



UNIVERSIDAD
NACIONAL
DE COLOMBIA

Detección indirecta de parámetros fitosanitarios, fenológicos y productivos del cultivo de ají Cayenne mediante el uso de plataformas de fenotipado e inteligencia artificial

Manuel Alejandro Cortes Quiceno

Universidad Nacional de Colombia sede Palmira

Facultad de Ciencias Agropecuarias

Palmira, Colombia

2023

Detección indirecta de parámetros sanitarios, fenológicos y productivos del cultivo de ají Cayenne mediante el uso de plataformas de fenotipado e inteligencia artificial

Manuel Alejandro Cortes Quiceno

Tesis o trabajo de investigación presentado como requisito parcial para optar al título de:
Magister en Ciencias Agrarias

Director: Ph.D Eyder Daniel Gómez López
Codirector: Ph.D Joaquín Guillermo Ramírez Gil
Asesor: Ph.D(C) Diego Felipe Conejo Rodríguez

Línea de Investigación: Protección de cultivos

Universidad Nacional de Colombia sede Palmira
Facultad de Ciencias Agropecuarias
Palmira, Colombia
2023

"La educación es el arte de hacer hombres sabios y libres al mismo tiempo."

Frédéric Bastiat

"La verdadera educación es la que obtienes más allá de la escuela, a través de tu propia búsqueda y exploración."

Lysander Spooner

"La educación no es preparación para la vida; la educación es la vida en sí misma."

Herbert Spencer

Declaración de obra original

Yo Manuel Alejandro Cortes Quiceno, c.c. 1113.657.355 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.



Nombre

Fecha: 04/08/2023

Agradecimientos

A mis queridos padres y hermanos, quiero expresar mi más sincero agradecimiento por su inquebrantable apoyo, amor y aliento a lo largo de esta travesía académica. Su constante respaldo ha sido la piedra angular de mi perseverancia y determinación para alcanzar este logro tan significativo en mi vida.

Asimismo, deseo extender mi gratitud a dos personas excepcionales, los profesores Ph.D (c) Diego Felipe Conejo Rodríguez y Ph.D Joaquín Guillermo Ramírez Gil. Su amplio conocimiento, dedicación y orientación han sido fundamentales para el desarrollo de mi tesis y mi formación profesional. Su mentoría ha sido un faro que me ha guiado a lo largo de este camino académico, brindándome perspectivas valiosas y desafiándome a superar mis límites.

Cada consejo, corrección y retroalimentación que recibí de ustedes ha sido invaluable para mejorar mi trabajo y ampliar mi horizonte de conocimiento. Su compromiso con la excelencia educativa ha dejado una huella duradera en mi formación y estoy verdaderamente agradecido por el tiempo y esfuerzo que han invertido en mí.

Este logro no solo es mío, sino también de ustedes, porque sin su apoyo y guía, no habría sido posible alcanzarlo. Una vez más, gracias por estar siempre a mi lado y ser mi mayor inspiración. Estoy lleno de gratitud y emoción mientras celebro este logro con ustedes.

Con todo mi cariño y agradecimiento.

Manuel Alejandro Cortes Quiceno

Resumen

Detección indirecta de parámetros fitosanitarios, fenológicos y productivos del cultivo de ají Cayenne mediante el uso de plataformas de fenotipado e inteligencia artificial

El ají (*Capsicum annuum* L.) es un cultivo relevante a nivel mundial, el cual en Colombia en los últimos años se ha convertido en una alternativa productiva debido a sus usos culinarios, propiedades medicinales y potencial de exportación. Sin embargo, este sistema productivo presenta limitantes productivos y tecnológicos, en especial enfrenta desafíos fitosanitarios, como el marchitamiento vascular (MV) asociado al agente causal *Fusarium* sp. Igualmente, aspectos asociados a la variabilidad del clima afectan la fenología de las plantas y los parámetros productivos, como el número de frutos, lo cual hace que se incremente la incertidumbre en las inversiones y la sostenibilidad en los sistemas agrícolas. En los últimos años se ha incrementado la capacidad de poder adquirir múltiples variables respuesta de forma masiva a nivel de plantas mediante un concepto denominado fenotipado de alto rendimiento (HTPP), la cual presenta múltiples aplicaciones, incluidas conocer y caracterizar las respuestas a fuentes de estrés bióticas y abióticas, parámetros fenológicos y productivos. Este enfoque, representa minería de rasgos fenotípicos y requiere métodos avanzados de análisis de datos como las herramientas de inteligencia artificial para la identificación de rasgos fenotípicos de mayor importancia a partir del uso de métodos como el aprendizaje automático (machine learning) y aprendizaje profundo (deep learning). El objetivo de nuestro trabajo fue detectar indirectamente parámetros fitosanitarios (MV), fenológicos (PF) y productivos (PP) del cultivo de ají Cayenne utilizando plataformas de fenotipado e inteligencia artificial. En un lote comercial de ají, el área de estudio fue de 1.145 m² divididas en 96 parcelas iguales, midiendo 3 plantas por parcela, y registrando periódicamente múltiples rasgos fotosintéticos usando el sensor proximal MultispeQ. Igualmente se evaluaron las respuestas espectrales en tres etapas del ciclo del cultivo utilizando un Vehículo Aéreo no Tripulado (VANT) de tipo DJI Phantom 4 con una cámara multiespectral acoplada con 5 bandas. Estas bandas, incluyen el espectro visible (RGB) junto con la banda del infrarrojo cercano (NIR) y, la banda de borde rojo (RE). Se utilizó la

función AutoML para evaluar diferentes modelos de aprendizaje automático (ML) y un enfoque de aprendizaje profundo (DL) para detectar la MV y predecir la fenología y el número de frutos. Los resultados mostraron que los rasgos fotosintéticos, espectrales y geométricos como Fv/Fm, NPQt, LDT, RelaChlo, Phi2, geometría del dosel, EVI, NDRE, CIRE y la banda de borde rojo fueron los más informativos y de mayor importancia para detectar la MV en el ají. Por su parte, para la estimación de PF y PP, los rasgos de mayor importancia fueron gH+, RelaChlo, PS1ActCent, FoPrime, EVI, VARI, Cirededge y CIRE. El enfoque basado en ML y el DL, demostró ser eficiente en la identificación de rasgos fotosintéticos clave que permiten la detección de MV y estimación de PF y PP. El presente trabajo presenta un avance relevante en aras de la implementación y validación de herramientas de agricultura 4.0, como base para mejorar las decisiones basadas en evidencia.

Palabras clave: Fotosíntesis, marchitez vascular, fenología, número de frutos, fenotipado de alto rendimiento, aprendizaje automático, aprendizaje profundo, agricultura 4.0.

Abstract

Indirect detection of phytosanitary, phenological, and productive parameters of Cayenne pepper cultivation through the use of phenotyping platforms and artificial intelligence

Chili pepper (*Capsicum annuum* L.) is a valuable crop around the world, and in Colombia, it has recently emerged as a viable alternative due to its culinary applications, medicinal benefits, and export potential. However, this production system has productivity and technological limits, particularly when dealing with phytosanitary issues such as vascular wilt (VW) caused by the causative agent *Fusarium* sp. Similarly, climate variability affects plant phenology and production parameters, such as fruit yield, increasing the uncertainty of investment and sustainability in agricultural systems. In recent years, the ability to collect multiple response variables at the plant level has increased thanks to a concept known as high-throughput phenotyping (HTPP), which has a variety of applications, including understanding and characterizing responses to biotic and abiotic stress sources, as well as phenological and yield parameters. This strategy is known as phenotypic trait mining, and it involves advanced data analysis methods such as artificial intelligence tools to identify phenotypic traits of major importance using methods such as machine learning and deep learning. Our study aimed to use phenotyping and artificial intelligence platforms to indirectly detect

phytosanitary (VW), phenological (PF), and productive (PP) factors in the Cayenne chili pepper crop. The study area in a commercial chili pepper plot was 1,145 m², divided into 96 identical plots, with three plants per plot and several photosynthetic traits recorded at regular intervals using the MultispeQ proximal sensor. Spectral responses were also assessed at three stages of the crop cycle using a DJI Phantom 4 Unmanned Aerial Vehicle (UAV) equipped with a multispectral sensor and 5 bands of light. These bands comprise the visible spectrum (RGB), near infrared (NIR), and red-edge band (RE). The AutoML function was used to assess various machine learning (ML) models and a deep learning (DL) technique for detecting MV, predicting phenology, and fruit number. The results revealed that photosynthetic, spectral, and geometric features such as Fv/Fm, NPQt, LDT, RelaChlo, Phi2, canopy geometry, EVI, NDRE, CIRE, and red-edge band were the most informative and important for detecting MV in chili pepper. For FP and PP estimation, the most essential traits were gH+, RelaChlo, PS1ActCent, FoPrime, EVI, VARI, Clrededge, and CIRE. The ML and DL-based technique demonstrated to be efficient in identifying important photosynthetic traits that allow for MV detection and PF and PP quantification. The current effort represents a significant step forward in the application and validation of agriculture 4.0 tools as a foundation for better evidence-based decision-making.

Keywords: Photosynthesis, vascular wilt, phenology, number of fruits, high-throughput phenotyping, machine learning, and deep learning, agriculture 4.0

Contenido

Pág.

Resumen.....	IX
Lista de figuras.....	XIV
Lista de tablas.....	XVI
Lista de Símbolos y abreviaturas.....	XVII
1.1 Consideraciones generales	19
1.1.1 Introducción	19
1.1.2 Planteamiento del problema.....	22
1.1.3 Justificación	24
1.1.4 Hipótesis	26
1.1.5 Objetivo general.....	26
1.1.6 Objetivos específicos	26
1.1.7 Referencias.....	26
2. Capítulo 2. Detección indirecta de parámetros fitosanitarios, fenológicos y productivos del cultivo de ají Cayenne mediante el uso de plataformas de fenotipado e inteligencia artificial.....	33
2.1 Introducción	34
2.2 Metodología	39
2.2.1 Material vegetal y condiciones generales de lote comercial usado.....	39
2.2.2 Esquema básico metodológico, adquisición de variables y escala temporal de evaluación	40
2.2.3 Variables evaluadas a nivel de cultivo	41
a. Sanidad del cultivo	41
b. Parámetros fenológicos y productivos.....	43
2.2.4 Captura y adquisición de variables predictoras.....	44
a. Adquisición de datos fotosintéticos.....	44
b. Adquisición de datos espectrales y geométricos a través de cámara espectral integrada a VANT	45
2.2.5 Selección de variables predictoras y ajuste a modelos de pronóstico de parámetros fitosanitarios, estados fenológicos y productivos en el sistema comercial de producción de ají usando variables fotosintéticas, espectrales y geométricas.....	46
a. Detección indirecta de parámetros fitosanitarios asociados a MV	47
b. Clasificación de estados fenológicos y pronóstico de componentes de rendimiento (# de frutos).....	49
2.3 Resultados	50
2.3.1 Importancia de la MV en el cultivo ají evaluado	50

2.3.2	Aproximación al pronóstico y determinación de variables predictivas de la MV utilizando variables fotosintéticas, espectrales y geométricas mediante multienfoque	51
a.	Enfoque estocástico: modelo de regresión logística multinomial	51
b.	Enfoque determinístico: modelos de machine learning	52
c.	Enfoque de deep Learning	54
2.3.3	Aproximación al pronóstico y determinación de variables predictivas de parámetros fenológicos (PF) utilizando variables fotosintéticas, espectrales y geométricas mediante enfoque de machine y Deep learning	58
a.	Enfoque de machine learning	58
b.	Enfoque de deep learning	62
2.3.4	Aproximación al pronóstico y determinación de variables predictivas de parámetros productivos (PP) utilizando variables fotosintéticas, espectrales y geométricas mediante enfoque de machine y Deep learning	65
a.	Enfoque de machine learning	65
b.	Enfoque de deep learning	67
2.4	Discusión.....	70
2.5	Conclusiones	79
2.6	Referencias.....	80
3.	Conclusiones y recomendaciones	100
3.1	Conclusiones	100
3.2	Recomendaciones.....	101
A.	Anexo A: tabla 1 de manejo integrado del sistema comercial de producción de ají	104
B.	Anexo A: Tabla 1 de índices de vegetación calculados a partir de las bandas	105
B.	Anexo B: Tabla 2. de métricas de evaluación de modelos según su origen	108
	C. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fitosanitarios asociados a MV utilizando variables fotosintéticas	110
	D. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fitosanitarios asociados a MV utilizando variables geométricas y espectrales	112
	E. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros fitosanitarios asociados a MV utilizando variables fotosintéticas, espectrales y geométricas.	115
	F. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fenológicos PF utilizando variables fotosintéticas	117
	G. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fenológicos PF utilizando variables espectrales y geométricas	118
	H. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros fenológicos utilizando variables fotosintéticas, espectrales y geométricas	121
	I. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros productivos PP utilizando variables fotosintéticas	122
	J. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros productivos PP utilizando variables espectrales y geométricas	125

K. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros productivos utilizando variables fotosintéticas, espectrales y geométricas. 128

Lista de figuras

Figura 2-1. (A) Área de estudio, (B) municipio de candelaria en contexto departamental del Valle del Cauca y (C) departamento en contexto de Colombia.....	40
Figura 2-2. Flujo de trabajo seguido en este estudio, (1) preadquisición de datos, (2) adquisición de datos, (3) preprocesamiento de datos y (4) procesamiento y análisis de datos	41
Figura 2-3. Escala de severidad de MV en plantas de ají Cayenne. (A) Ausencia de síntomas en la parte aérea de la planta de ají. (B) 25% de la parte aérea de la planta de ají presenta síntomas amarillamiento foliar, marchitez y leve. (C) Mas de 25.1% de la parte aérea de la planta de ají presenta síntomas de amarillamiento foliar, marchitez y epinastia avanzada, y presencia de haces vasculares necrosados	43
Figura 2-4 (A) número de plantas en cada nivel de MV en la etapa de desarrollo de fruto, (B) número de plantas en cada nivel de MV en emergencia de inflorescencia, (C) número de plantas en cada nivel de MV en floración y (D) número de plantas en cada nivel de MV en maduración de fruto .	51
Figura 2-5. Visualización de métricas asociadas a la clasificación de diferentes clases o grados de severidad de la MV en ají usando un modelo de regresión logística multinomial. (A): Matriz de confusión del modelo. (B): sensibilidad del modelo. (C) especificidad del modelo.	52
Figura 2-6. Visualización de métricas asociadas a la clasificación de diferentes clases o grados de severidad de la MV en ají usando un modelo de ML. (A) Identificación de rasgos fotosintéticos de mayor importancia. (B) curva AUC del modelo GBM con rasgos fotosintéticos. (C) matriz de confusión del modelo seleccionado con rasgos fotosintéticos. (D) Identificación de rasgos espectrales y geométricos de mayor importancia. (E) curva AUC del modelo GBM con rasgos espectrales y geométricos. (F) matriz de confusión del modelo GBM con rasgos espectrales y geométricos. (G) Identificación de rasgos fotosintéticos, espectrales y geométricos de mayor importancia. (H) curva AUC del modelo GBM con rasgos fotosintéticos, espectrales y geométricos. (I) matriz de confusión del modelo seleccionado con rasgos fotosintéticos, espectrales y geométricos.	53
Figura 2-7. Visualización de métricas asociadas a la clasificación de diferentes clases o grados de severidad de la MV en ají usando un modelo de DL. En la predicción de MV con DL se presenta:(A) rasgos fotosintéticos de mayor importancia (B) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos como predictores. (C) matriz de confusión para datos de prueba usando rasgos fotosintéticos como predictores (D) rasgos espectrales y geométricos de mayor importancia. (E) matriz de confusión para datos de entrenamiento usando rasgos espectrales y geométricos como predictores. (F) matriz de confusión para datos de prueba usando rasgos espectrales y geométricos	

como predictores. (G) rasgos fotosintéticos, espectrales y de mayor importancia (H) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos, espectrales y geométricos como predictores. (I) matriz de confusión para datos de prueba usando rasgos fotosintéticos, espectrales y geométricos como predictores..... 56

Figura 2-8. Diagrama de cajas de variables más importantes en la predicción de MV en el sistema comercial de producción de ají. (A)Fv/Fm, (B)NPQt, (C)LDT, (D)RelaChloroII, (E)Phi2, (F)geometría del dosel, (G)EVI, (H)NDRE, (I)CIRE y (J)Banda borde rojo 58

Figura 2-9. Visualización de métricas asociadas a la clasificación de diferentes estados fenológicos en ají usando un modelo de ML. (A) Identificación de rasgos fotosintéticos de mayor importancia. (B) curva AUC del modelo GBM con rasgos fotosintéticos. (C) matriz de confusión del modelo GBM con rasgos fotosintéticos. (D) Identificación de rasgos espectrales y geométricos de mayor importancia. (E) curva AUC del modelo GBM con rasgos espectrales y geométricos. (F) matriz de confusión del modelo GBM con rasgos espectrales y geométricos. (G) Identificación de rasgos fotosintéticos, espectrales y geométricos de mayor importancia. (H) curva AUC del modelo GBM con rasgos fotosintéticos, espectrales y geométricos. (I) matriz de confusión del modelo seleccionado con rasgos fotosintéticos, espectrales y geométricos. 60

Figura 2-10. Visualización de métricas asociadas a la clasificación de los cuatro estados fenológicos en ají usando un modelo de DL. En la predicción de clases o estados fenológicos con DL se presenta:(A) rasgos fotosintéticos de mayor importancia (B) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos como predictores. (C) matriz de confusión para datos de prueba usando rasgos fotosintéticos como predictores (D) rasgos espectrales y geométricos de mayor importancia. (E) matriz de confusión para datos de entrenamiento usando rasgos espectrales y geométricos como predictores. (F) matriz de confusión para datos de prueba usando rasgos espectrales y geométricos como predictores. (G) rasgos fotosintéticos, espectrales y de mayor importancia (H) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos, espectrales y geométricos como predictores. (I) matriz de confusión para datos de prueba usando rasgos fotosintéticos, espectrales y geométricos como predictores. **¡Error! Marcador no definido.**

Figura 2-11. Visualización de métricas asociadas al pronóstico de componentes de rendimiento en ají usando un modelo de regresión de ML. (A) Identificación de rasgos fotosintéticos de mayor importancia. (B) Rendimiento del modelo GBM para validación con datos de prueba. (C) rasgos espectrales y geométricos de mayor importancia. (D) rendimiento del modelo GLM en validación con datos de prueba. (E) Identificación de rasgos fotosintéticos, espectrales y geométricos de mayor importancia (F) Rendimiento del modelo GBM para validación con datos de prueba. 66

Figura 2-12. (A)Rasgos fotosintéticos de mayor importancia en el pronóstico de componentes de rendimiento seleccionadas por DL, (B) Rasgos espectrales y geométricos de mayor importancia en el pronóstico de componentes de rendimiento seleccionadas por DL y (C) Rasgos fotosintéticos, espectrales y geométricos de mayor importancia en el pronóstico de componentes de rendimiento seleccionadas por DL 68

Figura 2-13. Visualización de rasgos fotosintéticos, espectrales y geométricos de mayor importancia tanto en la clasificación de estados fenológicos como en el pronóstico de componentes de rendimiento en ají y sus niveles promedio y coeficientes de variación en los cuatro estados fenológicos evaluados. (A)valor promedio RelaChloroII, (B)CV RelaChloroII, (C)valor promedio gH+, (D)CV gH+, (E)valor promedio de LEF, (F)CV de LEF, (G)valor promedio de PS1ActCent, (H)CV de PS1ActCent, (I)valor promedio del índice NDRE y (J)CV de índice NDRE 70

Lista de tablas

Tabla 1. Variables y descripción básica de parámetros evaluados con el sensor proximal MultispeQV2.0.....	44
--	----

Lista de Símbolos y abreviaturas

Abreviaturas

Abreviatura	Término
<i>PSI</i>	Fotosistema 1
<i>PSII</i>	Fotosistema 2
<i>AutoML</i>	Automatization del aprendizaje automatico
<i>ML</i>	Aprendizaje automatico
<i>DL</i>	Aprendizaje profundo
<i>MV</i>	Marchitez vascular
<i>PF</i>	Parametros fenologicos
<i>PP</i>	Parametros productivos

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: título, resumen, palabras claves, introducción, materiales y métodos, resultados y discusión, seguidos de la lista de referencias. Este trabajo de investigación se encuentra organizado en tres 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 e hipótesis. El segundo capítulo se enfoca en el uso de herramientas de fenotipado de alto rendimiento y herramientas de analítica de datos para la detección indirecta de la marchitez vascular del cultivo de ají y el pronóstico de la fenología y variables de componentes rendimiento como el número de frutos. Por último, se presenta una breve sección de conclusiones y recomendaciones generales de la investigación realizada.

1.1 Consideraciones generales

1.1.1 Introducción

El ají (*Capsicum annuum* L.) es una planta del género *Capsicum*, ampliamente reconocida como uno de los vegetales, condimentos y especias más antiguos y populares a nivel mundial. Hay alrededor de 25 especies de *Capsicum* identificadas, con su centro de origen en las regiones tropicales y subtropicales de América, específicamente en Centroamérica, parte de Suramérica y México (Hernández-Pérez et al., 2020).

A lo largo de la historia, esta planta ha sido apreciada por sus diversas aplicaciones, tanto como vegetal, colorante natural y en la medicina tradicional. Se encuentra entre las primeras plantas que fueron domesticadas en el subcontinente mesoamericano (Hernández-Pérez et al., 2020; Ramchiary & Chittaranjan, 2019). Además de su relevancia en la gastronomía, donde los productos son conocidos a nivel mundial, se vislumbra un futuro prometedor en el que se desarrollarán numerosos productos nutracéuticos y farmacéuticos basados en los componentes extraídos de los frutos de esta planta (Hernández-Pérez et al., 2020; Ramchiary & Chittaranjan, 2019). El ají tipo Cayenne ha experimentado un crecimiento constante en su superficie de producción, incluyendo una mayor demanda de productos de origen orgánico (Ramchiary & Chittaranjan, 2019).

La producción mundial de ají se ve afectada por diversas enfermedades, entre las cuales destaca el marchitamiento vascular (MV), causado por patógenos del género *Fusarium* sp. (de Lamo & Takken, 2020; Gordon, 2017; Velarde-Félix et al., 2018). Existe evidencia clara de que esta enfermedad ocasiona pérdidas significativas en los cultivos de ají (Farihadina & Sutarman, 2022; Gabrekiristos & Demiyo, 2020; Shaheen et al., 2021; Velarde-Félix et al., 2018; Zhu et al., 2021). En Colombia, concretamente en el departamento del Valle del Cauca, los cultivos de ají enfrentan una importante limitación debido a la presencia de MV asociada a *Fusarium* sp. (Castro Clavijo, 2014; Velasco Belalcazar, 2016). Esta enfermedad conduce a síntomas que son visibles una vez que el patógeno ha colonizado el tejido vascular de la planta (Shaheen et al., 2021).

En un contexto de protección, planificación y modelación de cultivos, comprender y conocer la fenología resulta de vital importancia para una gestión efectiva de la información y la toma de

decisiones. La eficiencia de las labores de manejo está estrechamente ligada al estado fenológico específico del sistema de producción comercial de ají (Jing et al., 2017).

En la gestión efectiva del sistema de producción comercial de ají, existen aspectos clave que requieren especial atención, entre ellos el monitoreo y el rendimiento de frutos (Kalogiannidis et al., 2022; Srikanth et al., 2019). En este sentido, la evaluación del rendimiento de frutos se logra mediante la medición del número de frutos por planta (Aklilu et al., 2016; Gholipoor & Nadali, 2019). Actualmente, factores como la variabilidad de la fenología afectan el rendimiento y adaptación de las plantas (Bhutia L et al., 2018; Ramírez-Gil et al., 2020; Srikanth et al., 2019; Stemkovski et al., 2023). Por esta razón, resulta imprescindible detectar de manera oportuna las alteraciones en el desarrollo vegetal y estimar tanto la fenología como el número de frutos con el empleo de técnicas sofisticadas que permitan abordar este tipo de dificultades con precisión y eficacia.

La fenómica es un campo interdisciplinario que se centra en el estudio sistemático y a gran escala del fenoma o de los rasgos fenotípicos de un organismo o población (W. Yang et al., 2020). A su vez, el fenotipado hace referencia al conjunto de técnicas y procedimientos empleados para medir de manera precisa de características fenotípicas a nivel de organismo o población (W. Yang et al., 2020). El fenotipado de cultivos mediante métodos tradicionales como la adquisición de datos visuales, alométricos, parámetros de desarrollo y crecimiento es costoso en términos de mano de obra, lento, subjetivo y puede causar daño a las plantas (Xie & Yang, 2020; W. Yang et al., 2020). Sin embargo, el enfoque de fenotipado de alto rendimiento (HTPP, por sus siglas en inglés), ha introducido oportunidades para realizar un fenotipado no destructivo en campo (A. Singh et al., 2016; W. Yang et al., 2020; H. Zhang et al., 2023). El HTPP es un enfoque crucial en la biología y la genética que se centra en la caracterización y evaluación sistemática y eficiente de un gran número de características fenotípicas en organismos. Este enfoque se ha vuelto esencial en la investigación agrícola, biología molecular, y otras disciplinas científicas (A. Singh et al., 2016; W. Yang et al., 2020; H. Zhang et al., 2023). Este enfoque implica la recopilación y el análisis de datos fenotípicos a gran escala, a menudo utilizando tecnologías automatizadas y de alto rendimiento como plataformas autónomas, semiautónomas o manuales, equipadas con sensores únicos o múltiples para recopilar datos espaciales y temporales de manera masiva, lo que permite un análisis y almacenamiento significativo de información (A. Singh et al., 2016). Esta alternativa puede ser útil

para comprender la función de los genes, la variabilidad fenotípica, la adaptación de los organismos a su entorno y la selección de características deseables en aplicaciones agrícolas y biotecnológicas (A. Singh et al., 2016; W. Yang et al., 2020; H. Zhang et al., 2023). Es así, como el HTPP es una estrategia esencial para analizar y comprender un amplio espectro de características fenotípicas de manera eficiente y a gran escala, lo que contribuye significativamente al avance del conocimiento en rasgos fenotipos cuantificables, que pueden ser usados para caracterizar respuestas específicas de las plantas a fuentes de estrés biótico y abiótico (A. Singh et al., 2016; W. Yang et al., 2020; H. Zhang et al., 2023). En este sentido, el HTPP genera una alta gran cantidad de datos, por lo cual es necesario contar con herramientas de análisis eficiente.

Las diferentes técnicas de inteligencia artificial (IA) como los algoritmos de aprendizaje automático (*machine learning*-ML) y aprendizaje profundo (*deep learning*-DL) ofrecen un enfoque altamente prometedor para mejorar la velocidad, eficiencia y calidad del análisis de datos. Estas técnicas pertenecen a un campo interdisciplinario que se nutre y emplea conceptos de la teoría de la probabilidad, estadísticas, teoría de la decisión, optimización y visualización (A. Singh et al., 2016, 2021; A. K. Singh et al., 2018).

Tomando en cuenta este contexto, la presente investigación propone abordar las problemáticas de detección indirecta de la MV, y el pronóstico de la fenología y componentes de rendimiento (número de frutos) utilizando plataformas de HTPP en combinación con técnicas de inteligencia artificial (IA) como herramientas de análisis avanzado de datos, logrando de manera temprana detectar indirectamente MV y la estimación de la fenología y número de frutos con alta precisión.

