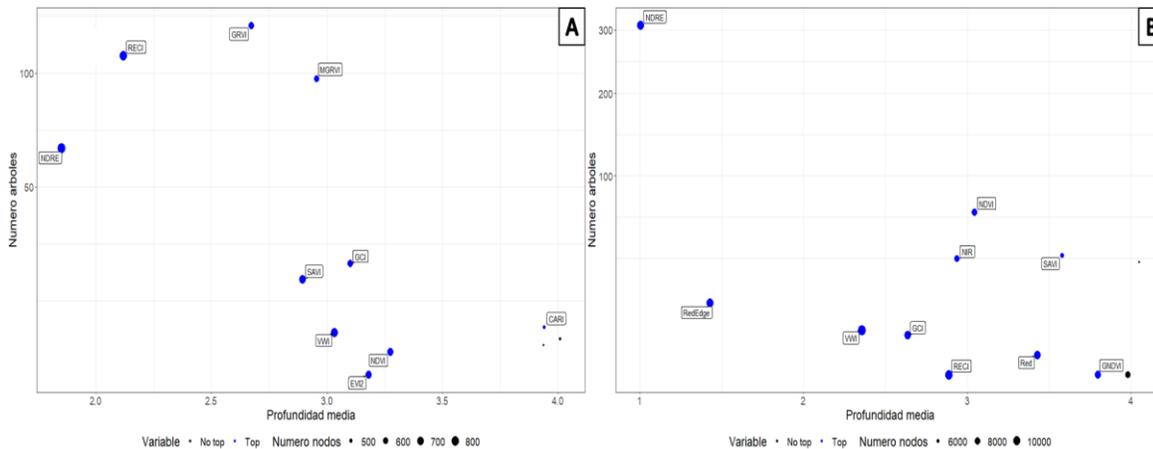


Figura 18. Índices espectrales informativos respecto a clasificación de plantas de papa Var. Diacol Capiro sanas y con síntomas de madurez temprana con el algoritmo BA. **A.** Índices a partir de bandas espectrales. **B.** Índices a partir de imágenes multiespectrales.

2.5 Discusión

En este estudio, se compararon diversos algoritmos para clasificar plantas de papa con diferentes grados de MT bajo dos condiciones (inoculación artificial y natural) utilizando firmas e imágenes espectrales. Con respecto a las firmas espectrales, todos los modelos se comportaron de manera similar en términos de exactitud, sin embargo, la tasa de clasificación de niveles bajos de severidad respecto a la escala usada (1 y 2) se vio afectada negativamente. A pesar de ello, se observa que los algoritmos usados en este estudio tienen enfoques de clasificación que son tan sensibles y específicos que logran clasificar las clases de la escala, lo cual muestra su potencial uso en la detección de patógenos en plantas. Con respecto a la clasificación de la presencia de MT, los algoritmos no presentaron diferencias, mostrando que, aunque sean enfoques distintos logran usar como discriminantes las variaciones espectrales presentadas por las plantas, convirtiéndolos en una herramienta para la identificación de bandas diferenciales entre plantas enfermas y sanas y variaciones en severidad. Estos métodos también mostraron tendencia a obtener las mismas áreas espectrales como variables de importancia en sus predicciones.

El uso de *GAP segment* como tratamiento previo de los datos de firmas espectrales puede mejorar los resultados al usar el método de discriminación PCA, ya que permite una mayor diferenciación de las áreas espectrales evaluadas (Kong et al., 2018; Wei et al., 2021), sin embargo, se recomienda el uso de métodos de selección de características múltiples o un conjunto de métodos múltiples sobre los datos espectrales debido a que las longitudes de onda seleccionadas son identificadas de manera individual, discriminando zonas con alto potencial de clasificación (Singh & Kaur, 2021; Wei et al., 2021), lo cual permite obtener mayores tasas de exactitud en los algoritmos.

Los algoritmos probados mostraron la capacidad de discriminar longitudes de onda similares respecto a la clasificación de presencia y severidad de la MT, las tasas de clasificación mayores al 80% también fueron reportadas por Shin et al., 2023 usando firmas espectrales de la región de 1596 a 2396 nm, las cuales fueron capturadas en plantas inoculadas con *Verticillium* spp. bajo condiciones de invernadero, lo cual muestra la consistencia de los resultados de esta investigación. Según la áreas espectrales identificadas, el aumento en la región del espectro visible (400 a 700 nm) en las plantas enfermas sugiere una disminución de pigmentos como la clorofila y los carotenoides en las hojas de papa (Marín-Ortiz et al., 2020); la reflectancia alrededor de 680 nm está controlada únicamente por la clorofila a (Gitelson & Merzlyak, 1996), área que tuvo comportamiento diferencial entre plantas con presencia de síntomas.

El aumento de la reflectancia de las hojas de plantas afectadas por MT en las bandas a partir de los 1500 nm principalmente en la clasificación de severidad muestra una posible afectación en el contenido de agua de las plantas evaluadas. Algunas bandas identificadas como importantes se encuentran ubicadas en la región relacionada con la estructura de la hoja (780 a 1450 nm), el contenido de agua y la acumulación de azúcares y almidón (>1500 nm) (Hong Li et al., 2021; Shin et al., 2023). Además, las longitudes de onda de 1660 nm y 2200 nm están asociadas con compuestos fenólicos que pueden acumularse en la célula como respuesta al ataque de patógenos (Junges et al., 2020; Shin et al., 2023).

Los índices relacionados con las regiones del rojo e infrarrojo cercano fueron los más importantes en la discriminación de plantas sanas y enfermas y niveles de severidad de MT. Dentro de estos, dos índices (NDRE y RECI) tienen en cuenta una banda del borde del rojo que se relaciona con la absorción de las clorofilas, por lo cual sus valores se ven más afectados por cambios en sus contenidos dentro de las plantas (Gitelson et al., 2003). Lo anterior se relaciona con los síntomas de clorosis encontrados en las hojas en las plantas afectadas por *Verticillium* spp. En este estudio se encontró que los valores medios de GRVI de plantas enfermas eran cercanos, lo cual se ha relacionado con el cambio en el verdor y la senescencia de las hojas (Motohka et al., 2010). Estos índices espectrales pueden utilizarse como una potencial herramienta para detectar el comienzo de los brotes de la enfermedad y guiar la aplicación de tácticas de gestión preventiva.

Las bandas identificadas han sido reportadas en diferentes cultivos destacándose papa (Gold, Townsend, Herrmann, et al., 2020; Gold, Townsend, Larson, et al., 2020), maní (Wei et al., 2021), tomate (Marín-Ortiz et al., 2020) y olivo (Rocío Calderón et al., 2015). Dichas bandas se relacionan con la disminución en los pigmentos como la clorofila y los carotenoides, el contenido de agua y la acumulación de azúcares. En el caso de MT, estos cambios espectrales pueden expresarse debido al taponamiento y daño vascular presentado, por lo que se recomienda tener en cuenta la biología del patógeno y el desarrollo de la enfermedad para la detección y diferenciación de las enfermedades de las plantas utilizando estrategias no invasivas (Gold, Townsend, Chlus, et al., 2020; Wei et al., 2021).

En comparación con patógenos foliares, los cuales tienen una interacción directa con las hojas de la planta, la infección de patógenos de suelo afectan primero la raíz o el sistema vascular de las plantas antes de inducir cualquier síntoma foliar (Wei et al., 2021), por lo cual los síntomas que se observan en la parte aérea son expresiones avanzadas de la enfermedad, limitando el alcance de las herramientas para la detección de la alteración en estados iniciales de infección en las plantas (León-Rueda et al., 2022; Lizarazo et al., 2023; Shin et al., 2023).

Los futuros estudios que pretendan detectar enfermedades de las plantas y dentro de estas las causadas por patógenos vasculares como MT durante las primeras etapas de la infección pueden incorporar algunas evaluaciones cualitativas o cuantitativas del desarrollo de la enfermedad, las cuales sean indicativas de la infección en estados iniciales sobre las plantas evaluadas (Shin et al., 2023). Además de esto, se recomienda el uso de las bandas espectrales reportadas en este trabajo, ya que pueden complementar los resultados de otras investigaciones como lo reportado por Shin et al., 2023, obteniendo modelos con mayor robustez en la detección del patógeno.

2.6 Conclusiones

Este estudio demuestra la capacidad y el potencial de los datos espectrales en la detección de plantas de papa infectadas con MT causada por *Verticillium* spp. en varias etapas de desarrollo de la enfermedad. Lo anterior permite considerarlos como una herramienta útil en la implementación de prácticas de gestión integrada de manejo de MT en cultivos de papa. La identificación de longitudes de onda óptimas utilizando métodos de selección de características basados en AA como BA, MVS y RNA fue posible, generando una metodología de análisis para futuras investigaciones relacionadas con enfermedades vasculares en diferentes sistemas productivos. Las longitudes de onda e índices espectrales como RECI, NDRE, VWI y GRVI identificados en este estudio pueden convertirse en insumo para el desarrollo de métodos de detección basados en el uso de sensores aplicados a la MT en el cultivo de papa.

2.7 Bibliografía

- Aasen, H., Honkavaara, E., Lucieer, A., & Zarco-Tejada, P. J. (2018). Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: A review of sensor technology, measurement procedures, and data correction workflows. In *Remote Sensing* (Vol. 10, Issue 7, p. 1091). Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/rs10071091>
- Abdulridha, J., Ampatzidis, Y., Kakarla, S. C., & Roberts, P. (2020). Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. *Precision Agriculture*, 21(5), 955–978. <https://doi.org/10.1007/s11119-019-09703-4>
- Aggarwal, N., Srivastava, M., & Dutta, M. (2016). Comparative Analysis of Pixel-Based and Object-Based Classification of High Resolution Remote Sensing Images – A

- Review. *International Journal of Engineering Trends and Technology*, 38(1), 5–11. <https://doi.org/10.14445/22315381/ijett-v38p202>
- Agilandeewari, L., Prabukumar, M., Radhesyam, V., Phaneendra, K. L. N. B., & Farhan, A. (2022). Crop Classification for Agricultural Applications in Hyperspectral Remote Sensing Images. *Applied Sciences*, 12(3). <https://doi.org/10.3390/app12031670>
- Agronet. (2018). *Agronet*. <http://www.agronet.gov.co/estadistica/Paginas/default.aspx>
- Al-Saddik, H., Simon, J. C., & Cointault, F. (2017). Development of spectral disease indices for 'flavescence dorée' grapevine disease identification. *Sensors (Switzerland)*, 17(12). <https://doi.org/10.3390/s17122772>
- AlAfandy, K. A., Omara, H., Lazaar, M., & Al Achhab, M. (2019, October 23). Artificial neural networks optimization and convolution neural networks to classifying images in remote sensing: A review. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3372938.3372945>
- Albetis, J., Jacquin, A., Goulard, M., Poilvé, H., Rousseau, J., Clenet, H., Dedieu, G., & Duthoit, S. (2019). On the potentiality of UAV multispectral imagery to detect Flavescence dorée and Grapevine Trunk Diseases. *Remote Sensing*, 11(1). <https://doi.org/10.3390/rs11010023>
- Ali, M. M., Bachik, N. A., Muhadi, N., 'Atirah, Tuan Yusof, T. N., & Gomes, C. (2019). Non-destructive techniques of detecting plant diseases: A review. In *Physiological and Molecular Plant Pathology* (Vol. 108). Academic Press. <https://doi.org/10.1016/j.pmpp.2019.101426>
- Antunes, E., Vuppaladadiyam, A. K., Sarmah, A. K., Varsha, S. S. V., Pant, K. K., Tiwari, B., & Pandey, A. (2021). Application of biochar for emerging contaminant mitigation. In *Advances in Chemical Pollution, Environmental Management and Protection* (Vol. 7, pp. 65–91). Elsevier. <https://doi.org/10.1016/bs.apmp.2021.08.003>
- Arneson, P. A. (2001). Plant Disease Epidemiology. *The Plant Health Instructor*, <https://www.apsnet.org/edcenter/disimpactmngmnt/to>. <https://doi.org/10.1094/PHI-A-2001-0524-01>
- Ashourloo, D., Aghighi, H., Matkan, A. A., Mobasheri, M. R., & Rad, A. M. (2016). An Investigation Into Machine Learning Regression Techniques for the Leaf Rust Disease Detection Using Hyperspectral Measurement. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(9), 4344–4351. <https://doi.org/10.1109/JSTARS.2016.2575360>
- Ashraf, A., Rauf, A., Fahim Abbas, M., & Rehman, R. (2012). ISOLATION AND IDENTIFICATION OF VERTICILLIUM DAHLIAE CAUSING WILT ON POTATO IN PAKISTAN. *J. Phytopathol*, 24(2), 112–116.
- Baldi, P., & La Porta, N. (2020). Molecular Approaches for Low-Cost Point-of-Care Pathogen Detection in Agriculture and Forestry. In *Frontiers in Plant Science* (Vol. 11). Frontiers Media SA. <https://doi.org/10.3389/fpls.2020.570862>
- Barbedo, J. G. A. (2019). A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses. *Drones*, 3(2), 1–27. <https://doi.org/10.3390/drones3020040>
- Behmann, J., Mahlein, A. K., Rumpf, T., Römer, C., & Plümer, L. (2015). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. In *Precision Agriculture*. <https://doi.org/10.1007/s11119-014-9372-7>
- Bekkar, M., Djemaa, H. K., & Alitouche, T. A. (2013). Evaluation Measures for Models Assessment over Imbalanced Data Sets. *Journal of Information Engineering and Applications*.
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications

- and future directions. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Blekos, K., Tsakas, A., Xouris, C., Evdokidis, I., Alexandropoulos, D., Alexakos, C., Katakis, S., Makedonas, A., Theoharatos, C., & Lalos, A. (2021). Analysis, Modeling and Multi-Spectral Sensing for the Predictive Management of Verticillium Wilt in Olive Groves. *Journal of Sensor and Actuator Networks*, 10(1), 15. <https://doi.org/10.3390/jsan10010015>
- Bock, C. H., Poole, G. H., Parker, P. E., & Gottwald, T. R. (2010). Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Critical Reviews in Plant Sciences*, 29(2), 59–107. <https://doi.org/10.1080/07352681003617285>
- Brodersen, K. H., Ong, C. S., Stephan, K. E., & Buhmann, J. M. (2010). The balanced accuracy and its posterior distribution. *Proceedings - International Conference on Pattern Recognition*. <https://doi.org/10.1109/ICPR.2010.764>
- Buja, I., Sabella, E., Monteduro, A. G., Chiriaco, M. S., De Bellis, L., Luvisi, A., & Maruccio, G. (2021). Advances in Plant Disease Detection and Monitoring: From Traditional Assays to In-Field Diagnostics. *Sensors (Basel, Switzerland)*, 21(6), 1–22. <https://doi.org/10.3390/S21062129>
- Buriticá, P. (1999). *Directorio de patógenos y enfermedades de las plantas de importancia económica en Colombia*. <http://www.buritica-antioquia.gov.co/presentacion.shtml>
- Calderón, R., Montes-Borrego, M., Landa, B. B., Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2014). Detection of downy mildew of opium poppy using high-resolution multi-spectral and thermal imagery acquired with an unmanned aerial vehicle. *Precision Agriculture*, 15(6), 639–661. <https://doi.org/10.1007/s11119-014-9360-y>
- Calderón, Rocio, Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2015). Early detection and quantification of verticillium wilt in olive using hyperspectral and thermal imagery over large areas. *Remote Sensing*. <https://doi.org/10.3390/rs70505584>
- Campbell, J. B., & Wynne, R. H. (2011). Introduction to Remote Sensing FIFTH EDITION. In *Uma ética para quantos?* <https://doi.org/10.1007/s13398-014-0173-7.2>
- Cockerton, H. M., Li, B., Vickerstaff, R. J., Eyre, C. A., Sargent, D. J., Armitage, A. D., Marina-Montes, C., Garcia-Cruz, A., Passey, A. J., Simpson, D. W., & Harrison, R. J. (2019). Identifying Verticillium dahliae resistance in strawberry through disease screening of multiple populations and image based phenotyping. *Frontiers in Plant Science*. <https://doi.org/10.3389/fpls.2019.00924>
- Cortes, C., & Mohri, M. (2004). AUC optimization vs. Error rate minimization. *Advances in Neural Information Processing Systems*.
- Couture, J. J., Singh, A., Charkowski, A. O., Groves, R. L., Gray, S. M., Bethke, P. C., & Townsend, P. A. (2018). Integrating Spectroscopy with Potato Disease Management. *Plant Disease*, 102(11), 2233–2240. <https://doi.org/10.1094/pdis-01-18-0054-re>
- Dash, J. P., Watt, M. S., Pearse, G. D., Heaphy, M., & Dungey, H. S. (2017). Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 1–14. <https://doi.org/10.1016/j.isprsjprs.2017.07.007>
- Duarte-Carvajalino, J. M., Alzate, D. F., Ramirez, A. A., Santa-Sepulveda, J. D., Fajardo-Rojas, A. E., & Soto-Suárez, M. (2018). Evaluating late blight severity in potato crops using unmanned aerial vehicles and machine learning algorithms. *Remote Sensing*. <https://doi.org/10.3390/rs10101513>
- Dung, J. K. S., Ingram, J. T., Cummings, T. F., & Johnson, D. A. (2012). Impact of seed lot infection on the development of black dot and verticillium wilt of potato in

- Washington. *Plant Disease*. <https://doi.org/10.1094/PDIS-01-12-0061-RE>
- El Hoummaidi, L., Larabi, A., & Alam, K. (2021). Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*, *7*(10). <https://doi.org/10.1016/j.heliyon.2021.e08154>
- Fang, Y., & Ramasamy, R. P. (2015). Current and prospective methods for plant disease detection. In *Biosensors*. <https://doi.org/10.3390/bios5030537>
- FAOSTAT. (2020). *FAOSTAT: Statistical database*. FAOSTAT: Statistical Database. <https://www.fao.org/faostat/es/#home>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Ferri, C., Hernández-Orallo, J., & Modroui, R. (2009). An experimental comparison of performance measures for classification. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2008.08.010>
- Friedman, J., Hastie, T., & Tibshirani, R. (2000). Additive logistic regression: A statistical view of boosting. *Annals of Statistics*, *28*(2), 337–407. <https://doi.org/10.1214/AOS/1016218223>
- Galieni, A., D'Ascenzo, N., Stagnari, F., Pagnani, G., Xie, Q., & Pisante, M. (2021). Past and Future of Plant Stress Detection: An Overview From Remote Sensing to Positron Emission Tomography. In *Frontiers in Plant Science* (Vol. 11, p. 1975). Frontiers Media S.A. <https://doi.org/10.3389/fpls.2020.609155>
- García-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2012.12.002>
- Gholami, R., & Fakhari, N. (2017). Support Vector Machine: Principles, Parameters, and Applications. In *Handbook of Neural Computation* (pp. 515–535). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-811318-9.00027-2>
- Gibson-Poole, S., Humphris, S., Toth, I., & Hamilton, A. (2017). Identification of the onset of disease within a potato crop using a UAV equipped with un-modified and modified commercial off-the-shelf digital cameras. *Advances in Animal Biosciences*, *8*(2), 812–816. <https://doi.org/10.1017/s204047001700084x>
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, *160*(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A., & Merzlyak, M. N. (1996). Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. *Journal of Plant Physiology*, *148*(3–4), 494–500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7)
- Gitelson, A. A., Merzlyak, M. N., & Chivkunova, O. B. (2001). Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. *Photochemistry and Photobiology*, *74*(1), 38. [https://doi.org/10.1562/0031-8655\(2001\)074<0038:opaneo>2.0.co;2](https://doi.org/10.1562/0031-8655(2001)074<0038:opaneo>2.0.co;2)
- Gold, K. M., Townsend, P. A., Chlus, A., Herrmann, I., Couture, J. J., Larson, E. R., & Gevens, A. J. (2020). Hyperspectral measurements enable pre-symptomatic detection and differentiation of contrasting physiological effects of late blight and early blight in potato. *Remote Sensing*, *12*(2), 286. <https://doi.org/10.3390/rs12020286>
- Gold, K. M., Townsend, P. A., Herrmann, I., & Gevens, A. J. (2020). Investigating potato late blight physiological differences across potato cultivars with spectroscopy and

- machine learning. *Plant Science*, 295, 110316. <https://doi.org/10.1016/j.plantsci.2019.110316>
- Gold, K. M., Townsend, P. A., Larson, E. R., Herrmann, I., & Gevens, A. J. (2020). Contact reflectance spectroscopy for rapid, accurate, and nondestructive phytophthora infestans clonal lineage discrimination. *Phytopathology*, 110(4), 851–862. <https://doi.org/10.1094/PHTO-08-19-0294-R>
- Görlich, F., Marks, E., Mahlein, A. K., König, K., Lottes, P., & Stachniss, C. (2021). Uav-based classification of cercospora leaf spot using rgb images. *Drones*, 5(2), 34. <https://doi.org/10.3390/drones5020034>
- Hamylton, S. M., Morris, R. H., Carvalho, R. C., Roder, N., Barlow, P., Mills, K., & Wang, L. (2020). Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation and machine learning approaches. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2020.102085>
- Hasmedi, I., Pakhriazad, H., & Shahrin, M. (2009). Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Geografia - Malaysian Journal of Society and Space*.
- Honkavaara, E., Saari, H., Kaivosoja, J., Pölönen, I., Hakala, T., Litkey, P., Mäkynen, J., & Pesonen, L. (2013). Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. *Remote Sensing*, 5(10), 5006–5039. <https://doi.org/10.3390/rs5105006>
- Hopkins, D. W. (2001). What is a Norris Derivative? *NIR News*, 12(3), 3–5. <https://doi.org/10.1255/nirn.611>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Hussain, T. (2016). Potatoes: Ensuring Food for the Future. *Advances in Plants & Agriculture Research*, 3(6). <https://doi.org/10.15406/apar.2016.03.00117>
- Imanian, K., Pourdarbani, R., Sabzi, S., García-Mateos, G., Arribas, J. I., & Molina-Martínez, J. M. (2021). Identification of internal defects in potato using spectroscopy and computational intelligence based on majority voting techniques. *Foods*, 10(5). <https://doi.org/10.3390/foods10050982>
- Jasiński, J., Pietrek, S., Walczykowski, P., & Orych, A. (2010). *Acquisition of spectral reflectance characteristics of land cover features based on hyperspectral images*. January.
- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112(10), 3833–3845. <https://doi.org/10.1016/j.rse.2008.06.006>
- Jing, R., Li, H., Hu, X., Shang, W., Shen, R., Guo, C., Guo, Q., & Subbarao, K. V. (2018). Verticillium wilt caused by verticillium dahliae and v. Nonalfalfae in potato in northern China. *Plant Disease*, 102(10), 1958–1964. <https://doi.org/10.1094/PDIS-01-18-0162-RE>
- Johnson, D. A., & Cummings, T. F. (2015). Effect of extended crop rotations on incidence of black dot, Silver scurf, and verticillium wilt of potato. *Plant Disease*, 99(2), 257–262. <https://doi.org/10.1094/PDIS-03-14-0271-RE>
- Johnson, D. A., Jeremiah, K., & Dung, S. (2010). Verticillium wilt of potato - The pathogen, disease and management. *Canadian Journal of Plant Pathology*. <https://doi.org/10.1080/07060661003621134>
- Junges, A. H., Almança, M. A. K., Fajardo, T. V. M., & Ducati, J. R. (2020). Leaf hyperspectral reflectance as a potential tool to detect diseases associated with vineyard decline. *Tropical Plant Pathology*, 45(5), 522–533.

- <https://doi.org/10.1007/s40858-020-00387-0>
- Kanti, M., Pradhan, R., & Sushan, S. (2010). Decision Tree Classification of Remotely Sensed Satellite Data using Spectral Separability Matrix. *International Journal of Advanced Computer Science and Applications*.
<https://doi.org/10.14569/ijacsa.2010.010516>
- Klosterman, S. J., Atallah, Z. K., Vallad, G. E., & Subbarao, K. V. (2009). Diversity, pathogenicity, and management of verticillium species. *Annual Review of Phytopathology*, 47, 39–62. <https://doi.org/10.1146/annurev-phyto-080508-081748>
- Kollist, H., Zandalinas, S. I., Sengupta, S., Nuhkat, M., Kangasjärvi, J., & Mittler, R. (2019). Rapid Responses to Abiotic Stress: Priming the Landscape for the Signal Transduction Network. In *Trends in Plant Science* (Vol. 24, Issue 1, pp. 25–37). Elsevier Ltd. <https://doi.org/10.1016/j.tplants.2018.10.003>
- Kong, W., Zhang, C., Huang, W., Liu, F., & He, Y. (2018). Application of hyperspectral imaging to detect *Sclerotinia sclerotiorum* on oilseed rape stems. *Sensors (Switzerland)*, 18(1). <https://doi.org/10.3390/s18010123>
- Kuang, B., Mahmood, H. S., Quraishi, M. Z., Hoogmoed, W. B., Mouazen, A. M., & van Henten, E. J. (2012). Sensing soil properties in the laboratory, in situ, and on-line. A review. In *Advances in Agronomy* (1st ed., Vol. 114, Issue October 2017). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-394275-3.00003-1>
- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>
- Kuska, M. T., & Mahlein, A. K. (2018). Aiming at decision making in plant disease protection and phenotyping by the use of optical sensors. *European Journal of Plant Pathology*, 152(4), 987–992. <https://doi.org/10.1007/s10658-018-1464-1>
- Larkin, R. P., Honeycutt, C. W., & Olanya, O. M. (2011). Management of Verticillium Wilt of Potato with Disease-Suppressive Green Manures and as Affected by Previous Cropping History. *Plant Disease*. <https://doi.org/10.1094/pdis-09-10-0670>
- Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3–10. <https://doi.org/10.1016/j.gsf.2015.07.003>
- Lê, S., Josse, J., & Husson, F. (2008). FactoMineR: An R package for multivariate analysis. *Journal of Statistical Software*, 25(1), 1–18. <https://doi.org/10.18637/jss.v025.i01>
- León-Rueda, W. A., León, C., Caro, S. G., & Ramírez-Gil, J. G. (2022). Identification of diseases and physiological disorders in potato via multispectral drone imagery using machine learning tools. *Tropical Plant Pathology*, 47(1), 152–167. <https://doi.org/10.1007/s40858-021-00460-2>
- Li, Haiyuan, Wang, Z., Hu, X., Shang, W., Shen, R., Guo, C., Guo, Q., & Subbarao, K. V. (2019). Assessment of resistance in potato cultivars to verticillium wilt caused by verticillium dahliae and verticillium nonalfalfae. *Plant Disease*, 103(6), 1357–1362. <https://doi.org/10.1094/PDIS-10-18-1815-RE>
- Li, Hong, Yang, W., Lei, J., She, J., & Zhou, X. (2021). Estimation of leaf water content from hyperspectral data of different plant species by using three new spectral absorption indices. *PLoS ONE*, 16(3 March). <https://doi.org/10.1371/journal.pone.0249351>
- Li, M., Zang, S., Zhang, B., Li, S., & Wu, C. (2014). A review of remote sensing image classification techniques: The role of Spatio-contextual information. *European Journal of Remote Sensing*, 47(1), 389–411. <https://doi.org/10.5721/EuJRS20144723>

- Liao, P. S., Chen, T. S., & Chung, P. C. (2001). A fast algorithm for multilevel thresholding. *Journal of Information Science and Engineering*, 17(5), 713–727.
- Lillesand, T. M., & Kiefer, R. W. (2004). Remote sensing and image interpretation. In *Remote sensing and image interpretation*. <https://doi.org/10.2307/634969>
- Liu, C., Sun, P. Sen, & Liu, S. R. (2016). A review of plant spectral reflectance response to water physiological changes. *Chinese Journal of Plant Ecology*, 40(1), 80–91. <https://doi.org/10.17521/cjpe.2015.0267>
- Liu, L., Dong, Y., Huang, W., Du, X., Ren, B., Huang, L., Zheng, Q., & Ma, H. (2020). A Disease Index for Efficiently Detecting Wheat Fusarium Head Blight Using Sentinel-2 Multispectral Imagery. *IEEE Access*, 8, 52181–52191. <https://doi.org/10.1109/ACCESS.2020.2980310>
- Liu, X. (2003). Supervised Classification and Unsupervised Classification. *Cfa.Harvard.Edu*.
- Lizarazo, I., Rodriguez, J. L., Cristancho, O., Olaya, F., Duarte, M., & Prieto, F. (2023). Identification of symptoms related to potato Verticillium wilt from UAV-based multispectral imagery using an ensemble of gradient boosting machines. *Smart Agricultural Technology*, 3, 100138. <https://doi.org/https://doi.org/10.1016/j.atech.2022.100138>
- Lizarazo Peña, P. A. (2020). Desarrollo , crecimiento y rendimiento de cultivares de papa diploide en ambientes contrastantes por altitud. In *Universidad Nacional de Colombia*. <https://repositorio.unal.edu.co/bitstream/handle/unal/78234/1022359762.2020.pdf?ssequence=1&isAllowed=y>
- Lowe, A., Harrison, N., & French, A. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. In *Plant Methods*. <https://doi.org/10.1186/s13007-017-0233-z>
- Lowe, B., & Kulkarni, A. (2015). Multispectral Image Analysis Using Random Forest. *International Journal on Soft Computing*. <https://doi.org/10.5121/ijsc.2015.6101>
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. In *International Journal of Remote Sensing*. <https://doi.org/10.1080/01431160600746456>
- Lu, J., Ehsani, R., Shi, Y., de Castro, A. I., & Wang, S. (2018). Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Scientific Reports*, 8(1), 1–11. <https://doi.org/10.1038/s41598-018-21191-6>
- Lu, N., Zhou, J., Han, Z., Li, D., Cao, Q., Yao, X., Tian, Y., Zhu, Y., Cao, W., & Cheng, T. (2019). Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. *Plant Methods*, 15(1), 17. <https://doi.org/10.1186/s13007-019-0402-3>
- Mahlein, A. K. (2016). Plant disease detection by imaging sensors – Parallels and specific demands for precision agriculture and plant phenotyping. In *Plant Disease* (Vol. 100, Issue 2, pp. 241–254). <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Mahlein, A. K., Kuska, M. T., Thomas, S., Bohnenkamp, D., Alisaac, E., Behmann, J., Wahabzada, M., & Kersting, K. (2017). Plant disease detection by hyperspectral imaging: from the lab to the field. *Advances in Animal Biosciences*. <https://doi.org/10.1017/s2040470017001248>
- Mahlein, A. K., Oerke, E. C., Steiner, U., & Dehne, H. W. (2012). Recent advances in sensing plant diseases for precision crop protection. In *European Journal of Plant Pathology*. <https://doi.org/10.1007/s10658-011-9878-z>
- Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., & Oerke, E.

- C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21–30. <https://doi.org/10.1016/j.rse.2012.09.019>
- Manici, L. M., & Cerato, C. (1994). Pathogenicity of *Fusarium oxysporum* f.sp. *tuberosi* isolates from tubers and potato plants. *Potato Research*, 37(2), 129–134. <https://doi.org/10.1007/BF02358713>
- Marín-Ortiz, J. C., Gutierrez-Toro, N., Botero-Fernández, V., & Hoyos-Carvajal, L. M. (2020). Linking physiological parameters with visible/near-infrared leaf reflectance in the incubation period of vascular wilt disease. *Saudi Journal of Biological Sciences*, 27(1), 88. <https://doi.org/10.1016/J.SJBS.2019.05.007>
- Mauromicale, G., Ierna, A., & Marchese, M. (2006). Chlorophyll fluorescence and chlorophyll content in field-grown potato as affected by nitrogen supply, genotype, and plant age. *Photosynthetica*, 44(1), 76–82. <https://doi.org/10.1007/S11099-005-0161-4>
- Meng, R., Lv, Z., Yan, J., Chen, G., Zhao, F., Zeng, L., & Xu, B. (2020). Development of spectral disease indices for southern corn rust detection and severity classification. *Remote Sensing*, 12(19), 1–16. <https://doi.org/10.3390/rs12193233>
- Mishra, P., Polder, G., & Vilfan, N. (2020). Close Range Spectral Imaging for Disease Detection in Plants Using Autonomous Platforms: a Review on Recent Studies. *Current Robotics Reports*, 1(2), 43–48. <https://doi.org/10.1007/s43154-020-00004-7>
- Mohapatra, S. K., & Mohanty, M. N. (2022). Big data classification with IoT-based application for e-health care. *Cognitive Big Data Intelligence with a Metaheuristic Approach*, 147–172. <https://doi.org/10.1016/B978-0-323-85117-6.00014-5>
- Mohseni-Dargah, M., Falahati, Z., Dabirmanesh, B., Nasrollahi, P., & Khajeh, K. (2022). Machine learning in surface plasmon resonance for environmental monitoring. In *Artificial Intelligence and Data Science in Environmental Sensing* (pp. 269–298). Academic Press. <https://doi.org/10.1016/B978-0-323-90508-4.00012-5>
- Mosley, L. S. D. (2013). A balanced approach to the multi-class imbalance problem. In *ProQuest Dissertations and Theses*.
- Motohka, T., Nasahara, K. N., Oguma, H., & Tsuchida, S. (2010). Applicability of Green-Red Vegetation Index for remote sensing of vegetation phenology. *Remote Sensing*, 2(10), 2369–2387. <https://doi.org/10.3390/rs2102369>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Müller, A. C., & Guido, S. (2016). Introduction to Machine Learning with Python: a guide for data scientists. In *Journal of Chemical Information and Modeling*. <https://doi.org/10.1017/CBO9781107415324.004>
- Mundt, C. C. (2019). The Study of Plant Disease Epidemics. *HortScience*, 44(7), 2065b – 2065. <https://doi.org/10.21273/hortsci.44.7.2065b>
- Neupane, K., & Baysal-Gurel, F. (2021). Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review. In *Remote Sensing* (Vol. 13, Issue 19, p. 3841). Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/rs13193841>
- Nieto, L. E. (1988). La Madurez Prematura de la Papa Causada por *Verticillium* spp. en Colombia. *Revista ICA*, 4, 334–340.
- Ning, F., Delhomme, D., LeCun, Y., Piano, F., Bottou, L., & Barbanò, P. E. (2005). Toward automatic phenotyping of developing embryos from videos. *IEEE Transactions on Image Processing*. <https://doi.org/10.1109/TIP.2005.852470>

- Oerke, E. C. (2020). Remote Sensing of Diseases. *Annual Review of Phytopathology*, 58, 225–252. <https://doi.org/10.1146/annurev-phyto-010820-012832>
- Oerke, E. C., Mahlein, A. K., & Steiner, U. (2014). Proximal sensing of plant diseases. In *Detection and Diagnostics of Plant Pathogens* (pp. 55–68). Springer Netherlands. https://doi.org/10.1007/978-94-017-9020-8_4
- Pandala, S. R. (2022). *lazypredict*. Python Software Foundation. <https://pypi.org/project/lazypredict/>
- Patrick, A., Pelham, S., Culbreath, A., Corely Holbrook, C., De Godoy, I. J., & Li, C. (2017). High throughput phenotyping of tomato spot wilt disease in peanuts using unmanned aerial systems and multispectral imaging. *IEEE Instrumentation and Measurement Magazine*, 20(3), 4–12. <https://doi.org/10.1109/MIM.2017.7951684>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(85), 2825–2830. <http://jmlr.org/papers/v12/pedregosa11a.html>
- Pourazar, H., Samadzadegan, F., Dadrass Javan, F., Giacomo, R., David, G., Gilbertson, J. K., Forum, P. O., Bouroubi, Y., Bugnet, P., Nguyen-xuan, T., Gosselin, C., Bélec, C., Longchamps, L., Vigneault, P., Ji, S., Zhang, C., Xu, A., Shi, Y., Duan, Y., ... Gore, M. A. (2017). Pest Detection on UAV Imagery using a Deep Convolutional Neural Network. *Remote Sensing*, 52(19), 17–31. <https://doi.org/10.3390/rs11192209>
- Powelson, M. L., & Rowe, R. C. (1993). Biology and management of early dying of potatoes. In *Annual Review of Phytopathology* (Vol. 31, pp. 111–126). Annual Reviews Inc. <https://doi.org/10.1146/annurev.py.31.090193.000551>
- Puletti, N., Perria, R., & Storchi, P. (2014). Unsupervised classification of very high remotely sensed images for grapevine rows detection. *European Journal of Remote Sensing*, 47(1), 45–54. <https://doi.org/10.5721/EuJRS20144704>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Rahman, H. ur, Jabbar Ch, N., Manzoor, S., Najeeb, F., Siddique, M. Y., & Khan, R. A. (2017). A comparative analysis of machine learning approaches for plant disease identification. *Advancements in Life Sciences*, 4(4), 120–126.
- Ramegowda, V., & Senthil-Kumar, M. (2015). The interactive effects of simultaneous biotic and abiotic stresses on plants: Mechanistic understanding from drought and pathogen combination. In *Journal of Plant Physiology* (Vol. 176, pp. 47–54). Urban und Fischer Verlag GmbH und Co. KG. <https://doi.org/10.1016/j.jplph.2014.11.008>
- Ramesh Reddy, D., Naga Santhosh, K., & Kodali, P. (2022). Convolutional Neural Networks for the Intuitive Identification of Plant Diseases. *5th International Conference on Inventive Computation Technologies, ICICT 2022 - Proceedings*, 10, 941. <https://doi.org/10.1109/ICICT54344.2022.9850695>
- Ramirez-Gil, J., Navas, J., & Gómez, S. (2019). Epidemiología e importancia económica de una alteración de origen desconocido en papa en la sabana occidente de Cundinamarca. *XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS*, 205–205.
- Ramirez Gil, J., Garcia, C., Navas, J., Leon, J., & Gómez, S. (2019). Implicaciones epidemiológicas y económicas de *Verticillium* sp., en una región productora de papa en Cundinamarca. *XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS*, 206–207.

- Raymundo, R., Asseng, S., Prasad, R., Kleinwechter, U., Concha, J., Condori, B., Bowen, W., Wolf, J., Olesen, J. E., Dong, Q., Zotarelli, L., Gastelo, M., Alva, A., Travasso, M., Quiroz, R., Arora, V., Graham, W., & Porter, C. (2017). Performance of the SUBSTOR-potato model across contrasting growing conditions. *Field Crops Research*, 202, 57–76. <https://doi.org/10.1016/j.fcr.2016.04.012>
- Ren, Y., Zhang, L., & Suganthan, P. N. (2016). Ensemble Classification and Regression-Recent Developments, Applications and Future Directions [Review Article]. In *IEEE Computational Intelligence Magazine* (Vol. 11, Issue 1, pp. 41–53). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/MCI.2015.2471235>
- Rodríguez, J., Lizarazo, I., Prieto, F., & Angulo-Morales, V. (2021). Assessment of potato late blight from UAV-based multispectral imagery. *Computers and Electronics in Agriculture*, 184, 106061. <https://doi.org/10.1016/j.compag.2021.106061>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS proceeding. *Third Earth Reserves Technology Satellite Symposium, Greenbelt: NASA SP-351, 30103017*, 317. <https://ui.adsabs.harvard.edu/abs/1974NASSP.351..309R/abstract>
- Rowe, R. C., & Powelson, M. L. (2002). Potato early dying: Management challenges in a changing production environment. In *Plant Disease* (Vol. 86, Issue 11, pp. 1184–1193). The American Phytopathological Society. <https://doi.org/10.1094/PDIS.2002.86.11.1184>
- Salamí, E., Barrado, C., & Pastor, E. (2014). UAV flight experiments applied to the remote sensing of vegetated areas. In *Remote Sensing* (Vol. 6, Issue 11, pp. 11051–11081). MDPI AG. <https://doi.org/10.3390/rs61111051>
- Sami, K., KC, K., John, F., Scott, S., & Erdal, O. (2020). Remote Sensing in Agriculture (Challenges and Opportunities). *Remote Sensing*, 10, 83–87.
- Sarić, R., Nguyen, V. D., Burge, T., Berkowitz, O., Trtílek, M., Whelan, J., Lewsey, M. G., & Čustović, E. (2022). Applications of hyperspectral imaging in plant phenotyping. In *Trends in Plant Science* (Vol. 27, Issue 3, pp. 301–315). Elsevier Current Trends. <https://doi.org/10.1016/j.tplants.2021.12.003>
- Sarkar, S. K., Das, J., Ehsani, R., & Kumar, V. (2016). Towards autonomous phytopathology: Outcomes and challenges of citrus greening disease detection through close-range remote sensing. *Proceedings - IEEE International Conference on Robotics and Automation, 2016-June*, 5143–5148. <https://doi.org/10.1109/ICRA.2016.7487719>
- Savitzky, A., & Golay, M. J. E. (1964). Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*, 36(8), 1627–1639. <https://doi.org/10.1021/ac60214a047>
- Seetha, M., Muralikrishna, Deekshatulu, B. L., Malleswari, B. L., Nagaratna, & Hegde, P. (2008). Artificial Neural Networks and Other Methods of Image Classification. *Theoretical and Applied Information Technology*.
- Segarra, J., Buchailot, M. L., Araus, J. L., & Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5), 1–18. <https://doi.org/10.3390/agronomy10050641>
- Shammi, S., Sohel, F., Diepeveen, D., Zander, S., & Jones, M. G. K. (2022). A survey of image-based computational learning techniques for frost detection in plants. In *Information Processing in Agriculture*. Elsevier. <https://doi.org/10.1016/j.inpa.2022.02.003>
- Shattock, R. (2002). Compendium of Potato Diseases, Second Edition. W.R. Stevenson. *Plant Pathology*, 51(4), 520–520. <https://doi.org/10.1046/j.1365-3059.2002.06934.x>

- Shi, Y., Han, L., Kleerekoper, A., Chang, S., & Hu, T. (2022). Novel CropdocNet Model for Automated Potato Late Blight Disease Detection from Unmanned Aerial Vehicle-Based Hyperspectral Imagery. *Remote Sensing*, *14*(2), 396. <https://doi.org/10.3390/rs14020396>
- Shin, M. Y., Gonzalez Viejo, C., Tongson, E., Wiechel, T., Taylor, P. W. J., & Fuentes, S. (2023). Early detection of Verticillium wilt of potatoes using near-infrared spectroscopy and machine learning modeling. *Computers and Electronics in Agriculture*, *204*, 107567. <https://doi.org/10.1016/J.COMPAG.2022.107567>
- Shruthi, U., Nagaveni, V., & Raghavendra, B. K. (2019). A Review on Machine Learning Classification Techniques for Plant Disease Detection. *2019 5th International Conference on Advanced Computing and Communication Systems, ICACCS 2019*, 281–284. <https://doi.org/10.1109/ICACCS.2019.8728415>
- Simko, I., & Piepho, H. P. (2012). The area under the disease progress stairs: Calculation, advantage, and application. *Phytopathology*, *102*(4), 381–389. <https://doi.org/10.1094/PHYTO-07-11-0216>
- Singh, A., & Kaur, H. (2021). Potato plant leaves disease detection and classification using machine learning methodologies. *IOP Conference Series: Materials Science and Engineering*, *1022*(1). <https://doi.org/10.1088/1757-899X/1022/1/012121>
- Singh, V., Sharma, N., & Singh, S. (2020). A review of imaging techniques for plant disease detection. In *Artificial Intelligence in Agriculture* (Vol. 4, pp. 229–242). KeAi Communications Co. <https://doi.org/10.1016/j.aiaa.2020.10.002>
- Stehman, S. V., & Foody, G. M. (2008). Accuracy Assessment. In *The SAGE Handbook of Remote Sensing*. <https://doi.org/10.4135/9780857021052.n21>
- Stevens, A., & Ramirez Lopez, L. (2014). An introduction to the prospectr package. In *R Package Vignette, Report No.: R Package Version 0.1* (Vol. 3, Issue August 2013, pp. 1–22). <https://cran.r-project.org/web/packages/prospectr/vignettes/prospectr.html>
- Stevenson, W., Loria, R., Franc, G., & Weingartner, D. (2001). Compendium of Potato Diseases, Second Edition. *Phytopathological Society*. <https://doi.org/10.1046/j.1365-3059.2002.06934.x>
- Su, J., Yi, D., Coombes, M., Liu, C., Zhai, X., McDonald-Maier, K., & Chen, W. H. (2022). Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. *Computers and Electronics in Agriculture*, *192*. <https://doi.org/10.1016/j.compag.2021.106621>
- Sugiura, R., Tsuda, S., Tamiya, S., Itoh, A., Nishiwaki, K., Murakami, N., Shibuya, Y., Hirafuji, M., & Nuske, S. (2016). Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering*. <https://doi.org/10.1016/j.biosystemseng.2016.04.010>
- Sun, W., & Du, Q. (2019). Hyperspectral band selection: A review. In *IEEE Geoscience and Remote Sensing Magazine* (Vol. 7, Issue 2, pp. 118–139). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/MGRS.2019.2911100>
- Suzuki, N., Rivero, R. M., Shulaev, V., Blumwald, E., & Mittler, R. (2014). Abiotic and biotic stress combinations. *New Phytologist*, *203*(1), 32–43. <https://doi.org/10.1111/nph.12797>
- Tetila, E. C., Brandoli Machado, B., Belete, N. A. D. S., Guimaraes, D. A., & Pistori, H. (2017). Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. *IEEE Geoscience and Remote Sensing Letters*. <https://doi.org/10.1109/LGRS.2017.2743715>
- Thai, L. H., Hai, T. S., & Thuy, N. T. (2012). Image Classification using Support Vector Machine and Artificial Neural Network. *International Journal of Information Technology and Computer Science*. <https://doi.org/10.5815/ijitcs.2012.05.05>

- Tripathi, K., Vyas, R. G., & Gupta, A. K. (2019). Document Classification Using Artificial Neural Network. *Asian Journal of Computer Science and Technology*, 8(2), 55–58.
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. *Information (Switzerland)*, 10(11). <https://doi.org/10.3390/info10110349>
- van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., Yu, T., & the scikit-image contributors. (2014). scikit-image: image processing in Python. *PeerJ*, 2, e453. <https://doi.org/10.7717/peerj.453>
- Vishnoi, V. K., Kumar, K., & Kumar, B. (2021). Plant disease detection using computational intelligence and image processing. In *Journal of Plant Diseases and Protection* (Vol. 128, Issue 1, pp. 19–53). Springer. <https://doi.org/10.1007/s41348-020-00368-0>
- Wan, L., Li, Y., Cen, H., Zhu, J., Yin, W., Wu, W., Zhu, H., Sun, D., Zhou, W., & He, Y. (2018). Combining UAV-based vegetation indices and image classification to estimate flower number in oilseed rape. *Remote Sensing*, 10(9), 1484. <https://doi.org/10.3390/rs10091484>
- Wang, C. ling, Shen, S. he, Zhang, S. yu, Li, Q. zhen, & Yao, Y. bi. (2015). Adaptation of potato production to climate change by optimizing sowing date in the Loess Plateau of central Gansu, China. *Journal of Integrative Agriculture*, 14(2), 398–409. [https://doi.org/10.1016/S2095-3119\(14\)60783-8](https://doi.org/10.1016/S2095-3119(14)60783-8)
- Wang, J., Lu, S., Wang, S. H., & Zhang, Y. D. (2021). A review on extreme learning machine. *Multimedia Tools and Applications*, 1–50. <https://doi.org/10.1007/s11042-021-11007-7>
- Wei, X., Johnson, M. A., Langston, D. B., Mehl, H. L., & Li, S. (2021). Identifying optimal wavelengths as disease signatures using hyperspectral sensor and machine learning. *Remote Sensing*, 13(14), 2833. <https://doi.org/10.3390/rs13142833>
- Xu, M., Watanachaturaporn, P., Varshney, P. K., & Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322–336. <https://doi.org/10.1016/j.rse.2005.05.008>
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. In *Journal of Sensors*. Hindawi Limited. <https://doi.org/10.1155/2017/1353691>
- Yan, Z., Ma, L., He, W., Zhou, L., Lu, H., Liu, G., & Huang, G. (2022). Comparing Object-Based and Pixel-Based Methods for Local Climate Zones Mapping with Multi-Source Data. *Remote Sensing*, 14(15). <https://doi.org/10.3390/rs14153744>
- Yang, C. M., Cheng, C. H., & Chen, R. K. (2007). Changes in spectral characteristics of rice canopy infested with brown planthopper and leafhopper. *Crop Science*. <https://doi.org/10.2135/cropsci2006.05.0335>
- Yeom, J., Jung, J., Chang, A., Ashapure, A., Maeda, M., Maeda, A., & Landivar, J. (2019). Comparison of vegetation indices derived from UAV data for differentiation of tillage effects in agriculture. *Remote Sensing*, 11(13). <https://doi.org/10.3390/rs11131548>
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. In *Precision Agriculture* (Vol. 13, Issue 6, pp. 693–712). Springer. <https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, H., Xu, F., Wu, Y., Hu, H. hai, & Dai, X. feng. (2017). Progress of potato staple food research and industry development in China. In *Journal of Integrative Agriculture* (Vol. 16, Issue 12, pp. 2924–2932). Elsevier. [https://doi.org/10.1016/S2095-3119\(17\)61736-2](https://doi.org/10.1016/S2095-3119(17)61736-2)

- Zheng, H., Li, W., Jiang, J., Liu, Y., Cheng, T., Tian, Y., Zhu, Y., Cao, W., Zhang, Y., & Yao, X. (2018). A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, *10*(12).
<https://doi.org/10.3390/rs10122026>
- Zhou, X., Huang, W., Zhang, J., Kong, W., Casa, R., & Huang, Y. (2019). A novel combined spectral index for estimating the ratio of carotenoid to chlorophyll content to monitor crop physiological and phenological status. *International Journal of Applied Earth Observation and Geoinformation*, *76*, 128–142.
<https://doi.org/https://doi.org/10.1016/j.jag.2018.10.012>

3. Propuesta metodológica para la detección y cuantificación de la severidad asociada a madurez temprana en cultivos de papa a partir de imágenes multiespectrales capturadas con VANT

En este capítulo se presenta un enfoque teórico y metodológico, el cual busca dar cumplimiento a los siguientes objetivos específicos del presente trabajo de tesis:

- Identificar técnicas de procesamiento de imágenes que permitan la identificación y cuantificación de alteraciones asociadas a madurez temprana causada por *Verticillium* spp. en el cultivo de papa a partir de datos espectrales.
- Validar los resultados con cada una de las técnicas de clasificación respecto a los mecanismos tradicionales de detección y cuantificación de la madurez temprana causada por *Verticillium* spp. en el cultivo de papa.

3.1 Resumen

La papa (*Solanum tuberosum*) es una especie alimenticia de alta importancia para la humanidad. Se considera que las enfermedades que afectan el cultivo son una de las mayores limitantes para la producción. Dentro de estas se encuentran algunos patógenos de suelo como *Verticillium* spp., el cual causa maduración temprana (MT), patología altamente compleja y con un impacto económico relevante. El reconocimiento de la problemática en campo se dificulta debido a la alta variabilidad de los síntomas, lo que aumenta la posibilidad de realizar evaluaciones poco precisas. Actualmente existen tecnologías emergentes como la detección indirecta usando herramientas espectrales. A partir de lo anterior, esta investigación tuvo como objetivo implementar el uso de datos multiespectrales capturados con VANT para la detección y cuantificación de la severidad

de la MT. Para ello, se tomaron imágenes multiespectrales usando la cámara Parrot Sequoia acoplada a un VANT, obteniendo mosaicos de alta resolución espectral (2.8 cm) sobre los cuales se calcularon nueve índices espectrales que fueron usados como variables de entrenamiento de distintos algoritmos de *Machine Learning* (ML), posterior a un proceso multipaso de procesamiento de imágenes. Se usó la exactitud como métrica de evaluación del ajuste de todos los modelos desarrollados a partir de datos de imágenes multiespectrales, finalmente se generaron regresiones lineales para comparar los resultados del procesamiento de imágenes y los datos de campo usando AUDPC como medida comparativa. Los resultados indicaron que la mayoría de los algoritmos de ML aplicados, son capaces de crear modelos con alta confiabilidad, sin embargo, se recomienda el uso de muestras de entrenamiento con mayor balance. La técnica de segmentación utilizada (Multi otsu) fue funcional en las clasificaciones ya que permite eliminar gran parte píxeles con información de clases como suelo y otras especies de plantas presentes en los lotes, además de disminuir el tiempo de procesamiento. Se corroboró que las regiones espectrales con mayor capacidad de diferenciación de plantas sanas y enfermedad están relacionadas con el rojo y el borde rojo, además se evidenció que los índices espectrales (ARI, CARI, entre otros), pueden ayudar en la diferenciación de niveles de enfermedad en las plantas de papa, por lo que pueden ser explorados de manera detallada en posteriores investigaciones.

Palabras claves: Segmentación, *machine learning*, índices de vegetación, detección indirecta

3.2 Introducción

En la actualidad, la papa es un cultivo esencial debido a que puede crecer en diferentes condiciones edafoclimáticas (Raymundo et al., 2017; Wang et al., 2015) y aporta un alto nivel de energía y otros nutrientes necesarios para la dieta humana (Hussain, 2016). Lo anterior genera que este cultivo sea de alta relevancia para la seguridad alimentaria del mundo (Hussain, 2016). Según las estimaciones de la FAO, desde el 2021 se produjeron más de 376 millones de toneladas métricas en todo el mundo, siendo China el mayor productor, con cerca de un tercio de la producción mundial (FAOSTAT, 2020). Sin embargo, este cultivo tiene algunas limitaciones productivas asociadas a la susceptibilidad a diferentes enfermedades que afectan su rendimiento (Hussain, 2016). Entre ellas, la madurez temprana (MT) causada por *Verticillium* spp., una enfermedad de suelo, la cual puede generar reducción en el número de tubérculos y la calidad de estos, causando pérdidas entre el 10 y 50% de la producción total (Johnson et al., 2010; Shattock, 2002). Este patógeno causa marchitez vascular al bloquear los elementos del xilema con estructuras que impiden el movimiento del agua (Rowe & Powelson, 2002). Las pérdidas causadas por la madurez temprana de la papa dependen de las variaciones ambientales, siendo especialmente severas bajo condiciones de estrés por altas temperaturas y elevadas tasas de evapotranspiración (Stevenson et al., 2001).

Comúnmente las estrategias para la identificación de síntomas en las plantas se basan en la evaluación visual, estimando el grado de afectación de una planta a partir de escalas de severidad de cada enfermedad, las cuales son utilizadas en diferentes etapas de desarrollo del cultivo (Bock et al., 2010). Sin embargo, la efectividad de las evaluaciones se ven limitadas debido a que requiere un cierto nivel de experiencia para lograr la identificación precisa de las alteraciones presentadas en las plantas (Shruthi et al., 2019; Singh et al., 2020). En los últimos años se ha incursionado en el uso de técnicas de detección de alteraciones mediante el uso de datos adquiridos por diferentes tipos de sensores (Singh et al., 2020) bajo la premisa de que los análisis detallados desarrollados a partir de los mismos, permiten realizar la identificación y cuantificación de diferentes enfermedades en las plantas (Lowe et al., 2017; Mahlein, 2016; Mahlein et al., 2017). Algunos procesos de detección pueden ser tan sensibles como para diferenciar los primeros estados de la infección dependiendo de la escala de medición (Mahlein et al., 2017; Singh et al., 2020). El éxito de la implementación de estas técnicas puede ser la base para un adecuado manejo de enfermedades en las plantas, puesto que se parte de un diagnóstico acertado, rápido y confiable.

Actualmente el uso de técnicas de detección indirecta de enfermedades en plantas se ha incrementado (Barbedo, 2019; Mahlein et al., 2012; Singh et al., 2020). El enfoque más utilizado se basa en sensores acoplados a vehículos aéreos no tripulados (VANT), los cuales pueden generar múltiples tipos de datos con alta resolución espacial y temporal (Barbedo, 2019), destacando la termografía y las imágenes ópticas (Mahlein et al., 2017; Singh et al., 2020). Usando sensores espectrales, se generan imágenes con información por píxel, que puede ser transformada a índices de vegetación (IV) o índices de enfermedad (IE) (Liu et al., 2020; Mahlein et al., 2017), mapas de calor, mapas en falso color (Lowe et al., 2017) o la identificación de bandas espectrales asociadas a reflectancias que se pueden relacionar con la presencia y cuantificación de una determinada alteración (Shruthi et al., 2019; Singh et al., 2020).