La primera parte del trabajo se centró en la captura de datos de rasgos fotosintéticos del sistema de producción comercial de ají, mediante el sensor proximal MultispeQ (Herts et al., 2020), así como la captura de datos de rasgos espectrales y geométricos a través de una cámara multiespectral acoplada a un vehículo aéreo no tripulado (VANT) (Moradi et al., 2022). Posteriormente, se procedió a implementar técnicas de ML y DL para el análisis de los datos con el objetivo de predecir MV asociada a *Fusarium* sp. (Karadağ et al., 2020; A. Singh et al., 2016, 2021; A. K. Singh et al., 2018; Tanner et al., 2022). La segunda parte del trabajo consistió en seguir los mismos pasos mencionados anteriormente para la recopilación de datos de HTPP y su análisis mediante ML y DL, con el fin de

predecir la fenología y el número de frutos del cultivo de ají (Gholipoor & Nadali, 2019; Stemkovski et al., 2023; Yalcin, 2018).

Finalmente, la identificación de los rasgos fenotípicos de importancia asociados a MV, así como a la fenología y al número de frutos, generará un conocimiento sumamente útil para comprender las relaciones existentes entre estos elementos. Además, permitirá la detección rápida, económica e indirecta de MV causado por algunas especies de *Fusarium* sp., así como la estimación precisa de la fenología y el número de frutos, lo que contribuirá significativamente a una gestión eficiente del sistema de producción de ají en las condiciones del Valle del Cauca.

1.1.2 Planteamiento del problema

En el año 2021, en Colombia, se establecieron un total de 7.948 hectáreas destinadas al cultivo de ají. En el departamento del Valle del Cauca se cultivan diversas variedades e híbridos de ají, entre las que se destacan las de tipo tabasco, Cayenne, habanero y jalapeño. Este departamento contribuyó con 286,9 hectáreas de ají Cayenne cultivadas, logrando una producción total de 476 toneladas en la región con un rendimiento promedio de 16,54 toneladas por hectárea (Agronet 2023). La MV asociada a *Fusarium* sp. es una enfermedad que afecta a los cultivos de ají en todo el mundo (Farihadina & Sutarman, 2022; Gabrekiristos & Demiyo, 2020; Shaheen et al., 2021). En Brasil, *Fusarium solani* (Mart.) Sacc., ha sido un problema importante en la producción (dos Anjos et al., 2018). En México, se han reportado síntomas como clorosis, marchitamiento y necrosis vascular causados por *Fusarium oxysporum* Schltdl. (Velarde-Félix et al., 2018). En China, se han reportado casos causados por *Fusarium semitectum* Berk and Rav (H. Y. Li et al., 2018).

En Colombia, especialmente en el departamento del Valle del Cauca, la MV representa una de las principales limitaciones para el cultivo de ají. Esta enfermedad, causada por algunas especies de *Fusarium* sp., puede ocasionar pérdidas de más del 50%, e incluso llegar al 100% en condiciones favorables para el desarrollo del patógeno (Castro Clavijo, 2014; Velasco Belalcazar, 2016). Actualmente, existen pocas opciones de manejo y prevención de la MV, como el uso de desinfectantes de suelo, la aplicación de fungicidas químicos, la rotación de cultivos y el empleo de

materiales resistentes, siendo este último considerado el método más efectivo (Gabrekiristos & Demiyo, 2020). En este contexto, resulta crucial llevar a cabo un monitoreo exhaustivo de la enfermedad.

Tradicionalmente, el monitoreo de la MV se ha realizado mediante evaluaciones visuales realizadas por expertos o personal capacitado (V. Singh et al., 2020). Además, se han utilizado técnicas basadas en el ADN y fundamentos de serología para la detección de la enfermedad (León-Rueda et al., 2022; Martinelli et al., 2014; V. Singh et al., 2020). Pero estos métodos requieren alto esfuerzo humano, tiempo, y presentan un costo elevado (Buja et al., 2021). Por lo tanto, los métodos sofisticados de monitoreo junto con la detección rápida, precisa y económica han sido promovidos como un objetivo prioritario a corto plazo en el manejo de enfermedades en las plantas (Buja et al., 2021).

En el contexto de manejo integral de cultivos, los parámetros fenológicos desempeñan un papel crucial en la gestión de estos (Feldmann & Rutikanga, 2021; Jing et al., 2017; Yalcin, 2015). Asimismo, los parámetros productivos suscitan gran interés debido a su relevancia en la proyección de la producción de cultivos. Uno de estos parámetros es el número de frutos por planta (Aklilu et al., 2016; Gholipoor & Nadali, 2019), el cual resulta fundamental para el monitoreo del rendimiento de frutos y, además, ofrece información valiosa para tomar decisiones en cuanto al momento óptimo de la cosecha y sus implicaciones logísticas. La fenología del cultivo de ají está estrechamente relacionada con varios factores, como el número de frutos, el ambiente y el manejo del cultivo (Gholipoor & Nadali, 2019; Lenk et al., 2020; Srivastava et al., 2022). Sin embargo, debido al impacto de la alta variabilidad climática, la fenología ha experimentado alteraciones significativas, lo que ha afectado directamente los rendimientos y la programación de las labores del cultivo (Bhutia L et al., 2018; Guo et al., 2021; Srikanth et al., 2019; Stemkovski et al., 2023).

Ante este escenario, resulta imprescindible llevar a cabo el desarrollo de una metodología eficiente para la detección indirecta y rápida de la MV, al igual que la estimación precisa, rápida y económica de la fenología y el número de frutos de ají en las condiciones específicas del Valle del Cauca. Para ello, se han propuesto técnicas innovadoras en la captura de rasgos fenotípicos como el HTPP y herramientas de análisis de datos como la IA que puede brindar información valiosa para la gestión eficiente del cultivo (Jing et al., 2017; Pérez-Gutiérrez et al., 2017; Rodrigues et al., 2023; Worrall et al., 2022; Yalcin, 2018). La detección de la MV, la fenología y el número de frutos se relaciona

con rasgos fenotípicos específicos que conducen al análisis a partir de herramientas de minería de datos y ML que permitan identificar características en grandes conjuntos de datos de rasgos fenotípicos (Rahaman et al., 2019). Hasta el alcance de la presente propuesta no se ha establecido un método definido que involucre el HTPP, la minería de rasgos fenotípicos y técnicas de IA que permitan la identificación de rasgos fenotípicos importantes en la detección indirecta de parámetros fitosanitarios, fenológicos y productivos en el sistema de producción comercial de ají tipo Cayenne.

1.1.3 Justificación

La marchitez vascular (MV) del ají, asociada a especies del género *Fusarium* sp. constituye una de las principales limitaciones para el cultivo de esta planta a nivel mundial (Farihadina & Sutarman, 2022; Shaheen et al., 2021; Zhu et al., 2021), causando un severo impacto en los rendimientos. En Colombia, especialmente en departamentos como el Valle del Cauca, esta enfermedad representa uno de los mayores problemas fitosanitarios para el cultivo de ají (Castro Clavijo, 2014; Velasco Belalcazar, 2016). Este hongo del suelo penetra la planta a través de las raíces y afecta sus tejidos vasculares, provocando la reducción del suministro de agua y nutrientes (de Lamo & Takken, 2020; Jangir et al., 2021). Como resultado, se produce la pudrición de los tejidos debido a la presencia de *Fusarium* sp. lo que se manifiesta mediante síntomas como el amarillamiento de las hojas, la epinastia y el marchitamiento de estas, así como el cierre de los estomas, lo que, en última instancia, conduce a la muerte de la planta en estados avanzados (de Lamo & Takken, 2020; Shaheen et al., 2021). La aparición de los síntomas de MV se observa una vez que el patógeno ha colonizado completamente el sistema vascular de la planta (Gabrekiristos & Demiyo, 2020; Shaheen et al., 2021). Por lo tanto, es de vital importancia detectar rápida, precisa y económicamente la MV para llevar a cabo una gestión adecuada y oportuna de la situación.

Por otro lado, conocer y entender la fenología del ají es crucial para la gestión y protección de este cultivo (Jing et al., 2017; Pérez-Gutiérrez et al., 2017). Así mismo, el número de frutos por planta es un parámetro que nos permite monitorear y proyectar el rendimiento de frutos y el momento de cosecha (Gholipoor & Nadali, 2019; González-Gordo et al., 2020; Haghghi et al., 2023). Factores como la variabilidad de la fenología de las plantas afecta el número de frutos del cultivo de ají (Bhuria

L et al., 2018; Pramanik et al., 2020; Stemkovski et al., 2023). Es por esto, por lo que la estimación de la fenología y el número de frutos permitirá optimizar la gestión del cultivo en el monitoreo de la fenología y a proyectar el rendimiento de frutos y el momento de cosecha.

Las plataformas de HTPP tienen la capacidad de recopilar grandes cantidades de datos, a partir de muestreos no destructivos, bajos costos y con rapidez de tiempo de muestreo (Herts et al., 2020; Jangra et al., 2021; Tayade et al., 2022; W. Yang et al., 2020). Las HTPP pueden ser claves en la obtención de diferentes datos fenotípicos como rasgos fotosintéticos, espectrales y geométricos relacionados con problemas como la MV, la variabilidad fenológica y el número de frutos en el cultivo de ají (Herts et al., 2020; Karadağ et al., 2020; Moradi et al., 2022; Sosa-Herrera et al., 2022).

En la actualidad, las diversas técnicas de IA, tales como el ML y el DL, han surgido como enfoques innovadores en el análisis de datos (Ahmad & Nabi, 2021; A. Singh et al., 2016). Estas metodologías se presentan como una herramientas prometedoras para mejorar nuestra comprensión de los rasgos fenotípicos de las plantas, así como para abordar fenómenos cruciales como el impacto de enfermedades, monitoreo de fenología y predicción de rendimiento, entre otros (Guo et al., 2021; Karadağ et al., 2020; Lizarazo et al., 2023; Nabwire et al., 2021; A. Singh et al., 2021; Yalcin, 2018).

La identificación de rasgos fenotípicos específicos de las plantas de ají, asociados a la MV, su fenología y el número de frutos, proporcionaría una sólida base de información para futuros estudios más detallados sobre su importancia biológica, epidemiológica y ecológica. Asimismo, permitiría establecer la relación a profundidad de estos rasgos fenotípicos con la MV, fenología y número de frutos (Cruz & Avenson, 2021; Harfouche et al., 2022; W. Yang et al., 2020). En cuanto al aporte de este trabajo sobre aspectos agronómicos, la implementación de HTPP, herramientas de IA y la identificación de rasgos fenotípicos importantes materializan una aproximación al desarrollo de sistemas validados, robustos y eficaces de monitoreo de la MV, fenología y número de frutos en sistemas comerciales a partir del seguimiento de cada uno de los rasgos identificados.

1.1.4 Hipótesis

Los rasgos fotosintéticos, espectrales y geométricos recolectados a través de plataformas de fenotipado de alto rendimiento junto con el análisis y minería de rasgos fenotípicos mediante técnicas de inteligencia artificial permiten la detección indirecta y precisa de parámetros fitosanitarios, fenológicos y productivos del cultivo de ají Cayenne.

1.1.5 Objetivo general

Implementar herramientas para la detección indirecta de parámetros fitosanitarios, fenológicos y productivos del cultivo de ají Cayenne mediante el uso de plataformas de fenotipado e inteligencia artificial.

1.1.6 Objetivos específicos

1- Desarrollar una metodología para la detección indirecta de parámetros fitosanitarios en el sistema de producción comercial de ají Cayenne mediante el uso de plataformas de fenotipado de alto rendimiento y herramientas de análisis y minería de rasgos fenotípicos basadas en inteligencia artificial.

2- Estimar parámetros fenológicos y productivos del sistema de producción comercial de ají Cayenne mediante el uso de plataformas de fenotipado de alto rendimiento y herramientas de análisis y minería de rasgos fenotípicos basadas en inteligencia artificial.

1.1.7 Referencias

Agronet, (2023). (Ministerio de Agricultura, Estadísticas). Recuperado de [HTPPs://www.agronet.gov.co/estadistica/Paginas/home.aspx?cod=2](https://www.agronet.gov.co/estadistica/Paginas/home.aspx?cod=2)

Ahmad, L., & Nabi, F. (2021). Agriculture 5.0: Artificial Intelligence, IoT, and Machine Learning. In *Agriculture 5.0: Artificial Intelligence, IoT, and Machine Learning*. CRC Press. [HTPPs://doi.org/10.1201/9781003125433](https://doi.org/10.1201/9781003125433)

- Aklilu, S., Abebie, B., Wogari, D., & T/Wolde, A. (2016). Genetic variability and association of characters in Ethiopian hot pepper (*Capsicum annum* L.) landraces. *Journal of Agricultural Sciences, Belgrade*, 61(1), 19–36. [HTPPs://doi.org/10.2298/jas1601019a](https://doi.org/10.2298/jas1601019a)
- Bhutia L, K., VK, K., Meetei NG, T., & Bhutia D, N. (2018). Effects Of Climate Change On Growth And Development Of Chilli. *Agrotechnology*, 07(02). [HTPPs://doi.org/10.4172/2168-9881.1000180](https://doi.org/10.4172/2168-9881.1000180)
- 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. In *Sensors* (Vol. 21, Issue 6, pp. 1–22). MDPI AG. [HTPPs://doi.org/10.3390/s21062129](https://doi.org/10.3390/s21062129)
- Castro Clavijo, S. D. (2014). *Búsqueda de resistencia a la pudrición causada por Fusarium spp. en Capsicum* [Maestría tesis, Universidad Nacional de Colombia sede Palmira]. [HTPPs://repositorio.unal.edu.co/handle/unal/53137](https://repositorio.unal.edu.co/handle/unal/53137)
- Cruz, J. A., & Avenson, T. J. (2021). Photosynthesis: a multiscopic view. *Journal of Plant Research*, 134(4), 665–682. [HTPPs://doi.org/10.1007/s10265-021-01321-4](https://doi.org/10.1007/s10265-021-01321-4)
- de Lamo, F. J., & Takken, F. L. W. (2020). Biocontrol by *Fusarium oxysporum* Using Endophyte-Mediated Resistance. In *Frontiers in Plant Science* (Vol. 11). Frontiers Media S.A. [HTPPs://doi.org/10.3389/fpls.2020.00037](https://doi.org/10.3389/fpls.2020.00037)
- dos Anjos, I. V., Silva, L. P., Silva, L. R., Araújo, K. L., Silva, A. F., Barelli, M. A. A., & Neves, L. G. (2018). *Reação de acessos de Capsicum spp. ao fungo Fusarium solani*. 16, 344–349.
- Farihadina, A. A., & Sutarman. (2022). Application of Biological Agents of *Trichoderma* and *Aspergillus* on Cayenne Chilli Plants in Endemic Land with *Fusarium* Wilt. *IOP Conference Series: Earth and Environmental Science*, 1104(1). [HTPPs://doi.org/10.1088/1755-1315/1104/1/012003](https://doi.org/10.1088/1755-1315/1104/1/012003)
- Feldmann, F., & Rutikanga, A. (2021). Phenological growth stages and BBCH-identification keys of Chilli (*Capsicum annum* L., *Capsicum chinense* JACQ., *Capsicum baccatum* L.). *Journal of Plant Diseases and Protection*, 128(2), 549–555. [HTPPs://doi.org/10.1007/s41348-020-00395-x](https://doi.org/10.1007/s41348-020-00395-x)
- Gabrekiristos, E., & Demiyo, T. (2020). Hot Pepper *Fusarium* Wilt (*Fusarium oxysporum* f. sp. capsici): Epidemics, Characteristic Features and Management Options. *Journal of Agricultural Science*, 12(10), 347. [HTPPs://doi.org/10.5539/jas.v12n10p347](https://doi.org/10.5539/jas.v12n10p347)
- Gholipoor, M., & Nadali, F. (2019). Fruit yield prediction of pepper using artificial neural network. *Scientia Horticulturae*, 250, 249–253. [HTPPs://doi.org/10.1016/j.scienta.2019.02.040](https://doi.org/10.1016/j.scienta.2019.02.040)

-
- González-Gordo, S., Rodríguez-Ruiz, M., Palma, J. M., & Corpas, F. J. (2020). Superoxide Radical Metabolism in Sweet Pepper (*Capsicum annuum* L.) Fruits Is Regulated by Ripening and by a NO-Enriched Environment. *Frontiers in Plant Science*, *11*. [HTPPs://doi.org/10.3389/fpls.2020.00485](https://doi.org/10.3389/fpls.2020.00485)
- Gordon, T. R. (2017). *Annual Review of Phytopathology Fusarium oxysporum and the Fusarium Wilt Syndrome*. [HTPPs://doi.org/10.1146/annurev-phyto-080615](https://doi.org/10.1146/annurev-phyto-080615)
- Guo, Y., Fu, Y., Hao, F., Zhang, X., Wu, W., Jin, X., Robin Bryant, C., & Senthilnath, J. (2021). Integrated phenology and climate in rice yields prediction using machine learning methods. *Ecological Indicators*, *120*. [HTPPs://doi.org/10.1016/j.ecolind.2020.106935](https://doi.org/10.1016/j.ecolind.2020.106935)
- Haghighi, M., Sharifani, M. J., & Parnianifard, F. (2023). Physiological changes of sweet pepper under low irrigation regimes applied in three phenological stages of vegetative growth, reproductive growth, and fruit set. *New Zealand Journal of Crop and Horticultural Science*. [HTPPs://doi.org/10.1080/01140671.2023.2171440](https://doi.org/10.1080/01140671.2023.2171440)
- Harfouche, A. L., Nakhle, F., Harfouche, A. H., Sardella, O. G., Dart, E., & Jacobson, D. (2022). A primer on artificial intelligence in plant digital phenomics: embarking on the data to insights journey. In *Trends in Plant Science*. Elsevier Ltd. [HTPPs://doi.org/10.1016/j.tplants.2022.08.021](https://doi.org/10.1016/j.tplants.2022.08.021)
- Hernández-Pérez, T., Gómez-García, M. del R., Valverde, M. E., & Paredes-López, O. (2020). *Capsicum annuum* (hot pepper): An ancient Latin-American crop with outstanding bioactive compounds and nutraceutical potential. A review. *Comprehensive Reviews in Food Science and Food Safety*, *19*(6), 2972–2993. [HTPPs://doi.org/10.1111/1541-4337.12634](https://doi.org/10.1111/1541-4337.12634)
- Herts, A., Tsidylo, I., Herts, N., Barna, L., & Mazur, S. I. (2020). PhotosynQ - Cloud platform powered by IoT devices. *E3S Web of Conferences*, *166*. [HTPPs://doi.org/10.1051/e3sconf/202016605001](https://doi.org/10.1051/e3sconf/202016605001)
- Jangir, P., Mehra, N., Sharma, K., Singh, N., Rani, M., & Kapoor, R. (2021). Secreted in Xylem Genes: Drivers of Host Adaptation in *Fusarium oxysporum*. In *Frontiers in Plant Science* (Vol. 12). Frontiers Media S.A. [HTPPs://doi.org/10.3389/fpls.2021.628611](https://doi.org/10.3389/fpls.2021.628611)
- Jangra, S., Chaudhary, V., Yadav, R. C., & Yadav, N. R. (2021). High-Throughput Phenotyping: A Platform to Accelerate Crop Improvement. *Phenomics*, *1*(2), 31–53. [HTPPs://doi.org/10.1007/s43657-020-00007-6](https://doi.org/10.1007/s43657-020-00007-6)
- Jing, H., Wang, X., Haoyu, W., Xingrong, F., & Mwngzhen, K. (2017). Prediction of crop phenology - a component of parallel agriculture management. *Chinese Automation Congress (CAC)*, 7704-7708. [HTPPs://doi.org/10.1109/CAC.2017.8244172](https://doi.org/10.1109/CAC.2017.8244172)
- Kalogiannidis, S., Kalfas, D., Chatzitheodoridis, F., & Papaevangelou, O. (2022). Role of Crop-Protection Technologies in Sustainable Agricultural Productivity and Management. *Land*, *11*(10). [HTPPs://doi.org/10.3390/land11101680](https://doi.org/10.3390/land11101680)

- Karadağ, K., Tenekeci, M. E., Taşaltın, R., & Bilgili, A. (2020). Detection of pepper fusarium disease using machine learning algorithms based on spectral reflectance. *Sustainable Computing: Informatics and Systems*, 28. [HTPPs://doi.org/10.1016/j.suscom.2019.01.001](https://doi.org/10.1016/j.suscom.2019.01.001)
- Lenk, S., Dieleman, J. A., Lefebvre, V., Heuvelink, E., Magán, J. J., Palloix, A., van Eeuwijk, F. A., & Barócsi, A. (2020). Phenotyping with fast fluorescence sensors approximates yield component measurements in pepper (*Capsicum annuum* L.). *Photosynthetica*, 58(Special Issue), 622–637. [HTPPs://doi.org/10.32615/ps.2020.016](https://doi.org/10.32615/ps.2020.016)
- 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. [HTPPs://doi.org/10.1007/s40858-021-00460-2](https://doi.org/10.1007/s40858-021-00460-2)
- Li, H. Y., Guo, W., Liu, D., & Li, M. Q. (2018). First report of fusarium semitectum causing root rot of greenhouse pepper (*Capsicum Annuum*) in China. In *Plant Disease* (Vol. 102, Issue 10, p. 2032). American Phytopathological Society. [HTPPs://doi.org/10.1094/PDIS-11-17-1704-PDN](https://doi.org/10.1094/PDIS-11-17-1704-PDN)
- 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*, 100138. [HTPPs://doi.org/10.1016/j.atech.2022.100138](https://doi.org/10.1016/j.atech.2022.100138)
- Martinelli, F., Scalenghe, R., Davino, S., Panno, S., Scuderi, G., Ruisi, P., Villa, P., Stroppiana, D., Boschetti, M., Goulart, L. R., Davis, C. E., & Dandekar, A. M. (2014). Advanced methods of plant disease detection. A review. In *Agronomy for Sustainable Development* (Vol. 35, Issue 1, pp. 1–25). Springer-Verlag France. [HTPPs://doi.org/10.1007/s13593-014-0246-1](https://doi.org/10.1007/s13593-014-0246-1)
- Moradi, S., Bokani, A., & Hassan, J. (2022). UAV-based Smart Agriculture: a Review of UAV Sensing and Applications. *2022 32nd International Telecommunication Networks and Applications Conference, ITNAC 2022*, 181–184. [HTPPs://doi.org/10.1109/ITNAC55475.2022.9998411](https://doi.org/10.1109/ITNAC55475.2022.9998411)
- Nabwire, S., Suh, H. K., Kim, M. S., Baek, I., & Cho, B. K. (2021). Review: Application of artificial intelligence in phenomics. In *Sensors* (Vol. 21, Issue 13). MDPI AG. [HTPPs://doi.org/10.3390/s21134363](https://doi.org/10.3390/s21134363)
- Pérez-Gutiérrez, A., Garruña, R., Vázquez, P., Latournerie-Moreno, L., Andrade, J. L., & Us-Santamaría, R. (2017). Growth, phenology and chlorophyll fluorescence of habanero pepper (*Capsicum chinense* Jacq.) under water stress conditions. *Acta Agronómica*, 66(2). [HTPPs://doi.org/10.15446/acag.v66n2.55897](https://doi.org/10.15446/acag.v66n2.55897)
- Pramanik, K., Mohapatra, P. P., Pradhan, J., Acharya, L. K., & Jena, C. (2020). Factors Influencing Performance of *Capsicum* under Protected Cultivation: A Review. *International Journal of Environment and Climate Change*, 572–588. [HTPPs://doi.org/10.9734/ijecc/2020/v10i1230339](https://doi.org/10.9734/ijecc/2020/v10i1230339)

-
- Rahaman, M. M., Ahsan, M. A., & Chen, M. (2019). Data-mining Techniques for Image-based Plant Phenotypic Traits Identification and Classification. *Scientific Reports*, 9(1).
HTPPs://doi.org/10.1038/s41598-019-55609-6
- Ramchiary, N., & Chittaranjan, K. (2019). *Compendium of Plant Genomes The Capsicum Genome* (N. Ramchiary & K. Chittaranjan, Eds.; 2019th ed.). Springer International Publishing.
HTPP://www.springer.com/series/11805
- Ramírez-Gil, J. G., Henao-Rojas, J. C., & Morales-Osorio, J. G. (2020). Mitigation of the adverse effects of the El Niño (El Niño, La Niña) southern oscillation (ENSO) phenomenon and the most important diseases in Avocado cv. hass crops. *Plants*, 9(6).
HTPPs://doi.org/10.3390/plants9060790
- Rodrigues, L., Magalhães, S. A., da Silva, D. Q., dos Santos, F. N., & Cunha, M. (2023). Computer Vision and Deep Learning as Tools for Leveraging Dynamic Phenological Classification in Vegetable Crops. *Agronomy*, 13(2). HTPPs://doi.org/10.3390/agronomy13020463
- Shaheen, N., Khan, U. M., Azhar, M. T., Tan, D. K. Y., Atif, R. M., Israr, M., Yang, S. H., Chung, G., & Rana, I. A. (2021). Genetics and genomics of fusarium wilt of chilies: A review. In *Agronomy* (Vol. 11, Issue 11). MDPI. HTPPs://doi.org/10.3390/agronomy11112162
- Singh, A., Ganapathysubramanian, B., Singh, A. K., & Sarkar, S. (2016). Machine Learning for High-Throughput Stress Phenotyping in Plants. In *Trends in Plant Science* (Vol. 21, Issue 2, pp. 110–124). Elsevier Ltd. HTPPs://doi.org/10.1016/j.tplants.2015.10.015
- Singh, A., Jones, S., Ganapathysubramanian, B., Sarkar, S., Mueller, D., Sandhu, K., & Nagasubramanian, K. (2021). Challenges and Opportunities in Machine-Augmented Plant Stress Phenotyping. In *Trends in Plant Science* (Vol. 26, Issue 1, pp. 53–69). Elsevier Ltd.
HTPPs://doi.org/10.1016/j.tplants.2020.07.010
- Singh, A. K., Ganapathysubramanian, B., Sarkar, S., & Singh, A. (2018). Deep Learning for Plant Stress Phenotyping: Trends and Future Perspectives. In *Trends in Plant Science* (Vol. 23, Issue 10, pp. 883–898). Elsevier Ltd. HTPPs://doi.org/10.1016/j.tplants.2018.07.004
- 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.
HTPPs://doi.org/10.1016/j.aiia.2020.10.002
- Sosa-Herrera, J. A., Alvarez-Jarquín, N., Cid-García, N. M., López-Araujo, D. J., & Vallejo-Pérez, M. R. (2022). Automated Health Estimation of Capsicum annum L. Crops by Means of Deep Learning and RGB Aerial Images. *Remote Sensing*, 14(19). HTPPs://doi.org/10.3390/rs14194943
- Srikanth, D., Rekha, G. K., Lakshmi, A. P., & Vimatha, P. (2019). Impact of Climate Change in Capsicum Production: A Review. *Current Journal of Applied Science and Technology*, 1–5.
HTPPs://doi.org/10.9734/cjast/2019/v33i330075