Uno de los métodos de análisis de imágenes espectrales es la clasificación de píxeles, la cual es el proceso de asignar valores a clases temáticas que representan fenómenos de interés en la zona de estudio (Aggarwal et al., 2016). Sin embargo, la selección de algoritmos apropiados para el procesamiento siempre ha sido un problema básico (Lu & Weng, 2007), causando que en aras de aumentar el alcance de estos métodos se utilicen diferentes estrategias que pretenden mejorar el proceso de análisis; una de ellas es la segmentación, la cual ha utilizado enfoques basados en umbrales para separar clases que representen las plantas del suelo desnudo, comúnmente un umbral cero o un umbral basado en el método de *Otsu* (Neupane & Baysal-Gurel, 2021; Rodríguez et al., 2021). Junto con esto, se identifican parámetros que permitan diferenciar los objetos de interés, como el color, la textura o la forma de las plantas (Tetila et al., 2017), características que se usan como variables predictoras en diversos algoritmos. Es así como a través del uso de algoritmos de aprendizaje automático (AA), se ha logrado cumplir con diversos objetivos de detección de alteraciones en las plantas a partir de esta información, convirtiéndose en un alternativa que ha despertado interés en los últimos años, puesto que son bastantes los

ejemplos exitosos de la integración con las tecnologías de la información, los conceptos de agricultura inteligente, y las técnicas tradicionales de detección, destacándose aquellos asociados a plagas y enfermedades (Duarte-Carvajalino et al., 2018; El Hoummaidi et al., 2021; Görlich et al., 2021; León-Rueda et al., 2022; Neupane & Baysal-Gurel, 2021; Rodríguez et al., 2021; Shi et al., 2022).

De esta forma se ha determinado que estas técnicas son eficientes para el reconocimiento y estimación de algunas sintomatologías de patologías en las plantas (Pourazar et al., 2017; Sugiura et al., 2016). En lo que respecta a las aplicaciones en sistemas de producción de papa, existen avances al respecto. Es así como múltiples enfoques como las Redes neuronales artificiales (RNA), árboles de decisión (BA), K-means, k vecinos más cercanos, máquinas de soporte vectorial (MVS) y análisis de regresión, han sido aplicados a la detección indirecta de enfermedades con resultados variables (Duarte-Carvajalino et al., 2018; León-Rueda et al., 2022; Lizarazo et al., 2023; Lu et al., 2018; Rodríguez et al., 2021; Singh & Kaur, 2021). Esto implica que el potencial de estas herramientas aplicadas a este cultivo puede ser alto, sin embargo, aún existen algunos vacíos que limitan el uso de estas tecnologías de forma masiva.

Con base a esto y sumado a la limitación de investigaciones enfocadas a la identificación de MT causada por *Verticillium* en papa (León-Rueda et al., 2022; Lizarazo et al., 2023), el enfoque de este trabajo fue evaluar distintos algoritmos de aprendizaje automático y procesamiento de imágenes con el fin de mejorar los procesos de identificación y cuantificación de la MT en plantas de papa usando datos multiespectrales capturadas con VANT. A partir de esto se plantearon tres objetivos específicos: (i) Identificar técnicas de procesamiento de imágenes que permitan la identificación y cuantificación de sintomatologías asociadas a madurez temprana en el cultivo de papa a partir de imágenes multiespectrales, ii) Identificar bandas e índices contrastantes usando algoritmos de aprendizaje automático en la clasificación de plantas sintomáticas y iii) Comparar los resultados obtenidos a partir de la evaluación en terreno y usando percepción remota respecto a la detección y cuantificación de alteraciones en papa asociadas a la madurez temprana del cultivo.

3.3 Materiales y métodos

En esta investigación se desarrolló una metodología reproducible en la cual se utilizan métodos de clasificación supervisada aplicados a imágenes multiespectrales capturadas con VANT sobre cultivos de papa afectados por madurez temprana causada por *Verticillium* spp. Como fase previa, se identificaron sintomatologías asociadas a la enfermedad en dos lotes, asegurando la identidad y ubicación de los niveles presentes en la escala de severidad utilizada. Posteriormente, se emplearon diversas métricas en las distintas etapas de desarrollo e implementación de los algoritmos, con el fin de evaluar su rendimiento y seleccionar aquel que resultara más apropiado para la situación analizada.

3.3.1.1 Localización de áreas experimentales

Los datos fueron capturados en cultivos de papa de la variedad Diacol Capiro desarrollados bajo condiciones de producción comercial en dos municipios de Cundinamarca (Figura 19), Subachoque (4°57'44.52"N, 74° 8'14.44"O) y Mosquera (4°39'40.58"N, 74°14'53.46"O). Las zonas de estudio se caracterizaron por presentar temperaturas en el rango entre 12 y 15°C, precipitación acumulada anual entre 600 y 1000 mm con distribución bimodal, altitud entre 2550 y 2750 msnm y humedad relativa entre 80 y 85%. Bajo esta condición la fuente de inóculo correspondió a la presencia de forma natural en el suelo de los lotes seleccionados para el estudio, en los cuales fue reportada la afectación por MT ocasionada por *Verticillium* en ciclos de cultivo previos y posteriormente corroborada mediante un protocolo desarrollado por el equipo de trabajo para la detección tanto del inóculo en suelo, como de la enfermedad en el hospedero (datos no presentados).

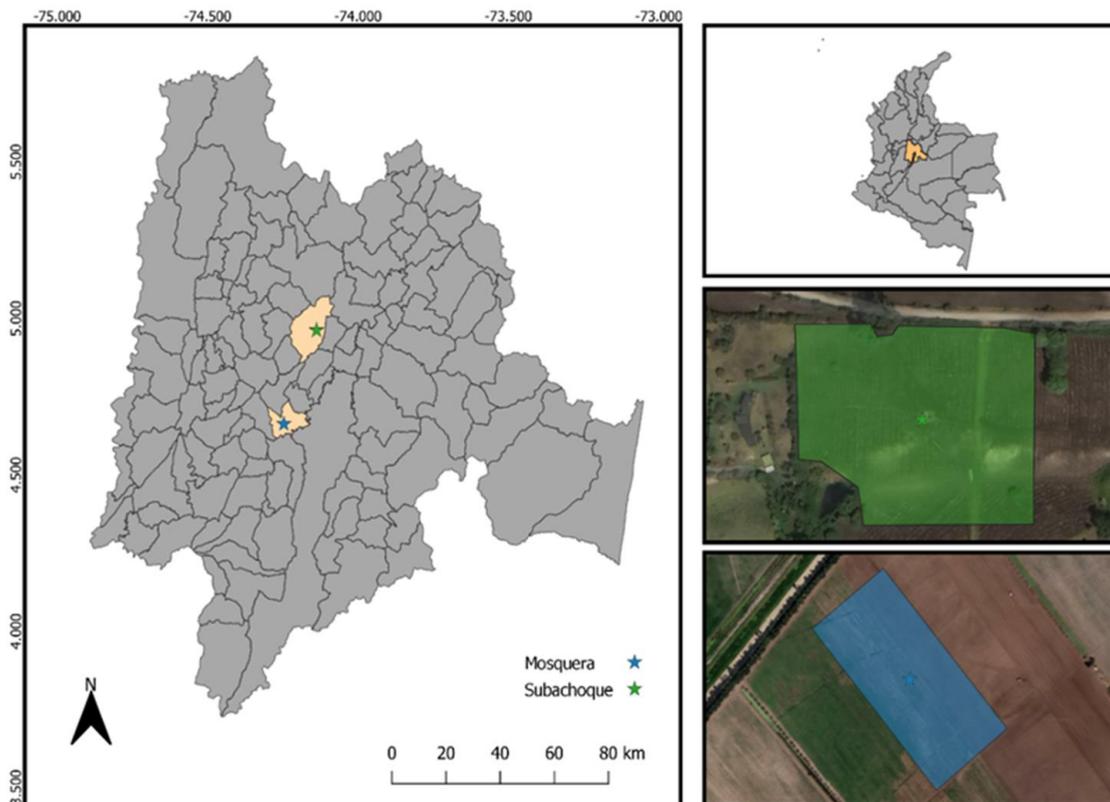


Figura 19. Ubicación de las áreas de estudio, mostrando las zonas de colecta de imágenes ubicadas en Subachoque y Mosquera (Cundinamarca).

3.3.1.2 Adquisición de datos en campo

A nivel de campo se determinaron dos variables asociadas a la intensidad de la enfermedad (presencia-ausencia y severidad) para cada una de las plantas seleccionadas en el muestreo. La severidad se evaluó a partir de una escala ordinal propuesta por Hunter et al. (1968), la cual presenta cinco niveles donde: 0, sin síntomas de marchitamiento; 1, clorosis intervenal en las hojas inferiores; 2, necrosis moderada y defoliación de las hojas inferiores; 3, necrosis y defoliación severas de las hojas, retraso en el crecimiento; y 4, defoliación severa acompañada de atrofia pronunciada, clorosis y necrosis de las hojas restantes y planta muerta.

Se realizaron siete muestreos cada 8 días entre los 60 días después de siembra (dds) y 115 dds, reportado como el periodo de aparición inicial de síntomas y progreso de la enfermedad en algunas investigaciones (Dung et al., 2012; Johnson et al., 2010). En cada momento de evaluación se muestrearon 30 puntos evaluando 15 plantas por sitio, obteniendo un total de 450 individuos. Se realizó un muestreo sistemático en grilla de 15 x 20 m, distribuido en una hectárea del lote evitando adquirir datos en bordes. Cada uno de los puntos fue georreferenciado usando un dispositivo GPS Reach RS2® (EMLID, HU). Adicionalmente, en cada punto de muestreo se determinó la severidad de la MT según la escala descrita anteriormente. De los valores obtenidos, se tomó cualquier número mayor a 0 como caso positivo para el posterior entrenamiento de los algoritmos para la variable presencia-ausencia.

En los dos lotes seleccionados se capturaron datos multiespectrales en cuatro momentos con intervalos de 8 días a partir de los 77 dds, abarcando la fase de floración y llenado del tubérculo. Se realizaron vuelos con un drone DJI Phantom 4 al cual se le acopló el sensor multiespectral Parrot Sequoia (Parrot®), con GPS integrado y panel de reflectancia. Las imágenes fueron capturadas a una altura de 27 m, con solapamiento mayor al 70%. Se obtuvieron datos en las bandas verde-G (550 nm centro, 40 nm de ancho de banda), rojo-R (660 nm centro, 40 nm de ancho de banda), borde rojo-RE (735 nm centro, 10 nm de ancho de banda) e infrarrojo cercano-NIR (790 nm centro, 40 nm de ancho de banda) con un tamaño de píxel de 2.8 cm. Para corregir radiométricamente las imágenes, se capturaron datos sobre un panel de calibración, al inicio y final del vuelo. Para el postproceso de los datos y la generación de los ortomosaicos, se empleó el software Agisoft Meta Shape 1.6.1 (Agisoft™).

3.3.1.3 Análisis de datos

El proceso de análisis fue desarrollado utilizando el software libre Python (versión 3.10) bajo el sistema operativo Linux (Ubuntu). El análisis se dividió en tres partes: i) Comparación de clasificaciones realizadas a partir de valores de índices espectrales extraídos de un área de influencia de la planta sobre imágenes multiespectrales segmentadas, ii) Identificación de bandas e índices espectrales de importancia en la

clasificación de la presencia y severidad de MT en plantas usando algoritmos de aprendizaje automático y iii) Aplicación de modelos sobre imágenes multispectrales para comparación de valores estimados con respecto a los datos de campo basándose en medidas de evaluación de la enfermedad. El esquema general del flujograma de trabajo se ilustra en la Figura 20.

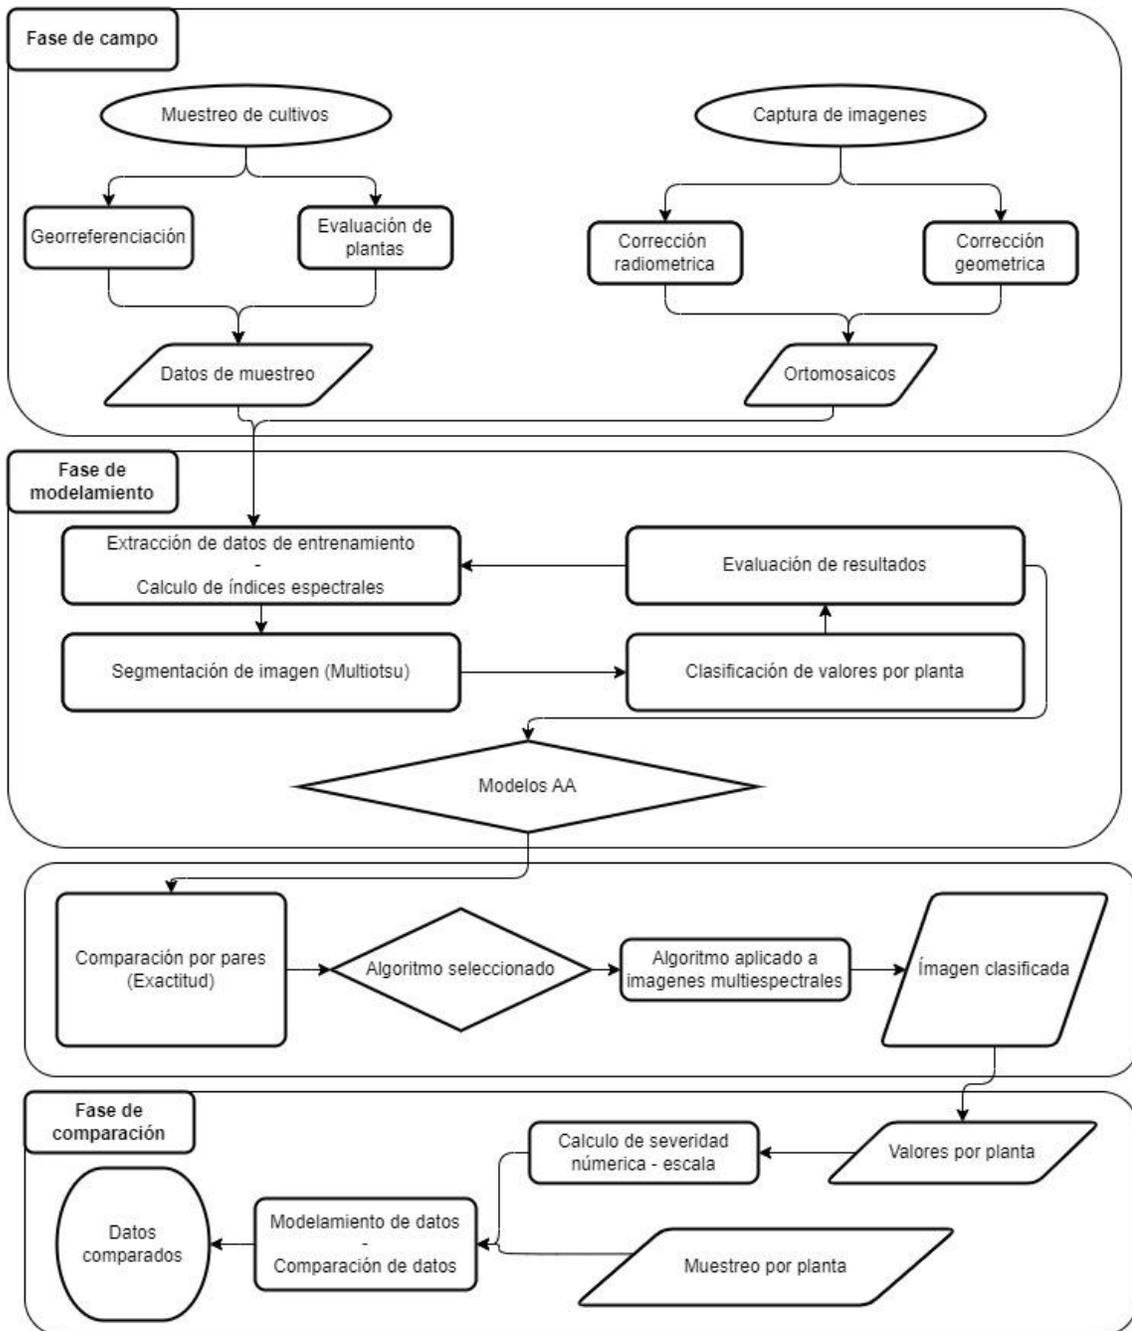


Figura 20. Diagrama de flujo de proceso metodológico utilizado

Segmentación

Con los valores de las bandas se calcularon nueve índices espectrales, reportados por su capacidad de detectar diferentes fuentes de estrés en plantas (Tabla 5) incluyendo el índice propuesto en el capítulo dos (VWI, Ecuación 19). Posteriormente, los niveles de cada capa generada fueron convertidos a ocho bits obteniendo valores entre cero y 255. Utilizando estos valores transformados, se realizó un proceso de segmentación sobre las imágenes, el cual incluyó dos fases, el ajuste de profundidad y posterior segmentación usando el método *multi otsu* (Liao et al., 2001) con la librería *scikit-image* (van der Walt et al., 2014). Se usaron cuatro niveles de umbral sobre la capa correspondiente al NDVI y NDRE, esto se tradujo en cinco niveles de diferenciación. Debido a que NDVI tuvo el mejor resultado visual, se realizó el proceso de segmentación sobre este índice en todas las imágenes capturadas en los lotes, generando una máscara a partir de las clases mayores al tercer nivel (3-4) para cada fecha. Finalmente, se realizaron recortes en los ortomosaicos utilizando todos los índices espectrales generados y las bandas del sensor, lo cual resultó en un conjunto de 13 bandas. Los mosaicos obtenidos después de este proceso tuvieron la remoción de píxeles asociados a suelo y algunas plantas diferentes al cultivo para cada fecha de muestreo en cada lote.

Tabla 5. Índices de vegetación utilizados para el procesamiento de imágenes multiespectrales para la detección de MT en cultivos de papa.

| Nombre | Ecuación | Referencia |
|---|---|---|
| Normalized difference vegetation index (NDVI) | $\frac{RNIR - RRED}{RNIR + RRED}$ (Ecuación 1) | (Rouse et al., 1974) |
| Green-Red Vegetation Index (GRVI) | $\frac{RGREEN - RRED}{RGREEN + RRED}$ (Ecuación 5) | (Motohka et al., 2010; Yeom et al., 2019) |
| Modified Green-Red Vegetation Index (MGRVI) | $\frac{RGREEN^2 - RRED^2}{RGREEN^2 + RRED^2}$ (Ecuación 6) | (Yeom et al., 2019) |
| Green Chlorophyll Index (GCI) | $\frac{RNIR^2}{RGREEN} - 1$ (Ecuación 7) | (Gitelson et al., 2003) |
| Red Edge Chlorophyll Index (RECI) | $\frac{RNIR}{RREDEGE} - 1$ (Ecuación 8) | (Gitelson et al., 2003) |
| Normalized Difference Red Edge Index (NDRE) | $\frac{RNIR - RREDEGE}{RNIR + RREDEGE}$ (Ecuación 9) | (Yeom et al., 2019) |
| Anthocyanin Reflectance Index (ARI) | $\frac{1}{RGREEN} - \frac{1}{RREDEGE}$ (Ecuación 11) | (Gitelson et al., 2001) |

| | | |
|--|---|---------------------|
| Anthocyanin Reflectance Index (CARI) | $\frac{RREDEGE}{RGREEN} - 1$ (Ecuación 12) | (Zhou et al., 2019) |
| Verticillium Wilt Index (VWI) | $\frac{\sqrt{NIR - REDEGE}}{(NIR - REDEGE)^2}$ (Ecuación 19) | Índice propuesto |

A partir de las imágenes multiespectrales segmentadas y los puntos de muestreo para cada una de las fechas, se extrajeron los datos de los píxeles asociados a cada planta, tomando los valores correspondientes a la mediana en un buffer con radio de 40 cm. Se usó la mediana para disminuir el sesgo de los valores atípicos de los píxeles presentes en el buffer generado para cada planta. Con ello se obtuvo un set de 4 bandas, 9 índices espectrales y los valores asociados a la evaluación de los síntomas de la enfermedad en campo respecto a la escala utilizada para cada uno de los momentos de evaluación. Posteriormente se generaron modelos de clasificación supervisada respecto a presencia y severidad usando los diferentes algoritmos presentes en la biblioteca de sklearn (Pedregosa et al., 2011). Se utilizaron modelos con enfoques de clasificación de conjunto, redes neuronales, entre otros (Pandala, 2022), seleccionando el que tuviera mayores valores en las métricas de exactitud, exactitud balanceada y tiempo de procesamiento como variables de selección de modelos. El proceso fue implementado bajo la biblioteca lazypredict (Pandala, 2022), teniendo conjuntos de datos divididos en grupos de entrenamiento y prueba bajo una proporción de 70:30, estratificando la división de datos con respecto a la variable de interés (Severidad/Presencia).

A partir de los resultados preliminares, se seleccionaron dos algoritmos para su implementación: AdaBoost (ADA) y bosques aleatorios (BA). Cada uno de los modelos fueron ajustados bajo los hiperparámetros correspondientes a cada algoritmo. En este sentido, ADA fue parametrizado con el número de cepas de decisión y la tasa de aprendizaje. Por su parte para BA se ajustaron la profundidad de los árboles, el número de características y el número de árboles. El ajuste y desarrollo de modelos fue generado usando la librería sklearn (Pedregosa et al., 2011), usando un equipo con procesador 11th Gen Intel(R) Core(TM) i5-11300H @ 3.10GHz 3.11 GHz, con 40 gb de memoria ram y tarjeta gráfica NVIDIA GeForce RTX 3050 4 GB. El rendimiento de cada modelo fue evaluado en la fase de entrenamiento, utilizando una validación cruzada de cinco veces para cada modelo de clasificación, posteriormente, se comparó el rendimiento de cada modelo para clasificar las clases de presencia y niveles severidad usando matrices de confusión para cada momento de evaluación. Adicionalmente se compararon las métricas de sensibilidad y especificidad de cada clase como métrica de evaluación de la escala de severidad utilizada. La importancia se evaluó utilizando dos métodos distintos. El primero midió la disminución de la impureza a través del índice de Gini. En el segundo método se generaron cinco permutaciones para evaluar la variabilidad que podría presentarse en la importancia de las variables al cambiar los parámetros del modelo generado.

A partir de la imagen clasificada bajo el modelo de mejor comportamiento (ADA) para la variable presencia, se extrajeron los valores de presencia y severidad porcentual por planta calculada a partir de la metodología propuesta. Se generó una escala basada en el porcentaje de píxeles asignados como enfermos respecto al número total en el área correspondiente a cada planta, esta escala fue propuesta por esta investigación. La escala cuenta con un número igual de niveles a la escala de severidad usada para evaluación en campo lo que permitió generar un proceso comparativo. La escala propuesta basada en el análisis de la imagen adquirida por medio de la cámara multispectral acoplada al VANT por cada región de análisis (buffer) se describe a continuación: 0, ningún píxel clasificado como enfermo; 1: $\leq 15\%$ píxeles de afectación; 2: >15 y $\leq 30\%$; 3: $>30\%$ y $\leq 50\%$; y 4: $> 50\%$.

Para generar una comparación de resultados, se tuvo en cuenta un parámetro relacionado con el desarrollo de la enfermedad, se calculó el AUDPC usando la Ecuación 20. Para ello se tomaron los valores de severidad obtenidos en campo y los valores de severidad generados mediante el procesamiento de imágenes en las áreas definidas previamente para cada planta en cada momento de evaluación, generando dos sets de valores de avance de la enfermedad.

$$AUDPC: \sum_{i=1}^{n-1} \left(\frac{y_i + y_{i+1}}{2} \right) (t_{i+1} - t_i) \text{ (Ecuación 20)}$$

Donde: y: niveles de severidad; t: momento de evaluación

Finalmente, se aplicaron modelos usando BA con enfoque de regresión (Ren et al., 2016) para comparar el comportamiento de los valores generados para AUDPC con las dos fuentes de datos (Simko & Piepho, 2012), se seleccionó el modelo con el mayor valor de R^2 , los modelos fueron desarrollados con la biblioteca sklearn (Pedregosa et al., 2011).

3.4 Resultados

Proceso de segmentación

A partir de la literatura se evidenció que el NDVI y el NDRE son índices adecuados para el proceso de segmentación. Al calcularlos sobre las imágenes se identificó que el NDVI tenía una mayor diferenciación entre los valores de las clases de interés a lo largo de ciclo evaluado (Figura 21), ya que se atribuyen valores cercanos a 0 al suelo y mayores a 200 a plantas de papa, creando una división de valores en el histograma que facilita la selección de umbrales para la segmentación. Por el contrario, los valores asociados al NDRE para plantas de papa fueron menores a 200, lo cual restringe su aplicabilidad en la segmentación. Sin embargo, se identificó que este índice tiene alto potencial de diferenciación a nivel de planta, puesto que se observó un aumento de valores de algunos píxeles en el dosel de algunas zonas marcadas en las áreas de comparación (Cuadros

rojos). Por su parte, los dos índices espectrales se comportaron de manera similar entre lotes, presentando los valores más altos en zonas de plantas de papa y valores menores en zonas correspondientes al suelo.

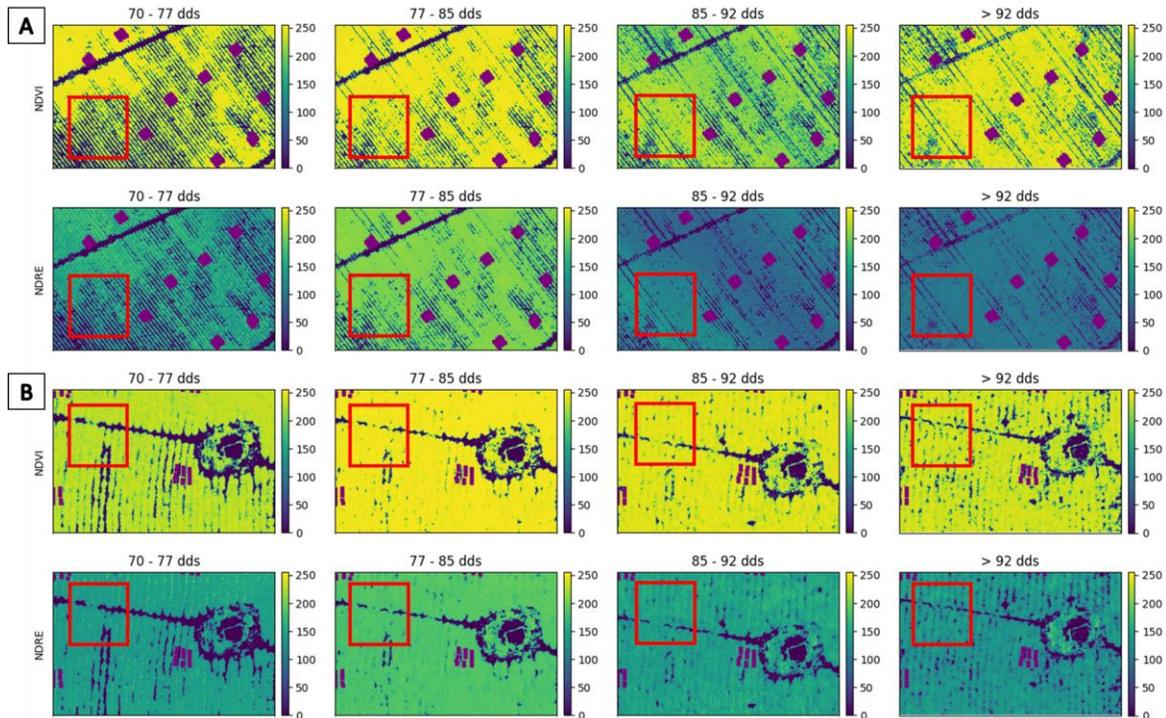


Figura 21. Desarrollo temporal de NDVI y NDRE en lotes de evaluación. Las áreas rojas corresponden a puntos de comparación del cambio en las imágenes. **A.** Mosquera. **B.** Subachoque.