- Srivastava, A. K., Safaei, N., Khaki, S., Lopez, G., Zeng, W., Ewert, F., Gaiser, T., & Rahimi, J. (2022). Winter wheat yield prediction using convolutional neural networks from environmental and phenological data. *Scientific Reports*, *12*(1). [HTPPs://doi.org/10.1038/s41598-022-06249-w](https://doi.org/10.1038/s41598-022-06249-w)
- Stemkovski, M., Bell, J. R., Ellwood, E. R., Inouye, B. D., Kobori, H., Lee, S. D., Lloyd-Evans, T., Primack, R. B., Templ, B., & Pearse, W. D. (2023). Disorder or a new order: How climate change affects phenological variability. *Ecology*, *104*(1). [HTPPs://doi.org/10.1002/ecy.3846](https://doi.org/10.1002/ecy.3846)
- Tanner, F., Tonn, S., de Wit, J., Van den Ackerveken, G., Berger, B., & Plett, D. (2022). Sensor-based phenotyping of above-ground plant-pathogen interactions. In *Plant Methods* (Vol. 18, Issue 1). BioMed Central Ltd. [HTPPs://doi.org/10.1186/s13007-022-00853-7](https://doi.org/10.1186/s13007-022-00853-7)
- Tayade, R., Yoon, J., Lay, L., Khan, A. L., Yoon, Y., & Kim, Y. (2022). Utilization of Spectral Indices for High-Throughput Phenotyping. In *Plants* (Vol. 11, Issue 13). MDPI. [HTPPs://doi.org/10.3390/plants11131712](https://doi.org/10.3390/plants11131712)
- Velarde-Félix, S., Garzón-Tiznado, J. A., Hernández-Verdugo, S., López-Orona, C. A., & Retes-Manjarrez, J. E. (2018). Occurrence of *Fusarium oxysporum* causing wilt on pepper in Mexico. *Canadian Journal of Plant Pathology*, *40*(2), 238–247. [HTPPs://doi.org/10.1080/07060661.2017.1420693](https://doi.org/10.1080/07060661.2017.1420693)
- Velasco Belalcazar, M. lucia. (2016). *CHARACTERIZACIÓN DE BACTERIAS ANTAGÓNICAS A Fusarium sp, ASOCIADAS A Capsicum frutescens EN GUACARÍ Y BOLIVAR, VALLE DEL CAUCA*. Universidad Nacional de Colombia sede Palmira.
- Worrall, G., Judge, J., Boote, K., & Rangarajan, A. (2022). In-Season Crop Phenology using Remote Sensing and Model-guided Machine Learning. *Agronomy Journal*. [HTPPs://doi.org/10.1002/agj2.21230](https://doi.org/10.1002/agj2.21230)
- Xie, C., & Yang, C. (2020). A review on plant high-throughput phenotyping traits using UAV-based sensors. In *Computers and Electronics in Agriculture* (Vol. 178). Elsevier B.V. [HTPPs://doi.org/10.1016/j.compag.2020.105731](https://doi.org/10.1016/j.compag.2020.105731)
- Yalcin, H. (2015). Phenology Monitoring Of Agricultural Plants Using Texture Analysis. *Cuarta Conferencia Internacional Sobre Agro-Geoinformática (Agro-Geoinformatics)*, 338–342. [HTPPs://doi.org/doi:10.1109/Agro-Geoinformatics.2015.7248114](https://doi.org/doi:10.1109/Agro-Geoinformatics.2015.7248114)
- Yalcin, H. (2018). Phenology Recognition using Deep Learning. *Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*, 1–5. [HTPPs://doi.org/doi:10.1109/EBBT.2018.8391423](https://doi.org/doi:10.1109/EBBT.2018.8391423)
- Yang, W., Feng, H., Zhang, X., Zhang, J., Doonan, J. H., Batchelor, W. D., Xiong, L., & Yan, J. (2020). Crop Phenomics and High-Throughput Phenotyping: Past Decades, Current Challenges, and

Future Perspectives. In *Molecular Plant* (Vol. 13, Issue 2, pp. 187–214). Cell Press.
[HTPPs://doi.org/10.1016/j.molp.2020.01.008](https://doi.org/10.1016/j.molp.2020.01.008)

Zhang, H., Wang, L., Jin, X., Bian, L., & Ge, Y. (2023). High-throughput phenotyping of plant leaf morphological, physiological, and biochemical traits on multiple scales using optical sensing. *The Crop Journal*. [HTPPs://doi.org/10.1016/j.cj.2023.04.014](https://doi.org/10.1016/j.cj.2023.04.014)

Zhu, Q., Chen, L., Chen, T., Xu, Q., He, T., Wang, Y., Deng, X., Zhang, S., Pan, Y., & Jin, A. (2021). Integrated transcriptome and metabolome analyses of biochar-induced pathways in response to Fusarium wilt infestation in pepper. *Genomics*, *113*(4), 2085–2095.
[HTPPs://doi.org/10.1016/j.ygeno.2021.04.031](https://doi.org/10.1016/j.ygeno.2021.04.031)

2. Capítulo 2. Detección indirecta de parámetros fitosanitarios, fenológicos y productivos del cultivo de ají Cayenne mediante el uso de plataformas de fenotipado e inteligencia artificial

Resumen

El ají Cayenne es un cultivo de gran relevancia en el mundo y con importancia creciente en Colombia debido a sus usos culinarios, propiedades medicinales y como un producto con alto potencial para la exportación. Sin embargo, este cultivo enfrenta desafíos como los problemas fitosanitarios y en especial un complejo denominado marchitamiento vascular (MV) y la variabilidad en su fenología y rendimiento. El objetivo de este trabajo fue desarrollar una metodología para la detección indirecta del estado fitosanitario asociado a MV y la estimación de parámetros fenológicos y productivos del sistema comercial de ají Cayenne mediante el uso de plataformas de fenotipado y herramientas de análisis de datos basado en inteligencia artificial. En un lote comercial, se realizaron mediciones periódicas de 23 parámetros fotosintéticos con un equipo tipo MultispeQ.V2.0. Igualmente, se evaluaron respuestas espectrales y variables geométricos durante tres etapas del cultivo usando un Vehículo Aéreo no Tripulado (VANT) tipo DJI Phantom con cámara multiespectral (5 bandas) acoplada. El análisis de datos consistió en ajustar un modelo de regresión logística multinomial, la implementación de la función AutoML con el objetivo de evaluar distintos modelos de aprendizaje automático (ML) y un modelo de aprendizaje profundo (DL) por su capacidad de clasificar distintos niveles de severidad del MV y parámetros productivos y fenológicos en ají. Se identificaron rasgos fotosintéticos, espectrales y geométricos informativos, como Fv/Fm, NPQt, LDT, RelaChlo, Phi2, geometría del dosel, los índices EVI, NDRE, CIRE y la banda de borde rojo, que permitieron la detección indirecta del MV. Por su parte, los rasgos fotosintéticos y espectrales, como gH+, RelaChlo, LEF, Fs, LDT, así como los índices de vegetación EVI, VARI, NGDRI, Clrededge y IPVI demostraron ser informativos en la estimación de la fenología. Para la estimación del número de frutos, se encontró que rasgos fotosintéticos, espectrales y geométricos como PS1ActCent, RelaChlo, FoPrime, gH+, Fs, Clrededge, CIRE, IPVI y TVI junto con la geometría del dosel. Finalmente, con base en nuestro enfoque fue posible utilizar técnicas de análisis de datos, ML y DL

para detectar y predecir parámetros fitosanitarios, fenológicos y productivos del cultivo de ají Cayenne.

Palabras claves: analítica de datos, clasificación, Regresión logística, AutoML, componentes de rendimiento

2.1 Introducción

El cultivo de ají (*Capsicum annuum* L.), especialmente la variedad Cayenne de nivel moderadamente picante ha cobrado importancia en los últimos años como una actividad hortícola en todo el mundo, dado su valor comercial, culinario, y por el papel que desempeña en la economía rural de países donde esta especie es cultivada (Hernández-Pérez et al., 2020). Esto ha dado lugar a la aparición de múltiples problemas que afectan su productividad, rendimiento y sostenibilidad de los sistemas de producción. Dentro de estas, las fuentes del estrés biótico y abiótico de las plantas, sumado a la influencia ejercida por la variabilidad fenológica y productiva, hacen de esto un reto para su manejo (Arora et al., 2021; Bhutia L et al., 2018; Pramanik et al., 2020; Srikanth et al., 2019; Srivastav et al., 2022). Los estudios en este cultivo sobre fuentes de estrés, sus efectos en la producción, herramientas de detección rápida y económica y sus medidas de manejo son escasas (dos Anjos et al., 2018).

A nivel mundial, el marchitamiento vascular (MV) del ají, causado por algunas especies del género *Fusarium* sp., es una enfermedad que ha tenido un impacto negativo en la producción de este cultivo (Gordon, 2017; Shaheen et al., 2021; Velarde-Félix et al., 2018). En el contexto colombiano, en el departamento del Valle del Cauca, esta enfermedad representa una de las mayores limitantes en el cultivo del ají (Castro Clavijo, 2014). En este patosistema, una vez que el hongo logra ingresar y afectar el tejido de la planta, se propaga entre las células del tejido cortical hasta alcanzar el xilema (Gabrekiristos & Demiyo, 2020; Jangir et al., 2021; Zhu et al., 2021). Esto resulta en la manifestación de síntomas como el marchitamiento severo, el colapso de la estructura, la disminución o desintegración del sistema vascular y, en última instancia, la muerte de la planta (Gordon, 2017; Jangir et al., 2021; Zhu et al., 2021). Es importante destacar que la manifestación visible de MV es un síntoma tardío de la infección por *Fusarium* sp. (Shaheen et al., 2021).

En cuanto a las opciones de manejo y prevención de la MV, existen pocas alternativas conocidas. Estas incluyen el uso de desinfectantes de suelo, la aplicación de fungicidas de síntesis química, la rotación de cultivos y el empleo de materiales resistentes, siendo este último considerado el método más efectivo (Gabrekiristos & Demiyó, 2020). Por lo tanto, es fundamental realizar un monitoreo de la enfermedad, el cual puede llevarse a cabo mediante evaluaciones visuales realizadas por expertos o personal capacitado (V. Singh et al., 2020), o mediante técnicas que utilizan el ADN y fundamentos de serología para la detección de la enfermedad (León-Rueda et al., 2022; Martinelli et al., 2014; V. Singh et al., 2020). Sin embargo, estos métodos requieren un alto esfuerzo humano, tiempo y presentan un costo elevado (Buja et al., 2021). Consecuentemente, el desarrollo de métodos novedosos de monitoreo junto con la detección rápida, precisa y económica han sido promovidos como un objetivo prioritario a corto plazo en el manejo de enfermedades en las plantas (Buja et al., 2021).

Las interacciones entre plantas y las fuentes de estrés biótico como la MV y abiótico pueden generar diferentes tipos de respuesta de la planta, dentro de estas se incluye cambios en la pigmentación, el metabolismo y la disipación de energía térmica (Tanner et al., 2022). En este sentido la infección por patógenos afecta los metabolitos primarios necesarios para la fotosíntesis y también los metabolitos secundarios, como las fitoalexinas que son generadas como respuesta al patógeno (Berger et al., 2007; Rojas et al., 2014; Tanner et al., 2022). Igualmente, la clorosis se caracteriza por un bajo contenido de pigmentos, mientras que en la necrosis no hay pigmentos y las células del mesófilo carecen de la cantidad de agua de un tejido sano, lo que lleva a un colapso celular y afecta la reflectancia de las plantas afectadas y que puede ser cuantificada de forma indirecta por sensores ópticos (Tanner et al., 2022). De igual manera, la variación en la temperatura de las hojas de las plantas puede ser causada por interacciones con patógenos o alteraciones en el balance de energía de los tejidos (Jones & Rotenberg, 2001). Como caso concreto, los patógenos vasculares que colonizan el xilema de las plantas hospederas pueden obstruir el flujo de agua causando síntomas similares al estrés hídrico (Calderón et al., 2013).

Por otra parte, el ají Cayenne, pasa por diversas etapas fenológicas en su ciclo de vida. En particular, en este cultivo se observa la emergencia de las inflorescencias, seguida de la floración, el desarrollo de los frutos y su posterior maduración (Feldmann & Rutikanga, 2021). Cada una de estas etapas tiene características específicas que se pueden describir mediante microetapas y mesoetapas, y son

de gran importancia en la producción y manejo agronómico de esta especie (Feldmann & Rutikanga, 2021; Meier et al., 2009). Es fundamental resaltar que la variabilidad de la fenología tiene implicaciones en la productividad y sostenibilidad de los sistemas de producción (Jing et al., 2017; Y. Li et al., 2023). Esta situación da lugar a la necesidad de desarrollar herramientas de análisis de respuestas rápidas a fuentes de estrés y variabilidad fenológica y así poder implementar estrategias de adaptación y mitigación que busquen lograr reducir el impacto de estos fenómenos, en especial sobre los componentes de rendimiento. En particular, en el caso de los cultivos de ají, el número de frutos por planta se convierte en un parámetro crucial para el seguimiento del rendimiento de frutos (Gholipoor & Nadali, 2019) y, a su vez, desempeña un papel crucial en la gestión del cultivo y la logística de la cosecha. Este parámetro también se ve directamente influenciado por los efectos de la variabilidad fenológica (Srikanth et al., 2019) a.

En la actualidad las plataformas de fenotipado de alto rendimiento en procesamiento (high-throughput phenotyping platforms - HTPP, por sus siglas en inglés) es una técnica que implica medir los rasgos de las plantas en diferentes condiciones ambientales con precisión utilizando múltiples fuentes de datos y procesamiento avanzado de datos a través de la inteligencia artificial (J. Y. Kim, 2020; A. Singh et al., 2016; V. Singh et al., 2020; Ye et al., 2020). El HTPP consiste en la recopilación de múltiples datos asociados al uso de diversos sensores próximos o remotos, los cuales pueden ser fijos o acoplados a vehículos autónomos terrestres, fenomóviles, tractores, torres de fenotipado, plataformas de exploración de campo, y vehículos aéreos no tripulados (VANT), aviones, zepelines y satélites (Andrade-Sánchez et al., 2014; Shakoor et al., 2017).

El HTPP de estrés biótico y abiótico en plantas es una técnica no invasiva o de caracterización indirecta importante para identificar materiales con respuesta diferencial y a partir de esto lograr desarrollar estrategias de manejo eficientes del estrés, gracias a la determinación de características discriminantes de la fuente u origen del estrés (Feng et al., 2021; A. Singh et al., 2021). Este enfoque se basa en la captura de múltiples fuentes de datos y su respectivo análisis. En este sentido, comúnmente se usa la reflectancia como base para determinar la salud de las plantas (Karadağ et al., 2020; Marín-Ortiz et al., 2020; Ortiz et al., 2019; Pugh et al., 2018; Sosa-Herrera et al., 2022; Tayade et al., 2022). Igualmente, la medición de parámetros fotosintéticos pueden ser una herramienta útil para detectar fuentes de estrés (Baker, 2008; Furbank & Tester, 2011; Murchie & Lawson, 2013). El HTPP se ha usado en múltiples enfoques como identificación de resistencia a enfermedades y

predicción genómica (Alkemade et al., 2021), análisis de transcripción a nivel global de genes de desarrollo vegetal (Schneider et al., 2022), rastrear el efecto de bioestimulantes (Ben-Jabeur et al., 2021), estimar el estado fenológico y los componentes de rendimiento (Andrade-Sanchez et al., 2014; Araus & Cairns, 2014; Galli et al., 2020; Sarkar et al., 2021; Q. Yang et al., 2020), entre otros.

Dentro del concepto de agricultura inteligente se puede incluir el HTPP, basado en el uso de vehículos aéreos no tripulados (VANT), como una herramienta potencial de “bajo costo” con la eficiencia necesaria para capturar los rasgos fisiológicos de las plantas y cultivos de manera rápida y con capacidad de escalar grandes extensiones, con sensores incorporados o acoplados (Qu et al., 2022; Tayade et al., 2022). El enfoque de cámaras espectrales acopladas a VANT, tradicionalmente se ha usado para la detección de múltiples problemas fitosanitarios en diferentes sistemas de producción, con ventajas y desventajas con respecto a los métodos tradicionales (Rodríguez et al., 2021; S. Zhang et al., 2022). En este sentido, se ha encontrado que el éxito de estos sensores como las cámaras multispectrales depende en gran parte de aspectos como la resolución espectral, espacial de la imagen, el tipo de sensor, aspectos de preprocesamiento y postprocesamiento de los datos y los métodos de análisis usados (Bouguettaya et al., 2022; Duarte-Carvajalino et al., 2018; Moradi et al., 2022; Pugh et al., 2018; Xie & Yang, 2020; Ye et al., 2020). Igualmente, influyen los tipos de índices a construir en función de las bandas de origen, los parámetros geométricos o texturales de las imágenes, y variables fisiológicas obtenidos con otros sensores (Bannari et al., 1995; Galli et al., 2020; León-Rueda et al., 2022; Ravichandran et al., 2016; Sosa-Herrera et al., 2019; Xiao et al., 2021).

El HTPP, no solo incluye datos obtenidos de cámaras multispectrales acopladas a VANT, sino también el uso de sensores manuales. En este sentido el sensor MultispeQ proporciona mediciones precisas y específicas, el cual ha sido diseñado especialmente para obtener información fisiológica de las plantas (Herts et al., 2020; Kuhlger et al., 2016). El MultispeQ captura de forma indirecta el estado fotofísico y fotoquímico del cultivo relacionando con parámetros fotosintéticos en cortos tiempos en comparación con técnicas tradicionales (Fernández-Calleja et al., 2020; Gu et al., 2023; Kanazawa et al., 2021).

Es así como HTPP, asociado al uso de datos obtenidos de plataformas tanto terrestres como aéreas, han superado ampliamente las capacidades de las técnicas de fenotipado convencionales (Feng et

al., 2021; A. Singh et al., 2016; H. Zhang et al., 2023). Esto se debe a su enfoque en el uso de muestreos no destructivos, la recopilación de grandes volúmenes de datos y la capacidad para ampliar la escala espacio temporal, entre otros aspectos (Jangra et al., 2021; Robles-Zazueta et al., 2022; W. Yang et al., 2020). El HTPP y las plataformas de obtención de datos de respuesta como herramienta de caracterización no solo se basa en las plataformas de adquisición de la data, sino en la correcta forma en que esta se puede analizar y lograr encontrar patrones y asociaciones con las fuentes de estrés de forma rápida, precisa, informativa y sensible.

En este sentido, la inteligencia artificial (AI) y todos sus métodos de análisis avanzados de datos donde se destacan el aprendizaje automático (ML) y profundo (DL) (Sujatha et al., 2021), se convierte en una herramienta clave para integrarse con el HTPP, dado sus múltiples ventajas con respecto a los métodos tradicionales de analítica de datos (Nabwire et al., 2021). El ML, utiliza herramientas para "aprender" de grandes colecciones de datos para clasificar, identificar patrones y características y predecir tendencias (Nabwire et al., 2021). Por su parte el DL funciona de manera similar a la estructura neuronal del cerebro humano, con capas y optimizadores que ayudan a construir respuestas fiables y precisas (Sujatha et al., 2021).

A pesar de los múltiples trabajos que han combinado elementos de HTPP con herramientas modernas de analítica de datos en diferentes especies, su aplicación en sistemas de producción comercial y su contribución a la toma de decisiones basadas en evidencia todavía es incipiente. En contraste, se ha observado un notable éxito en la aplicación de modelos de ML para predecir el desarrollo fenológico del ají, con altos niveles de precisión en la simulación del crecimiento del cultivo (Tang et al., 2023) y la predicción de componentes de rendimiento (Gholipoor & Nadali, 2019). Además, la detección de enfermedades mediante algoritmos de ML y el uso creciente de tecnologías de IA en el fenotipado vegetal para la caracterización de e identificación de diversos tipos de estrés (Karadağ et al., 2020; Nabwire et al., 2021; A. Singh et al., 2021; Sosa-Herrera et al., 2019, 2022).

Estos avances se han dado bajo condiciones controladas y se han limitado en temáticas particulares según las necesidades de los sistemas de producción, pero aún existe una necesidad de investigación sobre los rasgos fenotípicos relacionados con la detección indirecta (no invasiva), precisa y rápida de la MV, así como de la estimación de la fenología y el número de frutos en plantas de ají, esto representa un rezago para los cultivos comerciales en Colombia. Dado lo anterior, en este estudio, nos enfocamos en cerrar esta brecha tecnológica mediante la aplicación de HTPP e IA para la

minería de rasgos fenotípicos que faciliten detectar indirectamente parámetros fitosanitarios, fenológicos, y productivos del cultivo de ají bajo cultivos comerciales, este enfoque contribuirá a la implementación de métodos avanzados, originando las bases para la integración de herramientas de agricultura 4.0 a sistemas de producción comercial, fundamental para la planificación de la producción y la gestión eficiente del sistema productivo a nivel comercial.

2.2 Metodología

2.2.1 Material vegetal y condiciones generales de lote comercial usado

Se utilizó un cultivo comercial con objetivo de exportación de ají tipo Cayenne (*C. annuum*), de 1.2 hectáreas, ubicado en el corregimiento del Bolo, municipio de Candelaria, departamento del Valle del Cauca, Colombia (latitud 3°27'35.8" N, longitud de 76°19'52.6" O), a una altitud de 989 m (Figura 2-1). La germinación de las plántulas se realizó bajo condiciones de luz, humedad y temperatura controladas, en bandejas de 72 alvéolos, usando como sustrato turba (PINDSTRUP) garantizando así la fitosanidad, esta fue regada, dos veces por día. La germinación, se dio a los ocho días después de la siembra, posteriormente se procedió a realizar el trasplante a los 30 días después de germinación, el trasplante se realizó en agosto de 2021. La densidad de siembra fue de 0.3 m entre planta, en doble hilera y 1.5 m entre surcos para un total de 44.444 plantas por hectárea. Los surcos fueron cubiertos por plástico color gris plata para controlar arvenses. La irrigación del cultivo y la fertilización fue a través de sistemas de riego por goteo, según indicaciones del equipo técnico (no incluidas acá por temas de confidencialidad). El tutorado se realizó de manera convencional con hilo y madera seca a los 15 días después del trasplante. El manejo integrado y todas las prácticas del cultivo fue de acuerdo con las necesidades comerciales y los requerimientos para exportación de este cultivo bajo un estricto proceso de producción agrícola (para más información revisar la Tabla del anexo A).

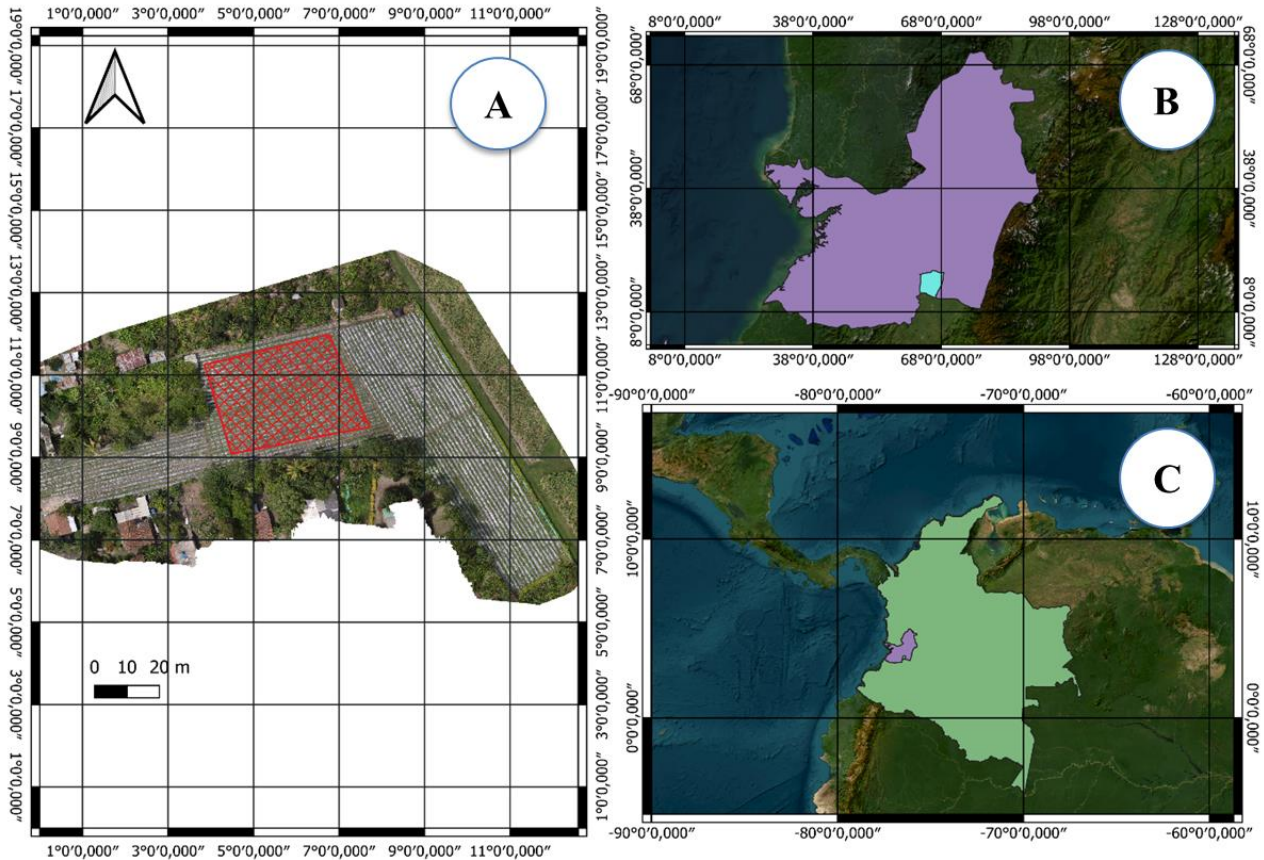


Figura 2-1. (A) Área de estudio, (B) municipio de candelaria en contexto departamental del Valle del Cauca y (C) departamento en contexto de Colombia

2.2.2 Esquema básico metodológico, adquisición de variables y escala temporal de evaluación

El cultivo fue monitoreado desde agosto de 2021 hasta enero de 2022. La captura de datos relacionados con variables fotosintéticas, fenológicas, fitosanitarias asociadas a MV y productivas se realizó en 12 ocasiones, comenzando 15 días después del trasplante y continuando cada dos semanas hasta terminar el ciclo de evaluación. Igualmente, las respuestas espectrales fueron determinadas en tres etapas del cultivo a los días 16 y 23 de septiembre (47 DDT y 54 DD respectivamente) y 24 de octubre de 2021 (58 DDT) (Figura 2-2). El esquema metodológico de captura, procesamiento y análisis paso a paso se describe en la Figura 2-2. Los muestreos se realizaron a partir de una área seleccionada en el lote comercial con 96 parcelas de 10 m de largo

por 1.5 m de ancho, y por cada parcela se muestrearon tres (3) plantas tanto para los parámetros fitosanitarios, productivos y fotosintéticos (Figura 2-1).

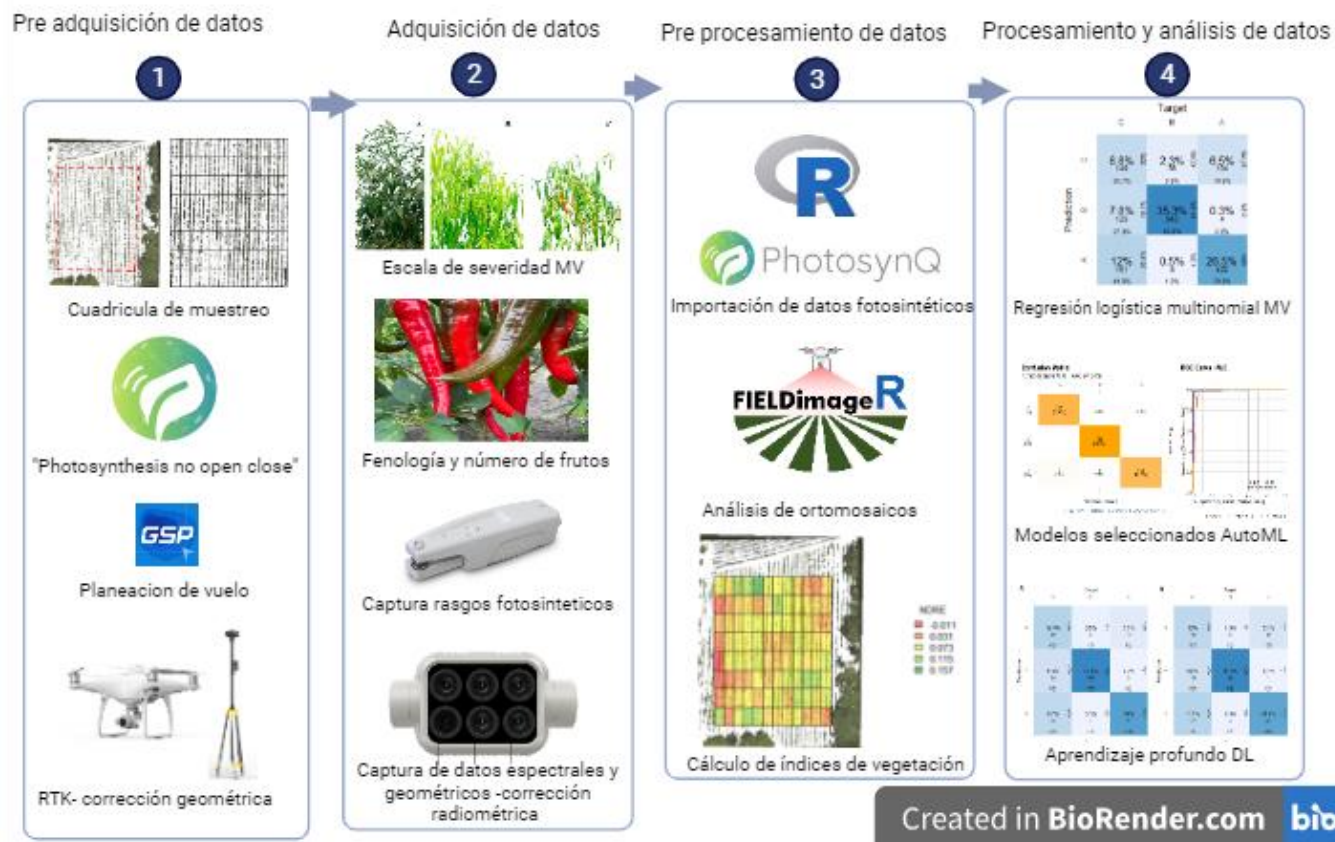


Figura 2-2. Flujo de trabajo seguido en este estudio, (1) preadquisición de datos, (2) adquisición de datos, (3) preprocesamiento de datos y (4) procesamiento y análisis de datos

2.2.3 Variables evaluadas a nivel de cultivo

a. Sanidad del cultivo

En cada fecha de evaluación descrita anteriormente tanto para rasgos fotosintéticos como espectrales y geométricos en cada una de las tres plantas asociadas a cada parcela, se evaluó la fitosanidad del cultivo principalmente la MV, dado que esta enfermedad fue la de mayor importancia en términos de incidencia, severidad e impacto en producción durante el ciclo de cultivo.

Los síntomas del MV que fueron tenidos en cuenta para la clasificación fitosanitaria del cultivo incluyeron un cambio en el color de las hojas, las cuales adquirieron una tonalidad amarillenta, retraso en el crecimiento general de la planta, evidenciada en un desarrollo más lento de sus tejidos y órganos, epinastia, asociada a la curvatura o flexión hacia abajo de los pecíolos de las hojas generando el marchitamiento gradual de las hojas, la pérdida de turgencia y la presencia de haces vasculares necrosados. Estos síntomas coinciden con los reportados para los procesos de diagnóstico de la MV relacionado con la presencia de *Fusarium* sp. agente causal de la enfermedad MV (Eke et al., 2021; Farihadina & Sutarman, 2022). Igualmente, este en estudio, se observó que el desarrollo temporal y la distribución espacial de esta afección no siguió un patrón uniforme o aleatorio, sino que tienden a formar agrupaciones o conglomerados similar a lo reportado en la literatura (Rekah et al., 1999). Basándonos en los síntomas observados, la distribución espacial a nivel de lote y los resultados de las pruebas de diagnóstico realizadas por el equipo técnico de la empresa (Colombina), identificamos nuestro objetivo o blanco biológico la MV asociada a algunas especies del género *Fusarium* sp. Estas pruebas de diagnóstico a las que se sometieron las muestras, realizadas por el personal técnico de la compañía, se centraron en la identificación morfológica y aislamiento de patógenos en laboratorio a partir de muestras de plantas recolectadas en diferentes municipios del departamento en años anteriores. Los resultados de estas pruebas confirmaron la presencia de hongos pertenecientes al género *Fusarium* sp. Igualmente, para el análisis se descartaron las plantas con síntomas confusos, potencialmente asociados a otras fuentes de estrés (deficiencias nutricionales, patologías foliares, estrés por sequía, entre otros).

La severidad de la MV se evaluó mediante observaciones periódicas utilizando una escala de severidad propuesta en este trabajo la cual previamente se validó y se ajustó para lograr representar la dinámica de la intensidad de la enfermedad según el avance de la MV y sus implicaciones en términos fitosanitarios para la planta (Ramírez-Gil & Morales-Osorio, 2020). La escala se basó en la presencia e intensidad de los síntomas de la enfermedad utilizando una escala visual con tres categorías: (a) ausencia de síntomas, (b) 0.1-25% de la parte aérea de la planta que presentó síntomas de marchitamiento y (c) > 25.1% de la parte aérea de la planta presenta síntomas de marchitamiento (Figura 2-3).




Figura 2-3. Escala de severidad de MV en plantas de ají Cayenne. (A) Ausencia de síntomas en la parte aérea de la planta de ají. (B) 25% de la parte aérea de la planta de ají presenta síntomas amarillamiento foliar, marchitez y leve. (C) Mas de 25.1% de la parte aérea de la planta de ají presenta síntomas de amarillamiento foliar, marchitez y epinastia avanzada, y presencia de haces vasculares necrosados

b. Parámetros fenológicos y productivos

Inicialmente se estimó la fenología por cada parcela del sistema comercial de producción de ají tipo Cayenne usando la escala B.B.C.H ajustada específicamente para este tipo de fenotipos (Feldmann & Rutikanga, 2021). Las etapas fenológicas se asociaron para nuestro caso en particular a cuatro clases: (i) emergencia de inflorescencia, (ii) floración, (iii) desarrollo de fruto y (iv) maduración del fruto. Los componentes de rendimiento del sistema comercial de producción de ají se determinaron a partir del número de frutos por planta, el cual se consideró como parámetro productivo. Para obtener esta información, se realizó un conteo numérico en campo de todos los frutos presentes en

la planta, independientemente de su estado de maduración y tamaño. No se llevaron a cabo marcaciones específicas en los frutos para cuantificarlos en la planta.

2.2.4 Captura y adquisición de variables predictoras

a. Adquisición de datos fotosintéticos

En cada parcela se midieron tres plantas, con tres repeticiones por cuadrícula (Figura 2-1). Los rasgos fotosintéticos se midieron utilizando el dispositivo MultispeQV2.0 siguiendo el protocolo "Photosynthesis RIDES no open/close" (Herts et al., 2020). Los muestreos se realizaron entre las 10:00 a.m. y las 3:00 p.m., con condiciones climáticas que no presentaran nubosidades mayores al 30%. El sensor fue ubicado sobre las hojas del tercio medio de la plantas según su condición sanitaria (sana o enferma y su grado de severidad según las descripción posterior), allí la medición se realiza de forma automática. Se recopilaron 1.338 datos entre fisiológicos y de severidad MV obtenidos a partir del sensor (para más información de la data consultar: [HTPPS://photosynq.org/projects/cayenne-5-0/explore](https://photosynq.org/projects/cayenne-5-0/explore) ;ID14582). En este estudio y con base la data que adquiere de forma indirecta el dispositivo MultispeQV2.0, se midieron 23 rasgos fotosintéticos (Tabla 1).

Tabla 1. Variables y descripción básica de rasgos fotosintéticos evaluados con el sensor proximal MultispeQV2.0.

Nombre Abreviado	Descripción
LEF	Flujo Lineal de Electrones
LDT	Diferencial de Temperatura Foliar
tp700	Tiempo de Vida de la Transferencia de Electrones P700
qL	Fracción de Centros del Fotosistema II Abiertos cuando el QA se Oxida (Aceptor de Electrones Primario)
ECS_tau	Tasa del Cambio Electrocrómico
gH⁺	Conductividad de Protones de la ATP Sintasa
ECSt mAU	Magnitud Total de la Disminución del Cambio Electrocrómico durante una Transición de Luz a Oscuridad expresada en mili Unidades de Absorbancia
Phi2	Fracción de Energía Lumínica Captada por Fotosistema II
PS1ActCent	Centros Activos del Fotosistema I
PS1OxidCent	Centros Oxidados del Fotosistema I
PS1reducedCenters	Centros Reducidos del Fotosistema I

PSIOpeCent	Centros Abiertos del Fotosistema I
PhiNPQ	Fracción de Energía Lumínica Captada por Fotosistema II dirigida a la Disipación No Fotoquímica
NPQt	Quenching No Fotoquímico
vH⁺	Flujo de Protones en Estado Estacionario
Fmprime	Fluorescencia Variable Máxima en Condiciones de Estado Estacionario
Fopprime	Fluorescencia Variable Mínima durante la Fase Oscura después de un Estado Estacionario
Fs	Fluorescencia Variable en Condiciones de Estado Estacionario
Fv/Fm	Eficiencia Cuántica Máxima de la Actividad Fotoquímica del Fotosistema II cuando Todos los Centros de Reacción del Fotosistema II están Abiertos
V_initial_p700	Tasa Inicial de Transferencia de Electrones en Estado Estacionario de P700
RelaChloroII	Contenido Relativo de Clorofila
kp700	Constante de Velocidad de Transferencia de Electrones en P700
PhiNO	Fracción de Energía Lumínica Capturada por Fotosistema II que se Pierde en Procesos No Regulados

b. Adquisición de datos espectrales y geométricos a través de cámara espectral integrada a VANT

Se recopilaron imágenes multiespectrales de la superficie del cultivo utilizando un VANT modelo DJI Phantom 4 Multiespectral. Este VANT cuenta con cinco bandas espectrales que cubren longitudes de onda en el espectro electromagnético: roja (R) a 650 nm con un ancho de banda ± 16 nm; verde (G) a 560 nm con un ancho de banda ± 16 nm; azul (B) a 450 nm con un ancho de banda ± 16 nm; borde rojo (RE) a 730 nm con un ancho de banda ± 16 nm e infrarrojo cercano (NIR) a 840 nm con un ancho de banda ± 26 nm. Todas estas imágenes se capturaron con una resolución de 2 megapíxeles y un obturador global en un cardán estabilizado de 3 ejes. El Phantom 4 Multiespectral cuenta con un sensor de luz solar espectral integrado en la parte superior que permite la captura de la radiación solar, permitiendo la corrección radiométrica automática para mejorar la precisión y la coherencia de los datos recogidos en diferentes días de vuelo.

Para la planificación de vuelos, se utilizó la aplicación DJI GS PRO. Para la generación de ortomosaicos se empleó una versión de prueba para Windows del software TERRA de DJI V 3.9.3 ([HTPPs://enterprise.dji.com/dji-terra/downloads](https://enterprise.dji.com/dji-terra/downloads)), asegurando previamente una superposición del

80% entre las imágenes capturadas. Además, la integración de una estación D-RTK 2 de alta precisión, permitió una corrección geométrica para mejorar la precisión de los datos recopilados. Los vuelos se realizaron a una altitud de 60 metros sobre el nivel del suelo, a una velocidad de 10 m s⁻¹, para obtener una cobertura adecuada del área de estudio.

A partir de las respuestas espectrales y geométricas del cultivo obtenidas en cada vuelo con base en el uso del VANT-Cámara de tipo DJI Phantom 4 Multiespectral y posterior a la generación de los ortomosaicos, se calcularon diferentes índices de vegetación para lo cual se usó la librería del software libre de R *FIELDImageR* para la extracción del valor promedio de los índices de vegetación de cada cuadrícula en el área de estudio (DeSalvio et al., 2022; Matias et al., 2020). En total se usaron los índices que se reportan en la Tabla S1 del anexo B, los cuales se han reportado previamente por su capacidad para detectar desórdenes asociados a estrés biótico y abiótico, al igual que se identifica su característica fisiológica y bioquímica implicada.

Dado que los rasgos fenotípicos a evaluar en este trabajo asociados a la MV, la fenología y el número de frutos son desconocidos para la variedad evaluada bajo condiciones de campo, fue necesario realizar una minería de múltiples índices (Tabla S1 del anexo B), es fundamental tener en cuenta que no siempre es evidente de antemano cuáles rasgos o índices son los más relevantes para predecir las variables de interés. Por lo tanto, se optó por incluir un amplio conjunto de variables de entrada en los modelos de con el propósito de permitir a los algoritmos identificar patrones y relaciones complejas entre los rasgos fotosintéticos y espectrales y las variables de respuesta.

2.2.5 Selección de variables predictoras y ajuste a modelos de pronóstico de parámetros fitosanitarios, fenológicos y productivos en el sistema comercial de producción de ají usando variables fotosintéticas, espectrales y geométricas

Para seleccionar las variables predictoras asociadas a los parámetros fitosanitarios, fenológicos y productivos del sistema comercial de producción de ají, se utilizaron 51 variables entre los rasgos fotosintéticos (Conejo Rodríguez et al., 2022), rasgos espectrales y geométricos (valores promedio de los índices de vegetación de cada cuadrícula) (Guimarães et al., 2021). Inicialmente, se realizó una organización, limpieza y estandarización de las variables predictoras.

a. Detección indirecta de parámetros fitosanitarios asociados a MV

El primer enfoque de análisis fue basado en la variable respuesta asociada a los tres niveles de severidad de la MV. Se realizó un ajuste a una regresión logística multinomial, implementada en la librería *nnet* en el software libre R (Uddin & Gaskins, 2023). Las variables usadas como predictoras fueron los rasgos fotosintéticos, espectrales y geométricos, posterior a eliminar las variables correlacionadas con el fin de evitar la colinealidad y sobrestimación del modelo. Para esta primera etapa se eliminaron las variables con menor sentido biológico, ecológico y epidemiológico de la enfermedad y que presentaran valores > 0.8 en el coeficiente de correlación de Pearson (relación entre variables continuos) o Spearman según el origen de la variable (como alternativa no paramétrica a la correlación de Person).

El modelo de regresión logística multinomial se basó internamente en la optimización de la función de verosimilitud mediante el método de descenso del gradiente. Esto permitió estimar los coeficientes que relacionan las variables predictoras con los diferentes niveles de MV (Resti et al., 2022). Las métricas utilizadas para la evaluación del modelo fueron la matriz de confusión, la precisión que mide la proporción de predicciones correctas, el índice Kappa que evalúa la concordancia teniendo en cuenta el acuerdo por azar, la sensibilidad que indica la proporción de casos reales correctamente identificados en una clase, y la especificidad que mide la proporción de casos reales excluidos correctamente de una clase (Ripley, 2007).

El segundo enfoque utilizado fue mediante la función AutoML implementada con la librería *h2o* del software libre R, la cual permite optimizar y seleccionar de forma automática un set de modelos de ML con base en múltiples métricas (Ledell & Poirier, 2020; Truong et al., 2019; Wever et al., 2021). La función AutoML realiza un entrenamiento y validación cruzada de varios algoritmos de forma predeterminada, que incluyen tres modelos preespecificados XGBoost GBM (Gradient Boosting Machine), una cuadrícula fija de GLM (Generalized Linear Model), un bosque aleatorio distribuido (DRF), cinco modelos GBM de *h2o* predeterminados, un bosque extremadamente aleatorio (XRT), una cuadrícula aleatoria de GBM XGBoost y una cuadrícula aleatoria de GBM de *h2o*. En el contexto de la función AutoML una “cuadrícula” es una técnica de búsqueda de hiperparámetros con una serie de valores predefinidos que se prueban sistemáticamente para encontrar la configuración óptima del algoritmo (Ledell & Poirier, 2020; Truong et al., 2019; Wever et al., 2021). Adicionalmente, la función AutoML consta de varios procesos: preparación de datos, ingeniería de características,

generación de modelos y evaluación de modelos (X. He et al., 2021). Para nuestro caso particular, se prepararon los datos escalando las variables numéricas y convirtiendo las variables categóricas en factores (*one hot encode*). El conjunto de datos se dividió automáticamente en un sets de entrenamiento con el 70% y de prueba el restante 30%.

Durante el proceso de evaluación de los modelos generados por la función AutoML, las métricas usadas en la predicción de MV fueron la media del error por clase (Mean-per-class-error), crucial en problemas de clasificación multiclase y detiene el modelo cuando la tasa de error promedio por clase no mejora (Ledell & Poirier, 2020; Naser & Alavi, 2021; Truong et al., 2019), pérdida logarítmica (Logloss) mide la cercanía de las probabilidades pronosticadas del modelo a los valores reales (Ledell & Poirier, 2020; Wever et al., 2021), error cuadrático medio (MSE) que evalúa el promedio de los errores al cuadrado en las predicciones, dando más peso a los errores significativos, siendo un MSE más bajo un indicativo de un mejor desempeño del modelo (Naser & Alavi, 2021), raíz del error cuadrático medio (RMSE) es similar al MSE, pero en unidades de la variable objetivo, lo que facilita la interpretación del tamaño del error (Naser & Alavi, 2021). La matriz de confusión muestra el desempeño del algoritmo en términos de falsos positivos, falsos negativos, verdaderos positivos y verdaderos negativos, con las etiquetas de clase basadas en la mayor probabilidad prevista (X. He et al., 2021; Ledell & Poirier, 2020). La tasa de precisión (ACC) mide la proporción de predicciones correctas en el conjunto de datos de prueba (Ledell & Poirier, 2020). El Área Bajo la Curva ROC (AUC) se utiliza para evaluar la capacidad de un modelo de clasificación multiclase para distinguir entre verdaderos y falsos positivos en todos los dominios (Ledell & Poirier, 2020). La importancia de las variables se establece al evaluar cuánto influye en el proceso, considerando si se selecciona para dividir nodos en la construcción de un árbol de decisión y cuánto mejora o empeora el error cuadrático en general debido a esta elección. Cuando *h2o* divide un nodo en un árbol de decisión, ya sea basado en una característica numérica o categórica, la importancia de esa característica se mide por la reducción del error al cuadrado. Esto significa que se compara el error cuadrático en el nodo antes de la división con el error cuadrático en los nodos resultantes de esa división. La reducción del error al cuadrado se traduce en la disminución de la variabilidad en los valores de respuesta dentro de ese nodo (Ledell & Poirier, 2020). Por último, la tabla de todos los modelos entrenados y selección del mejor modelo según métricas descritas anteriormente (Ledell & Poirier, 2020; Naser & Alavi, 2021). Posteriormente, y como complemento utilizamos la librería *esquisse* de R para visualizar la

distribución de los valores de las rasgos fotosintéticos y espectrales predictoras en función de los distintos niveles de severidad de MV.

Como tercer tipo de modelo los datos de severidad se ajustaron a un modelo basado en el enfoque de aprendizaje profundo (DL), implementado en la librería *h2o* de R. Se utilizó un modelo de red neuronal profunda o perceptrón multicapa (MLP) con cinco capas ocultas, cada una compuesta por 64 neuronas, cada capa oculta se configuro con una función de activación Rectifier, y se realizaron 100 épocas de entrenamiento para mejorar la precisión del modelo y buscar la convergencia del método. Se estableció una semilla aleatoria para garantizar la reproducibilidad de los resultados. Los rasgos fotosintéticos, espectrales y geométricos se especificaron como entradas para el modelo, mientras que la variable de respuesta fue los niveles de MV. El conjunto de datos de entrenamiento se utilizó para ajustar el modelo. Las métricas de evaluación del modelo DL en la predicción de MV, incluyeron error cuadrático medio, raíz del error cuadrático medio, pérdida logarítmica, matrices de confusión tanto para el conjunto de entrenamiento como para el conjunto de prueba (Candel et al., 2016). Además, se calculó la importancia de las variables mediante el método Gedeón (Candel et al., 2016; Gedeon, 1997).

b. Clasificación de estados fenológicos y pronóstico de componentes de rendimiento (# de frutos)

Para el ajuste al modelo de predicción de la fenología se utilizó el enfoque descrito en detalle anteriormente para MV, usando específicamente los modelos de ML y DL, dado que el objetivo es poder clasificar clases o estados fenológicos, en total cuatro según las descripción planteada anteriormente. Por su parte, para la predicción del número de frutos se usó el mismo enfoque, pero los modelos de ML y DL fueron de tipo regresión, dado que esta variable es de tipo continua. Para la función AutoML se usaron las métricas mencionadas anteriormente junto con R^2 , la cual refleja la adecuación de las predicciones de un modelo a los valores reales, con un rango entre 0 (sin correlación) y 1 (correlación perfecta) (Naser & Alavi, 2021), error absoluto medio (MAE) que es el promedio de los errores absolutos y es resistente a valores atípicos, error cuadrático medio (Ledell & Poirier, 2020; Naser & Alavi, 2021), error logarítmico cuadrático medio (RMSLE) usado cuando las predicciones insuficientes son más críticas que las predicciones excesivas y evita penalizar

diferencias grandes en valores altos (Naser & Alavi, 2021), y la desviación residual media (MRD) que mide la calidad de los ajustes de las predicciones de los modelos de regresión a los valores reales observados (Ledell & Poirier, 2020). Para el modelo DL las métricas usadas fueron error cuadrático medio, raíz del error cuadrático medio, error absoluto medio y la desviación residual media (Candel et al., 2016). La importancia de las variables se realizó siguiendo enfoque descrito anteriormente (Candel et al., 2016; Gedeon, 1997). Finalmente, utilizando las librerías *esquisse* y *Tidyverse* en R, se procedió a calcular el valor promedio y el coeficiente de variación de las rasgos fotosintéticos predictores de la fenología y el número de frutos en el cultivo de ají.

Para una mejor comprensión de las métricas utilizadas en este trabajo para evaluar los distintos modelos, y según el enfoque que queríamos determinar se sugiere revisar la información suplementaria Tabla S2 del anexo B.

2.3 Resultados

2.3.1 Importancia de la MV en el cultivo ají evaluado

En el sistema comercial de ají evaluado, se observó que el número de plantas afectadas por la MV estuvo relacionado con la etapa fenológica de la planta. En este sentido, se encontró que el número de plantas con MV y su grado de enfermedad (severidad) fue mayor durante la etapa fenológica de emergencia de la inflorescencia con respecto a la etapa de floración, donde se presentaron los menores valores. Sin embargo, se encontró un incremento en el número de plantas clasificadas como B y C (enfermas con valores altos de severidad), durante las etapas de desarrollo y maduración del fruto, siendo esta última la de mayor relevancia, no sólo en términos de plantas afectadas, sino también a nivel de severidad (mayores niveles de enfermedad) (Figura 2-4).

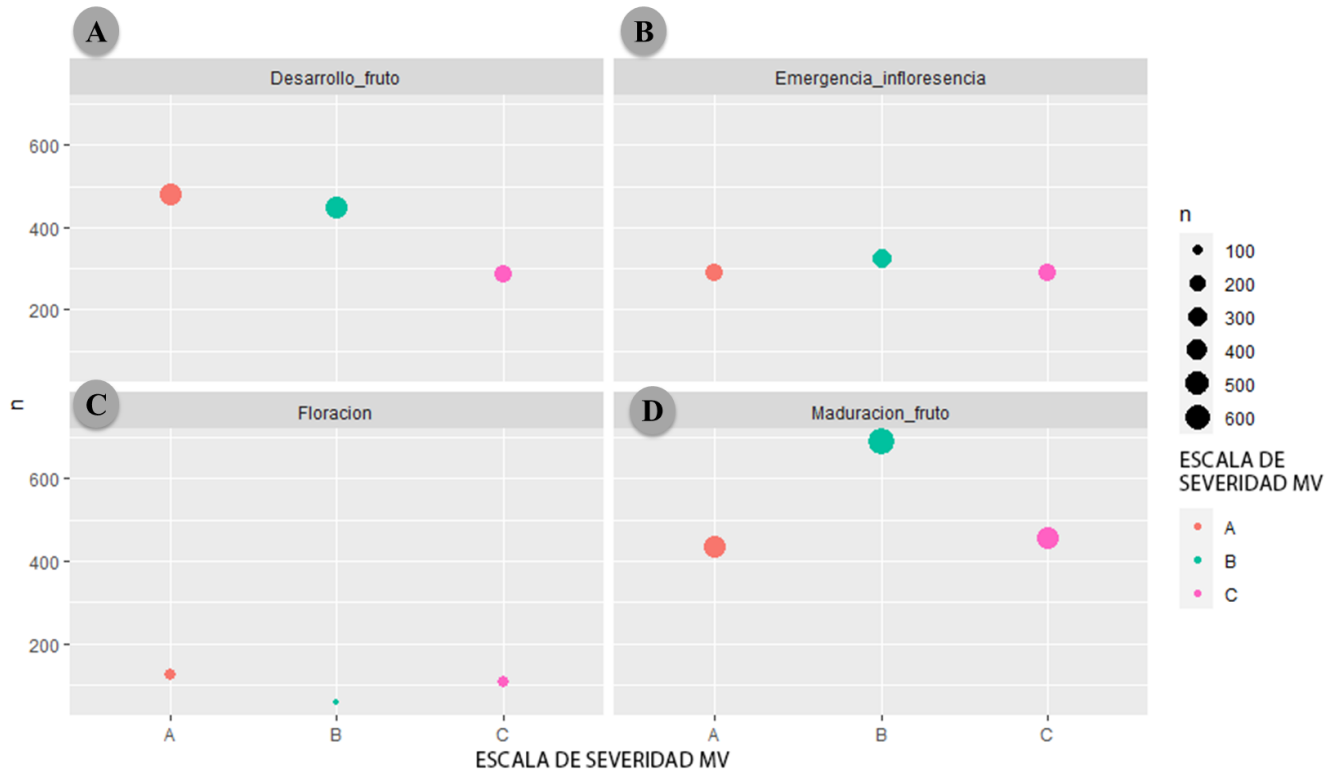


Figura 2-4 (A) número de plantas en cada nivel de MV en la etapa de desarrollo de fruto, (B) número de plantas en cada nivel de MV en emergencia de inflorescencia, (C) número de plantas en cada nivel de MV en floración y (D) número de plantas en cada nivel de MV en maduración de fruto

2.3.2 Aproximación al pronóstico y determinación de variables predictivas de la MV utilizando variables fotosintéticas, espectrales y geométricas mediante multienfoque

a. Enfoque estocástico: modelo de regresión logística multinomial

Se obtuvieron resultados significativos ($P < 0,05$) al realizar un ajuste a un modelo de regresión logística multinomial para la detección de la severidad de MV, logrando una precisión global de 0.6968, con un intervalo de confianza del 95% (0.6736, 0.7193) y un índice de Kappa de 0.5365, lo cual sugiere una concordancia moderada entre las predicciones y las observaciones reales. Sin embargo, al analizar la matriz de confusión, se observa que la precisión en la predicción varía según

la clase obteniendo 25.6 % para la clase A, 35.7% para la clase B y 8.4% para la clase C. En cuanto a la sensibilidad del modelo para la clase A, fue de 76.98%, para la clase B de 93.57% y para la clase C, de 29.38%. Con relación a la especificidad del modelo para la clase de A, B y C fue de 81.19, 96.31 y 86.98% respectivamente (Figura 2-5).