Al evaluar los valores de NDVI, se identificó una acumulación de píxeles con valores mayores a 150, lo cual correspondió a zonas identificadas como plantas en la imagen. Estos valores incluían zonas no correspondientes al cultivo, en especial arvenses, por ello se generó el proceso de segmentación usando valores mayores a 200, esto permitió eliminar algunos píxeles de zonas diferentes al cultivo. El método utilizado (Multi otsu) tuvo resultados bastante aceptables representados por la acumulación de valores correspondientes a píxeles de las clases tres y cuatro, los cuales fueron asociados a plantas del cultivo. Estos valores se representan en la zona verde de los histogramas presentes en la Figura 22. Se evidenció que el algoritmo de segmentación utilizado bajo los parámetros planteados en la metodología fue funcional en todas las localidades y todos los momentos de evaluación.

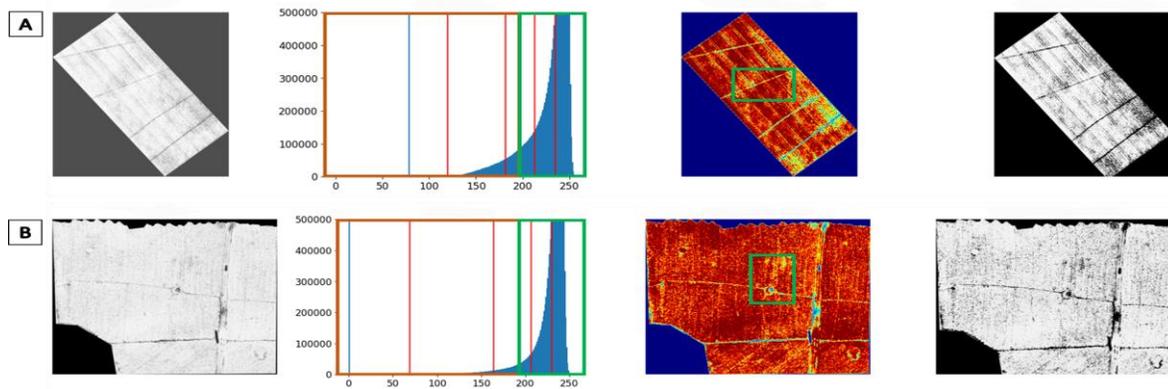


Figura 22. Resultados de segmentación de imágenes utilizando el algoritmo Multi otsu con cinco niveles. Se presenta de izquierda a derecha: Imagen original, histograma de valores, resultados de segmentación multi otsu e imagen segmentada. **A.** Mosquera. **B.** Subachoque.

Se observaron cambios importantes entre los diferentes momentos de desarrollo del cultivo para los dos lotes de evaluación, en especial a partir de los 85 dds, momento en el que se identificaron los mejores resultados del proceso de segmentación, puesto que se redujo un 25 % de píxeles en promedio, lo cual permitió una mayor diferenciación de áreas asociadas al cultivo de papa (Figura 23). Con respecto a los lotes evaluados, se identificó un retraso en el crecimiento de las plantas en parte del lote ubicado en Mosquera para la primera fecha de evaluación (Figura 23A - 70 – 77 dds), por lo cual el proceso de segmentación tuvo un patrón de eliminación de áreas considerable (33%) en los estados iniciales del cultivo, lo cual influyó en los resultados finales del proceso de clasificación, ya que se presentó una mayor expresión de la enfermedad en el cultivo.

Comparativamente el efecto de la enfermedad fue más visible en el lote ubicado en Mosquera, en el cual se observa un patrón de aumento de las áreas segmentadas como suelo, permitiendo diferenciar en todas las fechas de evaluación los surcos junto con la expresión de áreas de plantas con bajo crecimiento (Figura 23A). Por el contrario, el lote de Subachoque tuvo un comportamiento acorde al desarrollo del cultivo con la expresión de pérdida de área correspondiente al cultivo en las dos últimas fechas de muestreo, en ambos casos este efecto corresponde a un patrón de diseminación de la enfermedad en campo, en el cual hay decaimiento y muerte de la planta (Figura 23B).

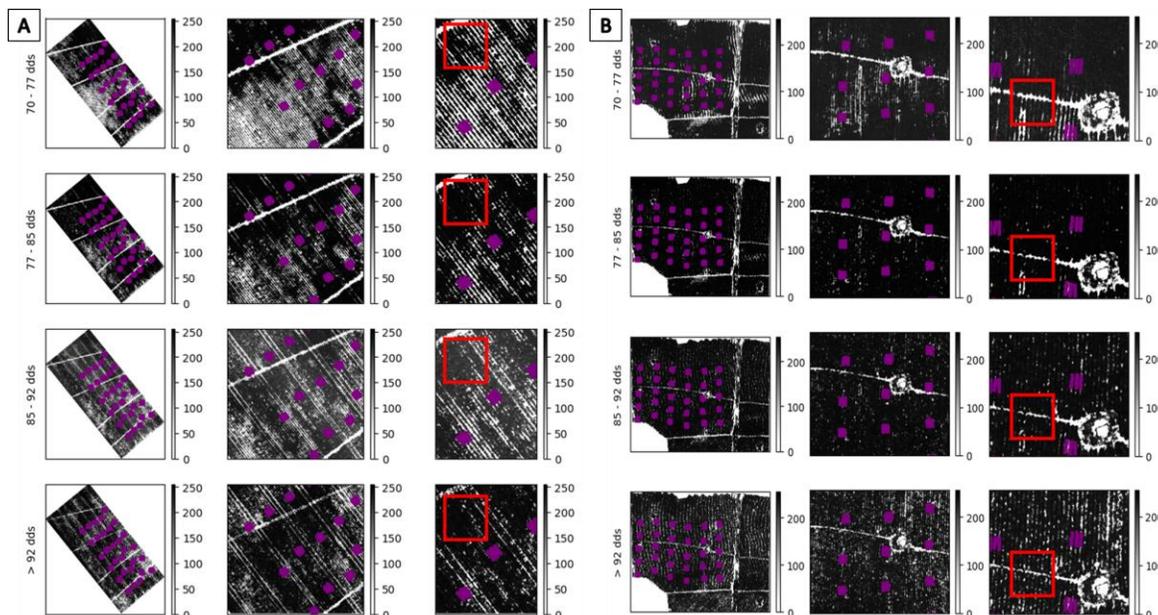


Figura 23. Desarrollo temporal de lotes de evaluación respecto a la segmentación realizada utilizando multi otsu. Los puntos de color morado corresponden a las plantas seleccionadas para la evaluación en campo. **A.** Mosquera. **B.** Subchoque.

Modelamiento presencia - severidad

Los resultados de los modelos con mayor exactitud de clasificación fueron superiores a los presentados en el capítulo dos, sin embargo, se obtuvo menor sensibilidad respecto a las firmas espectrales. La generación de datos de entrenamiento a partir de un área de influencia de plantas con sintomatologías identificadas en campo permitió mejorar las tasas de clasificación para los modelos evaluados, obteniendo valores de exactitud mayores al 85% para todos los modelos (Tabla 6), esto representa un incremento cercano al 5%, con respecto al anterior capítulo. Este resultado demuestra el efecto positivo del posprocesamiento de los datos cuando se usan herramientas indirectas en la detección de enfermedades en los cultivos. Con respecto a la evaluación del rendimiento de los algoritmos, el modelo con mayor exactitud de clasificación de plantas con presencia de síntomas de MT fue ADA, ya que tuvo una exactitud de 91% y una exactitud balanceada de 78%. El tiempo de procesamiento de este algoritmo también fue aceptable en comparación con los demás algoritmos, ya que se ubicó cerca al promedio de tiempos de ejecución (44 s). En general, los algoritmos utilizados tuvieron un buen comportamiento para la variable presencia, sin embargo, se observa que en casos con alta cantidad de datos KNeighborsClassifier puede ser una buena opción dado que su tiempo de procesamiento es 75% menor a las demás opciones usadas en esta investigación.

Tabla 6. Métricas de evaluación de modelos desarrollados a partir de datos extraídos de imágenes multispectrales en cultivos de papa afectados con madurez temprana.

| Variable | Modelo | Exactitud | Exactitud Balanceada | Valor F1 | Tiempo |
|------------------|-------------------------------|-----------|----------------------|----------|--------|
| Presencia | AdaBoostClassifier | 0.91 | 0.78 | 0.90 | 0.46 |
| | LabelSpreading | 0.90 | 0.80 | 0.90 | 0.59 |
| | KNeighborsClassifier | 0.90 | 0.77 | 0.89 | 0.11 |
| | ExtraTreesClassifier | 0.89 | 0.77 | 0.89 | 0.47 |
| | LabelPropagation | 0.89 | 0.77 | 0.89 | 0.45 |
| | RandomForestClassifier | 0.89 | 0.76 | 0.89 | 0.52 |
| Severidad | RandomForestClassifier | 0.85 | 0.35 | 0.82 | 0.52 |
| | SGDClassifier | 0.85 | 0.34 | 0.81 | 0.08 |
| | XGBClassifier | 0.84 | 0.34 | 0.82 | 1.23 |
| | ExtraTreesClassifier | 0.84 | 0.34 | 0.82 | 0.38 |
| | DecisionTreeClassifier | 0.80 | 0.33 | 0.80 | 0.04 |
| | AdaBoostClassifier | 0.81 | 0.31 | 0.79 | 0.42 |

En lo que respecta a la variable severidad, los resultados de los modelos de clasificación fueron similares entre los dos algoritmos utilizados, destacándose los generados usando BA (Tabla 7). Para esta variable, la exactitud de clasificación disminuyó en alrededor de 7% en comparación con los modelos de presencia de la enfermedad. En contraste, la exactitud balanceada se vio muy afectada puesto que los valores de esta métrica fueron menores al 50% para todos los algoritmos utilizados, mostrando el efecto del desbalance de las clases utilizadas en el entrenamiento del modelo (Figura 24). A pesar de las altas tasas de exactitud, se identificó un valor de sensibilidad (69%) y especificidad (66%) aceptable (Figura 24A), mostrando dificultad para clasificar algunos casos de plantas con síntomas de la enfermedad. Se identificó que los valores correspondientes a plantas enfermas con baja severidad (1-2) fueron clasificados mayormente en el nivel 0, haciendo evidente la dificultad de diferenciación de plantas en estados iniciales de la enfermedad (Figura 24D). Por su parte, los datos correspondientes a niveles más altos de escala (3 - 4) no fueron clasificados en las clases 1 y 2, lo que muestra la marcada diferenciación con respecto a plantas con niveles bajos de severidad.

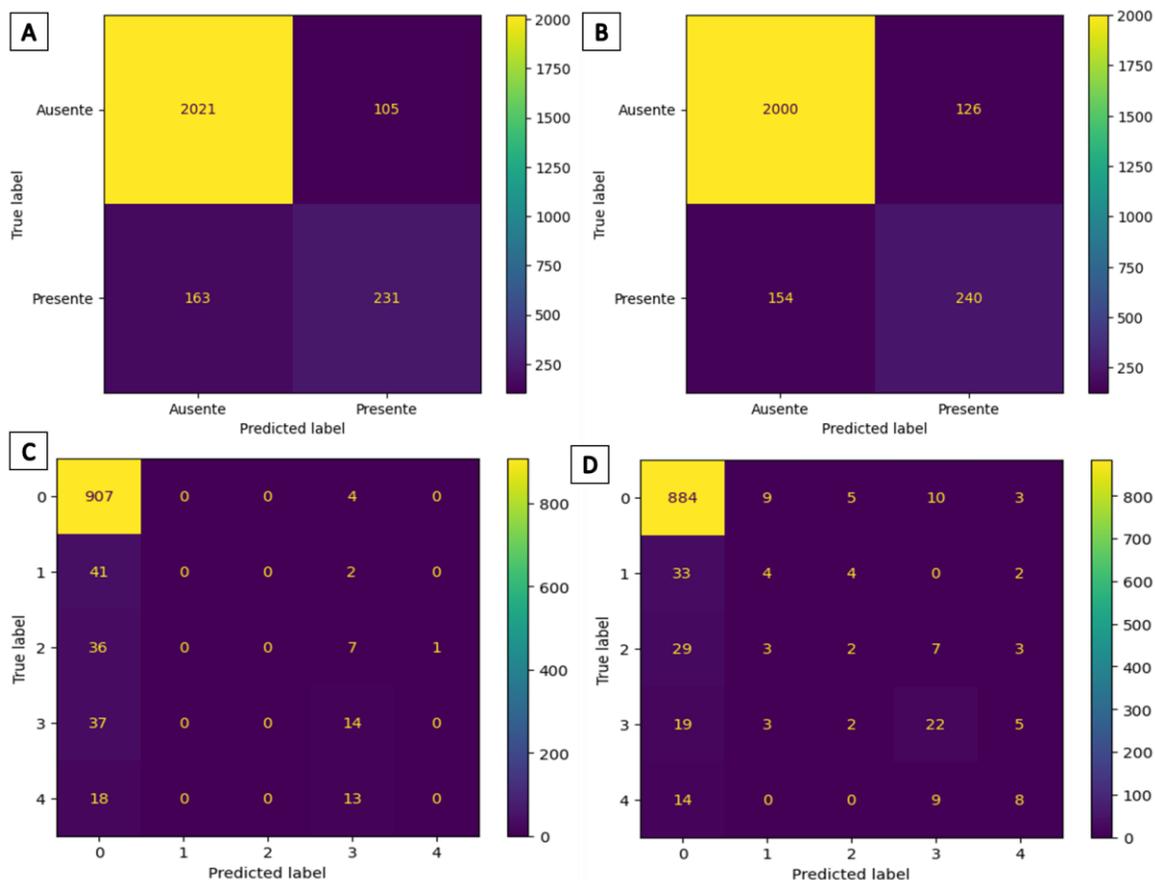


Figura 24. Matrices de confusión extraídas de los modelos desarrollados para las variables presencia/severidad a partir de datos extraídos de imágenes multispectrales. **A.** ADA - Presencia. **B.** BA – Presencia. **C.** ADA - Severidad. **D.** BA – Severidad.

Importancia de bandas e índices espectrales

Las variables de mayor importancia para discriminar entre presencia-ausencia de MT en plantas de papa fueron parcialmente coincidentes con los modelos presentados en el capítulo anterior. Se destacan las bandas correspondientes al NIR, RedEdge, Red, GRVI y CARI (Tabla 7). Los resultados muestran que la detección indirecta de plantas sintomáticas con MT puede estar asociada a las bandas capturadas por la cámara utilizada, indicando que los índices espectrales tienen limitaciones como variables de entrenamiento al ser usados en condiciones de campo. Los índices con mayor importancia (GRVI y CARI) incluyen las bandas del rojo y el área espectral del verde, esto puede indicar un efecto de estas regiones del espectro en la identificación de la enfermedad a partir de imágenes multispectrales. A partir de lo obtenido, se plantea que las bandas NIR, RedEdge y Red incluidas en los sensores pueden dar información suficiente para la identificación de los síntomas de la enfermedad en campo.

Tabla 7. Importancia de variables usadas como predictores en el entrenamiento de los algoritmos usando la variable presencia.

| Predictor | ADA* | BA* |
|------------------|-------------|------------|
| NIR | 0.220 | 0.09 |
| REDEdge | 0.112 | 0.07 |
| Red | 0.099 | 0.07 |
| GRVI | 0.085 | 0.05 |
| CARI | 0.082 | 0.03 |
| Green | 0.082 | 0.08 |
| MGRVI | 0.078 | 0.08 |
| NDVI | 0.074 | 0.07 |
| NDRE | 0.054 | 0.29 |
| RECI | 0.047 | 0.11 |
| GCI | 0.030 | 0.01 |
| VWI | 0.026 | 0.01 |
| ARI | 0.011 | 0.05 |

* Índice de Gini

Los índices seleccionados como variables de entrenamiento tuvieron comportamientos diferenciales para cada uno de los algoritmos evaluados, sin embargo, algunos índices como NDRE fueron comúnmente importantes en los modelos de severidad. En el caso de severidad, los índices ARI, NDRE y CARI tuvieron una alta importancia (Figura 25) para los modelos generados con ambos algoritmos (ADA - BA), por lo cual pueden tener alto potencial en la diferenciación de la intensidad de los síntomas de madurez temprana de la papa bajo condiciones de campo. Estos índices también fueron reportados en el capítulo anterior. A pesar de ello, se observó que algunos índices como NDRE y ARI tuvieron incrementos en el error tras la permutación por lo cual deben ser evaluados específicamente en cada situación, puesto que pueden verse afectados por cambios espectrales asociados al cambio de algunas condiciones del cultivo. Por su parte, al comparar los resultados por algoritmo, se identificó que ADA tiene una alta variabilidad en la importancia de la mayoría de los índices usados como variables de entrenamiento al usar permutaciones, mostrando que las condiciones de los datos pueden afectar su resultado. En contraste, los índices bajo el algoritmo BA tuvieron un comportamiento bastante similar tras la permutación, mostrando que NDRE y VWI tienen mayor variabilidad respecto a las condiciones evaluadas en los distintos lotes.

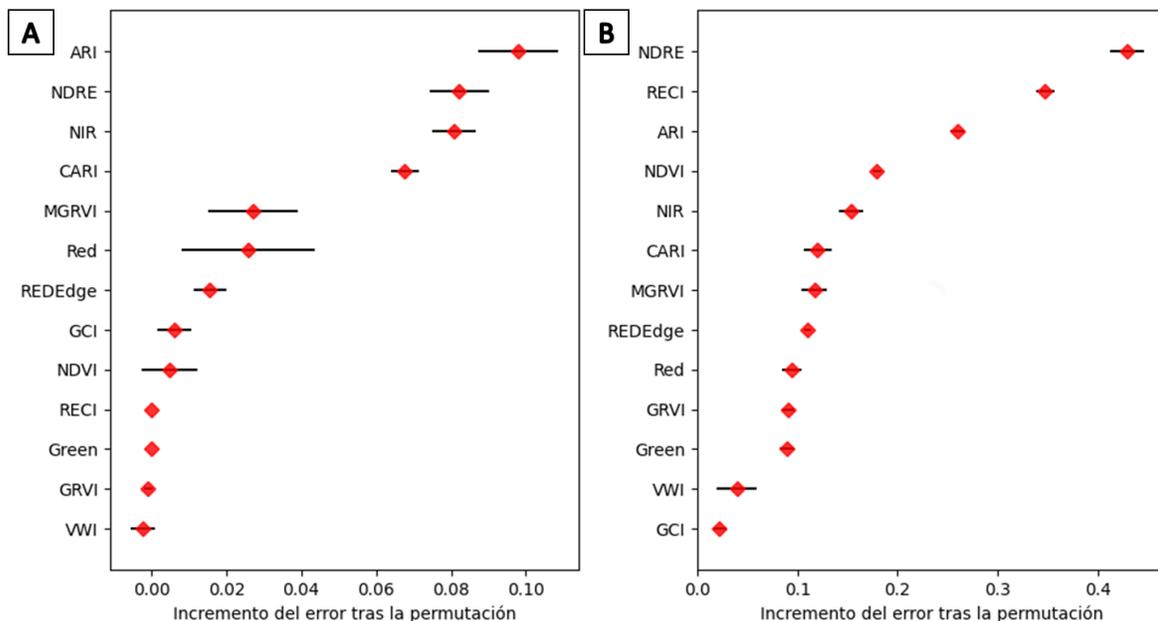


Figura 25. Importancia de variables tras la permutación usadas como predictores en el entrenamiento de los algoritmos usando la variable severidad. **A.** ADA. **B.** BA.

Resultados de clasificación

Los resultados de las clasificaciones realizadas utilizando el modelo desarrollado con ADA sobre las imágenes multiespectrales capturadas en campo bajo la variable presencia se presentan en la Figura 26. Se observaron comportamientos diferenciales de la expresión de los síntomas de la enfermedad al comparar la localidad. Las imágenes mostraron que en el lote ubicado en Mosquera (Figura 26A) se desarrollaron síntomas de manera rápida, incrementando la severidad (Niveles 3-4) e incidencia de manera exponencial partir de los 85 dds, esto concuerda con la curva de crecimiento de la enfermedad generada para esta localidad. Por el contrario, en el lote ubicado en Subachoque (Figura 26B), a lo largo de los muestreos se evidenció una focalización de las áreas de cultivo en las cuales se observaron los síntomas asociados a MT, esto se identificó en los datos de campo y los resultados de las imágenes clasificadas. A partir de lo anterior, se evidenció que la herramienta es funcional para evaluar los cultivos con afectación de esta enfermedad.

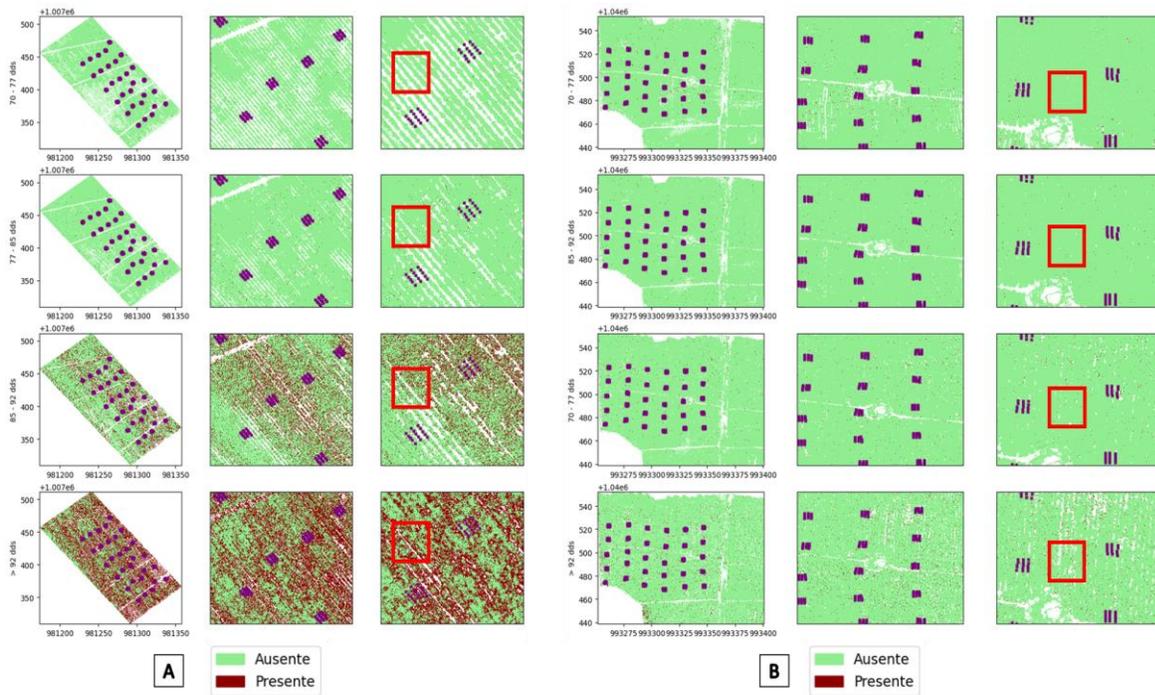


Figura 26. Resultados de clasificación de imágenes multispectrales con respecto a la presencia de síntomas de MT usando ADA. **A.** Mosquera. **B.** Subachoque.

Al comparar los valores de campo con respecto a los predichos por el modelo para cada área de influencia de cada planta a partir de matrices de confusión, se obtuvo una exactitud del 43% (Figura 27A). Se observó que la tasa de exactitud se vio afectada por que el 33% de las plantas calificadas en campo como sanas fueron clasificadas como enfermas. A pesar de lo anterior, al evaluar por nivel de severidad, se identificó una baja tasa de confusión respecto a los valores de campo, esto nos muestra que el modelo fue funcional para detectar plantas con MT (Figura 27BC).

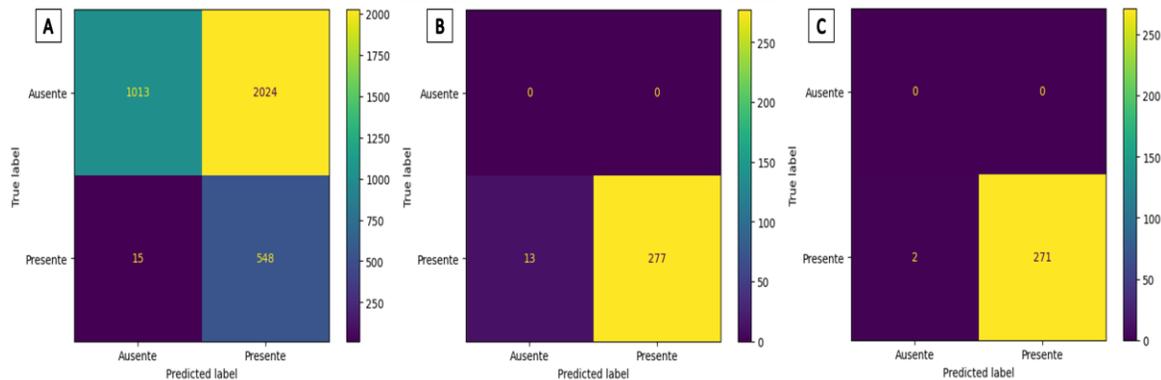


Figura 27. Matrices de confusión comparativas entre datos de campo y valores de presencia obtenidos a partir del flujo de trabajo propuesto en esta investigación. **A.** Presencia. **B.** Severidad - Niveles 1 y 2. **C.** Severidad - Niveles 3 y 4.

Comparación de campo y procesamiento de imágenes con respecto a MT

La comparación realizada para la variable severidad, evidenció que los valores calculados a partir del modelo ADA fueron similares al comportamiento visto en campo, mostrando que la enfermedad fue más severa en el lote ubicado en Mosquera (Figura 28A). Se identificó que los niveles de la enfermedad con mayor dificultad para clasificar fueron 1 y 2, ya que muchas de las plantas que fueron identificadas como sanas en campo tuvieron algún nivel de afectación según las clasificaciones realizadas (Figura 29B). Los niveles avanzados de la enfermedad fueron un poco más sensibles, en especial el grado 4, ya que alcanzó una tasa de exactitud cercana al 50%. Esto se tradujo en diferencias de los niveles de severidad obtenidos en los lotes de evaluación respecto a la fuente de evaluación de la enfermedad, lo cual se observa en la Figura 29A. A partir de datos de campo (Recuadro rojo), los dos lotes tuvieron valores de severidad de cero para la mayoría de las plantas; por el contrario, a partir de los datos obtenidos en el procesamiento (Recuadro naranja), se generaron picos en los niveles cero y uno de la enfermedad, mostrando la posibilidad de detección de síntomas en estados iniciales de la enfermedad.

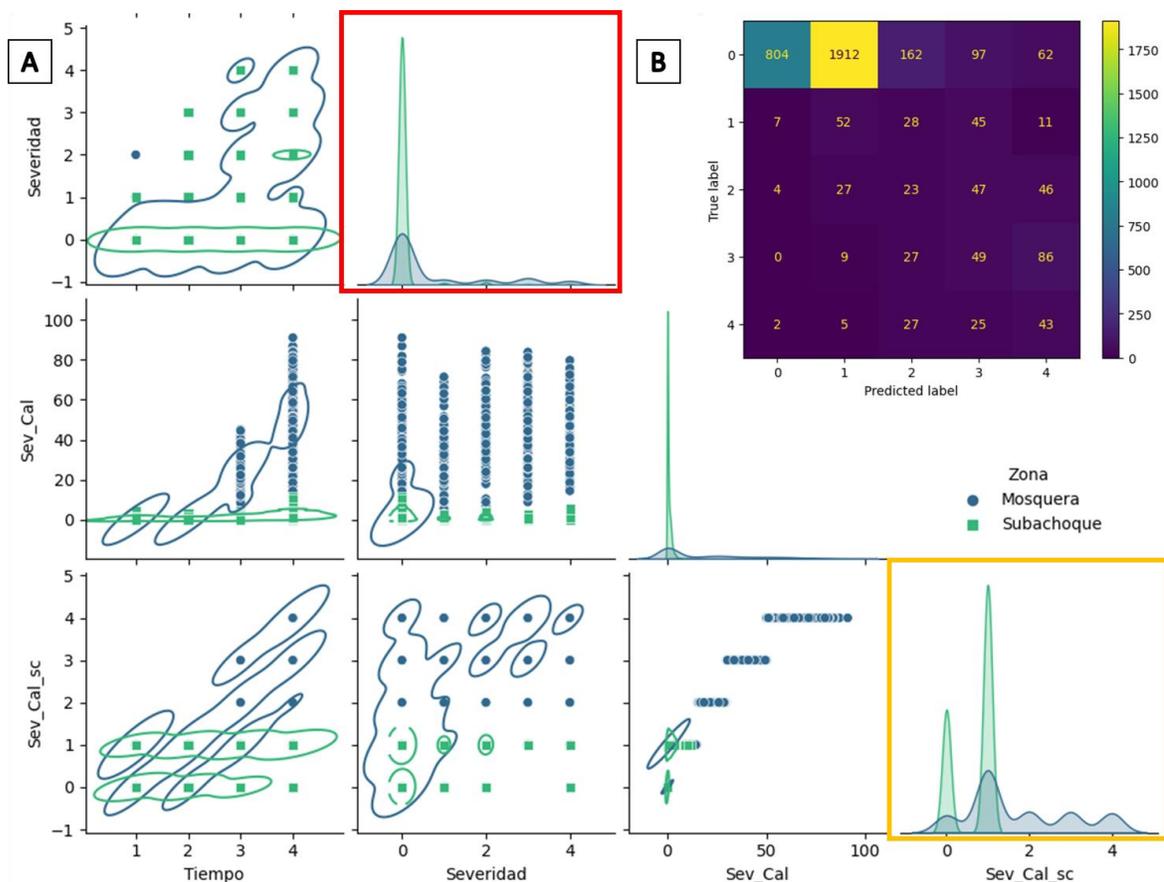


Figura 28. Comportamientos comparativos de valores de severidad calculada a partir de procesamiento de imágenes multispectrales con respecto a datos de campo. **A.** Comportamiento de variables. **B.** Matriz de confusión respecto a datos de campo.

Como comparación final, y con el fin de obtener una medida del avance de la enfermedad, se calculó el AUDPC por planta evaluada usando las dos fuentes de evaluación de la alteración (Campo – Imágenes). Se observó que los niveles de enfermedad fueron similares entre los dos procesos (Campo - Imágenes), sin embargo, se reportaron menores cambios en los valores de AUDPC con datos de las imágenes, ya que se obtuvieron valores máximos de 30 en plantas que tenían cambios cercanos a 70 según los datos de campo (Figura 29). Respecto a los modelos de regresión, los resultados son aceptables, puesto que se obtuvo un valor de R^2 de 0.42, con un rms de 4.5, mostrando una relación de baja a aceptable entre los datos de campo y los generados con el procesamiento planteado en esta investigación.

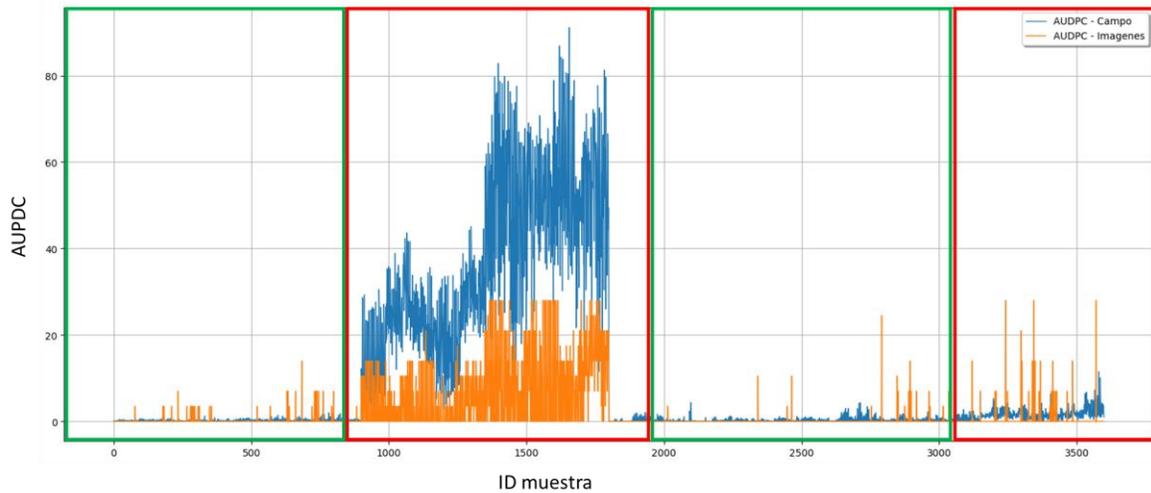


Figura 29. Comportamiento de valores de AUDPC generados a partir de procesamiento de imágenes multiespectrales con respecto a datos de campo.

3.5 Discusión

En este estudio, se compararon diversos métodos de AA para clasificar plantas de papa con diferentes grados de MT bajo condiciones de campo (producción comercial) usando imágenes multiespectrales capturadas con VANT. Para ello se desarrolló un flujo de trabajo que involucró un proceso de segmentación, el cálculo de un área de influencia de la planta y la posterior clasificación de diferentes clases asociadas con presencia, ausencia y niveles de severidad. En general los algoritmos de AA fueron bastante exactos a la hora de clasificar píxeles de plantas de papa con sintomatologías asociadas a MT, coincidiendo con resultados previos, en los cuales se había demostrado que este tipo de herramientas presentaba potencial para la detección indirecta de esta enfermedad (León-Rueda et al., 2022; Lizarazo et al., 2023). Como resultado importante después de comparar los datos obtenidos bajo un correcto diagnóstico de campo usando métodos tradicionales y un muestreo tanto espacial como temporal, se evidenció una limitación en cuanto a la caracterización de niveles de la escala o valores de severidad de la enfermedad, lo cual posiblemente está asociado al desbalance de las muestras usadas en el proceso de

entrenamiento, lo cual es una situación que se presenta comúnmente al aplicar estas técnicas bajo condiciones de campo, donde se pueden encontrar distintos niveles de la enfermedad, y en especial mayores porcentajes en niveles inferiores de afectación de las plantas. Esta situación ha sido reportada por diversos autores, como uno de los mayores limitantes del uso de estas herramientas en el cultivo de papa (Duarte-Carvajalino et al., 2018; León-Rueda et al., 2022; Rodríguez et al., 2021).

Por su parte, los resultados y el enfoque usado sugieren la necesidad de poder realizar un correcto preprocesamiento de las imágenes como requisito fundamental para lograr un adecuado uso del enfoque de detección indirecta de enfermedades en plantas mediante el uso de cámaras espectrales acopladas a VANT. En este sentido, el uso de Multiuso como algoritmo de segmentación permitió desarrollar un adecuado proceso de eliminación de clases distintas al cultivo de interés, como arvenses y suelo. Su ventaja frente a otros algoritmos radicó en la posibilidad de evaluar los umbrales de decisión para las distintas clases observadas en las imágenes, lo que permitió elegir los valores que generaban la mejor diferenciación de una manera ágil, facilitando la eliminación de píxeles con información con poca utilidad para los objetivos de esta investigación, esto puede ser una opción preliminar para mejorar los resultados respecto a lo discutido por Rodríguez et al., (2021), puesto que evitó el múltiple ajuste de los umbrales realizado en el proceso de segmentación de otras investigaciones. Esta técnica también disminuyó el tiempo procesamiento de los algoritmos de clasificación (Rodríguez et al., 2021) permitiendo optimizar el proceso de clasificación y posterior comparación respecto a los datos de campo.

Por su parte, uno de los aspectos de importancia a la hora de analizar respuestas espectrales adquiridas por medio de imágenes, es determinar el área de influencia sobre la cual se hace la extracción de características o variables a usar, puesto que puede mejorar su rendimiento como predictores en el proceso de clasificación de un estado fitosanitario en particular. Con base en el enfoque presentado por este trabajo, se determinó que el uso de áreas de influencia en el procesamiento, mejora significativamente la exactitud de clasificación de la mayoría de los algoritmos utilizados en el entrenamiento de los modelos de clasificación, coincidiendo con resultados previos de algunos autores (Lizarazo et al., 2023). De igual manera, el uso de áreas de análisis por planta también permitió la comparación por individuo, generando una evaluación al detalle requerido para la enfermedad en campo. Es así como la implementación de esta metodología, genera resultados aceptables en comparación con otros enfoques que toman el valor puntual como valor de entrenamiento de los algoritmos (Duarte-Carvajalino et al., 2018; Gibson-Poole et al., 2017; León-Rueda et al., 2022). Sumado a lo anterior, este enfoque se podría utilizar para evaluar diversas alteraciones presentes en las plantas de papa, lo que podría convertirse en una herramienta funcional de monitoreo fitosanitario.

Respecto a los algoritmos, se evidenció que la mayoría de algoritmos de clasificación son eficientes para clasificar problemas fitosanitarios basados en datos espectrales (Wei et al., 2021), a pesar de ello las diferencias de procesamiento pueden ser de interés al llevarlos

a una escala mayor. En lo que respecta a la detección indirecta de MT bajo condiciones de campo se encontró que tanto las bandas presentes en la cámara como los índices relacionados con las regiones del rojo e infrarrojo cercano fueron los más importantes en la discriminación de plantas sanas y enfermas, al igual que para los niveles de severidad. Dentro de estos, se destacaron dos índices (NDRE y RECI). Estos resultados coincidieron con lo encontrado bajo condiciones controladas (capítulo 2), por lo que su importancia estaría asociada a que tiene relación con la banda ubicada en el borde del rojo, la cual se relaciona con la absorción de las clorofilas, donde sus valores se ven más afectados por los cambios en el contenido de este componente dentro de las plantas (Gitelson et al., 2003). Esta situación coincide con la expresión de síntomas de MT en papa, ya que los primeros síntomas son clorosis y necrosis de los tejidos, lo que afecta este componente en las plantas (Johnson et al., 2010). En lo que respecta al índice NDRE, en estudios recientes se reporta su importancia en la diferenciación de los síntomas de MT en el cultivo de papa (León-Rueda et al., 2022; Lizarazo et al., 2023). Lo anterior se relaciona de la misma forma con la gravedad de los síntomas de MT. Los índices NDRE y RECI pueden utilizarse como una potencial herramienta para detectar el comienzo de los brotes de la enfermedad y poder tener una herramienta de análisis y decisión temprana para la aplicación de tácticas de gestión. En el caso de MT, estos cambios espectrales pueden expresarse debido al taponamiento y daño vascular presentado, por lo que se recomienda tener en cuenta la biología del patógeno y el desarrollo de la enfermedad para la detección y diferenciación de las enfermedades de las plantas utilizando estrategias no invasivas (Gold, Townsend, Chlus, et al., 2020; Wei et al., 2021).

Se obtuvieron resultados aceptables al comparar los resultados del procesamiento y los datos de campo. Por una parte, se logró tener alta similitud en los procesos de evaluación de la enfermedad en lotes de campo evidenciando el alto potencial de las herramientas de detección remota en la cuantificación y evaluación de enfermedades en cultivos de campo, resultados que concuerdan con lo reportado anteriormente (Duarte-Carvajalino et al., 2018; Gibson-Poole et al., 2017; Rodríguez et al., 2021). Igualmente, se evidencia la dificultad para diferenciar y estimar este parámetro de enfermedad en el cultivo usando imágenes multiespectrales en campo, por lo que se identifica la necesidad de un enfoque diferencial para lograr un proceso de detección precisa de la severidad de MT causada en campo. A partir de lo obtenido, se plantea que las bandas incluidas en los sensores multiespectrales pueden dar información suficiente para la identificación de los síntomas de la enfermedad en campo. Además, la inclusión de variables como el AUDPC asociadas a áreas de influencia de las plantas (Lizarazo et al., 2023), las cuales indican el desarrollo de la enfermedad, corroboró que se puede obtener una medición con un grado de confiabilidad aceptable en el proceso comparativo de la identificación y cuantificación de MT en lotes productores de papa.

El proceso desarrollado demostró que es posible realizar la estimación de MT causada por *Verticillium* spp. a partir de imágenes multiespectrales en lotes de producción de papa, sin embargo, el procedimiento requiere preprocesamiento de los datos capturados tanto en

campo como con el sensor multiespectral, por lo que necesita un grado de conocimiento moderado en técnicas geoespaciales.

Este estudio utilizó algunas propuestas metodológicas para detectar y cuantificar sintomatologías asociadas a MT causada por *Verticillium* spp. en cultivos de papa: la eliminación de píxeles asociados al suelo y otras plantas mediante segmentación de imágenes, un enfoque de aprendizaje automático para la clasificación de píxeles y una comparación basada en un área de influencia de las plantas para estimar su grado de afectación. La unión de estas propuestas en la metodología planteada podría ser útil para futuros estudios de identificación de enfermedades en cultivos, pero su aplicabilidad se puede limitar debido a algunos factores como el sensor, las localidades de evaluación, la variedad del cultivo, el tamaño y distribución del muestreo, entre otras. A partir de ello se recomienda que el planteamiento de futuras investigaciones se base en estos factores limitantes propendiendo por mejorar las tasas de exactitud de los niveles de severidad clasificados por las metodologías que se desarrollen y las escalas usadas en campo.

3.6 Conclusiones

Este estudio demostró que el uso de imágenes multiespectrales de alta resolución tiene un alto potencial en la identificación de enfermedades en cultivos de papa desarrollados bajo condiciones de campo, en especial sintomatologías asociadas a madurez temprana de la papa causada por *Verticillium* spp. Las técnicas de AA aplicadas sobre este tipo de imágenes tuvieron buenos resultados de manera general, por lo cual se infiere que la evaluación de la presencia y cuantificación de síntomas de madurez temprana es una meta alcanzable mediante la aplicación de estos enfoques. Los resultados sugieren que los estados iniciales de la enfermedad son difíciles de diferenciar en campo, convirtiendo esta tarea en un reto de investigaciones futuras enfocadas a esta enfermedad.

En general se evidencia que la mayoría de los algoritmos de AA evaluados en esta investigación son capaces de crear modelos con alta confiabilidad para la identificación de síntomas de madurez temprana causada por *Verticillium* spp., en especial AdaBoost Classifier, sin embargo, se recomienda el uso de muestras de entrenamiento con mayor balance para aumentar la sensibilidad y especificidad de los modelos generados. La técnica de segmentación utilizada (Multi otsu) fue muy funcional en las clasificaciones desde diversos puntos de vista, ya que permitió diferenciar de manera rápida el umbral de diferenciación permitiendo eliminar gran parte del suelo y malezas, además de disminuir el tiempo de procesamiento al aplicar las técnicas de clasificación de imágenes. Se corroboró que las regiones espectrales con mayor capacidad de diferenciación de plantas sanas y con síntomas asociados a madurez temprana están relacionadas con el rojo y borde rojo, además se evidenció que los índices espectrales (ARI, CARI, entre otros), los cuales están relacionados con compuestos producidos por la planta pueden ayudar en la diferenciación de niveles de enfermedad en las plantas de papa, por lo que pueden ser explorados de manera detallada en investigaciones posteriores. Por su parte, la metodología desarrollada para la estimación AUDPC a partir de imágenes multiespectrales

tuvo resultados aceptables en comparación con la evaluación de campo, por lo que se concluye que se requiere mayor parametrización del enfoque metodológico para obtener valores más cercanos a lo evidenciado en campo respecto a la enfermedad evaluada.

3.7 Bibliografía

- Aasen, H., Honkavaara, E., Lucieer, A., & Zarco-Tejada, P. J. (2018). Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: A review of sensor technology, measurement procedures, and data correction workflows. In *Remote Sensing* (Vol. 10, Issue 7, p. 1091). Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/rs10071091>
- Abdulridha, J., Ampatzidis, Y., Kakarla, S. C., & Roberts, P. (2020). Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. *Precision Agriculture*, 21(5), 955–978. <https://doi.org/10.1007/s11119-019-09703-4>
- Aggarwal, N., Srivastava, M., & Dutta, M. (2016). Comparative Analysis of Pixel-Based and Object-Based Classification of High Resolution Remote Sensing Images – A Review. *International Journal of Engineering Trends and Technology*, 38(1), 5–11. <https://doi.org/10.14445/22315381/ijett-v38p202>
- Agilandeewari, L., Prabukumar, M., Radhesyam, V., Phaneendra, K. L. N. B., & Farhan, A. (2022). Crop Classification for Agricultural Applications in Hyperspectral Remote Sensing Images. *Applied Sciences*, 12(3). <https://doi.org/10.3390/app12031670>
- Agronet. (2018). Agronet. <http://www.agronet.gov.co/estadistica/Paginas/default.aspx>
- Al-Saddik, H., Simon, J. C., & Cointault, F. (2017). Development of spectral disease indices for 'flavescence dorée' grapevine disease identification. *Sensors (Switzerland)*, 17(12). <https://doi.org/10.3390/s17122772>
- AlAfandy, K. A., Omara, H., Lazaar, M., & Al Achhab, M. (2019, October 23). Artificial neural networks optimization and convolution neural networks to classifying images in remote sensing: A review. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3372938.3372945>
- Albetis, J., Jacquin, A., Goulard, M., Poilvé, H., Rousseau, J., Clenet, H., Dedieu, G., & Duthoit, S. (2019). On the potentiality of UAV multispectral imagery to detect Flavescence dorée and Grapevine Trunk Diseases. *Remote Sensing*, 11(1). <https://doi.org/10.3390/rs11010023>
- Ali, M. M., Bachik, N. A., Muhadi, N., 'Atirah, Tuan Yusof, T. N., & Gomes, C. (2019). Non-destructive techniques of detecting plant diseases: A review. In *Physiological and Molecular Plant Pathology* (Vol. 108). Academic Press. <https://doi.org/10.1016/j.pmpp.2019.101426>
- Antunes, E., Vuppaladadiyam, A. K., Sarmah, A. K., Varsha, S. S. V., Pant, K. K., Tiwari, B., & Pandey, A. (2021). Application of biochar for emerging contaminant mitigation. In *Advances in Chemical Pollution, Environmental Management and Protection* (Vol. 7, pp. 65–91). Elsevier. <https://doi.org/10.1016/bs.apmp.2021.08.003>
- Arneson, P. A. (2001). Plant Disease Epidemiology. *The Plant Health Instructor*, <https://www.apsnet.org/edcenter/disimpactmngmnt/to>. <https://doi.org/10.1094/PHI-A-2001-0524-01>
- Ashourloo, D., Aghighi, H., Matkan, A. A., Mobasheri, M. R., & Rad, A. M. (2016). An Investigation Into Machine Learning Regression Techniques for the Leaf Rust Disease Detection Using Hyperspectral Measurement. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(9), 4344–4351.

- <https://doi.org/10.1109/JSTARS.2016.2575360>
- Ashraf, A., Rauf, A., Fahim Abbas, M., & Rehman, R. (2012). ISOLATION AND IDENTIFICATION OF VERTICILLIUM DAHLIAE CAUSING WILT ON POTATO IN PAKISTAN. *J. Phytopathol*, 24(2), 112–116.
- Baldi, P., & La Porta, N. (2020). Molecular Approaches for Low-Cost Point-of-Care Pathogen Detection in Agriculture and Forestry. In *Frontiers in Plant Science* (Vol. 11). Frontiers Media SA. <https://doi.org/10.3389/fpls.2020.570862>
- Barbedo, J. G. A. (2019). A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses. *Drones*, 3(2), 1–27. <https://doi.org/10.3390/drones3020040>
- Behmann, J., Mahlein, A. K., Rumpf, T., Römer, C., & Plümer, L. (2015). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. In *Precision Agriculture*. <https://doi.org/10.1007/s11119-014-9372-7>
- Bekkar, M., Djemaa, H. K., & Alitouche, T. A. (2013). Evaluation Measures for Models Assessment over Imbalanced Data Sets. *Journal of Information Engineering and Applications*.
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Blekos, K., Tsakas, A., Xouris, C., Evdokidis, I., Alexandropoulos, D., Alexakos, C., Katakis, S., Makedonas, A., Theoharatos, C., & Lalos, A. (2021). Analysis, Modeling and Multi-Spectral Sensing for the Predictive Management of Verticillium Wilt in Olive Groves. *Journal of Sensor and Actuator Networks*, 10(1), 15. <https://doi.org/10.3390/jsan10010015>
- Bock, C. H., Poole, G. H., Parker, P. E., & Gottwald, T. R. (2010). Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Critical Reviews in Plant Sciences*, 29(2), 59–107. <https://doi.org/10.1080/07352681003617285>
- Brodersen, K. H., Ong, C. S., Stephan, K. E., & Buhmann, J. M. (2010). The balanced accuracy and its posterior distribution. *Proceedings - International Conference on Pattern Recognition*. <https://doi.org/10.1109/ICPR.2010.764>
- Buja, I., Sabella, E., Monteduro, A. G., Chiriaco, M. S., De Bellis, L., Luvisi, A., & Maruccio, G. (2021). Advances in Plant Disease Detection and Monitoring: From Traditional Assays to In-Field Diagnostics. *Sensors (Basel, Switzerland)*, 21(6), 1–22. <https://doi.org/10.3390/S21062129>
- Buriticá, P. (1999). *Directorio de patógenos y enfermedades de las plantas de importancia económica en Colombia*. <http://www.buritica-antioquia.gov.co/presentacion.shtml>
- Calderón, R., Montes-Borrego, M., Landa, B. B., Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2014). Detection of downy mildew of opium poppy using high-resolution multi-spectral and thermal imagery acquired with an unmanned aerial vehicle. *Precision Agriculture*, 15(6), 639–661. <https://doi.org/10.1007/s11119-014-9360-y>
- Calderón, Rocío, Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2015). Early detection and quantification of verticillium wilt in olive using hyperspectral and thermal imagery over large areas. *Remote Sensing*. <https://doi.org/10.3390/rs70505584>
- Campbell, J. B., & Wynne, R. H. (2011). Introduction to Remote Sensing FIFTH EDITION. In *Uma ética para quantos?* <https://doi.org/10.1007/s13398-014-0173-7.2>
- Cockerton, H. M., Li, B., Vickerstaff, R. J., Eyre, C. A., Sargent, D. J., Armitage, A. D., Marina-Montes, C., Garcia-Cruz, A., Passey, A. J., Simpson, D. W., & Harrison, R. J. (2019). Identifying Verticillium dahliae resistance in strawberry through disease

- screening of multiple populations and image based phenotyping. *Frontiers in Plant Science*. <https://doi.org/10.3389/fpls.2019.00924>
- Cortes, C., & Mohri, M. (2004). AUC optimization vs. Error rate minimization. *Advances in Neural Information Processing Systems*.
- Couture, J. J., Singh, A., Charkowski, A. O., Groves, R. L., Gray, S. M., Bethke, P. C., & Townsend, P. A. (2018). Integrating Spectroscopy with Potato Disease Management. *Plant Disease*, 102(11), 2233–2240. <https://doi.org/10.1094/pdis-01-18-0054-re>
- Dash, J. P., Watt, M. S., Pearse, G. D., Heaphy, M., & Dungey, H. S. (2017). Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 1–14. <https://doi.org/10.1016/j.isprsjprs.2017.07.007>
- Duarte-Carvajalino, J. M., Alzate, D. F., Ramirez, A. A., Santa-Sepulveda, J. D., Fajardo-Rojas, A. E., & Soto-Suárez, M. (2018). Evaluating late blight severity in potato crops using unmanned aerial vehicles and machine learning algorithms. *Remote Sensing*. <https://doi.org/10.3390/rs10101513>
- Dung, J. K. S., Ingram, J. T., Cummings, T. F., & Johnson, D. A. (2012). Impact of seed lot infection on the development of black dot and verticillium wilt of potato in Washington. *Plant Disease*. <https://doi.org/10.1094/PDIS-01-12-0061-RE>
- El Hoummadi, L., Larabi, A., & Alam, K. (2021). Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*, 7(10). <https://doi.org/10.1016/j.heliyon.2021.e08154>
- Fang, Y., & Ramasamy, R. P. (2015). Current and prospective methods for plant disease detection. In *Biosensors*. <https://doi.org/10.3390/bios5030537>
- FAOSTAT. (2020). *FAOSTAT: Statistical database*. FAOSTAT: Statistical Database. <https://www.fao.org/faostat/es/#home>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Ferri, C., Hernández-Orallo, J., & Modroui, R. (2009). An experimental comparison of performance measures for classification. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2008.08.010>
- Friedman, J., Hastie, T., & Tibshirani, R. (2000). Additive logistic regression: A statistical view of boosting. *Annals of Statistics*, 28(2), 337–407. <https://doi.org/10.1214/AOS/1016218223>
- Galieni, A., D'Ascenzo, N., Stagnari, F., Pagnani, G., Xie, Q., & Pisante, M. (2021). Past and Future of Plant Stress Detection: An Overview From Remote Sensing to Positron Emission Tomography. In *Frontiers in Plant Science* (Vol. 11, p. 1975). Frontiers Media S.A. <https://doi.org/10.3389/fpls.2020.609155>
- Garcia-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2012.12.002>
- Gholami, R., & Fakhari, N. (2017). Support Vector Machine: Principles, Parameters, and Applications. In *Handbook of Neural Computation* (pp. 515–535). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-811318-9.00027-2>
- Gibson-Poole, S., Humphris, S., Toth, I., & Hamilton, A. (2017). Identification of the onset of disease within a potato crop using a UAV equipped with un-modified and modified commercial off-the-shelf digital cameras. *Advances in Animal Biosciences*, 8(2), 812–816. <https://doi.org/10.1017/s204047001700084x>
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll

- assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A., & Merzlyak, M. N. (1996). Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. *Journal of Plant Physiology*, 148(3–4), 494–500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7)
- Gitelson, A. A., Merzlyak, M. N., & Chivkunova, O. B. (2001). Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. *Photochemistry and Photobiology*, 74(1), 38. [https://doi.org/10.1562/0031-8655\(2001\)074<0038:opaneo>2.0.co;2](https://doi.org/10.1562/0031-8655(2001)074<0038:opaneo>2.0.co;2)
- Gold, K. M., Townsend, P. A., Chlus, A., Herrmann, I., Couture, J. J., Larson, E. R., & Gevens, A. J. (2020). Hyperspectral measurements enable pre-symptomatic detection and differentiation of contrasting physiological effects of late blight and early blight in potato. *Remote Sensing*, 12(2), 286. <https://doi.org/10.3390/rs12020286>
- Gold, K. M., Townsend, P. A., Herrmann, I., & Gevens, A. J. (2020). Investigating potato late blight physiological differences across potato cultivars with spectroscopy and machine learning. *Plant Science*, 295, 110316. <https://doi.org/10.1016/j.plantsci.2019.110316>
- Gold, K. M., Townsend, P. A., Larson, E. R., Herrmann, I., & Gevens, A. J. (2020). Contact reflectance spectroscopy for rapid, accurate, and nondestructive phytophthora infestans clonal lineage discrimination. *Phytopathology*, 110(4), 851–862. <https://doi.org/10.1094/PHYTO-08-19-0294-R>
- Görllich, F., Marks, E., Mahlein, A. K., König, K., Lottes, P., & Stachniss, C. (2021). UAV-based classification of cercospora leaf spot using rgb images. *Drones*, 5(2), 34. <https://doi.org/10.3390/drones5020034>
- Hamylton, S. M., Morris, R. H., Carvalho, R. C., Roder, N., Barlow, P., Mills, K., & Wang, L. (2020). Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation and machine learning approaches. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2020.102085>
- Hasmedi, I., Pakhriazad, H., & Shahrin, M. (2009). Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Geografia - Malaysian Journal of Society and Space*.
- Honkavaara, E., Saari, H., Kaivosoja, J., Pölonen, I., Hakala, T., Litkey, P., Mäkyänen, J., & Pesonen, L. (2013). Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. *Remote Sensing*, 5(10), 5006–5039. <https://doi.org/10.3390/rs5105006>
- Hopkins, D. W. (2001). What is a Norris Derivative? *NIR News*, 12(3), 3–5. <https://doi.org/10.1255/nirn.611>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Hussain, T. (2016). Potatoes: Ensuring Food for the Future. *Advances in Plants & Agriculture Research*, 3(6). <https://doi.org/10.15406/apar.2016.03.00117>
- Imanian, K., Pourdarbani, R., Sabzi, S., García-Mateos, G., Arribas, J. I., & Molina-Martínez, J. M. (2021). Identification of internal defects in potato using spectroscopy and computational intelligence based on majority voting techniques. *Foods*, 10(5). <https://doi.org/10.3390/foods10050982>
- Jasiński, J., Pietrek, S., Walczykowski, P., & Orych, A. (2010). *Acquisition of spectral reflectance characteristics of land cover features based on hyperspectral images*. January.

- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, 112(10), 3833–3845. <https://doi.org/10.1016/j.rse.2008.06.006>
- Jing, R., Li, H., Hu, X., Shang, W., Shen, R., Guo, C., Guo, Q., & Subbarao, K. V. (2018). Verticillium wilt caused by verticillium dahliae and v. Nonalfalfae in potato in northern China. *Plant Disease*, 102(10), 1958–1964. <https://doi.org/10.1094/PDIS-01-18-0162-RE>
- Johnson, D. A., & Cummings, T. F. (2015). Effect of extended crop rotations on incidence of black dot, Silver scurf, and verticillium wilt of potato. *Plant Disease*, 99(2), 257–262. <https://doi.org/10.1094/PDIS-03-14-0271-RE>
- Johnson, D. A., Jeremiah, K., & Dung, S. (2010). Verticillium wilt of potato - The pathogen, disease and management. *Canadian Journal of Plant Pathology*. <https://doi.org/10.1080/07060661003621134>
- Junges, A. H., Almança, M. A. K., Fajardo, T. V. M., & Ducati, J. R. (2020). Leaf hyperspectral reflectance as a potential tool to detect diseases associated with vineyard decline. *Tropical Plant Pathology*, 45(5), 522–533. <https://doi.org/10.1007/s40858-020-00387-0>
- Kanti, M., Pradhan, R., & Sushan, S. (2010). Decision Tree Classification of Remotely Sensed Satellite Data using Spectral Separability Matrix. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2010.010516>
- Klosterman, S. J., Atallah, Z. K., Vallad, G. E., & Subbarao, K. V. (2009). Diversity, pathogenicity, and management of verticillium species. *Annual Review of Phytopathology*, 47, 39–62. <https://doi.org/10.1146/annurev-phyto-080508-081748>
- Kollist, H., Zandalinas, S. I., Sengupta, S., Nuhkat, M., Kangasjärvi, J., & Mittler, R. (2019). Rapid Responses to Abiotic Stress: Priming the Landscape for the Signal Transduction Network. In *Trends in Plant Science* (Vol. 24, Issue 1, pp. 25–37). Elsevier Ltd. <https://doi.org/10.1016/j.tplants.2018.10.003>
- Kong, W., Zhang, C., Huang, W., Liu, F., & He, Y. (2018). Application of hyperspectral imaging to detect Sclerotinia sclerotiorum on oilseed rape stems. *Sensors (Switzerland)*, 18(1). <https://doi.org/10.3390/s18010123>
- Kuang, B., Mahmood, H. S., Quraishi, M. Z., Hoogmoed, W. B., Mouazen, A. M., & van Henten, E. J. (2012). Sensing soil properties in the laboratory, in situ, and on-line. A review. In *Advances in Agronomy* (1st ed., Vol. 114, Issue October 2017). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-394275-3.00003-1>
- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, 28(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>
- Kuska, M. T., & Mahlein, A. K. (2018). Aiming at decision making in plant disease protection and phenotyping by the use of optical sensors. *European Journal of Plant Pathology*, 152(4), 987–992. <https://doi.org/10.1007/s10658-018-1464-1>
- Larkin, R. P., Honeycutt, C. W., & Olanya, O. M. (2011). Management of Verticillium Wilt of Potato with Disease-Suppressive Green Manures and as Affected by Previous Cropping History. *Plant Disease*. <https://doi.org/10.1094/pdis-09-10-0670>
- Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3–10. <https://doi.org/10.1016/j.gsf.2015.07.003>
- Lê, S., Josse, J., & Husson, F. (2008). FactoMineR: An R package for multivariate analysis. *Journal of Statistical Software*, 25(1), 1–18. <https://doi.org/10.18637/jss.v025.i01>
- León-Rueda, W. A., León, C., Caro, S. G., & Ramírez-Gil, J. G. (2022). Identification of

- diseases and physiological disorders in potato via multispectral drone imagery using machine learning tools. *Tropical Plant Pathology*, 47(1), 152–167.
<https://doi.org/10.1007/s40858-021-00460-2>
- Li, Haiyuan, Wang, Z., Hu, X., Shang, W., Shen, R., Guo, C., Guo, Q., & Subbarao, K. V. (2019). Assessment of resistance in potato cultivars to verticillium wilt caused by verticillium dahliae and verticillium nonalfalfae. *Plant Disease*, 103(6), 1357–1362.
<https://doi.org/10.1094/PDIS-10-18-1815-RE>
- Li, Hong, Yang, W., Lei, J., She, J., & Zhou, X. (2021). Estimation of leaf water content from hyperspectral data of different plant species by using three new spectral absorption indices. *PLoS ONE*, 16(3 March).
<https://doi.org/10.1371/journal.pone.0249351>
- Li, M., Zang, S., Zhang, B., Li, S., & Wu, C. (2014). A review of remote sensing image classification techniques: The role of Spatio-contextual information. *European Journal of Remote Sensing*, 47(1), 389–411.
<https://doi.org/10.5721/EuJRS20144723>
- Liao, P. S., Chen, T. S., & Chung, P. C. (2001). A fast algorithm for multilevel thresholding. *Journal of Information Science and Engineering*, 17(5), 713–727.
- Lillesand, T. M., & Kiefer, R. W. (2004). Remote sensing and image interpretation. In *Remote sensing and image interpretation*. <https://doi.org/10.2307/634969>
- Liu, C., Sun, P. Sen, & Liu, S. R. (2016). A review of plant spectral reflectance response to water physiological changes. *Chinese Journal of Plant Ecology*, 40(1), 80–91.
<https://doi.org/10.17521/cjpe.2015.0267>
- Liu, L., Dong, Y., Huang, W., Du, X., Ren, B., Huang, L., Zheng, Q., & Ma, H. (2020). A Disease Index for Efficiently Detecting Wheat Fusarium Head Blight Using Sentinel-2 Multispectral Imagery. *IEEE Access*, 8, 52181–52191.
<https://doi.org/10.1109/ACCESS.2020.2980310>
- Liu, X. (2003). Supervised Classification and Unsupervised Classification. *Cfa.Harvard.Edu*.
- Lizarazo, I., Rodriguez, J. L., Cristancho, O., Olaya, F., Duarte, M., & Prieto, F. (2023). Identification of symptoms related to potato Verticillium wilt from UAV-based multispectral imagery using an ensemble of gradient boosting machines. *Smart Agricultural Technology*, 3, 100138.
<https://doi.org/https://doi.org/10.1016/j.atech.2022.100138>
- Lizarazo Peña, P. A. (2020). Desarrollo , crecimiento y rendimiento de cultivares de papa diploide en ambientes contrastantes por altitud. In *Universidad Nacional de Colombia*.
<https://repositorio.unal.edu.co/bitstream/handle/unal/78234/1022359762.2020.pdf?sequence=1&isAllowed=y>
- Lowe, A., Harrison, N., & French, A. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. In *Plant Methods*. <https://doi.org/10.1186/s13007-017-0233-z>
- Lowe, B., & Kulkarni, A. (2015). Multispectral Image Analysis Using Random Forest. *International Journal on Soft Computing*. <https://doi.org/10.5121/ijsc.2015.6101>
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. In *International Journal of Remote Sensing*.
<https://doi.org/10.1080/01431160600746456>
- Lu, J., Ehsani, R., Shi, Y., de Castro, A. I., & Wang, S. (2018). Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Scientific Reports*, 8(1), 1–11.
<https://doi.org/10.1038/s41598-018-21191-6>

- Lu, N., Zhou, J., Han, Z., Li, D., Cao, Q., Yao, X., Tian, Y., Zhu, Y., Cao, W., & Cheng, T. (2019). Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. *Plant Methods*, 15(1), 17. <https://doi.org/10.1186/s13007-019-0402-3>
- Mahlein, A. K. (2016). Plant disease detection by imaging sensors – Parallels and specific demands for precision agriculture and plant phenotyping. In *Plant Disease* (Vol. 100, Issue 2, pp. 241–254). <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Mahlein, A. K., Kuska, M. T., Thomas, S., Bohnenkamp, D., Alisaac, E., Behmann, J., Wahabzada, M., & Kersting, K. (2017). Plant disease detection by hyperspectral imaging: from the lab to the field. *Advances in Animal Biosciences*. <https://doi.org/10.1017/s2040470017001248>
- Mahlein, A. K., Oerke, E. C., Steiner, U., & Dehne, H. W. (2012). Recent advances in sensing plant diseases for precision crop protection. In *European Journal of Plant Pathology*. <https://doi.org/10.1007/s10658-011-9878-z>
- Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., & Oerke, E. C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21–30. <https://doi.org/10.1016/j.rse.2012.09.019>
- Manici, L. M., & Cerato, C. (1994). Pathogenicity of *Fusarium oxysporum* f.sp. *tuberosi* isolates from tubers and potato plants. *Potato Research*, 37(2), 129–134. <https://doi.org/10.1007/BF02358713>
- Marín-Ortiz, J. C., Gutierrez-Toro, N., Botero-Fernández, V., & Hoyos-Carvajal, L. M. (2020). Linking physiological parameters with visible/near-infrared leaf reflectance in the incubation period of vascular wilt disease. *Saudi Journal of Biological Sciences*, 27(1), 88. <https://doi.org/10.1016/J.SJBS.2019.05.007>
- Mauromicale, G., Ierna, A., & Marchese, M. (2006). Chlorophyll fluorescence and chlorophyll content in field-grown potato as affected by nitrogen supply, genotype, and plant age. *Photosynthetica*, 44(1), 76–82. <https://doi.org/10.1007/S11099-005-0161-4>
- Meng, R., Lv, Z., Yan, J., Chen, G., Zhao, F., Zeng, L., & Xu, B. (2020). Development of spectral disease indices for southern corn rust detection and severity classification. *Remote Sensing*, 12(19), 1–16. <https://doi.org/10.3390/rs12193233>
- Mishra, P., Polder, G., & Vilfan, N. (2020). Close Range Spectral Imaging for Disease Detection in Plants Using Autonomous Platforms: a Review on Recent Studies. *Current Robotics Reports*, 1(2), 43–48. <https://doi.org/10.1007/s43154-020-00004-7>
- Mohapatra, S. K., & Mohanty, M. N. (2022). Big data classification with IoT-based application for e-health care. *Cognitive Big Data Intelligence with a Metaheuristic Approach*, 147–172. <https://doi.org/10.1016/B978-0-323-85117-6.00014-5>
- Mohseni-Dargah, M., Falahati, Z., Dabirmanesh, B., Nasrollahi, P., & Khajeh, K. (2022). Machine learning in surface plasmon resonance for environmental monitoring. In *Artificial Intelligence and Data Science in Environmental Sensing* (pp. 269–298). Academic Press. <https://doi.org/10.1016/B978-0-323-90508-4.00012-5>
- Mosley, L. S. D. (2013). A balanced approach to the multi-class imbalance problem. In *ProQuest Dissertations and Theses*.
- Motohka, T., Nasahara, K. N., Oguma, H., & Tsuchida, S. (2010). Applicability of Green-Red Vegetation Index for remote sensing of vegetation phenology. *Remote Sensing*, 2(10), 2369–2387. <https://doi.org/10.3390/rs2102369>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>

- Müller, A. C., & Guido, S. (2016). Introduction to Machine Learning with Python: a guide for data scientists. In *Journal of Chemical Information and Modeling*.
<https://doi.org/10.1017/CBO9781107415324.004>
- Mundt, C. C. (2019). The Study of Plant Disease Epidemics. *HortScience*, *44*(7), 2065b – 2065. <https://doi.org/10.21273/hortsci.44.7.2065b>
- Neupane, K., & Baysal-Gurel, F. (2021). Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review. In *Remote Sensing* (Vol. 13, Issue 19, p. 3841). Multidisciplinary Digital Publishing Institute.
<https://doi.org/10.3390/rs13193841>
- Nieto, L. E. (1988). La Madurez Prematura de la Papa Causada por *Verticillium* spp. en Colombia. *Revista ICA*, *4*, 334–340.
- Ning, F., Delhomme, D., LeCun, Y., Piano, F., Bottou, L., & Barbanò, P. E. (2005). Toward automatic phenotyping of developing embryos from videos. *IEEE Transactions on Image Processing*. <https://doi.org/10.1109/TIP.2005.852470>
- Oerke, E. C. (2020). Remote Sensing of Diseases. *Annual Review of Phytopathology*, *58*, 225–252. <https://doi.org/10.1146/annurev-phyto-010820-012832>
- Oerke, E. C., Mahlein, A. K., & Steiner, U. (2014). Proximal sensing of plant diseases. In *Detection and Diagnostics of Plant Pathogens* (pp. 55–68). Springer Netherlands.
https://doi.org/10.1007/978-94-017-9020-8_4
- Pandala, S. R. (2022). *lazypredict*. Python Software Foundation.
<https://pypi.org/project/lazypredict/>
- Patrick, A., Pelham, S., Culbreath, A., Corely Holbrook, C., De Godoy, I. J., & Li, C. (2017). High throughput phenotyping of tomato spot wilt disease in peanuts using unmanned aerial systems and multispectral imaging. *IEEE Instrumentation and Measurement Magazine*, *20*(3), 4–12. <https://doi.org/10.1109/MIM.2017.7951684>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, *12*(85), 2825–2830. <http://jmlr.org/papers/v12/pedregosa11a.html>
- Pourazar, H., Samadzadegan, F., Dadrass Javan, F., Giacomo, R., David, G., Gilbertson, J. K., Forum, P. O., Bouroubi, Y., Bugnet, P., Nguyen-xuan, T., Gosselin, C., Bélec, C., Longchamps, L., Vigneault, P., Ji, S., Zhang, C., Xu, A., Shi, Y., Duan, Y., ... Gore, M. A. (2017). Pest Detection on UAV Imagery using a Deep Convolutional Neural Network. *Remote Sensing*, *52*(19), 17–31.
<https://doi.org/10.3390/rs11192209>
- Powelson, M. L., & Rowe, R. C. (1993). Biology and management of early dying of potatoes. In *Annual Review of Phytopathology* (Vol. 31, pp. 111–126). Annual Reviews Inc. <https://doi.org/10.1146/annurev.py.31.090193.000551>
- Puletti, N., Perria, R., & Storchi, P. (2014). Unsupervised classification of very high remotely sensed images for grapevine rows detection. *European Journal of Remote Sensing*, *47*(1), 45–54. <https://doi.org/10.5721/EuJRS20144704>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, *48*(2), 119–126.
[https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Rahman, H. ur, Jabbar Ch, N., Manzoor, S., Najeeb, F., Siddique, M. Y., & Khan, R. A. (2017). A comparative analysis of machine learning approaches for plant disease identification. *Advancements in Life Sciences*, *4*(4), 120–126.
- Ramegowda, V., & Senthil-Kumar, M. (2015). The interactive effects of simultaneous biotic and abiotic stresses on plants: Mechanistic understanding from drought and

- pathogen combination. In *Journal of Plant Physiology* (Vol. 176, pp. 47–54). Urban und Fischer Verlag GmbH und Co. KG. <https://doi.org/10.1016/j.jplph.2014.11.008>
- Ramesh Reddy, D., Naga Santhosh, K., & Kodali, P. (2022). Convolutional Neural Networks for the Intuitive Identification of Plant Diseases. *5th International Conference on Inventive Computation Technologies, ICICT 2022 - Proceedings, 10*, 941. <https://doi.org/10.1109/ICICT54344.2022.9850695>
- Ramirez-Gil, J., Navas, J., & Gómez, S. (2019). Epidemiología e importancia económica de una alteración de origen desconocido en papa en la sabana occidente de Cundinamarca. *XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS*, 205–205.
- Ramirez Gil, J., Garcia, C., Navas, J., Leon, J., & Gómez, S. (2019). Implicaciones epidemiológicas y económicas de *Verticillium* sp., en una región productora de papa en Cundinamarca. *XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS*, 206–207.
- Raymundo, R., Asseng, S., Prasad, R., Kleinwechter, U., Concha, J., Condori, B., Bowen, W., Wolf, J., Olesen, J. E., Dong, Q., Zotarelli, L., Gastelo, M., Alva, A., Travasso, M., Quiroz, R., Arora, V., Graham, W., & Porter, C. (2017). Performance of the SUBSTOR-potato model across contrasting growing conditions. *Field Crops Research, 202*, 57–76. <https://doi.org/10.1016/j.fcr.2016.04.012>
- Ren, Y., Zhang, L., & Suganthan, P. N. (2016). Ensemble Classification and Regression-Recent Developments, Applications and Future Directions [Review Article]. In *IEEE Computational Intelligence Magazine* (Vol. 11, Issue 1, pp. 41–53). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/MCI.2015.2471235>
- Rodríguez, J., Lizarazo, I., Prieto, F., & Angulo-Morales, V. (2021). Assessment of potato late blight from UAV-based multispectral imagery. *Computers and Electronics in Agriculture, 184*, 106061. <https://doi.org/10.1016/j.compag.2021.106061>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS proceeding. *Third Earth Reserves Technology Satellite Symposium, Greenbelt: NASA SP-351, 30103017*, 317. <https://ui.adsabs.harvard.edu/abs/1974NASSP.351..309R/abstract>
- Rowe, R. C., & Powelson, M. L. (2002). Potato early dying: Management challenges in a changing production environment. In *Plant Disease* (Vol. 86, Issue 11, pp. 1184–1193). The American Phytopathological Society. <https://doi.org/10.1094/PDIS.2002.86.11.1184>
- Salamí, E., Barrado, C., & Pastor, E. (2014). UAV flight experiments applied to the remote sensing of vegetated areas. In *Remote Sensing* (Vol. 6, Issue 11, pp. 11051–11081). MDPI AG. <https://doi.org/10.3390/rs61111051>
- Sami, K., KC, K., John, F., Scott, S., & Erdal, O. (2020). Remote Sensing in Agriculture (Challenges and Opportunities). *Remote Sensing, 10*, 83–87.
- Sarić, R., Nguyen, V. D., Burge, T., Berkowitz, O., Trtílek, M., Whelan, J., Lewsey, M. G., & Čustović, E. (2022). Applications of hyperspectral imaging in plant phenotyping. In *Trends in Plant Science* (Vol. 27, Issue 3, pp. 301–315). Elsevier Current Trends. <https://doi.org/10.1016/j.tplants.2021.12.003>
- Sarkar, S. K., Das, J., Ehsani, R., & Kumar, V. (2016). Towards autonomous phytopathology: Outcomes and challenges of citrus greening disease detection through close-range remote sensing. *Proceedings - IEEE International Conference on Robotics and Automation, 2016-June*, 5143–5148. <https://doi.org/10.1109/ICRA.2016.7487719>
- Savitzky, A., & Golay, M. J. E. (1964). Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry, 36*(8), 1627–1639.

- <https://doi.org/10.1021/ac60214a047>
- Seetha, M., Muralikrishna, Deekshatulu, B. L., Malleswari, B. L., Nagaratna, & Hegde, P. (2008). Artificial Neural Networks and Other Methods of Image Classification. *Theoretical and Applied Information Technology*.
- Segarra, J., Buchailot, M. L., Araus, J. L., & Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5), 1–18. <https://doi.org/10.3390/agronomy10050641>
- Shammi, S., Soheli, F., Diepeveen, D., Zander, S., & Jones, M. G. K. (2022). A survey of image-based computational learning techniques for frost detection in plants. In *Information Processing in Agriculture*. Elsevier. <https://doi.org/10.1016/j.inpa.2022.02.003>
- Shattock, R. (2002). Compendium of Potato Diseases, Second Edition. W.R. Stevenson. *Plant Pathology*, 51(4), 520–520. <https://doi.org/10.1046/j.1365-3059.2002.06934.x>
- Shi, Y., Han, L., Kleerekoper, A., Chang, S., & Hu, T. (2022). Novel CropdocNet Model for Automated Potato Late Blight Disease Detection from Unmanned Aerial Vehicle-Based Hyperspectral Imagery. *Remote Sensing*, 14(2), 396. <https://doi.org/10.3390/rs14020396>
- Shin, M. Y., Gonzalez Viejo, C., Tongson, E., Wiechel, T., Taylor, P. W. J., & Fuentes, S. (2023). Early detection of Verticillium wilt of potatoes using near-infrared spectroscopy and machine learning modeling. *Computers and Electronics in Agriculture*, 204, 107567. <https://doi.org/10.1016/J.COMPAG.2022.107567>
- Shruthi, U., Nagaveni, V., & Raghavendra, B. K. (2019). A Review on Machine Learning Classification Techniques for Plant Disease Detection. *2019 5th International Conference on Advanced Computing and Communication Systems, ICACCS 2019*, 281–284. <https://doi.org/10.1109/ICACCS.2019.8728415>
- Simko, I., & Piepho, H. P. (2012). The area under the disease progress stairs: Calculation, advantage, and application. *Phytopathology*, 102(4), 381–389. <https://doi.org/10.1094/PHYTO-07-11-0216>
- Singh, A., & Kaur, H. (2021). Potato plant leaves disease detection and classification using machine learning methodologies. *IOP Conference Series: Materials Science and Engineering*, 1022(1). <https://doi.org/10.1088/1757-899X/1022/1/012121>
- Singh, V., Sharma, N., & Singh, S. (2020). A review of imaging techniques for plant disease detection. In *Artificial Intelligence in Agriculture* (Vol. 4, pp. 229–242). KeAi Communications Co. <https://doi.org/10.1016/j.aiaa.2020.10.002>
- Stehman, S. V., & Foody, G. M. (2008). Accuracy Assessment. In *The SAGE Handbook of Remote Sensing*. <https://doi.org/10.4135/9780857021052.n21>
- Stevens, A., & Ramirez Lopez, L. (2014). An introduction to the prospectr package. In *R Package Vignette, Report No.: R Package Version 0.1* (Vol. 3, Issue August 2013, pp. 1–22). <https://cran.r-project.org/web/packages/prospectr/vignettes/prospectr.html>
- Stevenson, W., Loria, R., Franc, G., & Weingartner, D. (2001). Compendium of Potato Diseases, Second Edition. *Phytopathological Society*. <https://doi.org/10.1046/j.1365-3059.2002.06934.x>
- Su, J., Yi, D., Coombes, M., Liu, C., Zhai, X., McDonald-Maier, K., & Chen, W. H. (2022). Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. *Computers and Electronics in Agriculture*, 192. <https://doi.org/10.1016/j.compag.2021.106621>
- Sugiura, R., Tsuda, S., Tamiya, S., Itoh, A., Nishiwaki, K., Murakami, N., Shibuya, Y., Hirafuji, M., & Nuske, S. (2016). Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering*. <https://doi.org/10.1016/j.biosystemseng.2016.04.010>

- Sun, W., & Du, Q. (2019). Hyperspectral band selection: A review. In *IEEE Geoscience and Remote Sensing Magazine* (Vol. 7, Issue 2, pp. 118–139). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/MGRS.2019.2911100>
- Suzuki, N., Rivero, R. M., Shulaev, V., Blumwald, E., & Mittler, R. (2014). Abiotic and biotic stress combinations. *New Phytologist*, 203(1), 32–43. <https://doi.org/10.1111/nph.12797>
- Tetila, E. C., Brandoli Machado, B., Belete, N. A. D. S., Guimaraes, D. A., & Pistori, H. (2017). Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. *IEEE Geoscience and Remote Sensing Letters*. <https://doi.org/10.1109/LGRS.2017.2743715>
- Thai, L. H., Hai, T. S., & Thuy, N. T. (2012). Image Classification using Support Vector Machine and Artificial Neural Network. *International Journal of Information Technology and Computer Science*. <https://doi.org/10.5815/ijitcs.2012.05.05>
- Tripathi, K., Vyas, R. G., & Gupta, A. K. (2019). Document Classification Using Artificial Neural Network. *Asian Journal of Computer Science and Technology*, 8(2), 55–58.
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. *Information (Switzerland)*, 10(11). <https://doi.org/10.3390/info10110349>
- van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., Yu, T., & the scikit-image contributors. (2014). scikit-image: image processing in {P}ython. *PeerJ*, 2, e453. <https://doi.org/10.7717/peerj.453>
- Vishnoi, V. K., Kumar, K., & Kumar, B. (2021). Plant disease detection using computational intelligence and image processing. In *Journal of Plant Diseases and Protection* (Vol. 128, Issue 1, pp. 19–53). Springer. <https://doi.org/10.1007/s41348-020-00368-0>
- Wan, L., Li, Y., Cen, H., Zhu, J., Yin, W., Wu, W., Zhu, H., Sun, D., Zhou, W., & He, Y. (2018). Combining UAV-based vegetation indices and image classification to estimate flower number in oilseed rape. *Remote Sensing*, 10(9), 1484. <https://doi.org/10.3390/rs10091484>
- Wang, C. ling, Shen, S. he, Zhang, S. yu, Li, Q. zhen, & Yao, Y. bi. (2015). Adaptation of potato production to climate change by optimizing sowing date in the Loess Plateau of central Gansu, China. *Journal of Integrative Agriculture*, 14(2), 398–409. [https://doi.org/10.1016/S2095-3119\(14\)60783-8](https://doi.org/10.1016/S2095-3119(14)60783-8)
- Wang, J., Lu, S., Wang, S. H., & Zhang, Y. D. (2021). A review on extreme learning machine. *Multimedia Tools and Applications*, 1–50. <https://doi.org/10.1007/s11042-021-11007-7>
- Wei, X., Johnson, M. A., Langston, D. B., Mehl, H. L., & Li, S. (2021). Identifying optimal wavelengths as disease signatures using hyperspectral sensor and machine learning. *Remote Sensing*, 13(14), 2833. <https://doi.org/10.3390/rs13142833>
- Xu, M., Watanachaturaporn, P., Varshney, P. K., & Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322–336. <https://doi.org/10.1016/j.rse.2005.05.008>
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. In *Journal of Sensors*. Hindawi Limited. <https://doi.org/10.1155/2017/1353691>
- Yan, Z., Ma, L., He, W., Zhou, L., Lu, H., Liu, G., & Huang, G. (2022). Comparing Object-Based and Pixel-Based Methods for Local Climate Zones Mapping with Multi-Source Data. *Remote Sensing*, 14(15). <https://doi.org/10.3390/rs14153744>
- Yang, C. M., Cheng, C. H., & Chen, R. K. (2007). Changes in spectral characteristics of rice canopy infested with brown planthopper and leafhopper. *Crop Science*.