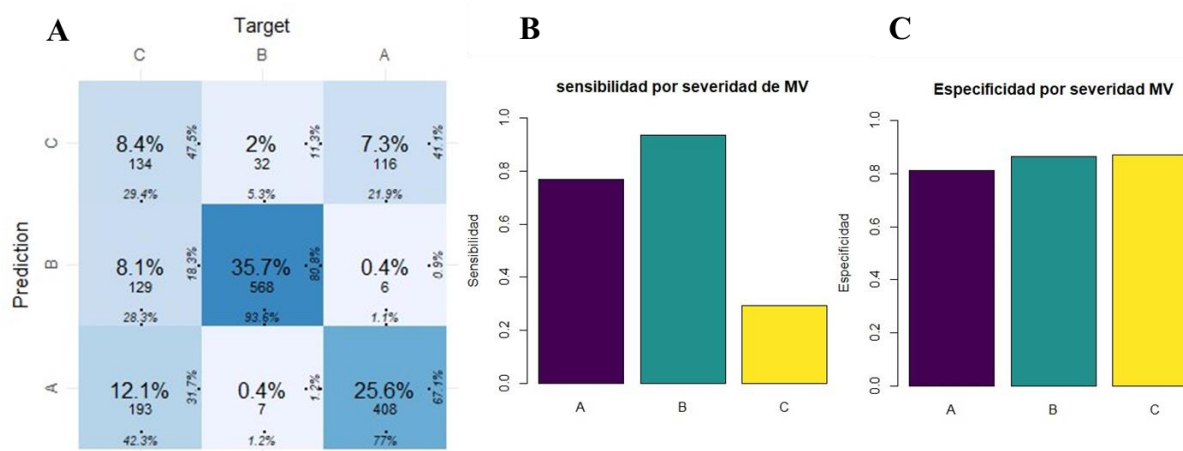


Figura 2-5. Visualización de métricas asociadas a la clasificación de diferentes clases o grados de severidad de la MV en ají usando un modelo de regresión logística multinomial. (A): Matriz de confusión del modelo. (B): sensibilidad del modelo. (C) especificidad del modelo.

b. Enfoque determinístico: modelos de *machine learning*

La función AutoML determinó que el modelo GBM_model_14 fue el más destacado en la clasificación de los distintos grados de severidad de MV tras evaluar un total de 63 modelos usando como predictores los rasgos fotosintéticos (Tabla Suplementaria del anexo C). Este modelo presentó un buen rendimiento, con una media de error por clase de 0.0609, pérdida logarítmica de 0.1748, un RMSE de 0.2128 y MSE de 0.0452. Según las predicciones obtenidas mediante la matriz de confusión, se logró 99.2% de precisión para la clase A, 100% para la clase B y 92.7% para la clase C (Figura 2-6C). Además, se obtuvo un AUC de 99.76% y un ACC de 97.49% en la matriz de confusión (Figura 2-6B). Estos resultados indican la efectividad de este modelo en la clasificación de los niveles de severidad de MV. El modelo seleccionado identificó los rasgos fotosintéticos más relevantes en la predicción de MV, las cuales incluyen el Fv/Fm (19.5%), NPQt (16%), LDT (6.3%), RelaChloroll (4.7%) y Phi2 (4.7%) (Figura 2-6A).

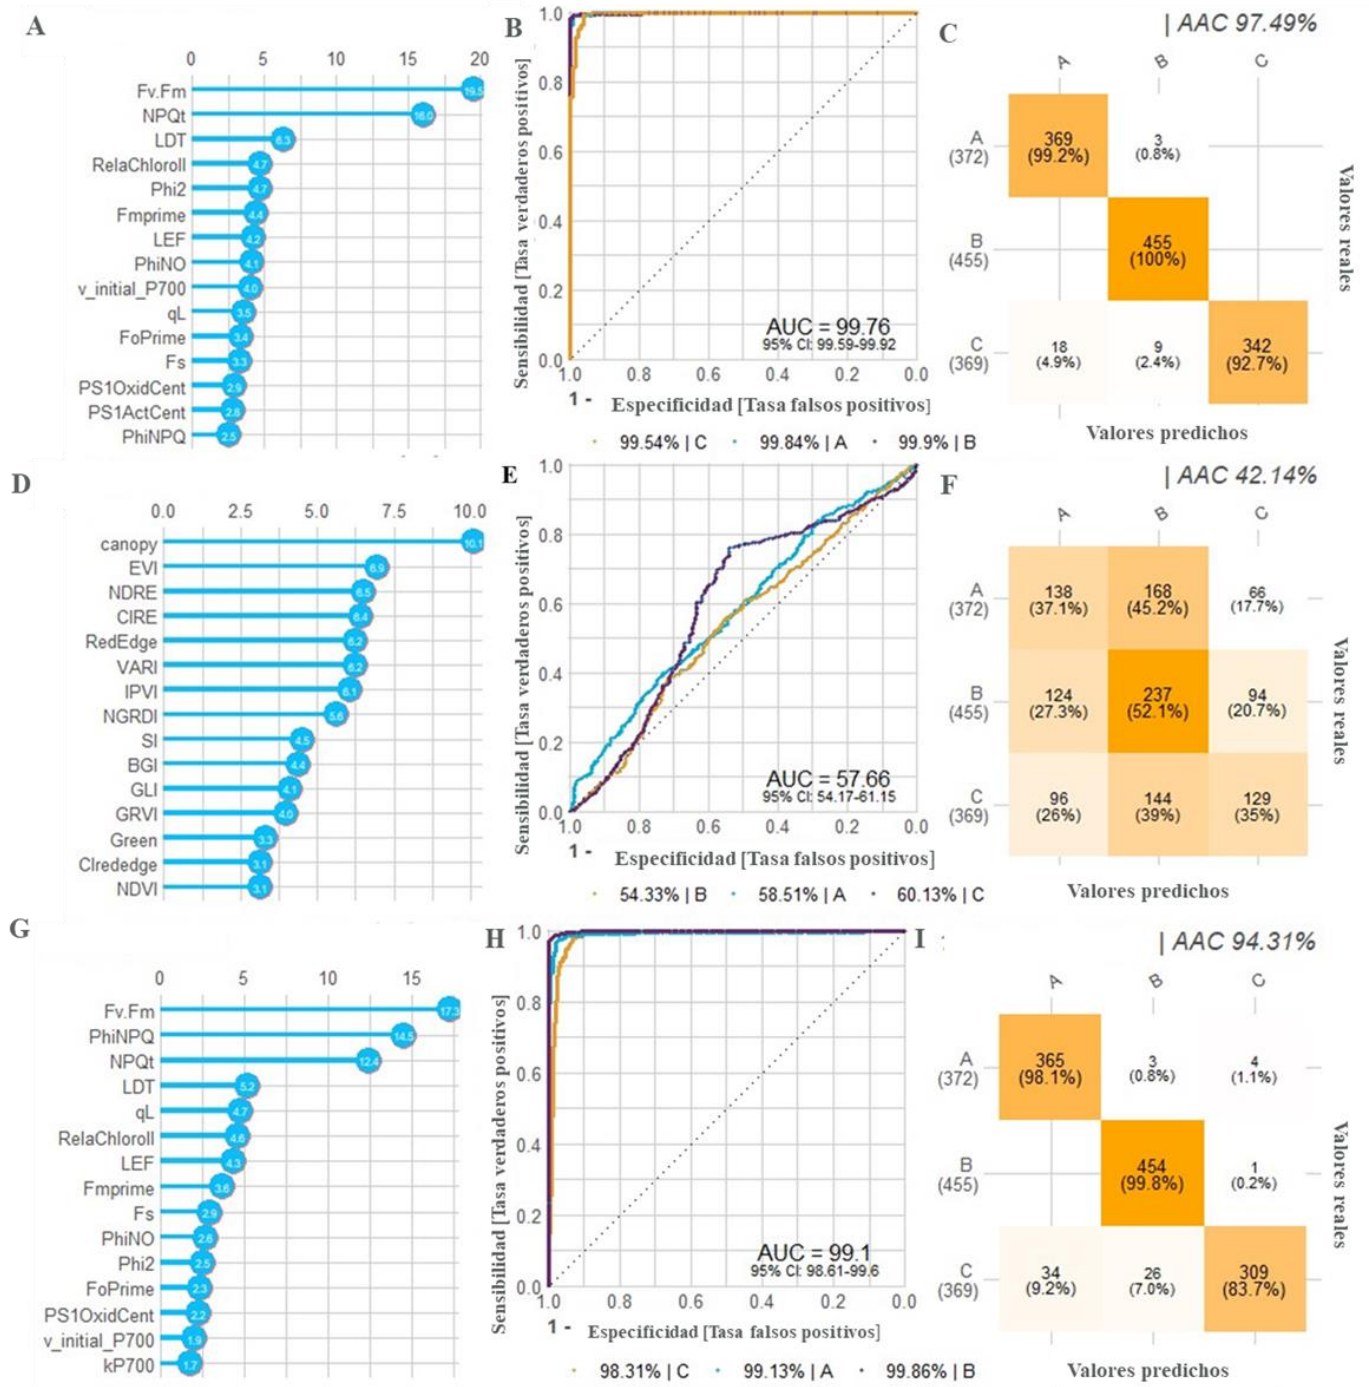


Figura 2-6. Visualización de métricas asociadas a la clasificación de diferentes clases o grados de severidad de la MV en ají usando un modelo de ML. (A) Identificación de rasgos fotosintéticos de mayor importancia. (B) curva AUC del modelo GBM con rasgos fotosintéticos. (C) matriz de confusión del modelo seleccionado con rasgos fotosintéticos. (D) Identificación de rasgos espectrales y geométricos de mayor importancia. (E) curva AUC del modelo GBM con rasgos

espectrales y geométricos. (F) matriz de confusión del modelo GBM con rasgos espectrales y geométricos. (G) Identificación de rasgos fotosintéticos, espectrales y geométricos de mayor importancia. (H) curva AUC del modelo GBM con rasgos fotosintéticos, espectrales y geométricos. (I) matriz de confusión del modelo seleccionado con rasgos fotosintéticos, espectrales y geométricos.

Con relación al ajuste del modelo utilizando rasgos espectrales y geométricos, se evaluaron un total de 108 modelos (Tabla Suplementaria del anexo D). La función AutoML seleccionó el modelo GBM _model_54 como el mejor para clasificar la severidad de MV. Aunque este modelo ha mostrado un rendimiento inferior en comparación con el anterior, presentó valores de error promedio por clase de 0.5819, pérdida logarítmica de 1.1200, un RMSE de 0.6564 y MSE de 0.4309. Las predicciones de la matriz de confusión alcanzaron 37.1% para la clase A, 52.1% para la clase B y 35% para la clase C (Figura 2-6F). Además, obtuvo un AUC de 57.66% y ACC de 42.14% en la matriz de confusión (Figura 2-6E). Este modelo determinó que los rasgos espectrales y geométricos más importantes en la predicción de MV fueron la geometría del dosel (10.1%), el índice EVI (6.9%), NDRE (6.5%), CIRE (6.4%) y la banda RedEdge (6.2%). (Figura 2-6D).

Cuando se ajustaron los datos para la predicción de MV con la combinación de rasgos fotosintéticos, espectrales y geométricos, se evaluaron un total de 35 modelos (Tabla Suplementaria del anexo E), la función de AutoML destacó al modelo GBM_model_25 como el mejor en la clasificación de la severidad de MV. Este modelo mostró promedio de error por clase de 0.1086, pérdida logarítmica de 0.2601, RMSE y MSE de 0.2716 y 0.0737, respectivamente. En cuanto a las predicciones obtenidas a partir de la matriz de confusión, el modelo logró un porcentaje de precisión del 98.1% para la clase A, 99.8% para la clase B y 83.7% para la clase C (Figura 2-6 I). Además, las métricas de AUC y tasa ACC fueron de 99.1% y 94.31%, respectivamente (Figura 2-6 H). Es importante destacar que el modelo seleccionado sólo consideró rasgos fotosintéticos, excluyendo tanto los rasgos espectrales como geométricos. Los rasgos más importantes incluyeron Fv/Fm, PhiNPQ, NPQt, LDT y qL (Figura 2-6 G).

c. Enfoque de *deep Learning*

El enfoque de DL ajustado con rasgos fotosintéticos para la clasificación de la severidad de MV, se obtuvieron los siguientes valores según las métricas evaluadas. MSE de: 0.1609 para el conjunto de entrenamiento y 0.1985 para el conjunto de prueba. Así mismo un RMSE de 0.4011 para

entrenamiento y 0.4456 para prueba. Además, se registraron valores de pérdida logarítmica de 0.6598 para entrenamiento y 0.8481 para prueba. Considerando las predicciones de la matriz de confusión, con rasgos fotosintéticos se observó que la clase A obtuvo 30% de precisión en los datos de entrenamiento y 28.1% en los datos de prueba. En cuanto a la clase B, se obtuvo 37.1% en los datos de entrenamiento y 36.5% en los datos de prueba. Por último, la clase C 12.4% en los datos de entrenamiento y 10% en los datos de prueba (Figura 2-7 B y C).

Este modelo identificó los rasgos fotosintéticos más importantes en la clasificación de la severidad de MV. Estas incluyen los centros de reacción oxidados del PS1 (PS1 OxidCent), la constante de velocidad de transferencia de electrones p700 (kp700), centros de reacción reducidos del PS1 (PS1 Reduced Centers), Flujo de protones en estado estacionario (vH), y centros de reacción activos del PS1 (PS1ActCent) (Figura 2-7A).

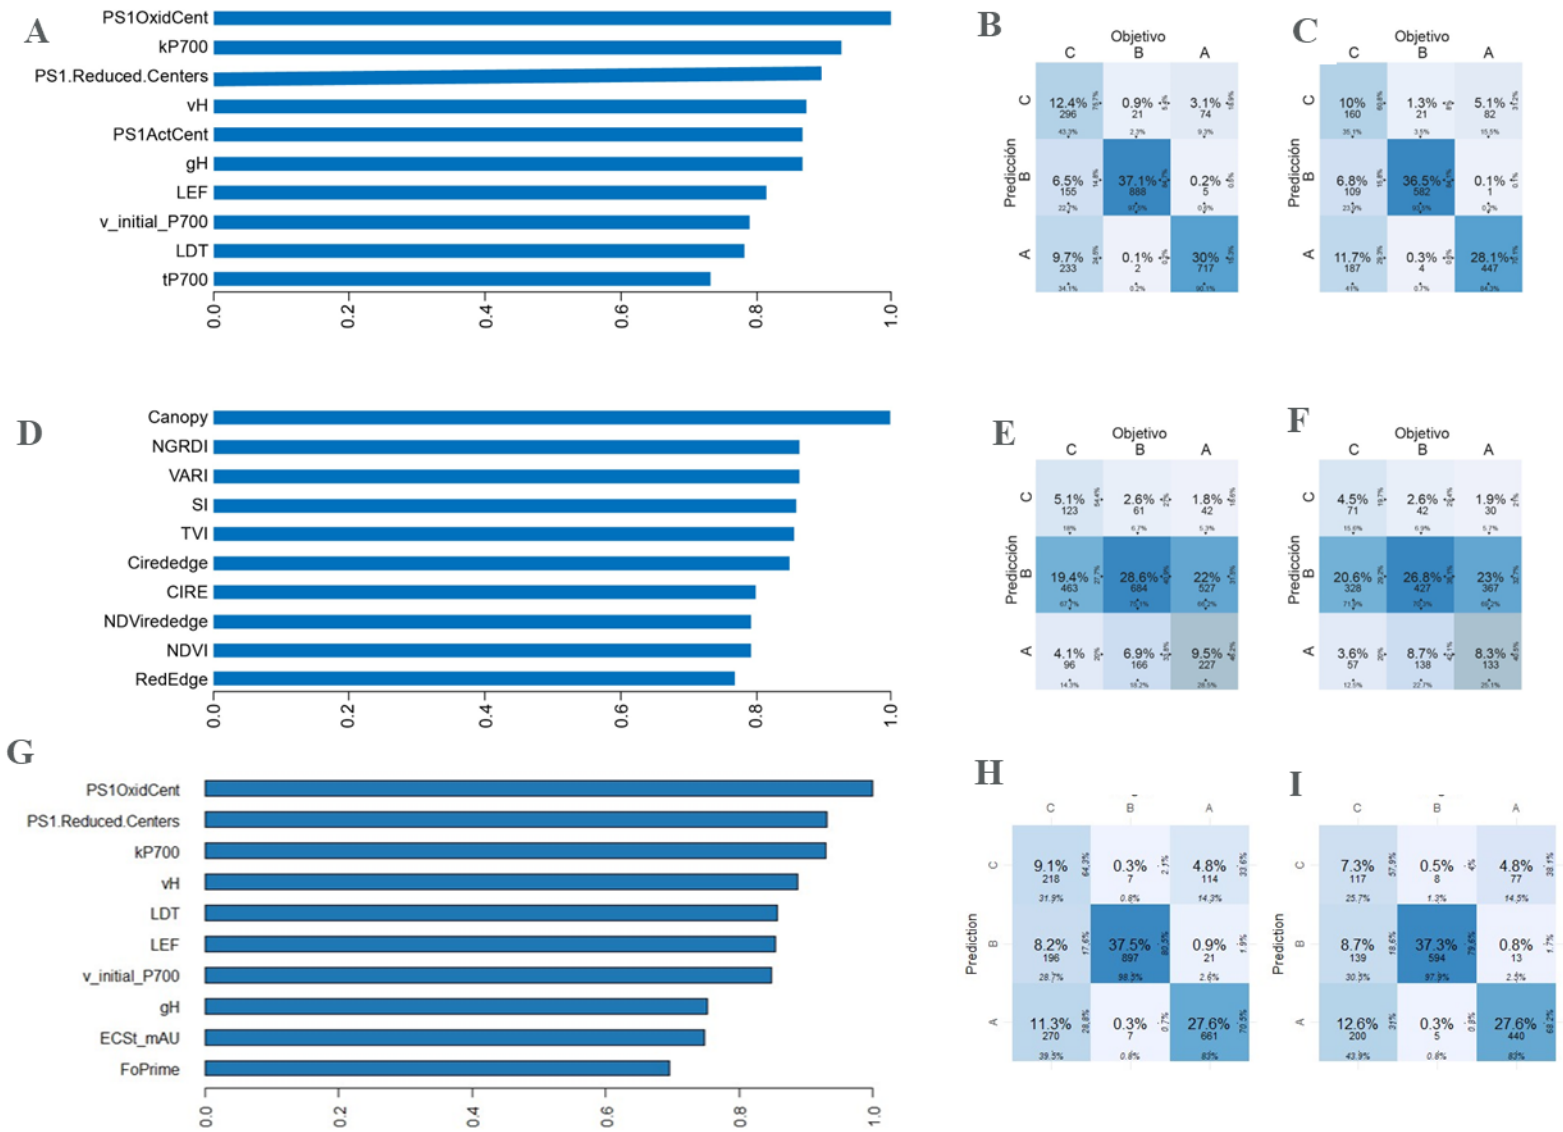


Figura 2-7. Visualización de métricas asociadas a la clasificación de diferentes clases o grados de severidad de la MV en ají usando un modelo de DL. En la predicción de MV con DL se presenta: (A) rasgos fotosintéticos de mayor importancia (B) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos como predictores. (C) matriz de confusión para datos de prueba usando rasgos fotosintéticos como predictores (D) rasgos espectrales y geométricos de mayor importancia. (E) matriz de confusión para datos de entrenamiento usando rasgos espectrales y geométricos como predictores. (F) matriz de confusión para datos de prueba usando rasgos espectrales y geométricos como predictores. (G) rasgos fotosintéticos, espectrales y de mayor importancia (H) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos, espectrales y geométricos como predictores. (I) matriz de confusión para datos de prueba usando rasgos fotosintéticos, espectrales y geométricos como predictores.

Al evaluar el rendimiento del modelo DL ajustado con rasgos espectrales y geométricos para la clasificación de MV, se obtuvieron valores para el MSE de 0.4105 para entrenamiento y 0.4361 para prueba. Asimismo, se registraron los siguientes valores para RMSE de 0.6407 para entrenamiento y 0.6604 para prueba. Además, valores de pérdida logarítmica de 1.1992 para entrenamiento y 1.2705 para prueba, respectivamente. Del mismo modo y según las predicciones de la matriz de confusión, con los rasgos espectrales y geométricos, para la clase A se obtuvo un 9.5% de precisión con datos de entrenamiento y 8.3% con datos de prueba, para la clase B obtuvo una precisión de 28.6% con datos de entrenamiento y 26.8% con datos de prueba y para la clase C obtuvo un rendimiento de 5.1 % con datos de entrenamiento y 4.5% con datos de prueba (Figura 2-7 E y F). Además, el modelo DL identificó los rasgos espectrales y geométricos de importancia en la clasificación de la severidad de MV como geometría del dosel (Canopy) y los índices NGRDI, VARI, SI y TVI (Figura 2-7D).

Durante la evaluación del modelo ajustado con rasgos fotosintéticos, espectrales y geométricos, se encontró que el MSE presentó valores de 0.1808 para entrenamiento y 0.2477 para prueba. Adicionalmente, se registraron valores para RMSE de 0.4252 para entrenamiento y 0.4977 para prueba. Además, la pérdida logarítmica fue de 0.7793 para entrenamiento y 1.2658 en prueba. Según las predicciones de la matriz de confusión, con las rasgos fotosintéticos, espectrales y geométricos, para la clase A se obtuvo 27.6% de precisión tanto para entrenamiento como para prueba, para la clase B obtuvo una precisión de 37.5% con datos de entrenamiento y 37.3% con datos de prueba y para la clase C obtuvo un rendimiento de 9.1 % con datos de entrenamiento y 7.3% con datos de prueba (Figura 2-7 H y I). En la selección de rasgos importantes en la predicción de la severidad de MV, el modelo identificó sólo rasgos fotosintéticos muy similares al ajuste del modelo usando solo rasgos fotosintéticos (Figura 2-7 G).

Como complemento y como base para entender la variación de los predictores de mayor relevancia en la detección indirecta de la MV, Por su parte, los resultados asociados al diagramas de cajas y bigotes muestran la distribución de los valores de las rasgos fotosintéticos, espectrales y geométricos predictores, en relación con los diferentes niveles de severidad de la MV (Figura 2-8). Esta representación revela que los valores de los predictores promedio de los rasgos fotosintéticos,

espectrales y geométricos tienen sentido biológico con respecto a cada nivel de MV en ají encontrado bajo condiciones de campo.

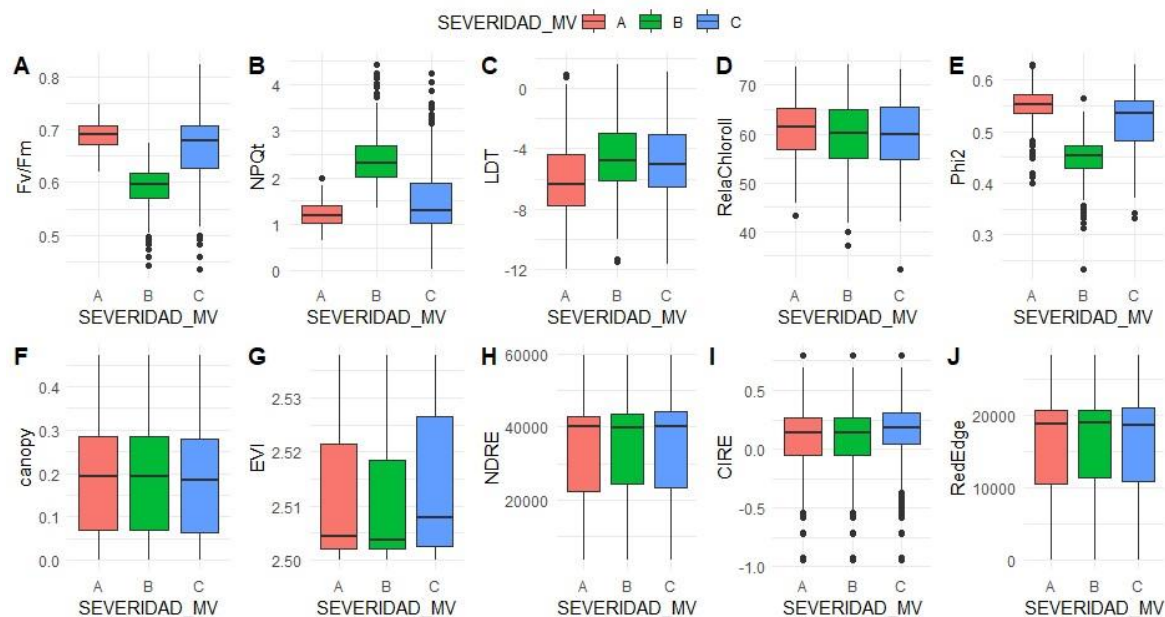


Figura 2-8. Diagrama de cajas de variables más importantes en la predicción de MV en el sistema comercial de producción de ají. (A)Fv/Fm, (B)NPQt, (C)LDT, (D)RelaChloroII, (E)Phi2, (F)geometría del dosel, (G)EVI, (H)NDRE, (I)CIRE y (J)Banda borde rojo

2.3.3 Aproximación al pronóstico y determinación de variables predictivas de parámetros fenológicos (PF) utilizando variables fotosintéticas, espectrales y geométricas mediante enfoque de *machine* y *Deep learning*

a. Enfoque de *machine learning*

La función AutoML determinó que el modelo GBM_model_12 fue el mejor en la clasificación de las cuatro categorías fenológicas del sistema comercial de producción de ají entre 41 modelos evaluados usando rasgos fotosintéticos como predictores (Tabla Suplementaria del anexo F). Este modelo exhibió un rendimiento superior, con un promedio de error por clase de 0.0782, pérdida logarítmica de 0.1968, una RMSE de 0.2190 y un MSE de 0.0479. Por su parte, las predicciones de la matriz de confusión alcanzaron 95.3% de precisión para la etapa de emergencia de inflorescencia,

100% para la fase de floración, 96.9% en el desarrollo de fruto y 98.1% en la maduración de fruto (Figura 2-9C). Además, el modelo logró una AUC de 99.8% y tasa ACC de 97.24% (Figura 2-9B). El modelo identificó los siguientes rasgos fotosintéticos de importancia: gH+ (9.8%), RelChloroll (9.6%), LEF (6.6%), Fs (6.5%) y LDT (6.3%) (Figura 2-9A).