- <https://doi.org/10.2135/cropsci2006.05.0335>
- Yeom, J., Jung, J., Chang, A., Ashapure, A., Maeda, M., Maeda, A., & Landivar, J. (2019). Comparison of vegetation indices derived from UAV data for differentiation of tillage effects in agriculture. *Remote Sensing*, *11*(13).
<https://doi.org/10.3390/rs11131548>
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. In *Precision Agriculture* (Vol. 13, Issue 6, pp. 693–712). Springer. <https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, H., Xu, F., Wu, Y., Hu, H. hai, & Dai, X. feng. (2017). Progress of potato staple food research and industry development in China. In *Journal of Integrative Agriculture* (Vol. 16, Issue 12, pp. 2924–2932). Elsevier.
[https://doi.org/10.1016/S2095-3119\(17\)61736-2](https://doi.org/10.1016/S2095-3119(17)61736-2)
- Zheng, H., Li, W., Jiang, J., Liu, Y., Cheng, T., Tian, Y., Zhu, Y., Cao, W., Zhang, Y., & Yao, X. (2018). A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, *10*(12).
<https://doi.org/10.3390/rs10122026>
- Zhou, X., Huang, W., Zhang, J., Kong, W., Casa, R., & Huang, Y. (2019). A novel combined spectral index for estimating the ratio of carotenoid to chlorophyll content to monitor crop physiological and phenological status. *International Journal of Applied Earth Observation and Geoinformation*, *76*, 128–142.
<https://doi.org/https://doi.org/10.1016/j.jag.2018.10.012>

4. Discusión general

La madurez temprana provocada por *Verticillium* spp. es una enfermedad limitante del suelo que ha generado reducción en la calidad y el número de tubérculos en plantas de papa, con pérdidas reportadas entre el 10 a 50% (Klosterman et al., 2009; Larkin et al., 2011; Powelson & Rowe, 1993). Las pérdidas causadas por la enfermedad dependen de las condiciones ambientales, siendo severas bajo estrés por altas temperaturas y tasas de evapotranspiración (Stevenson et al., 2001). En cultivos tradicionales, la enfermedad se logra identificar en estados tardíos (Johnson et al., 2010) con una distribución espacial en focos, asociando la presencia de clorosis intervenal en hojas del tercio inferior, posteriormente se marchitan y necrosan de forma acropétala desde la base del tallo (Rowe & Powelson, 2002). En los últimos años se ha incursionado en el uso de técnicas de detección temprana de agentes causales de enfermedades mediante datos adquiridos por diferentes tipos de sensores (Buja et al., 2021; Galieni et al., 2021; Segarra et al., 2020; Singh et al., 2020; Tsouros et al., 2019). Se plantea que los análisis detallados de datos obtenidos por estos dispositivos de los procesos de infección permiten realizar una detección temprana, identificación y cuantificación de diferentes enfermedades vegetales relevantes, los cuales, dependiendo de la escala de medición, pueden ser tan sensibles como para detectar estados tempranos de diversas alteraciones en los cultivos (A. Lowe et al., 2017; Mahlein, 2016; Mahlein et al., 2017).

En esta investigación se abordaron diversos enfoques para la detección y clasificación de plantas de papa con sintomatologías asociadas a madurez temprana causadas por *Verticillium* spp., y realizar una aproximación a la cuantificación indirecta de la severidad. Para lograr cumplir los objetivos se compararon diversos algoritmos para clasificar datos asociados a plantas con diferentes grados de MT bajo dos condiciones de crecimiento utilizando firmas e imágenes espectrales, algunas investigaciones han abordado el tema mostrando resultados prometedores (León-Rueda et al., 2022; Lizarazo et al., 2023; Shin et al., 2023). En general los dos enfoques utilizados fueron funcionales, sin embargo se observó una mayor capacidad de discriminación de los algoritmos usando datos capturados con firmas espectrales, esto concuerda con lo presentado por diversos autores (Singh et al., 2020; Wei et al., 2021), los cuales identifican que el uso de métodos de selección de características múltiples o un conjunto de métodos múltiples tienen alto grado de especificidad debido a que las longitudes de onda seleccionadas son identificadas de manera individual, discriminando zonas con alto potencial de clasificación (Singh & Kaur, 2021; Wei et al., 2021). Este enfoque permite obtener mayores tasas de exactitud en las

clasificaciones. Con respecto a MT, Shin et al., (2023) reportan tasas de clasificación cercanas al 80% usando firmas espectrales en el área del NIR, las cuales son similares a las encontradas en esta investigación.

El uso de preprocesamiento de datos fue clave en el desarrollo de este estudio, ya que indistintamente de la fuente de datos, estos procesos mejoran tanto la capacidad de clasificación como el tiempo de procesamiento. Este trabajo demuestra que el uso de *GAP segment* como tratamiento previo de los datos de firmas espectrales puede mejorar los resultados al usar técnicas discriminantes básicas usadas tradicionalmente como los PCA, ya que permite una mayor diferenciación de las áreas espectrales evaluadas y con capacidad de diferenciación (Kong et al., 2018; Wei et al., 2021). Por su parte se identificó que, para el caso del enfoque de imágenes espectrales, el uso de la segmentación *Multio utsu* favorece las tasas de clasificación realizadas en las imágenes. En este sentido algunos autores reportan este mismo efecto (Ning et al., 2005; Rodríguez et al., 2021). Es importante tener en cuenta el algoritmo que se utilizara para este proceso, ya que se debe evitar la pérdida de información útil en los diferentes procedimientos que se realizan en las investigaciones o aplicaciones con imágenes capturadas con VANT.

Sin importar la fuente de datos y los algoritmos de clasificación utilizados se identificó un comportamiento similar en términos de exactitud para presencia y severidad de MT, logrando obtener tasas de clasificación entre 70 y 80% para todos los casos, sin embargo, las métricas de evaluación para los niveles bajos de severidad respecto a la escala usada (1 y 2) se vieron afectadas negativamente, mostrando dificultad en su clasificación, por lo que esto se convierte en el reto para futuras investigaciones relacionadas con MT (Shin et al., 2023). Los algoritmos usados en este estudio tienen enfoques de clasificación que son tan sensibles y específicos que logran clasificar las clases de la escala utilizada, lo cual muestra su uso potencial como herramientas en la detección de MT en plantas de papa (Duarte-Carvajalino et al., 2018; Lizarazo et al., 2023; Rodríguez et al., 2021). Estos métodos identificaron longitudes de onda similares respecto a la clasificación de presencia y severidad de MT sin importar las fuentes de datos y el enfoque de detección usado. Principalmente se identificó un aumento en la región del espectro visible (400 a 700 nm) en las plantas enfermas, lo que sugiere una disminución de pigmentos como la clorofila y los carotenoides en las hojas de papa (Marín-Ortiz et al., 2020). Por su parte, la región correspondiente al rojo fue la de más relevancia en todos los casos, zona que está controlada únicamente por la clorofila a (Gitelson & Merzlyak, 1996), En esta región encontramos que tuvo comportamiento diferencial entre plantas con presencia de síntomas. Este resultado sugiere que el uso de sensores que obtienen información en el espectro visible pueden ser una opción viable para la detección en campo de esta enfermedad en los cultivos de papa.

La posibilidad de comparar diversos sensores debe ser la base para el desarrollo de investigaciones enfocadas a la detección de enfermedades en plantas ya que permitió identificar desde diferentes enfoques algunos factores informativos asociados a la identificación de las patologías como las inducidas por MT a partir de datos

espectrales. En relación con las firmas espectrales, las bandas identificadas en esta investigación han sido reportadas en diferentes cultivos por su capacidad discriminante (Gold, Townsend, Chlus, et al., 2020; Gold, Townsend, Larson, et al., 2020; Wei et al., 2021), principalmente se relacionan con la disminución en los pigmentos como la clorofila y los carotenoides, el contenido de agua y la acumulación de azúcares. Bajo el presente trabajo se identificó el aumento de la reflectancia de las hojas de plantas afectadas por MT en las bandas a partir de los 1500 nm principalmente en la clasificación de severidad, esto plantea una posible afectación en el contenido de agua de las plantas evaluadas, este resultado coincide con los reportado por Shin et al., (2023). Algunas bandas identificadas como importantes también se encuentran ubicadas en la región relacionada con la estructura de la hoja (780 a 1450 nm), el contenido de agua y la acumulación de azúcares y almidón (>1500 nm) (Li et al., 2021). Además, las longitudes de onda de 1660 nm y 2200 nm están asociadas con compuestos fenólicos que pueden acumularse en la célula en respuesta a patógenos (Junges et al., 2020; Shin et al., 2023).

La posibilidad de identificar bandas y zonas con capacidad de diferenciación permitieron el desarrollo de un índice asociado a la enfermedad y propuesto en este trabajo como el VWI. En cuanto a sus resultados, estos fueron aceptables, ya que tuvo una importancia considerable en el desarrollo de los modelos con datos de firmas espectrales y valores puntuales extraídos de las imágenes multiespectrales, sin embargo, su aplicación en campo se vio limitada por la saturación de valores, lo que indica la necesidad de hacer ajuste en futuros trabajos. A pesar de esto, las bandas usadas en el índice pueden ser funcionales para la detección de MT, en especial porque fue uno de los índices con mejor variación o transmisión del error al realizar su evaluación bajo distintas condiciones, como por ejemplo lotes contrastantes y variaciones espaciales dentro de los lotes.

Los resultados de las clasificaciones a partir de imágenes multiespectrales mostraron que las bandas capturadas por el sensor en especial el rojo, NIR y Rededge influyen de manera importante en las tasas de clasificación, este resultado era esperado, ya que a partir de los de los modelos con firmas espectrales las variables importantes estaban ubicadas en esta región del espectro. En consecuencia, los índices espectrales relacionados con las regiones del rojo, infrarrojo cercano y borde rojo fueron los más importantes, esto concuerda con lo reportado por diversos autores (León-Rueda et al., 2022; Lizarazo et al., 2023). Dentro de estos, dos índices NDRE y RECI, tienen en cuenta una banda del borde del rojo que se relaciona con la absorción de las clorofilas, por lo cual sus valores se ven más afectados por cambios en sus contenidos dentro de las plantas (Gitelson et al., 2003). Lo anterior se relaciona con los síntomas de clorosis encontrados en las hojas en las plantas afectadas por *Verticillium*. Estos índices espectrales pueden utilizarse como una potencial herramienta para detectar el comienzo de los brotes de la enfermedad y guiar la aplicación de tácticas de gestión. Otros índices relacionados con el contenido de compuestos en las plantas fueron identificados como importantes (Gitelson et al., 2001; Zhou et al., 2019), esto puede deberse a que los síntomas de la enfermedad causan alteraciones en las plantas que modifican los procesos químicos de las mismas, como los

índices ARI y CARI (Gitelson et al., 2001; Zhou et al., 2019), los cuales pueden ser opción para la cuantificación del nivel de los cambios presentados por MT en las plantas de papa.

En comparación con patógenos foliares, los cuales tienen una interacción directa con las hojas de la planta, la infección de patógenos de suelo afectan primero la raíz o el sistema vascular de las plantas antes de inducir cualquier síntoma foliar (Wei et al., 2021), por lo cual los síntomas que se observan en la parte aérea son expresiones avanzadas de la enfermedad, limitando el alcance de las herramientas para la detección de la alteración en estados iniciales de infección en las plantas (León-Rueda et al., 2022; Lizarazo et al., 2023; Rodríguez et al., 2021).

En resumen, el uso de datos espectrales para la detección de enfermedades de la papa puede ser una herramienta valiosa para agricultores e investigadores. Sin embargo, es importante tener en cuenta que estos métodos requieren un cierto nivel de conocimientos técnicos para su aplicación. Esta investigación generó información para el desarrollo de estrategias enfocadas al uso de sensores en cultivos de papa como herramienta de detección y una base preliminar para el desarrollo de sensores con bandas específicas que permitan identificar de manera oportuna síntomas de MT en el cultivo, mostrando el impacto que puede tener las nuevas tecnologías en el cultivo de papa y el sector agrícola en general.

5.Recomendaciones

- Los futuros estudios que pretendan detectar las enfermedades de las plantas durante las primeras etapas de la infección pueden incorporar algunas evaluaciones relacionadas con factores abióticos que favorezcan el desarrollo de la enfermedad y la planta, las cuales pueden ser indicativos de la infección en estados iniciales de la enfermedad.
- Para cualquier caso de detección de enfermedades en el cultivo de papa con sensores remotos se recomienda evaluar técnicas que permitan la estimación del dosel de la planta para obtener mayor precisión en la comparación por individuo.
- Se sugiere seguir investigando en establecer relaciones entre datos obtenidos bajo condiciones controladas y de campo para generar mecanismos de detección indirecta para MT que sean aplicables a las condiciones comerciales del cultivo de papa, teniendo en cuenta variables bióticas y abióticas que permitan estimar el desarrollo y afectación en estados tempranos de la enfermedad.
- Se recomienda seguir explorando enfoques de aprendizaje automático ya que proveen herramientas de procesamiento ágil y con alta exactitud en relación con los datos evaluados en campo.

6. Bibliografía

- Aasen, H., Honkavaara, E., Lucieer, A., & Zarco-Tejada, P. J. (2018). Quantitative remote sensing at ultra-high resolution with UAV spectroscopy: A review of sensor technology, measurement procedures, and data correction workflows. In *Remote Sensing* (Vol. 10, Issue 7, p. 1091). Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/rs10071091>
- Abdulridha, J., Ampatzidis, Y., Kakarla, S. C., & Roberts, P. (2020). Detection of target spot and bacterial spot diseases in tomato using UAV-based and benchtop-based hyperspectral imaging techniques. *Precision Agriculture*, 21(5), 955–978. <https://doi.org/10.1007/s11119-019-09703-4>
- Aggarwal, N., Srivastava, M., & Dutta, M. (2016). Comparative Analysis of Pixel-Based and Object-Based Classification of High Resolution Remote Sensing Images – A Review. *International Journal of Engineering Trends and Technology*, 38(1), 5–11. <https://doi.org/10.14445/22315381/ijett-v38p202>
- Agilandeewari, L., Prabukumar, M., Radhesyam, V., Phaneendra, K. L. N. B., & Farhan, A. (2022). Crop Classification for Agricultural Applications in Hyperspectral Remote Sensing Images. *Applied Sciences*, 12(3). <https://doi.org/10.3390/app12031670>
- Agronet. (2018). Agronet. <http://www.agronet.gov.co/estadistica/Paginas/default.aspx>
- Al-Saddik, H., Simon, J. C., & Cointault, F. (2017). Development of spectral disease indices for 'flavescence dorée' grapevine disease identification. *Sensors (Switzerland)*, 17(12). <https://doi.org/10.3390/s17122772>
- AlAfyandy, K. A., Omara, H., Lazaar, M., & Al Achhab, M. (2019, October 23). Artificial neural networks optimization and convolution neural networks to classifying images in remote sensing: A review. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3372938.3372945>
- Albetis, J., Jacquin, A., Goulard, M., Poilvé, H., Rousseau, J., Clenet, H., Dedieu, G., & Duthoit, S. (2019). On the potentiality of UAV multispectral imagery to detect Flavescence dorée and Grapevine Trunk Diseases. *Remote Sensing*, 11(1). <https://doi.org/10.3390/rs11010023>
- Ali, M. M., Bachik, N. A., Muhadi, N., 'Atirah, Tuan Yusof, T. N., & Gomes, C. (2019). Non-destructive techniques of detecting plant diseases: A review. In *Physiological and Molecular Plant Pathology* (Vol. 108). Academic Press. <https://doi.org/10.1016/j.pmpp.2019.101426>
- Antunes, E., Vuppaladadiyam, A. K., Sarmah, A. K., Varsha, S. S. V., Pant, K. K., Tiwari, B., & Pandey, A. (2021). Application of biochar for emerging contaminant mitigation. In *Advances in Chemical Pollution, Environmental Management and Protection* (Vol. 7, pp. 65–91). Elsevier. <https://doi.org/10.1016/bs.apmp.2021.08.003>
- Arneson, P. A. (2001). Plant Disease Epidemiology. *The Plant Health Instructor*,

- <https://www.apsnet.org/edcenter/disimpactmngmnt/to>. <https://doi.org/10.1094/PHI-A-2001-0524-01>
- Ashourloo, D., Aghighi, H., Matkan, A. A., Mobasheri, M. R., & Rad, A. M. (2016). An Investigation Into Machine Learning Regression Techniques for the Leaf Rust Disease Detection Using Hyperspectral Measurement. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 9(9), 4344–4351. <https://doi.org/10.1109/JSTARS.2016.2575360>
- Ashraf, A., Rauf, A., Fahim Abbas, M., & Rehman, R. (2012). ISOLATION AND IDENTIFICATION OF VERTICILLIUM DAHLIAE CAUSING WILT ON POTATO IN PAKISTAN. *J. Phytopathol*, 24(2), 112–116.
- Baldi, P., & La Porta, N. (2020). Molecular Approaches for Low-Cost Point-of-Care Pathogen Detection in Agriculture and Forestry. In *Frontiers in Plant Science* (Vol. 11). Frontiers Media SA. <https://doi.org/10.3389/fpls.2020.570862>
- Barbedo, J. G. A. (2019). A review on the use of unmanned aerial vehicles and imaging sensors for monitoring and assessing plant stresses. *Drones*, 3(2), 1–27. <https://doi.org/10.3390/drones3020040>
- Behmann, J., Mahlein, A. K., Rumpf, T., Römer, C., & Plümer, L. (2015). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. In *Precision Agriculture*. <https://doi.org/10.1007/s11119-014-9372-7>
- Bekkar, M., Djemaa, H. K., & Alitouche, T. A. (2013). Evaluation Measures for Models Assessment over Imbalanced Data Sets. *Journal of Information Engineering and Applications*.
- Belgiu, M., & Drăgu, L. (2016). Random forest in remote sensing: A review of applications and future directions. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- Blekos, K., Tsakas, A., Xouris, C., Evdokidis, I., Alexandropoulos, D., Alexakos, C., Katakis, S., Makedonas, A., Theoharatos, C., & Lalos, A. (2021). Analysis, Modeling and Multi-Spectral Sensing for the Predictive Management of Verticillium Wilt in Olive Groves. *Journal of Sensor and Actuator Networks*, 10(1), 15. <https://doi.org/10.3390/jsan10010015>
- Bock, C. H., Poole, G. H., Parker, P. E., & Gottwald, T. R. (2010). Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Critical Reviews in Plant Sciences*, 29(2), 59–107. <https://doi.org/10.1080/07352681003617285>
- Brodersen, K. H., Ong, C. S., Stephan, K. E., & Buhmann, J. M. (2010). The balanced accuracy and its posterior distribution. *Proceedings - International Conference on Pattern Recognition*. <https://doi.org/10.1109/ICPR.2010.764>
- Buja, I., Sabella, E., Monteduro, A. G., Chiriaco, M. S., De Bellis, L., Luvisi, A., & Maruccio, G. (2021). Advances in Plant Disease Detection and Monitoring: From Traditional Assays to In-Field Diagnostics. *Sensors (Basel, Switzerland)*, 21(6), 1–22. <https://doi.org/10.3390/S21062129>
- Buriticá, P. (1999). *Directorio de patógenos y enfermedades de las plantas de importancia económica en Colombia*. <http://www.buritica-antioquia.gov.co/presentacion.shtml>
- Calderón, R., Montes-Borrego, M., Landa, B. B., Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2014). Detection of downy mildew of opium poppy using high-resolution multi-spectral and thermal imagery acquired with an unmanned aerial vehicle. *Precision Agriculture*, 15(6), 639–661. <https://doi.org/10.1007/s11119-014-9360-y>
- Calderón, Rocío, Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2015). Early detection and quantification of verticillium wilt in olive using hyperspectral and thermal imagery over

- large areas. *Remote Sensing*. <https://doi.org/10.3390/rs70505584>
- Campbell, J. B., & Wynne, R. H. (2011). Introduction to Remote Sensing FIFTH EDITION. In *Uma ética para quantos?* <https://doi.org/10.1007/s13398-014-0173-7.2>
- Cockerton, H. M., Li, B., Vickerstaff, R. J., Eyre, C. A., Sargent, D. J., Armitage, A. D., Marina-Montes, C., Garcia-Cruz, A., Passey, A. J., Simpson, D. W., & Harrison, R. J. (2019). Identifying *Verticillium dahliae* resistance in strawberry through disease screening of multiple populations and image based phenotyping. *Frontiers in Plant Science*. <https://doi.org/10.3389/fpls.2019.00924>
- Cortes, C., & Mohri, M. (2004). AUC optimization vs. Error rate minimization. *Advances in Neural Information Processing Systems*.
- Couture, J. J., Singh, A., Charkowski, A. O., Groves, R. L., Gray, S. M., Bethke, P. C., & Townsend, P. A. (2018). Integrating Spectroscopy with Potato Disease Management. *Plant Disease*, 102(11), 2233–2240. <https://doi.org/10.1094/pdis-01-18-0054-re>
- Dash, J. P., Watt, M. S., Pearse, G. D., Heaphy, M., & Dungey, H. S. (2017). Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. *ISPRS Journal of Photogrammetry and Remote Sensing*, 131, 1–14. <https://doi.org/10.1016/j.isprsjprs.2017.07.007>
- Duarte-Carvajalino, J. M., Alzate, D. F., Ramirez, A. A., Santa-Sepulveda, J. D., Fajardo-Rojas, A. E., & Soto-Suárez, M. (2018). Evaluating late blight severity in potato crops using unmanned aerial vehicles and machine learning algorithms. *Remote Sensing*. <https://doi.org/10.3390/rs10101513>
- Dung, J. K. S., Ingram, J. T., Cummings, T. F., & Johnson, D. A. (2012). Impact of seed lot infection on the development of black dot and verticillium wilt of potato in Washington. *Plant Disease*. <https://doi.org/10.1094/PDIS-01-12-0061-RE>
- El Hoummadi, L., Larabi, A., & Alam, K. (2021). Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon*, 7(10). <https://doi.org/10.1016/j.heliyon.2021.e08154>
- Fang, Y., & Ramasamy, R. P. (2015). Current and prospective methods for plant disease detection. In *Biosensors*. <https://doi.org/10.3390/bios5030537>
- FAOSTAT. (2020). *FAOSTAT: Statistical database*. FAOSTAT: Statistical Database. <https://www.fao.org/faostat/es/#home>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Ferri, C., Hernández-Orallo, J., & Modroui, R. (2009). An experimental comparison of performance measures for classification. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2008.08.010>
- Friedman, J., Hastie, T., & Tibshirani, R. (2000). Additive logistic regression: A statistical view of boosting. *Annals of Statistics*, 28(2), 337–407. <https://doi.org/10.1214/AOS/1016218223>
- Galieni, A., D'Ascenzo, N., Stagnari, F., Pagnani, G., Xie, Q., & Pisante, M. (2021). Past and Future of Plant Stress Detection: An Overview From Remote Sensing to Positron Emission Tomography. In *Frontiers in Plant Science* (Vol. 11, p. 1975). Frontiers Media S.A. <https://doi.org/10.3389/fpls.2020.609155>
- Garcia-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*. <https://doi.org/10.1016/j.compag.2012.12.002>
- Gholami, R., & Fakhari, N. (2017). Support Vector Machine: Principles, Parameters, and Applications. In *Handbook of Neural Computation* (pp. 515–535). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-811318-9.00027-2>

- Gibson-Poole, S., Humphris, S., Toth, I., & Hamilton, A. (2017). Identification of the onset of disease within a potato crop using a UAV equipped with un-modified and modified commercial off-the-shelf digital cameras. *Advances in Animal Biosciences*, 8(2), 812–816. <https://doi.org/10.1017/s204047001700084x>
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A., & Merzlyak, M. N. (1996). Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. *Journal of Plant Physiology*, 148(3–4), 494–500. [https://doi.org/10.1016/S0176-1617\(96\)80284-7](https://doi.org/10.1016/S0176-1617(96)80284-7)
- Gitelson, A. A., Merzlyak, M. N., & Chivkunova, O. B. (2001). Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. *Photochemistry and Photobiology*, 74(1), 38. [https://doi.org/10.1562/0031-8655\(2001\)074<0038:opaneo>2.0.co;2](https://doi.org/10.1562/0031-8655(2001)074<0038:opaneo>2.0.co;2)
- Gold, K. M., Townsend, P. A., Chlus, A., Herrmann, I., Couture, J. J., Larson, E. R., & Gevens, A. J. (2020). Hyperspectral measurements enable pre-symptomatic detection and differentiation of contrasting physiological effects of late blight and early blight in potato. *Remote Sensing*, 12(2), 286. <https://doi.org/10.3390/rs12020286>
- Gold, K. M., Townsend, P. A., Herrmann, I., & Gevens, A. J. (2020). Investigating potato late blight physiological differences across potato cultivars with spectroscopy and machine learning. *Plant Science*, 295, 110316. <https://doi.org/10.1016/j.plantsci.2019.110316>
- Gold, K. M., Townsend, P. A., Larson, E. R., Herrmann, I., & Gevens, A. J. (2020). Contact reflectance spectroscopy for rapid, accurate, and nondestructive phytophthora infestans clonal lineage discrimination. *Phytopathology*, 110(4), 851–862. <https://doi.org/10.1094/PHYTO-08-19-0294-R>
- Görlich, F., Marks, E., Mahlein, A. K., König, K., Lottes, P., & Stachniss, C. (2021). Uav-based classification of cercospora leaf spot using rgb images. *Drones*, 5(2), 34. <https://doi.org/10.3390/drones5020034>
- Hamylton, S. M., Morris, R. H., Carvalho, R. C., Roder, N., Barlow, P., Mills, K., & Wang, L. (2020). Evaluating techniques for mapping island vegetation from unmanned aerial vehicle (UAV) images: Pixel classification, visual interpretation and machine learning approaches. *International Journal of Applied Earth Observation and Geoinformation*. <https://doi.org/10.1016/j.jag.2020.102085>
- Hasmadi, I., Pakhriazad, H., & Shahrin, M. (2009). Evaluating supervised and unsupervised techniques for land cover mapping using remote sensing data. *Geografia - Malaysian Journal of Society and Space*.
- Honkavaara, E., Saari, H., Kaivosoja, J., Pölönen, I., Hakala, T., Litkey, P., Mäkynen, J., & Pesonen, L. (2013). Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. *Remote Sensing*, 5(10), 5006–5039. <https://doi.org/10.3390/rs5105006>
- Hopkins, D. W. (2001). What is a Norris Derivative? *NIR News*, 12(3), 3–5. <https://doi.org/10.1255/nirn.611>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Hussain, T. (2016). Potatoes: Ensuring Food for the Future. *Advances in Plants & Agriculture Research*, 3(6). <https://doi.org/10.15406/apar.2016.03.00117>
- Imanian, K., Pourdarbani, R., Sabzi, S., García-Mateos, G., Arribas, J. I., & Molina-

- Martínez, J. M. (2021). Identification of internal defects in potato using spectroscopy and computational intelligence based on majority voting techniques. *Foods*, *10*(5). <https://doi.org/10.3390/foods10050982>
- Jasiński, J., Pietrek, S., Walczykowski, P., & Orych, A. (2010). *Acquisition of spectral reflectance characteristics of land cover features based on hyperspectral images*. January.
- Jiang, Z., Huete, A. R., Didan, K., & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*, *112*(10), 3833–3845. <https://doi.org/10.1016/j.rse.2008.06.006>
- Jing, R., Li, H., Hu, X., Shang, W., Shen, R., Guo, C., Guo, Q., & Subbarao, K. V. (2018). Verticillium wilt caused by verticillium dahliae and v. Nonalfalfae in potato in northern China. *Plant Disease*, *102*(10), 1958–1964. <https://doi.org/10.1094/PDIS-01-18-0162-RE>
- Johnson, D. A., & Cummings, T. F. (2015). Effect of extended crop rotations on incidence of black dot, Silver scurf, and verticillium wilt of potato. *Plant Disease*, *99*(2), 257–262. <https://doi.org/10.1094/PDIS-03-14-0271-RE>
- Johnson, D. A., Jeremiah, K., & Dung, S. (2010). Verticillium wilt of potato - The pathogen, disease and management. *Canadian Journal of Plant Pathology*. <https://doi.org/10.1080/07060661003621134>
- Junges, A. H., Almança, M. A. K., Fajardo, T. V. M., & Ducati, J. R. (2020). Leaf hyperspectral reflectance as a potential tool to detect diseases associated with vineyard decline. *Tropical Plant Pathology*, *45*(5), 522–533. <https://doi.org/10.1007/s40858-020-00387-0>
- Kanti, M., Pradhan, R., & Sushan, S. (2010). Decision Tree Classification of Remotely Sensed Satellite Data using Spectral Separability Matrix. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2010.010516>
- Klosterman, S. J., Atallah, Z. K., Vallad, G. E., & Subbarao, K. V. (2009). Diversity, pathogenicity, and management of verticillium species. *Annual Review of Phytopathology*, *47*, 39–62. <https://doi.org/10.1146/annurev-phyto-080508-081748>
- Kollist, H., Zandalinas, S. I., Sengupta, S., Nuhkat, M., Kangasjärvi, J., & Mittler, R. (2019). Rapid Responses to Abiotic Stress: Priming the Landscape for the Signal Transduction Network. In *Trends in Plant Science* (Vol. 24, Issue 1, pp. 25–37). Elsevier Ltd. <https://doi.org/10.1016/j.tplants.2018.10.003>
- Kong, W., Zhang, C., Huang, W., Liu, F., & He, Y. (2018). Application of hyperspectral imaging to detect Sclerotinia sclerotiorum on oilseed rape stems. *Sensors (Switzerland)*, *18*(1). <https://doi.org/10.3390/s18010123>
- Kuang, B., Mahmood, H. S., Quraishi, M. Z., Hoogmoed, W. B., Mouazen, A. M., & van Henten, E. J. (2012). Sensing soil properties in the laboratory, in situ, and on-line. A review. In *Advances in Agronomy* (1st ed., Vol. 114, Issue October 2017). Elsevier Inc. <https://doi.org/10.1016/B978-0-12-394275-3.00003-1>
- Kuhn, M. (2008). Building predictive models in R using the caret package. *Journal of Statistical Software*, *28*(5), 1–26. <https://doi.org/10.18637/jss.v028.i05>
- Kuska, M. T., & Mahlein, A. K. (2018). Aiming at decision making in plant disease protection and phenotyping by the use of optical sensors. *European Journal of Plant Pathology*, *152*(4), 987–992. <https://doi.org/10.1007/s10658-018-1464-1>
- Larkin, R. P., Honeycutt, C. W., & Olanya, O. M. (2011). Management of Verticillium Wilt of Potato with Disease-Suppressive Green Manures and as Affected by Previous Cropping History. *Plant Disease*. <https://doi.org/10.1094/pdis-09-10-0670>
- Lary, D. J., Alavi, A. H., Gandomi, A. H., & Walker, A. L. (2016). Machine learning in