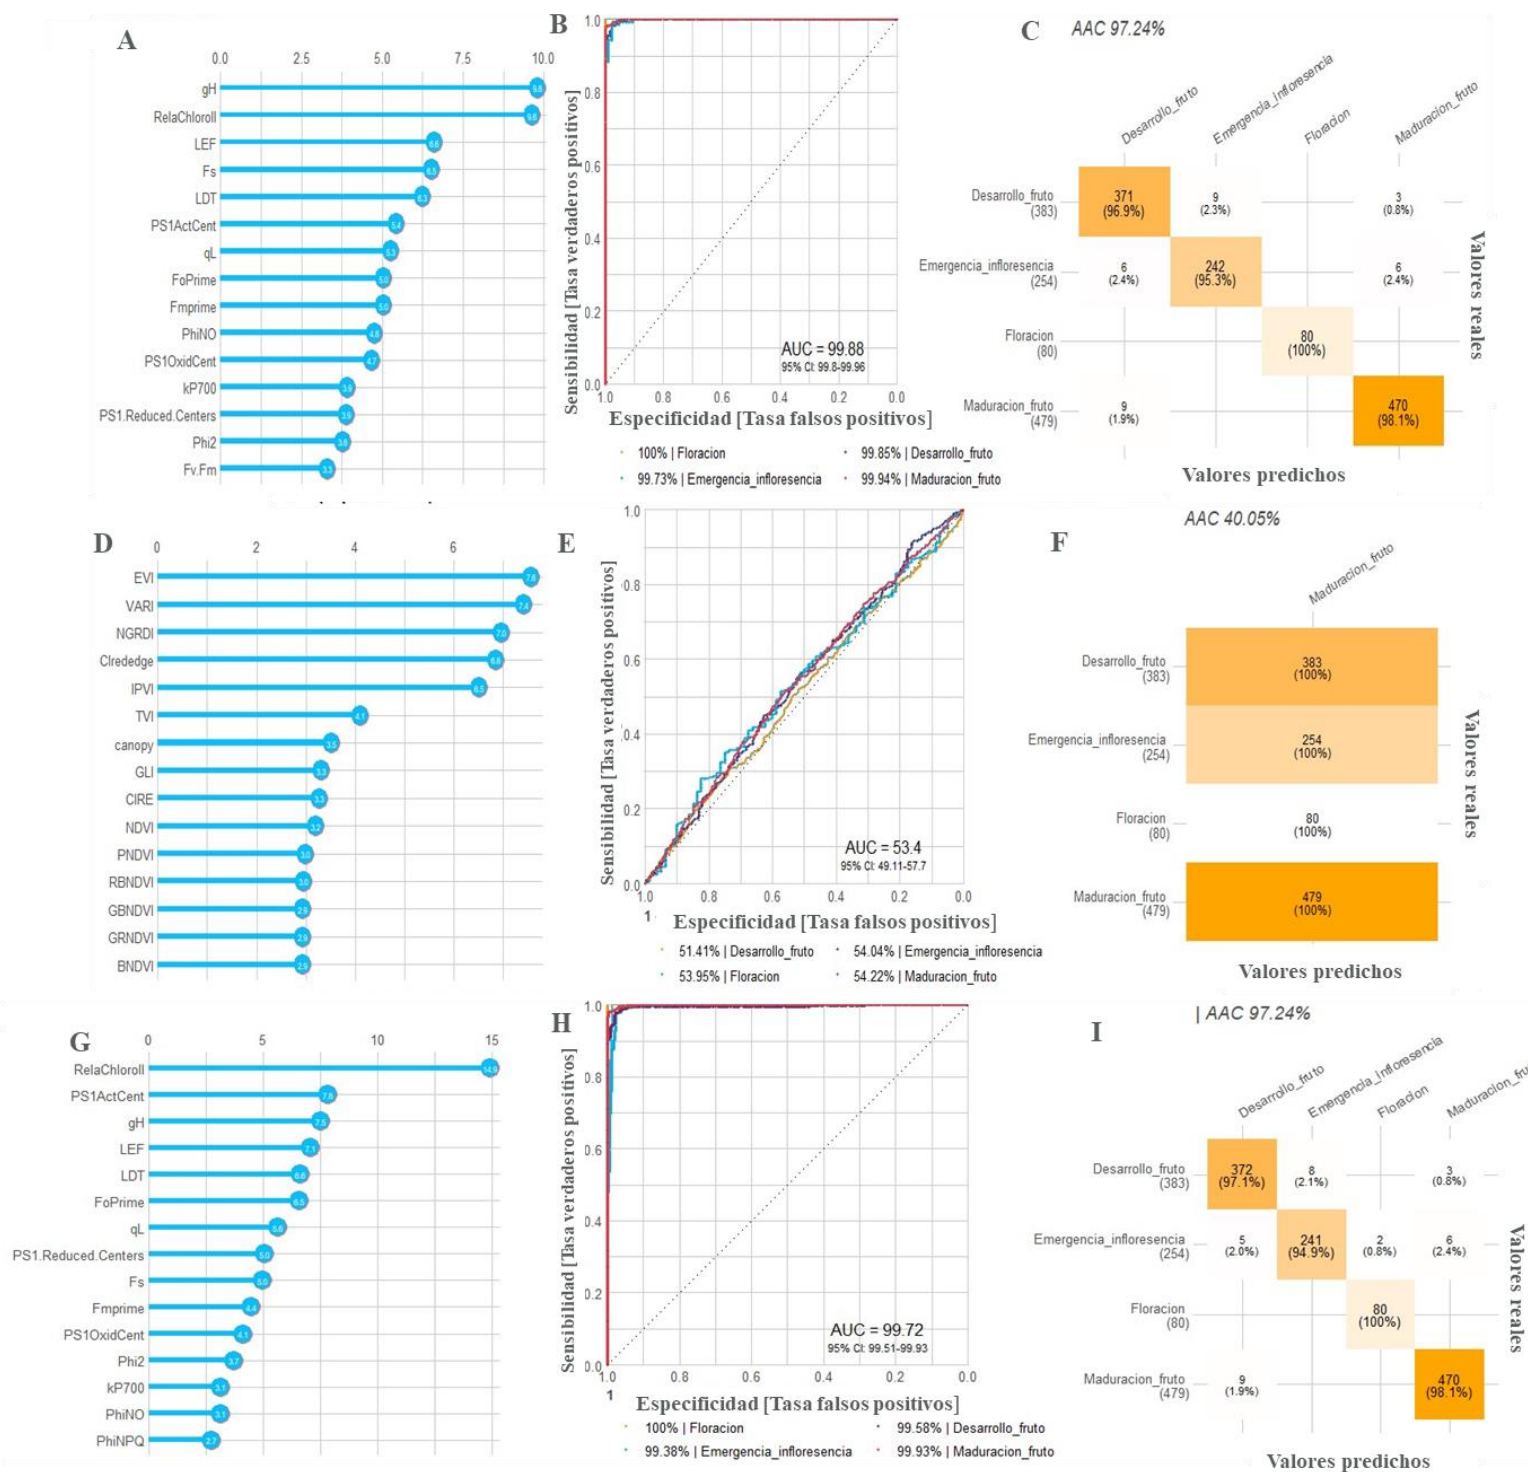


Figura 2-9. Visualización de métricas asociadas a la clasificación de diferentes estados fenológicos en ají usando un modelo de ML. (A) Identificación de rasgos fotosintéticos de mayor importancia. (B) curva AUC del modelo GBM con rasgos fotosintéticos. (C) matriz de confusión del modelo

GBM con rasgos fotosintéticos. (D) Identificación de rasgos espectrales y geométricos de mayor importancia. (E) curva AUC del modelo GLM con rasgos espectrales y geométricos. (F) matriz de confusión del modelo GLM con rasgos espectrales y geométricos. (G) Identificación de rasgos fotosintéticos, espectrales y geométricos de mayor importancia. (H) curva AUC del modelo GBM con rasgos fotosintéticos, espectrales y geométricos. (I) matriz de confusión del modelo seleccionado con rasgos fotosintéticos, espectrales y geométricos.

Por otro lado, en el ajuste del modelo usando rasgos espectrales y geométricos se evaluaron un total de 108 modelos (Tabla Suplementaria del anexo G). La función AutoML seleccionó el modelo GLM_1_AutoML_7 como el mejor en la clasificación de los estadios fenológicos. El modelo seleccionado mostró un rendimiento inferior en comparación con el ajustado con rasgos fotosintéticos, mostrando un promedio de error por clase de 0.75, pérdida logarítmica de 1.263108, RMSE de 0.7021 y MSE de 0.4930. Según las predicciones de la matriz de confusión, se logró una predicción del 100% en la maduración de los frutos, mientras que para las otras clases hubo baja predicción (Figura 2-9F). Además, su AUC fue de 53.4%, y su ACC alcanzó solo el 40.05% (Figura 2-9E). Estos resultados evidencian que los rasgos fotosintéticos presentan mayor capacidad en la clasificación de los estados fenológicos que los rasgos espectrales y geométricos. El modelo señaló que los índices de vegetación de mayor importancia en la clasificación fenológica fueron el, EVI (7.6%), VARI (7.4%), NGRDI (7.0%), CIrededge (6.8%) y IPVI (6.5%) (Figura 2-9D).

En el ajuste del modelo para la clasificación de estados fenológicos empleando los rasgos fotosintéticos, espectrales y geométricos, se llevó a cabo la evaluación de un total de 11 modelos distintos (Tabla Suplementaria del anexo H). En este contexto, se seleccionó el modelo GBM_2_AutoML_11 como el más sobresaliente en términos de clasificación de parámetros fenológicos. Dicho modelo exhibió un índice promedio de error por categoría de 0.1004. Además, una pérdida logarítmica de 0.2531, mientras que los valores de RMSE y MSE fueron de 0.2457 y 0.0603, respectivamente. En relación con las predicciones derivadas de la matriz de confusión, los resultados fueron los siguientes: 94.9% para la fase de emergencia de inflorescencia, 100% para la etapa de floración, 97.1% para el desarrollo del fruto, y 98.1% para la maduración frutos (Figura 2-9 I). Asimismo, cabe mencionar que el modelo mostró un desempeño aceptable con un AUC de 99.72%, y ACC de 97.24% (Figura 2-9 H y I). Resulta relevante subrayar que el modelo seleccionado únicamente tomó en consideración los rasgos fotosintéticos, prescindiendo tanto de los rasgos espectrales como geométricos. Entre los rasgos que ejercieron mayor influencia, se destacan el

RelaChloroll (14.9%), PS1ActCent (7.8%), gH+ (7.5%), LEF (7.1%) y LDT (6.6%) (Anexo L Figura A).

b. Enfoque de *deep learning*

Durante la evaluación del rendimiento del modelo DL ajustado con rasgos fotosintéticos, los valores de MSE fueron de 0.2604 para entrenamiento y 0.3029 para prueba, del mismo modo, la RMSE presentó valores de 0.5147 para entrenamiento y 0.5560 para prueba. Por su parte, la métrica perdida logarítmica presentó valores de 1.1384 para entrenamiento y 1.4287 para prueba. Según los resultados de la matriz de confusión, se observaron valores muy inferiores con respecto al enfoque de ML presentado anteriormente. Para la emergencia de inflorescencia, se obtuvieron 11.6% en datos de entrenamiento y 10.1% en datos de prueba; en la etapa de floración, se lograron 1.2% y 0.6% respectivamente; en el desarrollo del fruto, se registraron 29% en datos de entrenamiento y 28.4% en datos de prueba; y en la maduración del fruto se obtuvieron 25.8% y 24.2% respectivamente (Figura 2-10 B y C). El modelo DL, identificó rasgos fotosintéticos de importancia como la constante de velocidad de transferencia de electrones p700 (kp700), los centros de reacción activos del PS1(PS1ActCent), la conductividad de protones (gH+), la tasa inicial de transferencia de electrones en estado estacionario p700 (V_initial_p700) y los centros reducidos del PS1(PS1reducedCnters) (Figura 2-10A).

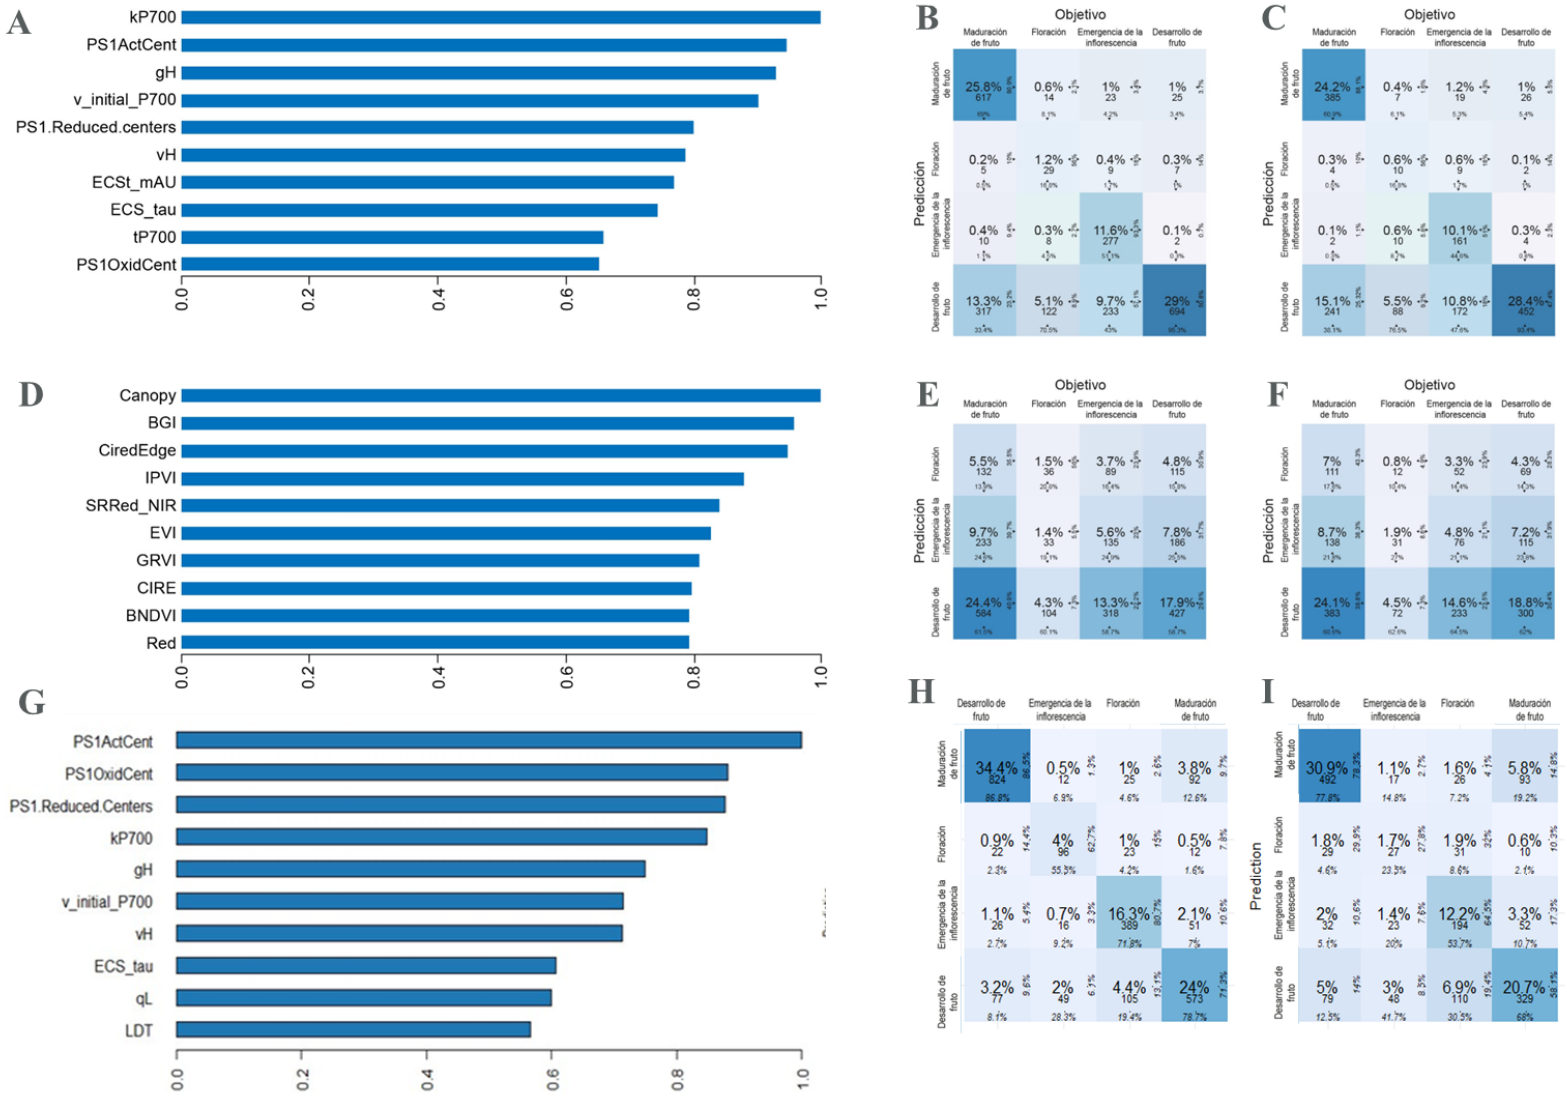


Figura 2-10. Visualización de métricas asociadas a la clasificación de los cuatro estados fenológicos en ají usando un modelo de DL. En la predicción de clases o estados fenológicos con DL se presenta: (A) rasgos fotosintéticos de mayor importancia (B) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos como predictores. (C) matriz de confusión para datos de prueba usando rasgos fotosintéticos como predictores (D) rasgos espectrales y geométricos de mayor importancia. (E) matriz de confusión para datos de entrenamiento usando rasgos espectrales y geométricos como predictores. (F) matriz de confusión para datos de prueba usando rasgos espectrales y geométricos como predictores. (G) rasgos fotosintéticos, espectrales y de mayor importancia (H) matriz de confusión para datos de entrenamiento usando rasgos fotosintéticos, espectrales y geométricos como predictores. (I) matriz de confusión para datos de prueba usando rasgos fotosintéticos, espectrales y geométricos como predictores

En el proceso de ajuste del modelo con rasgos espectrales y geométricos, el rendimiento de este modelo para la clasificación de estados fenológicos presentó un MSE de 0.6613 para entrenamiento y 0.6722 en prueba, mientras en la RMSE presentó valores de 0.8132 en entrenamiento y 0.8198 para el conjunto de prueba, la pérdida logarítmica fue de 2.2924 para entrenamiento y 2.3565 para prueba. Teniendo en cuenta las predicciones de la matriz de confusión, los resultados para la etapa de emergencia de inflorescencia fueron del 5.6% en entrenamiento y 4.8% en prueba. En cuanto a la floración, se obtuvo un 1.5% de precisión en entrenamiento y un 0.8% con los datos de prueba. Para el desarrollo de fruto, se obtuvo un 17.9% con los datos de entrenamiento y 18.8% para prueba. Para la etapa de maduración del fruto, se obtuvo de 3.8% con los datos de entrenamiento y 5.8% con los datos de prueba (Figura 2-10 E y F). El modelo DL identificó los rasgos espectrales y geométricos que presentan mayor capacidad de clasificación de los estadios fenológicos, entre estos están la geometría del dosel (Canopy) y los índices de vegetación BGI, Cirededge e IPVI. (Figura 2-10 D).

Posteriormente, durante el proceso de ajuste de este modelo, se emplearon rasgos fotosintéticos, así como rasgos espectrales y geométricos, obteniéndose valores de MSE en entrenamiento y prueba de 0.5288 y 0.6033 respectivamente. Además, se registró un RMSE, de 0.7272 para entrenamiento y 0.7767 para prueba, pérdidas logarítmicas de 3.0312 para entrenamiento y 3.7648 para prueba. Según los resultados de la matriz de confusión para la emergencia de inflorescencia, se obtuvieron 0.7% en datos de entrenamiento y 14% en datos de prueba; en la etapa de floración, se lograron 1% y 1.9% respectivamente para entrenamiento y prueba; en el desarrollo del fruto, se registraron 3.2% en datos de entrenamiento y 5% en datos de prueba; y en la maduración del fruto se obtuvieron 3.8% y 5.8% respectivamente para entrenamiento y prueba (Figura 2-10 H y I). En cuanto a la selección de rasgos importantes para la clasificación de estados fenológicos el modelo solo identificó rasgos fotosintéticos similares a los utilizados en el ajuste del modelo que solo consideraba dichos rasgos (Figura 2-10 G).

2.3.4 Aproximación al pronóstico y determinación de variables predictivas de parámetros productivos (PP) utilizando variables fotosintéticas, espectrales y geométricas mediante enfoque de *machine* y *Deep learning*

a. Enfoque de *machine learning*

Durante el ajuste de este modelo usando solo rasgos fotosintéticos, de los 100 modelos evaluados (Tabla Suplementaria del anexo I), el GBM_model_11, presentó la mejor predicción del número de frutos. En la evaluación del rendimiento, este modelo presentó valores de MAE de 0.7250, RMSE de 2.0239, MSE de 4.0963, RMSLE de 0.3712 y la desviación residual media de 4.0963. Para la validación con los datos de prueba el modelo seleccionado presentó valores de R^2 de 0.957, RMSE de 1.282 y MAE de 0.3095 (Figura 2-11B). El modelo seleccionado identificó como los rasgos fotosintéticos más importantes PS1ActCent (16.5%), RelaChloroll (12.1%), FoPrime (9.7%), gH+ (8.5%) y Fs (5%) (Figura 2-11A).

En el ajuste del modelo con rasgos espectrales y geométricos se evaluaron un total de 108 modelos (Tabla Suplementaria del anexo J) para la predicción del número de frutos. La función AutoML seleccionó el modelo GLM_AutoML_13, como el mejor en el pronóstico de número de frutos. Sin embargo, este modelo mostró un rendimiento inferior en comparación con la predicción realizada usando rasgos fotosintéticos según las métricas como MAE (5.4107), RMSE (6.2599), MSE (39.1865) y raíz del RMSLE (1.2438) y la desviación residual media (39.1865). Para la validación con datos de prueba el modelo seleccionado presentó valores de MAE de 5.403, RMSE de 6.249 (Figura 2-11D). Del mismo modo, se identificaron los rasgos espectrales y geométricos relevantes en el pronóstico de número de frutos como CIrededge (16.9%), CIRE (10.6%), IPVI (9.3%), geometría del dosel (Canopy) con (8%) y TVI (6.2%) (Figura 2-11C).

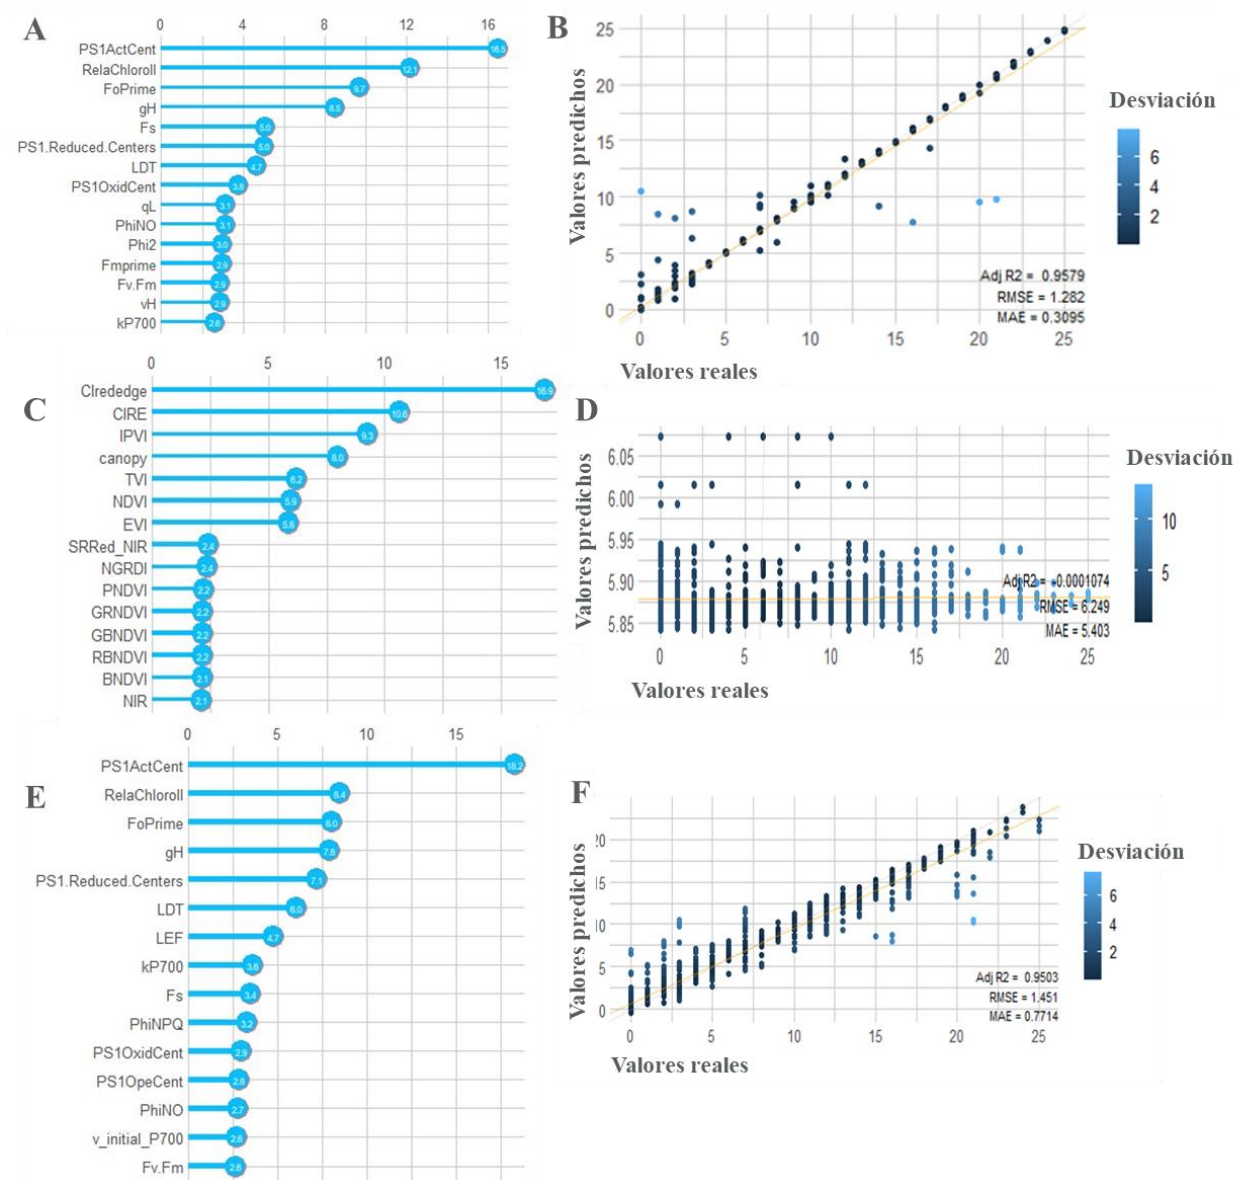


Figura 2-11. Visualización de métricas asociadas al pronóstico de componentes de rendimiento en ají usando un modelo de regresión de ML. (A) Identificación de rasgos fotosintéticos de mayor importancia. (B) Rendimiento del modelo GBM para validación con datos de prueba. (C) rasgos espectrales y geométricos de mayor importancia. (D) rendimiento del modelo GLM en validación con datos de prueba. (E) Identificación de rasgos fotosintéticos, espectrales y geométricos de mayor importancia (F) Rendimiento del modelo GBM para validación con datos de prueba.

Finalmente, se llevó a cabo una combinación en el ajuste del modelo al incorporar tanto rasgos fotosintéticos, como rasgos espectrales y geométricos. Se evaluaron un total de 57 modelos y se

seleccionó el GBM_model_46, como el mejor para predecir el número de frutos (Tabla Suplementaria del anexo K). En términos de rendimiento, este modelo presentó los siguientes valores: MAE de 1.2754, RMSE de 2.3272, MSE de 5.4162, RMSLE de 0.4667 y una desviación residual media de 5.4162. Para la validación con los datos de prueba el modelo seleccionado presentó valores de R^2 de 0.9503, RMSE de 1.451 y MAE de 0.7714 (Figura 2-11 F). Este modelo identificó únicamente los rasgos fotosintéticos como variables importantes en la predicción de los componentes de rendimiento, estas incluyeron PS1ActCent (18.2%), RelaChloroll (8.4%), FoPrime (8.0%) gH+ (7.8%) y PS1.Reduced.Centers (7.1%) (Figura 2-11 E).

b. Enfoque de *deep learning*

Durante el ajuste de este modelo, que se basó en el uso rasgos fotosintéticos, en la evaluación del rendimiento, el MSE obtuvo valores de 0.4770 para entrenamiento y 0.5706 para prueba. En cuanto a RMSE, se registraron valores de 0.6907 para entrenamiento y 0.7554 para prueba. Por otro lado, el MAE presentó valores de 0.4949 para entrenamiento y 0.5531 para prueba. Finalmente, la MRD mostró valores de 0.4770 para entrenamiento y 0.5706 para prueba. El modelo identificó los parámetros fotosintéticos más relevantes en la predicción de números de frutos los centros reducidos del PS1, los centros activos del PS1, gH+, la tasa inicial de transferencia de electrones en estado estacionario p700 ($V_{initial_p700}$) y la constante de velocidad de transferencia de electrones p700 ($kp700$) (Figura 2-12 A).

Para el ajuste del modelo utilizando rasgos espectrales y geométricos, en la evaluación del rendimiento mostró las siguientes métricas: MSE de 1.8633 para entrenamiento y 1.9662 para prueba, RMSE de 1.365 para entrenamiento y 1.4022 para prueba, MAE de 0.9668 para entrenamiento y 0.9985 para prueba. Por último, la MRD se situó en 1.8633 para entrenamiento y 1.9662 para prueba. En cuanto a la selección de variables, el modelo identificó la geometría del dosel (Canopy), así como los índices de vegetación VARI y CIRE, junto con la banda Red Edge, como las más importantes en el pronóstico de componentes de rendimiento (número de frutos) (Figura 2-11F).