- geosciences and remote sensing. *Geoscience Frontiers*, 7(1), 3–10.
<https://doi.org/10.1016/j.gsf.2015.07.003>
- Lê, S., Josse, J., & Husson, F. (2008). FactoMineR: An R package for multivariate analysis. *Journal of Statistical Software*, 25(1), 1–18.
<https://doi.org/10.18637/jss.v025.i01>
- León-Rueda, W. A., León, C., Caro, S. G., & Ramírez-Gil, J. G. (2022). Identification of diseases and physiological disorders in potato via multispectral drone imagery using machine learning tools. *Tropical Plant Pathology*, 47(1), 152–167.
<https://doi.org/10.1007/s40858-021-00460-2>
- Li, Haiyuan, Wang, Z., Hu, X., Shang, W., Shen, R., Guo, C., Guo, Q., & Subbarao, K. V. (2019). Assessment of resistance in potato cultivars to verticillium wilt caused by verticillium dahliae and verticillium nonalfalfae. *Plant Disease*, 103(6), 1357–1362.
<https://doi.org/10.1094/PDIS-10-18-1815-RE>
- Li, Hong, Yang, W., Lei, J., She, J., & Zhou, X. (2021). Estimation of leaf water content from hyperspectral data of different plant species by using three new spectral absorption indices. *PLoS ONE*, 16(3 March).
<https://doi.org/10.1371/journal.pone.0249351>
- Li, M., Zang, S., Zhang, B., Li, S., & Wu, C. (2014). A review of remote sensing image classification techniques: The role of Spatio-contextual information. *European Journal of Remote Sensing*, 47(1), 389–411.
<https://doi.org/10.5721/EuJRS20144723>
- Liao, P. S., Chen, T. S., & Chung, P. C. (2001). A fast algorithm for multilevel thresholding. *Journal of Information Science and Engineering*, 17(5), 713–727.
- Lillesand, T. M., & Kiefer, R. W. (2004). Remote sensing and image interpretation. In *Remote sensing and image interpretation*. <https://doi.org/10.2307/634969>
- Liu, C., Sun, P. Sen, & Liu, S. R. (2016). A review of plant spectral reflectance response to water physiological changes. *Chinese Journal of Plant Ecology*, 40(1), 80–91.
<https://doi.org/10.17521/cjpe.2015.0267>
- Liu, L., Dong, Y., Huang, W., Du, X., Ren, B., Huang, L., Zheng, Q., & Ma, H. (2020). A Disease Index for Efficiently Detecting Wheat Fusarium Head Blight Using Sentinel-2 Multispectral Imagery. *IEEE Access*, 8, 52181–52191.
<https://doi.org/10.1109/ACCESS.2020.2980310>
- Liu, X. (2003). Supervised Classification and Unsupervised Classification. *Cfa.Harvard.Edu*.
- Lizarazo, I., Rodriguez, J. L., Cristancho, O., Olaya, F., Duarte, M., & Prieto, F. (2023). Identification of symptoms related to potato Verticillium wilt from UAV-based multispectral imagery using an ensemble of gradient boosting machines. *Smart Agricultural Technology*, 3, 100138.
<https://doi.org/https://doi.org/10.1016/j.atech.2022.100138>
- Lizarazo Peña, P. A. (2020). Desarrollo , crecimiento y rendimiento de cultivares de papa diploide en ambientes contrastantes por altitud. In *Universidad Nacional de Colombia*.
https://repositorio.unal.edu.co/bitstream/handle/unal/78234/1022359762.2020.pdf?s_equence=1&isAllowed=y
- Lowe, A., Harrison, N., & French, A. (2017). Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. In *Plant Methods*. <https://doi.org/10.1186/s13007-017-0233-z>
- Lowe, B., & Kulkarni, A. (2015). Multispectral Image Analysis Using Random Forest. *International Journal on Soft Computing*. <https://doi.org/10.5121/ijsc.2015.6101>
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for

- improving classification performance. In *International Journal of Remote Sensing*. <https://doi.org/10.1080/01431160600746456>
- Lu, J., Ehsani, R., Shi, Y., de Castro, A. I., & Wang, S. (2018). Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Scientific Reports*, 8(1), 1–11. <https://doi.org/10.1038/s41598-018-21191-6>
- Lu, N., Zhou, J., Han, Z., Li, D., Cao, Q., Yao, X., Tian, Y., Zhu, Y., Cao, W., & Cheng, T. (2019). Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. *Plant Methods*, 15(1), 17. <https://doi.org/10.1186/s13007-019-0402-3>
- Mahlein, A. K. (2016). Plant disease detection by imaging sensors – Parallels and specific demands for precision agriculture and plant phenotyping. In *Plant Disease* (Vol. 100, Issue 2, pp. 241–254). <https://doi.org/10.1094/PDIS-03-15-0340-FE>
- Mahlein, A. K., Kuska, M. T., Thomas, S., Bohnenkamp, D., Alisaac, E., Behmann, J., Wahabzada, M., & Kersting, K. (2017). Plant disease detection by hyperspectral imaging: from the lab to the field. *Advances in Animal Biosciences*. <https://doi.org/10.1017/s2040470017001248>
- Mahlein, A. K., Oerke, E. C., Steiner, U., & Dehne, H. W. (2012). Recent advances in sensing plant diseases for precision crop protection. In *European Journal of Plant Pathology*. <https://doi.org/10.1007/s10658-011-9878-z>
- Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., & Oerke, E. C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote Sensing of Environment*, 128, 21–30. <https://doi.org/10.1016/j.rse.2012.09.019>
- Manici, L. M., & Cerato, C. (1994). Pathogenicity of *Fusarium oxysporum* f.sp. *tuberosi* isolates from tubers and potato plants. *Potato Research*, 37(2), 129–134. <https://doi.org/10.1007/BF02358713>
- Marín-Ortiz, J. C., Gutierrez-Toro, N., Botero-Fernández, V., & Hoyos-Carvajal, L. M. (2020). Linking physiological parameters with visible/near-infrared leaf reflectance in the incubation period of vascular wilt disease. *Saudi Journal of Biological Sciences*, 27(1), 88. <https://doi.org/10.1016/J.SJBS.2019.05.007>
- Mauromicale, G., Ierna, A., & Marchese, M. (2006). Chlorophyll fluorescence and chlorophyll content in field-grown potato as affected by nitrogen supply, genotype, and plant age. *Photosynthetica*, 44(1), 76–82. <https://doi.org/10.1007/S11099-005-0161-4>
- Meng, R., Lv, Z., Yan, J., Chen, G., Zhao, F., Zeng, L., & Xu, B. (2020). Development of spectral disease indices for southern corn rust detection and severity classification. *Remote Sensing*, 12(19), 1–16. <https://doi.org/10.3390/rs12193233>
- Mishra, P., Polder, G., & Vilfan, N. (2020). Close Range Spectral Imaging for Disease Detection in Plants Using Autonomous Platforms: a Review on Recent Studies. *Current Robotics Reports*, 1(2), 43–48. <https://doi.org/10.1007/s43154-020-00004-7>
- Mohapatra, S. K., & Mohanty, M. N. (2022). Big data classification with IoT-based application for e-health care. *Cognitive Big Data Intelligence with a Metaheuristic Approach*, 147–172. <https://doi.org/10.1016/B978-0-323-85117-6.00014-5>
- Mohseni-Dargah, M., Falahati, Z., Dabirmanesh, B., Nasrollahi, P., & Khajeh, K. (2022). Machine learning in surface plasmon resonance for environmental monitoring. In *Artificial Intelligence and Data Science in Environmental Sensing* (pp. 269–298). Academic Press. <https://doi.org/10.1016/B978-0-323-90508-4.00012-5>
- Mosley, L. S. D. (2013). A balanced approach to the multi-class imbalance problem. In *ProQuest Dissertations and Theses*.

- Motohka, T., Nasahara, K. N., Oguma, H., & Tsuchida, S. (2010). Applicability of Green-Red Vegetation Index for remote sensing of vegetation phenology. *Remote Sensing*, 2(10), 2369–2387. <https://doi.org/10.3390/rs2102369>
- Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. In *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2010.11.001>
- Müller, A. C., & Guido, S. (2016). Introduction to Machine Learning with Python: a guide for data scientists. In *Journal of Chemical Information and Modeling*. <https://doi.org/10.1017/CBO9781107415324.004>
- Mundt, C. C. (2019). The Study of Plant Disease Epidemics. *HortScience*, 44(7), 2065b – 2065. <https://doi.org/10.21273/hortsci.44.7.2065b>
- Neupane, K., & Baysal-Gurel, F. (2021). Automatic identification and monitoring of plant diseases using unmanned aerial vehicles: A review. In *Remote Sensing* (Vol. 13, Issue 19, p. 3841). Multidisciplinary Digital Publishing Institute. <https://doi.org/10.3390/rs13193841>
- Nieto, L. E. (1988). La Madurez Prematura de la Papa Causada por *Verticillium* spp. en Colombia. *Revista ICA*, 4, 334–340.
- Ning, F., Delhomme, D., LeCun, Y., Piano, F., Bottou, L., & Barbanò, P. E. (2005). Toward automatic phenotyping of developing embryos from videos. *IEEE Transactions on Image Processing*. <https://doi.org/10.1109/TIP.2005.852470>
- Oerke, E. C. (2020). Remote Sensing of Diseases. *Annual Review of Phytopathology*, 58, 225–252. <https://doi.org/10.1146/annurev-phyto-010820-012832>
- Oerke, E. C., Mahlein, A. K., & Steiner, U. (2014). Proximal sensing of plant diseases. In *Detection and Diagnostics of Plant Pathogens* (pp. 55–68). Springer Netherlands. https://doi.org/10.1007/978-94-017-9020-8_4
- Pandala, S. R. (2022). *lazypredict*. Python Software Foundation. <https://pypi.org/project/lazypredict/>
- Patrick, A., Pelham, S., Culbreath, A., Corely Holbrook, C., De Godoy, I. J., & Li, C. (2017). High throughput phenotyping of tomato spot wilt disease in peanuts using unmanned aerial systems and multispectral imaging. *IEEE Instrumentation and Measurement Magazine*, 20(3), 4–12. <https://doi.org/10.1109/MIM.2017.7951684>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12(85), 2825–2830. <http://jmlr.org/papers/v12/pedregosa11a.html>
- Pourazar, H., Samadzadegan, F., Dadrass Javan, F., Giacomo, R., David, G., Gilbertson, J. K., Forum, P. O., Bouroubi, Y., Bugnet, P., Nguyen-xuan, T., Gosselin, C., Bélec, C., Longchamps, L., Vigneault, P., Ji, S., Zhang, C., Xu, A., Shi, Y., Duan, Y., ... Gore, M. A. (2017). Pest Detection on UAV Imagery using a Deep Convolutional Neural Network. *Remote Sensing*, 52(19), 17–31. <https://doi.org/10.3390/rs11192209>
- Powelson, M. L., & Rowe, R. C. (1993). Biology and management of early dying of potatoes. In *Annual Review of Phytopathology* (Vol. 31, pp. 111–126). Annual Reviews Inc. <https://doi.org/10.1146/annurev.py.31.090193.000551>
- Puletti, N., Perria, R., & Storchi, P. (2014). Unsupervised classification of very high remotely sensed images for grapevine rows detection. *European Journal of Remote Sensing*, 47(1), 45–54. <https://doi.org/10.5721/EuJRS20144704>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119–126.

- [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Rahman, H. ur, Jabbar Ch, N., Manzoor, S., Najeeb, F., Siddique, M. Y., & Khan, R. A. (2017). A comparative analysis of machine learning approaches for plant disease identification. *Advancements in Life Sciences*, 4(4), 120–126.
- Ramegowda, V., & Senthil-Kumar, M. (2015). The interactive effects of simultaneous biotic and abiotic stresses on plants: Mechanistic understanding from drought and pathogen combination. In *Journal of Plant Physiology* (Vol. 176, pp. 47–54). Urban und Fischer Verlag GmbH und Co. KG. <https://doi.org/10.1016/j.jplph.2014.11.008>
- Ramesh Reddy, D., Naga Santhosh, K., & Kodali, P. (2022). Convolutional Neural Networks for the Intuitive Identification of Plant Diseases. *5th International Conference on Inventive Computation Technologies, ICICT 2022 - Proceedings*, 10, 941. <https://doi.org/10.1109/ICICT54344.2022.9850695>
- Ramirez-Gil, J., Navas, J., & Gómez, S. (2019). Epidemiología e importancia económica de una alteración de origen desconocido en papa en la sabana occidente de Cundinamarca. *XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS*, 205–205.
- Ramirez Gil, J., Garcia, C., Navas, J., Leon, J., & Gómez, S. (2019). Implicaciones epidemiológicas y económicas de *Verticillium* sp., en una región productora de papa en Cundinamarca. *XXXIV CONGRESO COLOMBIANO DE FITOPOPATOLOGIA Y CIENCIAS AFINES MEMORIAS*, 206–207.
- Raymundo, R., Asseng, S., Prasad, R., Kleinwechter, U., Concha, J., Condori, B., Bowen, W., Wolf, J., Olesen, J. E., Dong, Q., Zotarelli, L., Gastelo, M., Alva, A., Travasso, M., Quiroz, R., Arora, V., Graham, W., & Porter, C. (2017). Performance of the SUBSTOR-potato model across contrasting growing conditions. *Field Crops Research*, 202, 57–76. <https://doi.org/10.1016/j.fcr.2016.04.012>
- Ren, Y., Zhang, L., & Suganthan, P. N. (2016). Ensemble Classification and Regression-Recent Developments, Applications and Future Directions [Review Article]. In *IEEE Computational Intelligence Magazine* (Vol. 11, Issue 1, pp. 41–53). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/MCI.2015.2471235>
- Rodríguez, J., Lizarazo, I., Prieto, F., & Angulo-Morales, V. (2021). Assessment of potato late blight from UAV-based multispectral imagery. *Computers and Electronics in Agriculture*, 184, 106061. <https://doi.org/10.1016/j.compag.2021.106061>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS proceeding. *Third Earth Reserves Technology Satellite Symposium, Greenbelt: NASA SP-351, 30103017*, 317. <https://ui.adsabs.harvard.edu/abs/1974NASSP.351..309R/abstract>
- Rowe, R. C., & Powelson, M. L. (2002). Potato early dying: Management challenges in a changing production environment. In *Plant Disease* (Vol. 86, Issue 11, pp. 1184–1193). The American Phytopathological Society. <https://doi.org/10.1094/PDIS.2002.86.11.1184>
- Salamí, E., Barrado, C., & Pastor, E. (2014). UAV flight experiments applied to the remote sensing of vegetated areas. In *Remote Sensing* (Vol. 6, Issue 11, pp. 11051–11081). MDPI AG. <https://doi.org/10.3390/rs61111051>
- Sami, K., KC, K., John, F., Scott, S., & Erdal, O. (2020). Remote Sensing in Agriculture (Challenges and Opportunities). *Remote Sensing*, 10, 83–87.
- Sarić, R., Nguyen, V. D., Burge, T., Berkowitz, O., Trtílek, M., Whelan, J., Lewsey, M. G., & Čustović, E. (2022). Applications of hyperspectral imaging in plant phenotyping. In *Trends in Plant Science* (Vol. 27, Issue 3, pp. 301–315). Elsevier Current Trends. <https://doi.org/10.1016/j.tplants.2021.12.003>
- Sarkar, S. K., Das, J., Ehsani, R., & Kumar, V. (2016). Towards autonomous

- phytopathology: Outcomes and challenges of citrus greening disease detection through close-range remote sensing. *Proceedings - IEEE International Conference on Robotics and Automation, 2016-June*, 5143–5148.
<https://doi.org/10.1109/ICRA.2016.7487719>
- Savitzky, A., & Golay, M. J. E. (1964). Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry*, 36(8), 1627–1639.
<https://doi.org/10.1021/ac60214a047>
- Seetha, M., Muralikrishna, Deekshatulu, B. L., Malleswari, B. L., Nagaratna, & Hegde, P. (2008). Artificial Neural Networks and Other Methods of Image Classification. *Theoretical and Applied Information Technology*.
- Segarra, J., Buchailot, M. L., Araus, J. L., & Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5), 1–18. <https://doi.org/10.3390/agronomy10050641>
- Shammi, S., Sohel, F., Diepeveen, D., Zander, S., & Jones, M. G. K. (2022). A survey of image-based computational learning techniques for frost detection in plants. In *Information Processing in Agriculture*. Elsevier.
<https://doi.org/10.1016/j.inpa.2022.02.003>
- Shattock, R. (2002). Compendium of Potato Diseases, Second Edition. W.R. Stevenson. *Plant Pathology*, 51(4), 520–520. <https://doi.org/10.1046/j.1365-3059.2002.06934.x>
- Shi, Y., Han, L., Kleerekoper, A., Chang, S., & Hu, T. (2022). Novel CropdocNet Model for Automated Potato Late Blight Disease Detection from Unmanned Aerial Vehicle-Based Hyperspectral Imagery. *Remote Sensing*, 14(2), 396.
<https://doi.org/10.3390/rs14020396>
- Shin, M. Y., Gonzalez Viejo, C., Tongson, E., Wiechel, T., Taylor, P. W. J., & Fuentes, S. (2023). Early detection of Verticillium wilt of potatoes using near-infrared spectroscopy and machine learning modeling. *Computers and Electronics in Agriculture*, 204, 107567. <https://doi.org/10.1016/J.COMPAG.2022.107567>
- Shruthi, U., Nagaveni, V., & Raghavendra, B. K. (2019). A Review on Machine Learning Classification Techniques for Plant Disease Detection. *2019 5th International Conference on Advanced Computing and Communication Systems, ICACCS 2019*, 281–284. <https://doi.org/10.1109/ICACCS.2019.8728415>
- Simko, I., & Piepho, H. P. (2012). The area under the disease progress stairs: Calculation, advantage, and application. *Phytopathology*, 102(4), 381–389.
<https://doi.org/10.1094/PHYTO-07-11-0216>
- Singh, A., & Kaur, H. (2021). Potato plant leaves disease detection and classification using machine learning methodologies. *IOP Conference Series: Materials Science and Engineering*, 1022(1). <https://doi.org/10.1088/1757-899X/1022/1/012121>
- Singh, V., Sharma, N., & Singh, S. (2020). A review of imaging techniques for plant disease detection. In *Artificial Intelligence in Agriculture* (Vol. 4, pp. 229–242). KeAi Communications Co. <https://doi.org/10.1016/j.aiaa.2020.10.002>
- Stehman, S. V., & Foody, G. M. (2008). Accuracy Assessment. In *The SAGE Handbook of Remote Sensing*. <https://doi.org/10.4135/9780857021052.n21>
- Stevens, A., & Ramirez Lopez, L. (2014). An introduction to the prospectr package. In *R Package Vignette, Report No.: R Package Version 0.1* (Vol. 3, Issue August 2013, pp. 1–22). <https://cran.r-project.org/web/packages/prospectr/vignettes/prospectr.html>
- Stevenson, W., Loria, R., Franc, G., & Weingartner, D. (2001). Compendium of Potato Diseases, Second Edition. *Phytopathological Society*. <https://doi.org/10.1046/j.1365-3059.2002.06934.x>
- Su, J., Yi, D., Coombes, M., Liu, C., Zhai, X., McDonald-Maier, K., & Chen, W. H. (2022). Spectral analysis and mapping of blackgrass weed by leveraging machine learning

- and UAV multispectral imagery. *Computers and Electronics in Agriculture*, 192. <https://doi.org/10.1016/j.compag.2021.106621>
- Sugiura, R., Tsuda, S., Tamiya, S., Itoh, A., Nishiwaki, K., Murakami, N., Shibuya, Y., Hirafuji, M., & Nuske, S. (2016). Field phenotyping system for the assessment of potato late blight resistance using RGB imagery from an unmanned aerial vehicle. *Biosystems Engineering*. <https://doi.org/10.1016/j.biosystemseng.2016.04.010>
- Sun, W., & Du, Q. (2019). Hyperspectral band selection: A review. In *IEEE Geoscience and Remote Sensing Magazine* (Vol. 7, Issue 2, pp. 118–139). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/MGRS.2019.2911100>
- Suzuki, N., Rivero, R. M., Shulaev, V., Blumwald, E., & Mittler, R. (2014). Abiotic and biotic stress combinations. *New Phytologist*, 203(1), 32–43. <https://doi.org/10.1111/nph.12797>
- Tetila, E. C., Brandoli Machado, B., Belete, N. A. D. S., Guimaraes, D. A., & Pistori, H. (2017). Identification of Soybean Foliar Diseases Using Unmanned Aerial Vehicle Images. *IEEE Geoscience and Remote Sensing Letters*. <https://doi.org/10.1109/LGRS.2017.2743715>
- Thai, L. H., Hai, T. S., & Thuy, N. T. (2012). Image Classification using Support Vector Machine and Artificial Neural Network. *International Journal of Information Technology and Computer Science*. <https://doi.org/10.5815/ijitcs.2012.05.05>
- Tripathi, K., Vyas, R. G., & Gupta, A. K. (2019). Document Classification Using Artificial Neural Network. *Asian Journal of Computer Science and Technology*, 8(2), 55–58.
- Tsouros, D. C., Bibi, S., & Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. *Information (Switzerland)*, 10(11). <https://doi.org/10.3390/info10110349>
- van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., Yu, T., & the scikit-image contributors. (2014). scikit-image: image processing in {P}ython. *PeerJ*, 2, e453. <https://doi.org/10.7717/peerj.453>
- Vishnoi, V. K., Kumar, K., & Kumar, B. (2021). Plant disease detection using computational intelligence and image processing. In *Journal of Plant Diseases and Protection* (Vol. 128, Issue 1, pp. 19–53). Springer. <https://doi.org/10.1007/s41348-020-00368-0>
- Wan, L., Li, Y., Cen, H., Zhu, J., Yin, W., Wu, W., Zhu, H., Sun, D., Zhou, W., & He, Y. (2018). Combining UAV-based vegetation indices and image classification to estimate flower number in oilseed rape. *Remote Sensing*, 10(9), 1484. <https://doi.org/10.3390/rs10091484>
- Wang, C. ling, Shen, S. he, Zhang, S. yu, Li, Q. zhen, & Yao, Y. bi. (2015). Adaptation of potato production to climate change by optimizing sowing date in the Loess Plateau of central Gansu, China. *Journal of Integrative Agriculture*, 14(2), 398–409. [https://doi.org/10.1016/S2095-3119\(14\)60783-8](https://doi.org/10.1016/S2095-3119(14)60783-8)
- Wang, J., Lu, S., Wang, S. H., & Zhang, Y. D. (2021). A review on extreme learning machine. *Multimedia Tools and Applications*, 1–50. <https://doi.org/10.1007/s11042-021-11007-7>
- Wei, X., Johnson, M. A., Langston, D. B., Mehl, H. L., & Li, S. (2021). Identifying optimal wavelengths as disease signatures using hyperspectral sensor and machine learning. *Remote Sensing*, 13(14), 2833. <https://doi.org/10.3390/rs13142833>
- Xu, M., Watanachaturaporn, P., Varshney, P. K., & Arora, M. K. (2005). Decision tree regression for soft classification of remote sensing data. *Remote Sensing of Environment*, 97(3), 322–336. <https://doi.org/10.1016/j.rse.2005.05.008>
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. In *Journal of Sensors*. Hindawi Limited.

- <https://doi.org/10.1155/2017/1353691>
- Yan, Z., Ma, L., He, W., Zhou, L., Lu, H., Liu, G., & Huang, G. (2022). Comparing Object-Based and Pixel-Based Methods for Local Climate Zones Mapping with Multi-Source Data. *Remote Sensing*, 14(15). <https://doi.org/10.3390/rs14153744>
- Yang, C. M., Cheng, C. H., & Chen, R. K. (2007). Changes in spectral characteristics of rice canopy infested with brown planthopper and leafroller. *Crop Science*. <https://doi.org/10.2135/cropsci2006.05.0335>
- Yeom, J., Jung, J., Chang, A., Ashapure, A., Maeda, M., Maeda, A., & Landivar, J. (2019). Comparison of vegetation indices derived from UAV data for differentiation of tillage effects in agriculture. *Remote Sensing*, 11(13). <https://doi.org/10.3390/rs11131548>
- Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: A review. In *Precision Agriculture* (Vol. 13, Issue 6, pp. 693–712). Springer. <https://doi.org/10.1007/s11119-012-9274-5>
- Zhang, H., Xu, F., Wu, Y., Hu, H. hai, & Dai, X. feng. (2017). Progress of potato staple food research and industry development in China. In *Journal of Integrative Agriculture* (Vol. 16, Issue 12, pp. 2924–2932). Elsevier. [https://doi.org/10.1016/S2095-3119\(17\)61736-2](https://doi.org/10.1016/S2095-3119(17)61736-2)
- Zheng, H., Li, W., Jiang, J., Liu, Y., Cheng, T., Tian, Y., Zhu, Y., Cao, W., Zhang, Y., & Yao, X. (2018). A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. *Remote Sensing*, 10(12). <https://doi.org/10.3390/rs10122026>
- Zhou, X., Huang, W., Zhang, J., Kong, W., Casa, R., & Huang, Y. (2019). A novel combined spectral index for estimating the ratio of carotenoid to chlorophyll content to monitor crop physiological and phenological status. *International Journal of Applied Earth Observation and Geoinformation*, 76, 128–142. <https://doi.org/https://doi.org/10.1016/j.jag.2018.10.012>

Aportes al conocimiento generados a partir de esta investigación

1. Artículo científico publicado: León-Rueda, W. A., León, C., Caro, S. G., & Ramírez-Gil, J. G. (2022). Identification of diseases and physiological disorders in potato via multispectral drone imagery using machine learning tools. *Tropical Plant Pathology*, 47(1), 152–167. <https://doi.org/10.1007/s40858-021-00460-2>.
2. Artículo sometido a revista científica: Linking the laboratory and the field in potato early dying detection: from spectral signatures to vegetation indices obtained with multispectral cameras mounted to drones.
3. Presentación en congreso nacional: Bandas espectrales contrastantes en plantas de papa con sintomatologías asociadas a madurez temprana causada por *Verticillium* spp.
4. Presentación en congreso internacional: Variabilidad y escenarios de cambio climático en zonas productoras de papa en Colombia: una aproximación a la amenaza e incertidumbre climática.