Finalmente, durante el proceso de ajuste del modelo al combinar rasgos fotosintéticos, espectrales y geométricos, el MSE fue de 0.4594 para entrenamiento y 0.8201 para prueba, RMSE de 0.6778 y 0.9056 respectivamente, para entrenamiento y prueba. Adicionalmente, el MAE de 0.4973 para

entrenamiento y 0.6765 para prueba, MRD de 0.4594 para entrenamiento y 0.8201 para prueba. En lo que respecta a la selección de rasgos significativos, el modelo destacó exclusivamente rasgos fotosintéticos similares al proceso de ajuste llevado a cabo con el conjunto de datos de dichos rasgos (Figura 2-12 C).




Figura 2-12. (A) Rasgos fotosintéticos de mayor importancia en el pronóstico de componentes de rendimiento seleccionadas por DL, (B) Rasgos espectrales y geométricos de mayor importancia en

el pronóstico de componentes de rendimiento seleccionadas por DL y (C) Rasgos fotosintéticos, espectrales y geométricos de mayor importancia en el pronóstico de componentes de rendimiento seleccionadas por DL

Al evaluar el comportamiento de los rasgos fotosintéticos, y su relación con la fenología y el número de frutos, estos exhibieron niveles promedio y coeficientes de variación similares en las distintas etapas fenológicas analizadas. Por otro lado, al analizar el contenido relativo de clorofila (RelaChloroII), se encontró que sus niveles promedio eran similares a los valores de gH+ y PS1ActCent, aunque presentaron un coeficiente de variación mayor durante las etapas de emergencia de inflorescencia, desarrollo y maduración de frutos. Con relación al diferencial de temperatura en la hoja (LDT), se observó que tanto sus niveles promedio como su coeficiente de variación permanecieron similares a lo largo de todas las etapas fenológicas. Sin embargo, al explorar el flujo lineal de electrones (LEF), se encontró que este parámetro mostró valores promedio y un coeficiente de variación más elevado durante las etapas de desarrollo y maduración de frutos en comparación con las etapas de emergencia de inflorescencia y floración. Por último, el índice NDRE presentó valores promedio y coeficientes de variación similares en todas las etapas fenológicas consideradas en este estudio (Figura 2-13).



Figura 2-13. Visualización de rasgos fotosintéticos, espectrales y geométricos de mayor importancia tanto en la clasificación de estados fenológicos como en el pronóstico de componentes de rendimiento en ají y sus niveles promedio y coeficientes de variación en los cuatro estados fenológicos evaluados. (A)valor promedio RelaChloroII, (B)CV RelaChloroII, (C)valor promedio gH+, (D)CV gH+, (E)valor promedio de LEF, (F)CV de LEF, (G)valor promedio de PS1ActCent, (H)CV de PS1ActCent, (I)valor promedio del índice NDRE y (J)CV de índice NDRE

2.4 Discusión

El hallazgo más relevante de nuestro estudio fue identificar que los rasgos fotosintéticos capturados a través del sensor proximal MultispeQ fueron los más informativos en la detección indirecta, precisa y rápida de distintos niveles de severidad de MV, las cuatro clases fenológicas y el número de frutos en cultivos comerciales de ají. Esta habilidad supera a la ofrecida por los rasgos espectrales y geométricos obtenidos mediante la cámara multispectral acoplada a VANT, en los enfoques de modelado y selección de variables, tanto en ML como DL. Estos resultados respaldan nuestra hipótesis inicial de que las HTPP, combinadas con enfoques de IA en la minería de rasgos

fenotípicos, permiten detectar de manera indirecta los niveles de severidad de MV, así como estimar con precisión la fenología y predecir componentes del rendimiento, como el número de frutos en el cultivo de ají Cayenne bajo condiciones comerciales.

El MultispeQ es un sensor proximal que permite adquirir rasgos fotosintéticos relacionados con el estado fotofísico y fotoquímico durante los momentos de la fotosíntesis en el cultivo, todo ello en un lapso breve en comparación con los métodos tradicionales ya que captura múltiples datos de una forma rápida y fácil de manipulación (Fernández-Calleja et al., 2020; Gu et al., 2023; Kanazawa et al., 2021). La implementación de este dispositivo ha demostrado su éxito en el HTPP, al facilitar la recolección eficiente de gran cantidad de datos en campo, abarcando un gran número de mediciones a lo largo de todo el ciclo fenológico de múltiples cultivos (Alkemade et al., 2021; Ben-Jabeur et al., 2021; Fernández-Calleja et al., 2020; Kanazawa et al., 2021; Kuhlger et al., 2016; Schneider et al., 2022).

Igualmente, y como complemento al uso del sensor manual tipo MultispeQ, en nuestro trabajo exploramos los avances en las estrategias de monitoreo fitosanitarios basados en el uso de VANT con cámaras acopladas. Los VANT son considerados plataformas aéreas de fenotipado altamente eficientes en la captura datos espectrales (Moradi et al., 2022; Qu et al., 2022). Los VANT han demostrado ser exitosos en la captura de respuestas espectrales a partir de sensores multispectrales, superespectrales e hiperespectrales contribuyendo a la detección de estrés biótico y abiótico (Ampatzidis & Partel, 2019; Görlich et al., 2021; Moradi et al., 2022; Qu et al., 2022; Rodríguez et al., 2021; Xie & Yang, 2020). Los VANT también han sido importantes en la estimación de fenología y componentes de rendimiento en diferentes cultivos (Kurbanov & Litvinov, 2020; Saravia et al., 2022; M. Zhou et al., 2023). Sin embargo, en comparación con los rasgos fotosintéticos en la clasificación de MV, estos presentaron menor precisión en la clasificación de los estados evaluados para nuestro caso asociado al sistema de producción comercial de ají.

Nuestro trabajo logró la integración de técnicas de HTPP con procesos eficientes e informativos de análisis rápido de la gran cantidad de datos que se generan bajo este enfoque de fenotipado de plantas sometidas a distintas fuentes de estrés. En este sentido el uso de herramientas de AI presenta un avance en el uso de técnicas avanzadas de análisis y minería de datos aplicadas a la identificación de rasgos fenotípicos que permitan la detección indirecta, precisa y rápida de enfermedades en plantas, estimación de la fenología y el pronóstico de componentes de rendimiento. Las técnicas de

IA como ML y DL han tenido un impacto significativo en los últimos años, desempeñando un papel crucial en la detección y clasificación de múltiples fuentes de estrés biótico y abiótico en plantas y cultivos (Duarte-Carvajalino et al., 2018; Karadağ et al., 2020; Nabwire et al., 2021; Noon et al., 2020; A. Singh et al., 2016, 2021; A. K. Singh et al., 2018; Sosa-Herrera et al., 2022).

Para nuestro ejemplo de campo, encontramos como los modelos basados en máquina de aumento de gradiente (GBM), demostraron el mejor comportamiento, coincidiendo con otros trabajos realizados, donde ha demostrado presentar un comportamiento estable y significativo en la identificación de estrés biótico en cultivos (Elvanidi & Katsoulas, 2022) así como en la detección de síntomas de marchitamiento causados por *Verticillium* en cultivos de papa (Lizarazo et al., 2023). De la misma manera, los diferentes enfoques como el ML y DL han sido fundamentales en la estimación precisa de estados fenológicos y componentes de rendimiento en diversos cultivos (Gholipoor & Nadali, 2019; Jing et al., 2017; Yalcin, 2018; Q. Yang et al., 2020).

Es necesario señalar que esta investigación distingue claramente entre dos enfoques para el análisis de datos en la adaptación de modelos, basadas en el grado de automatización y necesidad de configuración (Noon et al., 2020; A. K. Singh et al., 2018; Truong et al., 2019; Wever et al., 2021). En el enfoque de AutoML, se automatiza la selección y adaptación de modelos de ML, lo que implica la exploración de múltiples algoritmos y ajustes de hiperparámetros, específicamente, un máximo de 120 modelos en este estudio (Ledell & Poirier, 2020). En este caso, se automatiza el ajuste de los hiperparámetros de un conjunto de modelos de ML basándose en las métricas establecidas (Ledell & Poirier, 2020). Por otro lado, en el enfoque de DL, se requiere una configuración manual de la arquitectura de la red neuronal profunda, que incluye determinar el número de capas ocultas (5 en este estudio) y la función de activación (Rectifier) en la optimización de las conexiones internas del modelo DL para capturar patrones complejos en los datos analizados (Candel et al., 2016). En cuanto a la adaptación del modelo, el número de épocas (epochs) especificado en 100 en este estudio determina cuántas veces se recorrerá el conjunto de entrenamiento durante el proceso de entrenamiento (Candel et al., 2016). Esto implica que el enfoque de DL requiere un mayor esfuerzo no solo computacional, sino de a nivel humano, y por ende la configuración de un buen modelo puede estar sujeta al tiempo disponible y la configuración interna, lo que explicaría porque en nuestro ejemplo los resultados de estos fueron inferiores a los obtenidos con los modelos de ML

Por su parte, aunque los modelos de regresión logística multinomial son útiles en escenarios más simples, su enfoque lineal puede limitar su capacidad para capturar las diferencias y relaciones intrincadas presentes en los datos de fotosíntesis y espectrales (Alameen, 2022; Resti et al., 2022). En contraste, los enfoques de ML y DL tienen la ventaja de adaptarse mejor a la complejidad de los datos fenotípicos y, por lo tanto, ofrecen un rendimiento más sólido y preciso en la predicción de MV (Duarte-Carvajalino et al., 2018; Karadağ et al., 2020; León-Rueda et al., 2022; Thakur et al., 2022; Xiao et al., 2021).

En lo que respecta a la interacción tipo de data y enfoque de modelo, se encontró que tanto para el AutoML y DL, identificaron que los rasgos espectrales y geométricos no arrojaron resultados satisfactorios en comparación con aquellos que emplearon rasgos fotosintéticos para predecir los niveles de MV, estado fenológico y componentes de rendimiento. Esto se debe a posiblemente a el sensor proximal proporciona mediciones más precisas y específicas, diseñado especialmente para obtener rasgos de fisiología de la fotosíntesis de las plantas (Herts et al., 2020; Kanazawa et al., 2021; Kuhlger et al., 2016). La relación entre el uso del sensor MultispeQ en la identificación de rasgos fotosintéticos y detección de enfermedades parece estar dada, mientras que los rasgos espectrales y geométricos pueden contener más ruido y menos información relevante en relación con la enfermedad, lo que afecta la precisión de los modelos (Xiao et al., 2021). En este estudio, el sensor MultispeQ se adapta de manera óptima a las necesidades de captura de datos fenotípicos relevantes en la detección de enfermedades de las plantas (A. Singh et al., 2016; A. K. Singh et al., 2018), la estimación de la fenología y componentes de rendimiento en las plantas de ají.

La MV en plantas de ají es causada por algunas especies del género *Fusarium* sp., estos hongos del suelo invaden y bloquean el sistema vascular de la planta, interrumpiendo el transporte de agua y nutrientes. Esto provoca síntomas de MV y, finalmente, la muerte de la planta (Gordon, 2017; Jangir et al., 2021). Según nuestros hallazgos los niveles de severidad de MV, son clasificados por rasgos fotosintéticos como Fv/Fm, NPQt, LDT, RelaChloroII y Phi2, los cuales han sido previamente reportados como altamente informativos para la caracterización de distintas respuesta de estrés en plantas (Fernández-Calleja et al., 2020; Kaiser et al., 2019; J. H. Kim et al., 2019; Kromdijk & Walter, 2023; Nurcahyani et al., 2021; Tanner et al., 2022). En este sentido, el rendimiento cuántico del fotosistema II (Fv/Fm) es un rasgo eficiente en la detección del marchitamiento bacteriano en plantas de tomate (J. H. Kim et al., 2019), además la estabilidad del valor de Fv/Fm indica la ausencia

de estrés en plantas (Carmona et al., 2021). Entre tanto NPQt es un parámetro del estado de salud de las plantas (Kanazawa et al., 2021; Tietz et al., 2017; Zeng et al., 2020).

Por otra parte, el ciclo de xantofilas está estrechamente relacionado con NPQt ya que conduce a mecanismos de foto protección (Arellano, 2023; Fernández-Calleja et al., 2020; Kaiser et al., 2019; Kanazawa et al., 2021; Kromdijk & Walter, 2023; Zeng et al., 2020). El estrés por patógenos puede alterar el ciclo de las xantofilas, influenciando la actividad de la ATP sintasa conduciendo a cambios en el pH del lumen de los tilacoides. Estos cambios en el pH activan el ciclo de las xantofilas y antagoniza la síntesis de ABA, un regulador fisiológico que influye en respuestas de defensa de la planta contra patógenos, así como en la regulación de apertura y cierre de estomas tratando de evitar la pérdida de agua. Estos efectos pueden llevar a la aparición de síntomas de marchitamiento en la planta (Zeng et al., 2020; J. Zhou et al., 2015). El aumento de NPQ protege a las plantas de la sequía al reducir la presión en PSII y suprimir la actividad del complejo citocromo b6f (Cyt), beneficiando el PSI (Gu et al., 2022; Guadagno et al., 2021). Además, debido a que la apertura y el cierre de estomas se ven afectados, se genera una regulación insuficiente de la temperatura foliar, originando variaciones en el diferencial de temperatura de la hoja (LDT). Esto a su vez provoca un desequilibrio en el flujo de agua dentro de la planta, lo que puede desencadenar síntomas similares a los del estrés por sequía cuando la planta se enfrenta a infecciones por patógenos (Tanner et al., 2022) como lo observamos en nuestro estudio. La clorofila desempeña un papel fundamental en el proceso de la fotosíntesis, ya que su función principal es captar la energía solar y convertirla en carbohidratos (Nurcahyani et al., 2021), sin embargo, la infección por patógenos es un factor que impacta negativamente en los niveles de clorofila, afectando la eficiencia fotosintética y generando síntomas de clorosis a nivel foliar (Nurcahyani et al., 2021; Salaria et al., 2023). Por otro lado, Phi2 representa la cantidad de energía del PSII reservada para la fotoquímica en el proceso fotosintético, alteraciones en Phi2 se han asociado como indicador de estrés en plantas (Fernández-Calleja et al., 2020; Wang et al., 2018).

En esta investigación se encontró que los centros de reacción oxidados del PSI (PSIOxidCent) son importantes en la predicción de MV. En condiciones normales el sistema de transporte de electrones fotosintético cumple la función de captar la energía de los fotones y conducir los electrones a través de la cadena de transporte impulsando el flujo de electrones desde el PSII al PSI (Kanazawa et al., 2017; Kubota-Kawai et al., 2018). En el PSI, el P700 se foto excita. Luego el P700 excitado dona un electrón al portador de electrones primario, y el P700 queda en estado oxidado. Posteriormente, el

P700 oxidado acepta un electrón de la plastocianina reducida (PC) para restaurar P700. La PC oxidada a su vez es reducida por los electrones provenientes del PSII (Miyake, 2020). Sin embargo, en condiciones de estrés los electrones acumulados en el lado del aceptor de PSI se utilizan para la reducción del oxígeno generando un radical superóxido, una forma de (ROS), lo que conduce al estrés oxidativo y la inactivación del PSI. Este daño oxidativo, causado por las ROS, se manifiesta en condiciones de estrés, resultando en una disminución de la eficiencia fotosintética (Fernández-Calleja et al., 2020; Kanazawa et al., 2017; Kuhlert et al., 2016; Miyake, 2020). El estado de reducción de P700 en PSI favorece la generación de ROS mientras que la oxidación de P700 en PSI controla la disminución de la producción de ROS (Miyake, 2020). Por otro lado, el vH^+ como rasgo asociado a la detección indirecta de la MV se relaciona con la fuerza motriz del protón en el tilacoide, la cual está acoplada a la transferencia de electrones impulsada por la luz. Esto impulsa la síntesis de ATP y sirve como una señal para iniciar la regulación de los centros de reacción (Avenson et al., 2005).

Los patógenos igualmente afectan la división del agua en el PSII, la fluorescencia mínima (F_o), la fluorescencia máxima (F_m) y el flujo de absorción en centros de reacción activos (Panova et al., 2012), estos rasgos fotosintéticos fueron identificados en el presente estudio, y están afectados en la interacción ají-MV. No obstante, q_L representa la fracción de centros abiertos del PSII, indicando el estado redox de Q_a (Kramer et al., 2004). Esta medida se emplea para evaluar la salud y el crecimiento de las plantas (Miyake et al., 2009). q_L es crucial para comprender cómo el estrés ambiental y otros factores pueden afectar la fotosíntesis (Baker, 2008; Kuhlert et al., 2016). La relación entre q_L , NPQ y F_v/F_m revela el mecanismo de regulación del nivel redox de la reserva de PQ y refleja la eficiencia de la reacción fotoquímica en el PSII (Miyake et al., 2009) estrechamente relacionado a los mecanismos de foto protección.

Igualmente, se han identificado rasgos espectrales, geométricos e índices de vegetación más informativos para detectar la MV. Entre estos rasgos, se destacan la geometría del dosel, los índices EVI, NDRE, CIRE y la banda de borde rojo. Bajo esta consideración, la MV asociada *Fusarium* sp. afecta la estructura interna de la planta al obstruir los haces vasculares encargados de transportar agua y nutrientes. Esto puede resultar a un debilitamiento y colapso de la planta, lo que se manifiesta como marchitamiento y daño a la estructura y cambios en la geometría del dosel (Zhao et al., 2022). En cuanto a los índices de vegetación, cada uno utiliza combinaciones específicas de bandas del

espectro electromagnético para resaltar diferentes aspectos de la vegetación (Boiarskii, 2019; Lizarazo et al., 2023; Nur Anisa et al., 2020; Rodríguez et al., 2021; Sharma et al., 2015; Sosa-Herrera et al., 2022; Ye et al., 2021). La selección cuidadosa de estas bandas en cada índice mejora significativamente la sensibilidad y precisión para detectar cambios en el dosel y la salud de las plantas (Courbier & Pierik, 2019). La banda de borde rojo es sensible a la variación en los niveles de clorofila, por lo tanto, puede ser útil en la detección de enfermedades (Huang et al., 2014; Liu et al., 2020; Ye et al., 2020). Esto es de suma importancia, ya que facilita la detección rápida y precisa de enfermedades o estrés hídrico, lo que a su vez permite tomar medidas oportunas para mitigar los efectos negativos y garantizar la productividad y sostenibilidad de los cultivos de ají en condiciones comerciales.

La detección indirecta, rápida y precisa del MV puede contribuir a prevenir la propagación de la enfermedad (Gabrekiristos & Demiyo, 2020; Gordon, 2017) y estos rasgos fotosintéticos identificados pueden ser indicadores en el seguimiento de la enfermedad durante el ciclo del cultivo. Desde una perspectiva epidemiológica, estos rasgos pueden ser útiles en aspectos agronómicos dirigiendo procesos de monitoreo y seguimiento en el desarrollo de la MV. En nuestro estudio demostramos que los rasgos fotosintéticos están estrechamente asociados a la susceptibilidad y respuesta fisiológica de la planta a enfermedades vasculares, por lo cual el uso de sensores proximales como el MultispeQ contribuiría a la detección indirecta y precisa de MV en el sistema comercial de producción de ají, sin embargo, es necesario validar estas herramientas bajo otras condiciones, integrando este procedimiento metodológico en el monitoreo y seguimiento en la producción de diversos cultivos.

Por otro lado, los estados fenológicos y el número de frutos del sistema comercial de ají fueron altamente discriminados por rasgos fotosintéticos como $gH+$, el contenido relativo de clorofila, PS1ActCent y Fs. El flujo transmembrana de protones a través de la ATP sintasa desencadena la rotación de un conjunto oligomérico de subunidades, lo que tiene un impacto inmediato en la eficiencia fotosintética (Yamamoto et al., 2023). Esta conductividad es crucial para la generación de ATP, que es esencial para llevar a cabo la fotosíntesis y estimular el crecimiento de las plantas. Por lo tanto, desempeña un papel fundamental en la fenología de las plantas y en el rendimiento de sus frutos (Yamamoto et al., 2023). Así mismo, la fluorescencia de la clorofila en estado estacionario (Fs) puede estar positivamente relacionada con la fenología y el número de frutos, ya que un aumento

en que F_s depende de la competencia entre la desexcitación fotoquímica y no fotoquímica de la energía absorbida por los complejos captadores de luz. Este rasgo generalmente indica una mayor acción fotosintética, lo que puede proporcionar más energía para el desarrollo de frutos durante las etapas de floración y fructificación. Sin embargo, esta relación puede verse afectada por factores específicos y la influencia del ambiente (Flexas et al., 2002).

Estos rasgos fotosintéticos mostraron niveles más altos en las etapas de desarrollo y maduración de los frutos, también presentaron un coeficiente de variación elevado en estas dos últimas etapas (Figura 2-13). La variación en estos rasgos fotosintéticos en las diferentes etapas fenológicas puede estar relacionada con cambios en la demanda energética y metabólica de la planta durante su ciclo de vida (González-Gordo et al., 2020; Kavga et al., 2019; Pérez-Gutiérrez et al., 2017). Durante la emergencia de la inflorescencia y la floración, es posible que la planta requiere menos energía, mientras que, durante el desarrollo y la maduración del fruto, la demanda de energía puede aumentar, lo que se refleja en un aumento en la actividad fotosintética y la producción de clorofila (Dong et al., 2019; Lenk et al., 2020). Esto sugiere que existe una mayor variabilidad en la actividad fotosintética y en la producción de clorofila durante estas fases, lo que podría estar relacionado con la complejidad y la dinámica de los procesos metabólicos involucrados en el desarrollo y maduración de los frutos de ají (Gholipour & Nadali, 2019; Hornero-Méndez & Mínguez-Mosquera, 2002; Pramanik et al., 2020). Estos rasgos fotosintéticos están estrechamente relacionados con el incremento en la capacidad fotosintética (Avenson et al., 2005; Baker, 2008; Kanazawa et al., 2017; Kuhlert et al., 2016; H. Zhang et al., 2023). La capacidad fotosintética está asociada con un aumento significativo en la cantidad de frutos en las plantas de ají (Y. Li et al., 2023). Por lo tanto, el contenido de clorofila es crucial para proporcionar información valiosa sobre los diagnósticos del estado productivo de las plantas (Y. Wang et al., 2023; H. Zhang et al., 2023; X. Zhou et al., 2019). Aunque la fluorescencia de la clorofila inducida por el sol (SIF) es una herramienta sofisticada para detectar cambios fenológicos y/o productivos (Chen et al., 2022), puede ser implementada en combinación con los parámetros identificados en este estudio.

En cuanto a los índices de vegetación identificados, tales como el índice EVI, VARI, NGRDI y CIrededge fueron altamente informativos para la estimación precisa de la fenología del cultivo de ají. Cada uno de estos índices ha sido cuidadosamente diseñado para capturar características específicas de la vegetación y proporcionar información valiosa sobre el ciclo de crecimiento de las

plantas de ají (J. He et al., 2019; Koide et al., 2019; Tucker, 1979; Vincini et al., 2008; C. Wang et al., 2022). Al analizar la variación de estos índices a lo largo del tiempo, es posible obtener una visión detallada del desarrollo de las plantas, incluyendo la identificación de etapas fenológicas clave (Crippen, 1990; J. He et al., 2019). La combinación estratégica de estos índices permite un monitoreo eficiente y oportuno de la fenología del cultivo de ají.

Los índices de vegetación identificados son herramientas clave en el pronóstico de componentes de rendimiento, como el número de frutos por planta. La combinación de cada índice proporciona información única sobre el estado y la salud de la vegetación (Bannari et al., 1995; Moradi et al., 2022; Stanton et al., 2017). El índice Cired edge y CIRE, son sensibles al contenido de clorofila, permiten evaluar la cantidad de follaje y su salud (Bannari et al., 1995; Gitelson et al., 2003, 2005). El índice IPVI y el índice TVI se enfocan en la geometría del dosel y pueden ayudar a medir la estructura y densidad de la vegetación (Broge & Leblanc, 2000; Crippen, 1990). En conjunto, estos índices proporcionan una visión completa de los componentes de rendimiento, como el número de frutos en las plantas de ají (Fei et al., 2023; Y. Li et al., 2023; Sharma et al., 2015).

El monitoreo de cultivos tiene beneficios significativos en la comprensión de las relaciones entre la productividad, la salud de la vegetación y su relación con las condiciones ambientales (Yalcin, 2015). La fenología de las plantas es influenciada por factores genéticos, ambientales y de manejo del cultivo, comprende los eventos biológicos temporales como el crecimiento, la floración, la fructificación, la maduración y la senescencia. Estos eventos están determinados por la temperatura, la luz, la disponibilidad de agua y nutrientes, y las horas luz (Feldmann & Rutikanga, 2021; Jing et al., 2017; Morellato et al., 2016; Rodrigues et al., 2023). Poder lograr métodos no destructivos de monitoreo y análisis de datos como los presentados en este trabajo, generan un gran avance en la comprensión de las dinámicas de crecimiento y desarrollo del ají bajo cultivos comerciales y da posibilidad de poder usar estos resultados a futuro a la integración de modelos de predicción y gestión del sistema productivo, como base para la toma de decisiones en el manejo agronómico. En este sentido se ha reportado que los rasgos de la fotosíntesis en diferentes etapas fenológicas están directamente relacionado al número de frutos por planta (Haghighi et al., 2023).

El uso del sensor MultispeQ requiere que el usuario determine el protocolo a evaluar. En nuestro estudio usamos el protocolo “*Photosynthesis No Open/ Close*” siendo este útil, debido a la rapidez

de la captura de los rasgos fotosintéticos. Además, en la elección del protocolo se puede integrar la escala a evaluar y otras características durante cada muestreo (Herts et al., 2020). En este trabajo, realizamos la identificación de rasgos fotofísicos y fotoquímicos para el monitoreo y evaluación del ají en condiciones comerciales, sin embargo, la selección y análisis de estos parámetros se pueden determinar en diversos contextos de protección de cultivos.

Finalmente, la identificación y selección de rasgos fotosintéticos predictores de la severidad de MV asociado a algunas especies de *Fusarium* sp., fue conducida por enfoques de AI demostrando la capacidad de clasificación de estados de severidad. En este trabajo usamos la función AutoML con el objetivo de evaluar el mayor número de modelos y seleccionar el de, mayor precisión, sin embargo, el monitoreo de enfermedades puede ser clasificado usando diversos modelos de AI actualmente aplicados en diversos enfoques de investigación (Aqel et al., 2022; Buja et al., 2021; Karadağ et al., 2020; Mezenner et al., 2022; Ubaidillah et al., 2022; Ye et al., 2021). La generación de modelos de predicción a partir de rasgos fotosintéticos con alta capacidad predictiva contribuye al monitoreo y detección indirecta y precisa de enfermedades como lo demostramos en este estudio. Entre tanto, la determinación precisa de la fenología y número de frutos es fundamental en la gestión de sistemas de producción. Considerando esto, se han logrado resultados interesantes para el caso particular de sistemas comerciales de producción de ají Cayenne mediante el uso de rasgos fenotípicos medidos por HTPP. En esta parte utilizamos algoritmos de ML y DL con el objetivo de predecir con precisión aspectos fenológicos como productivos (número de frutos). Esto indica el potencial de las herramientas de HTPP que en combinación con métodos avanzados de análisis y minería de datos, logran mejorar la gestión de la información y obtener elementos para la caracterización de distintos fenómenos que alteran el desarrollo y componentes de producción en las plantas (Chang et al., 2021; Fei et al., 2023; Gholipoor & Nadali, 2019; Guo et al., 2021; Jhajharia et al., 2023; Jing et al., 2017; Srivastava et al., 2022; Tang et al., 2023; Yalcin, 2018; M. Zhou et al., 2023).

2.5 Conclusiones

Este estudio resalta de manera notable el poder y la versatilidad de las técnicas de IA en el ámbito agrícola. Estas técnicas se aplican al análisis y minería de rasgos fenotípicos recopilados a través de HTPP, demostrando su capacidad tanto en la detección indirecta de la severidad de MV como en la estimación precisa de la fenología y el pronóstico del número de frutos. Mediante enfoques como AutoML y el DL, se han identificado rasgos fotosintéticos clave en cada contexto específico. En el caso de la detección de la MV, han surgido rasgos como Fv/Fm, NPQt, LDT, RelaChloroII y Phi2 como rasgos cruciales. En contraste, en lo que respecta a la estimación de la fenología y el rendimiento de frutos, se han destacado parámetros como gH+, RelaChloroII, LEF, PS1ActCent y Foprime. Además, es fundamental reconocer que los rasgos fotosintéticos identificados, junto con el uso de fenotipado de alto rendimiento y la aplicación de inteligencia artificial, brinda implicaciones agronómicas interesantes. Estos hallazgos no solo pueden contribuir al entendimiento de las relaciones entre los rasgos fotosintéticos, la severidad de enfermedades, la fenología y la productividad de las plantas de ají, sino que también ofrecen una base sólida para la protección de cultivos en la implementación de un método de monitoreo integral que incluya el sensor proximal MultispeQ y las técnicas de inteligencia artificial en cultivos comerciales. Tal enfoque puede resultar invaluable en la gestión efectiva y sostenible de diferentes cultivos.

2.6 Referencias

- Ahmad, L., & Nabi, F. (2021). Agriculture 5.0: Artificial Intelligence, IoT, and Machine Learning. In *Agriculture 5.0: Artificial Intelligence, IoT, and Machine Learning*. CRC Press. [HTPPs://doi.org/10.1201/9781003125433](https://doi.org/10.1201/9781003125433)
- Aklilu, S., Abebie, B., Wogari, D., & T/Wolde, A. (2016). Genetic variability and association of characters in Ethiopian hot pepper (*Capsicum annum* L.) landraces. *Journal of Agricultural Sciences, Belgrade*, *61*(1), 19–36. [HTPPs://doi.org/10.2298/jas1601019a](https://doi.org/10.2298/jas1601019a)
- Alameen, A. (2022). Improving the Accuracy of Multi-Valued Datasets in Agriculture Using Logistic Regression and LSTM-RNN Method. *TEM Journal*, *11*(1), 454–462. [HTPPs://doi.org/10.18421/TEM111-58](https://doi.org/10.18421/TEM111-58)
- Alkemade, J. A., Messmer, M. M., Arncken, C., Leska, A., Annicchiarico, P., Nazzicari, N., Książkiewicz, M., Voegelé, R. T., Finckh, M. R., & Hohmann, P. (2021). A high-throughput phenotyping tool to identify field-relevant anthracnose resistance in white lupin. *Plant Disease*, *105*(6). [HTPPs://doi.org/10.1094/PDIS-07-20-1531-RE](https://doi.org/10.1094/PDIS-07-20-1531-RE)

- Ampatzidis, Y., & Partel, V. (2019). UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. *Remote Sensing*, *11*(4). [HTPPs://doi.org/10.3390/rs11040410](https://doi.org/10.3390/rs11040410)
- Andrade-Sanchez, P., Gore, M. A., Heun, J. T., Thorp, K. R., Carmo-Silva, A. E., French, A. N., Salvucci, M. E., & White, J. W. (2014). Development and evaluation of a field-based high-throughput phenotyping platform. *Functional Plant Biology*, *41*(1), 68–79. [HTPPs://doi.org/10.1071/FP13126](https://doi.org/10.1071/FP13126)
- Aqel, D., Al-Zubi, S., Mughaid, A., & Jararweh, Y. (2022). Extreme learning machine for plant diseases classification: a sustainable approach for smart agriculture. *Cluster Computing*, *25*(3), 2007–2020. [HTPPs://doi.org/10.1007/s10586-021-03397-y](https://doi.org/10.1007/s10586-021-03397-y)
- Araus, J. L., & Cairns, J. E. (2014). Field high-throughput phenotyping: The new crop breeding frontier. In *Trends in Plant Science* (Vol. 19, Issue 1, pp. 52–61). [HTPPs://doi.org/10.1016/j.tplants.2013.09.008](https://doi.org/10.1016/j.tplants.2013.09.008)
- Arellano, J. B. (2023). Non-photochemical quenching of photosystem I as an adaptive response to prolonged drought. *Journal of Experimental Botany*, *74*(1), 16–18. [HTPPs://doi.org/10.1093/jxb/erac438](https://doi.org/10.1093/jxb/erac438)
- Arora, H., Sharma, A., Sharma, S., Haron, F. F., Gafur, A., Sayyed, R. Z., & Datta, R. (2021). Pythium damping-off and root rot of capsicum annum l.: Impacts, diagnosis, and management. In *Microorganisms* (Vol. 9, Issue 4). MDPI AG. [HTPPs://doi.org/10.3390/microorganisms9040823](https://doi.org/10.3390/microorganisms9040823)
- Avenson, T. J., Kanazawa, A., Cruz, J. A., Takizawa, K., Ettinger, W. E., & Kramer, D. M. (2005). Integrating the proton circuit into photosynthesis: Progress and challenges. In *Plant, Cell and Environment* (Vol. 28, Issue 1, pp. 97–109). [HTPPs://doi.org/10.1111/j.1365-3040.2005.01294.x](https://doi.org/10.1111/j.1365-3040.2005.01294.x)
- Baker, N. R. (2008). Chlorophyll fluorescence: A probe of photosynthesis in vivo. *Annual Review of Plant Biology*, *59*, 89–113. [HTPPs://doi.org/10.1146/annurev.arplant.59.032607.092759](https://doi.org/10.1146/annurev.arplant.59.032607.092759)
- Bannari, A., Morin, D., Bonn, F., & Huete, A. R. (1995). A review of vegetation indices. *Remote Sensing Reviews*, *13*(1–2), 95–120. [HTPPs://doi.org/10.1080/02757259509532298](https://doi.org/10.1080/02757259509532298)
- Ben-Jabeur, M., Romero, A. G., Vicente, R., Kthiri, Z., Kefauver, S. C., Serret, M. D., Ortega, J. L. A., & Hamada, W. (2021). MultispeQ for Tracing Biostimulants Effect on Growth Promoting and Water Stress Tolerance in Wheat. *Environmental Science and Engineering*, 1207–1211. [HTPPs://doi.org/10.1007/978-3-030-51210-1_191](https://doi.org/10.1007/978-3-030-51210-1_191)

-
- Berger, S., Sinha, A. K., & Roitsch, T. (2007). Plant physiology meets phytopathology: Plant primary metabolism and plant-pathogen interactions. In *Journal of Experimental Botany* (Vol. 58, Issues 15–16, pp. 4019–4026). [HTPPs://doi.org/10.1093/jxb/erm298](https://doi.org/10.1093/jxb/erm298)
- Bhutia L, K., VK, K., Meetei NG, T., & Bhutia D, N. (2018). Effects Of Climate Change On Growth And Development Of Chilli. *Agrotechnology*, 07(02). [HTPPs://doi.org/10.4172/2168-9881.1000180](https://doi.org/10.4172/2168-9881.1000180)
- Boiarskii, B. (2019). Comparison of NDVI and NDRE Indices to Detect Differences in Vegetation and Chlorophyll Content. *JOURNAL OF MECHANICS OF CONTINUA AND MATHEMATICAL SCIENCES*, spl1(4). [HTPPs://doi.org/10.26782/jmcms.spl.4/2019.11.00003](https://doi.org/10.26782/jmcms.spl.4/2019.11.00003)
- Bouguettaya, A., Zarzour, H., Kechida, A., & Taberkit, A. M. (2022). A survey on deep learning-based identification of plant and crop diseases from UAV-based aerial images. *Cluster Computing*. [HTPPs://doi.org/10.1007/s10586-022-03627-x](https://doi.org/10.1007/s10586-022-03627-x)
- Broge, N. H., & Leblanc, E. (2000). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*. www.elsevier.com/locate/rse
- 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. In *Sensors* (Vol. 21, Issue 6, pp. 1–22). MDPI AG. [HTPPs://doi.org/10.3390/s21062129](https://doi.org/10.3390/s21062129)
- Calderón, R., Navas-Cortés, J. A., Lucena, C., & Zarco-Tejada, P. J. (2013). High-resolution airborne hyperspectral and thermal imagery for early detection of Verticillium wilt of olive using fluorescence, temperature and narrow-band spectral indices. *Remote Sensing of Environment*, 139, 231–245. [HTPPs://doi.org/10.1016/j.rse.2013.07.031](https://doi.org/10.1016/j.rse.2013.07.031)
- Candel, A., Ledell, E., & Bartz, A. (2016). *Deep Learning with H2O*. [HTPP://h2o.ai/resources/](https://h2o.ai/resources/)
- Carmona, S. L., Villarreal-Navarrete, A., Burbano-David, D., Gómez-Marroquín, M., Torres-Rojas, E., & Soto-Suárez, M. (2021). Protection of tomato plants against Fusarium oxysporum f. sp. lycopersici induced by chitosan. *Revista Colombiana de Ciencias Hortícolas*, 15(3). [HTPPs://doi.org/10.17584/rcch.2021v15i3.12822](https://doi.org/10.17584/rcch.2021v15i3.12822)
- Castro Clavijo, S. D. (2014). *Búsqueda de resistencia a la pudrición causada por Fusarium spp. en Capsicum* [Maestría tesis, Universidad Nacional de Colombia sede Palmira]. [HTPPs://repositorio.unal.edu.co/handle/unal/53137](https://repositorio.unal.edu.co/handle/unal/53137)

- Chang, S., Lee, U., Hong, M. J., Jo, Y. D., & Kim, J. B. (2021). Time-Series Growth Prediction Model Based on U-Net and Machine Learning in Arabidopsis. *Frontiers in Plant Science*, *12*. [HTPPs://doi.org/10.3389/fpls.2021.721512](https://doi.org/10.3389/fpls.2021.721512)
- Chen, A., Meng, F., Mao, J., Ricciuto, D., & Knapp, A. K. (2022). Photosynthesis phenology, as defined by solar-induced chlorophyll fluorescence, is overestimated by vegetation indices in the extratropical Northern Hemisphere. *Agricultural and Forest Meteorology*, *323*. [HTPPs://doi.org/10.1016/j.agrformet.2022.109027](https://doi.org/10.1016/j.agrformet.2022.109027)
- Conejo Rodriguez, D. F., Urban, M. O., Santaella, M., Gereda, J. M., Contreras, A. D., & Wenzl, P. (2022). Using phenomics to identify and integrate traits of interest for better-performing common beans: A validation study on an interspecific hybrid and its *Acutifolii* parents. *Frontiers in Plant Science*, *13*. [HTPPs://doi.org/10.3389/fpls.2022.1008666](https://doi.org/10.3389/fpls.2022.1008666)
- Courbier, S., & Pierik, R. (2019). Canopy Light Quality Modulates Stress Responses in Plants. *CellPress*. [HTPPs://doi.org/10.1016/j.isci](https://doi.org/10.1016/j.isci)
- Crippen, R. E. (1990). Calculating the Vegetation Index Faster. *Remote Sensing of Environment*, *34*, 71–73. [HTPPs://doi.org/doi:10.1016/0034-4257\(90\)90085-z](https://doi.org/10.1016/0034-4257(90)90085-z)
- Cruz, J. A., & Avenson, T. J. (2021). Photosynthesis: a multiscope view. *Journal of Plant Research*, *134*(4), 665–682. [HTPPs://doi.org/10.1007/s10265-021-01321-4](https://doi.org/10.1007/s10265-021-01321-4)
- de Lamo, F. J., & Takken, F. L. W. (2020). Biocontrol by *Fusarium oxysporum* Using Endophyte-Mediated Resistance. In *Frontiers in Plant Science* (Vol. 11). Frontiers Media S.A. [HTPPs://doi.org/10.3389/fpls.2020.00037](https://doi.org/10.3389/fpls.2020.00037)
- DeSalvio, A. J., Adak, A., Murray, S. C., Wilde, S. C., & Isakeit, T. (2022). Phenomic data-facilitated rust and senescence prediction in maize using machine learning algorithms. *Scientific Reports*, *12*(1). [HTPPs://doi.org/10.1038/s41598-022-11591-0](https://doi.org/10.1038/s41598-022-11591-0)
- Dong, T., Shang, J., Chen, J. M., Liu, J., Qian, B., Ma, B., Morrison, M. J., Zhang, C., Liu, Y., Shi, Y., Pan, H., & Zhou, G. (2019). Assessment of portable chlorophyll meters for measuring crop leaf chlorophyll concentration. *Remote Sensing*, *11*(22). [HTPPs://doi.org/10.3390/rs11222706](https://doi.org/10.3390/rs11222706)
- dos Anjos, I. V., Silva, L. P., Silva, L. R., Araújo, K. L., Silva, A. F., Barelli, M. A. A., & Neves, L. G. (2018). *Reação de acessos de Capsicum spp. ao fungo Fusarium solani*. *16*, 344–349.
- 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*, 10(10). [HTPPs://doi.org/10.3390/rs10101513](https://doi.org/10.3390/rs10101513)
- Eke, P., Dinango, V. N., Nana Wakam, L., Toghueo, R. M. K., Kouokap, L. R. K., Mabou, L. C. N., Wankeu, T. H. K., Ngomsi, P., & Boyom, F. F. (2021). Diagnosis and bioefficacy of endospheric trichoderma strains of selected medicinal plant on pepper root rot and vascular wilt in Cameroon. *Archives of Phytopathology and Plant Protection*, 54(13–14), 794–812. [HTPPs://doi.org/10.1080/03235408.2020.1844524](https://doi.org/10.1080/03235408.2020.1844524)
- Elvanidi, A., & Katsoulas, N. (2022). *Performance of Gradient Boosting Learning Algorithm for Crop Stress Identification in Greenhouse Cultivation*. 25. [HTPPs://doi.org/10.3390/iecho2022-12508](https://doi.org/10.3390/iecho2022-12508)
- Eng, L. S., Ismail, R., Hashim, W., & Baharum, A. (2019). The use of VARI, GLI, And VIgreen formulas in detecting vegetation in aerial images. *International Journal of Technology*, 10(7), 1385–1394. [HTPPs://doi.org/10.14716/ijtech.v10i7.3275](https://doi.org/10.14716/ijtech.v10i7.3275)
- Escadafal, R. (1994). SOIL SPECTRAL PROPERTIES AND THEIR RELATIONSHIPS WITH ENVIRON-MENTAL PARAMETERS-EXAMPLES FROM ARID REGIONS. In J. M. J. Hill (Ed.), *Imaging Spectrometry — a Tool for Environmental Observations: Vol. vol 4* (Springer, Dordrecht). [HTPPs://doi.org/10.1007/978-0-585-33173-7_5](https://doi.org/10.1007/978-0-585-33173-7_5)
- Farihadina, A. A., & Sutarman. (2022). Application of Biological Agents of Trichoderma and Aspergillus on Cayenne Chilli Plants in Endemic Land with Fusarium Wilt. *IOP Conference Series: Earth and Environmental Science*, 1104(1). [HTPPs://doi.org/10.1088/1755-1315/1104/1/012003](https://doi.org/10.1088/1755-1315/1104/1/012003)
- Fei, S., Hassan, M. A., Xiao, Y., Su, X., Chen, Z., Cheng, Q., Duan, F., Chen, R., & Ma, Y. (2023). UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat. *Precision Agriculture*, 24(1), 187–212. [HTPPs://doi.org/10.1007/s11119-022-09938-8](https://doi.org/10.1007/s11119-022-09938-8)
- Feldmann, F., & Rutikanga, A. (2021). Phenological growth stages and BBCH-identification keys of Chilli (*Capsicum annum* L., *Capsicum chinense* JACQ., *Capsicum baccatum* L.). *Journal of Plant Diseases and Protection*, 128(2), 549–555. [HTPPs://doi.org/10.1007/s41348-020-00395-x](https://doi.org/10.1007/s41348-020-00395-x)
- Feng, L., Chen, S., Zhang, C., Zhang, Y., & He, Y. (2021). A comprehensive review on recent applications of unmanned aerial vehicle remote sensing with various sensors for high-throughput plant phenotyping. In *Computers and Electronics in Agriculture* (Vol. 182). Elsevier B.V. [HTPPs://doi.org/10.1016/j.compag.2021.106033](https://doi.org/10.1016/j.compag.2021.106033)

- Fernández-Calleja, M., Monteagudo, A., Casas, A. M., Boutin, C., Pin, P. A., Morales, F., & Igartua, E. (2020). Rapid on-site phenotyping via field fluorimeter detects differences in photosynthetic performance in a hybrid—parent barley germplasm set. *Sensors (Switzerland)*, 20(5). [HTPPs://doi.org/10.3390/s20051486](https://doi.org/10.3390/s20051486)
- Flexas, J., Escalona, M., Evain, S., Gulías, J., Moya, I., Osmond, C. B., & Medrano, H. (2002). *Steady-state chlorophyll fluorescence (Fs) measurements as a tool to follow variations of net CO₂ assimilation and stomatal conductance during water-stress in C₃ plants.*
- Furbank, R. T., & Tester, M. (2011). Phenomics - technologies to relieve the phenotyping bottleneck. In *Trends in Plant Science* (Vol. 16, Issue 12, pp. 635–644). [HTPPs://doi.org/10.1016/j.tplants.2011.09.005](https://doi.org/10.1016/j.tplants.2011.09.005)
- Gabrekiristos, E., & Demiyo, T. (2020). Hot Pepper Fusarium Wilt (*Fusarium oxysporum* f. sp. capsici): Epidemics, Characteristic Features and Management Options. *Journal of Agricultural Science*, 12(10), 347. [HTPPs://doi.org/10.5539/jas.v12n10p347](https://doi.org/10.5539/jas.v12n10p347)
- Galli, G., Horne, D. W., Collins, S. D., Jung, J., Chang, A., Fritsche-Neto, R., & Rooney, W. L. (2020). Optimization of UAS-based high-throughput phenotyping to estimate plant health and grain yield in sorghum. *Plant Phenome Journal*, 3(1). [HTPPs://doi.org/10.1002/ppj2.20010](https://doi.org/10.1002/ppj2.20010)
- Gedeon, T. D. (1997). DATA MINING OF INPUTS: ANALYSING MAGNITUDE AND FUNCTIONAL MEASURES. *International Journal of Neural Systems*, 8 No. 2, 209–218. www.worldscientific.com
- Gholipoor, M., & Nadali, F. (2019). Fruit yield prediction of pepper using artificial neural network. *Scientia Horticulturae*, 250, 249–253. [HTPPs://doi.org/10.1016/j.scienta.2019.02.040](https://doi.org/10.1016/j.scienta.2019.02.040)
- 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. In *J. Plant Physiol* (Vol. 160). [HTPP://www.urbanfischer.de/journals/jpp](http://www.urbanfischer.de/journals/jpp)
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). *Novel algorithms for remote estimation of vegetation fraction.* www.elsevier.com/locate/rse
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., & Arkebauer, T. J. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, 32(8), 1–4. [HTPPs://doi.org/10.1029/2005GL022688](https://doi.org/10.1029/2005GL022688)

-
- González-Gordo, S., Rodríguez-Ruiz, M., Palma, J. M., & Corpas, F. J. (2020). Superoxide Radical Metabolism in Sweet Pepper (*Capsicum annuum* L.) Fruits Is Regulated by Ripening and by a NO-Enriched Environment. *Frontiers in Plant Science*, *11*. [HTPPs://doi.org/10.3389/fpls.2020.00485](https://doi.org/10.3389/fpls.2020.00485)
- Gordon, T. R. (2017). *Annual Review of Phytopathology Fusarium oxysporum and the Fusarium Wilt Syndrome*. [HTPPs://doi.org/10.1146/annurev-phyto-080615](https://doi.org/10.1146/annurev-phyto-080615)
- 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). [HTPPs://doi.org/10.3390/drones5020034](https://doi.org/10.3390/drones5020034)
- Gu, L., Grodzinski, B., Han, J., Marie, T., Zhang, Y. J., Song, Y. C., & Sun, Y. (2022). Granal thylakoid structure and function: explaining an enduring mystery of higher plants. *New Phytologist*, *236*(2), 319–329. [HTPPs://doi.org/10.1111/nph.18371](https://doi.org/10.1111/nph.18371)
- Gu, L., Grodzinski, B., Han, J., Marie, T., Zhang, Y. J., Song, Y. C., & Sun, Y. (2023). An exploratory steady-state redox model of photosynthetic linear electron transport for use in complete modelling of photosynthesis for broad applications. *Plant Cell and Environment*. [HTPPs://doi.org/10.1111/pce.14563](https://doi.org/10.1111/pce.14563)
- Guadagno, C. R., Beverly, D. P., & Ewers, B. E. (2021). The love–hate relationship between chlorophyll a and water in psii affects fluorescence products. *Photosynthetica*, *59*(Special Issue), 409–421. [HTPPs://doi.org/10.32615/ps.2021.023](https://doi.org/10.32615/ps.2021.023)
- Guimarães, M., Queiroz, M., & Alfenas, R. (2021). RGB-based phenotyping of foliar disease severity under controlled conditions. *OSFPREPRINTS*, 1–29. [HTPPs://doi.org/10.31219/osf.io/fs4vm](https://doi.org/10.31219/osf.io/fs4vm)
- Guo, Y., Fu, Y., Hao, F., Zhang, X., Wu, W., Jin, X., Robin Bryant, C., & Senthilnath, J. (2021). Integrated phenology and climate in rice yields prediction using machine learning methods. *Ecological Indicators*, *120*. [HTPPs://doi.org/10.1016/j.ecolind.2020.106935](https://doi.org/10.1016/j.ecolind.2020.106935)
- Haghighi, M., Sharifani, M. J., & Parnianifard, F. (2023). Physiological changes of sweet pepper under low irrigation regimes applied in three phenological stages of vegetative growth, reproductive growth, and fruit set. *New Zealand Journal of Crop and Horticultural Science*. [HTPPs://doi.org/10.1080/01140671.2023.2171440](https://doi.org/10.1080/01140671.2023.2171440)
- Harfouche, A. L., Nakhle, F., Harfouche, A. H., Sardella, O. G., Dart, E., & Jacobson, D. (2022). A primer on artificial intelligence in plant digital phenomics: embarking on the data to insights journey. In *Trends in Plant Science*. Elsevier Ltd. [HTPPs://doi.org/10.1016/j.tplants.2022.08.021](https://doi.org/10.1016/j.tplants.2022.08.021)

- Hazir, M. H. M., & Muda, T. M. T. (2020). The viability of remote sensing for extracting rubber smallholding information: A case study in Malaysia. *Egyptian Journal of Remote Sensing and Space Science*, 23(1), 35–47. [HTPPs://doi.org/10.1016/j.ejrs.2018.05.001](https://doi.org/10.1016/j.ejrs.2018.05.001)
- He, J., Zhang, N., Su, X., Lu, J., Yao, X., Cheng, T., Zhu, Y., Cao, W., & Tian, Y. (2019). Estimating leaf area index with a new vegetation index considering the influence of rice panicles. *Remote Sensing*, 11(15). [HTPPs://doi.org/10.3390/rs11151809](https://doi.org/10.3390/rs11151809)
- He, X., Zhao, K., & Chu, X. (2021). AutoML: A survey of the state-of-the-art. *Knowledge-Based Systems*, 212. [HTPPs://doi.org/10.1016/j.knsys.2020.106622](https://doi.org/10.1016/j.knsys.2020.106622)
- Hernández-Pérez, T., Gómez-García, M. del R., Valverde, M. E., & Paredes-López, O. (2020). Capsicum annuum (hot pepper): An ancient Latin-American crop with outstanding bioactive compounds and nutraceutical potential. A review. *Comprehensive Reviews in Food Science and Food Safety*, 19(6), 2972–2993. [HTPPs://doi.org/10.1111/1541-4337.12634](https://doi.org/10.1111/1541-4337.12634)
- Herts, A., Tsidylo, I., Herts, N., Barna, L., & Mazur, S. I. (2020). PhotosynQ - Cloud platform powered by IoT devices. *E3S Web of Conferences*, 166. [HTPPs://doi.org/10.1051/e3sconf/202016605001](https://doi.org/10.1051/e3sconf/202016605001)
- Hornero-Méndez, D., & Mínguez-Mosquera, M. I. (2002). Chlorophyll disappearance and chlorophyllase activity during ripening of Capsicum annuum L fruits. *Journal of the Science of Food and Agriculture*, 82(13), 1564–1570. [HTPPs://doi.org/10.1002/jsfa.1231](https://doi.org/10.1002/jsfa.1231)
- Huang, W., Guan, Q., Luo, J., Zhang, J., Zhao, J., Liang, D., Huang, L., & Zhang, D. (2014). New optimized spectral indices for identifying and monitoring winter wheat diseases. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2516–2524. [HTPPs://doi.org/10.1109/JSTARS.2013.2294961](https://doi.org/10.1109/JSTARS.2013.2294961)
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). *Overview of the radiometric and biophysical performance of the MODIS vegetation indices*. www.elsevier.com/locate/rse
- Jangir, P., Mehra, N., Sharma, K., Singh, N., Rani, M., & Kapoor, R. (2021). Secreted in Xylem Genes: Drivers of Host Adaptation in Fusarium oxysporum. In *Frontiers in Plant Science* (Vol. 12). Frontiers Media S.A. [HTPPs://doi.org/10.3389/fpls.2021.628611](https://doi.org/10.3389/fpls.2021.628611)
- Jangra, S., Chaudhary, V., Yadav, R. C., & Yadav, N. R. (2021). High-Throughput Phenotyping: A Platform to Accelerate Crop Improvement. *Phenomics*, 1(2), 31–53. [HTPPs://doi.org/10.1007/s43657-020-00007-6](https://doi.org/10.1007/s43657-020-00007-6)

-
- Jhajharia, K., Mathur, P., Jain, S., & Nijhawan, S. (2023). Crop Yield Prediction using Machine Learning and Deep Learning Techniques. *Procedia Computer Science*, 218, 406–417. [HTPPS://doi.org/10.1016/j.procs.2023.01.023](https://doi.org/10.1016/j.procs.2023.01.023)
- Jing, H., Wang, X., Haoyu, W., Xingrong, F., & Mwngzhen, K. (2017). Prediction of crop phenology - a component of parallel agriculture management. *Chinese Automation Congress (CAC)*, 7704-7708. [HTPPS://doi.org/10.1109/CAC.2017.8244172](https://doi.org/10.1109/CAC.2017.8244172).
- Jones, H. G., & Rotenberg, E. (2001). Energy, Radiation and Temperature Regulation in Plants. In *eLS*. Wiley. [HTPPS://doi.org/10.1038/npg.els.0003199](https://doi.org/10.1038/npg.els.0003199)
- Kaiser, E., Galvis, V. C., & Armbruster, U. (2019). Efficient photosynthesis in dynamic light environments: A chloroplast's perspective. *Biochemical Journal*, 476(19), 2725–2741. [HTPPS://doi.org/10.1042/BCJ20190134](https://doi.org/10.1042/BCJ20190134)
- Kalogiannidis, S., Kalfas, D., Chatzitheodoridis, F., & Papaevangelou, O. (2022). Role of Crop-Protection Technologies in Sustainable Agricultural Productivity and Management. *Land*, 11(10). [HTPPS://doi.org/10.3390/land11101680](https://doi.org/10.3390/land11101680)
- Kanazawa, A., Chattopadhyay, A., Kuhlger, S., Tuitupou, H., Maiti, T., & Kramer, D. M. (2021). Light potentials of photosynthetic energy storage in the field: what limits the ability to use or dissipate rapidly increased light energy? *Royal Society Open Science*, 8(12). [HTPPS://doi.org/10.1098/rsos.211102](https://doi.org/10.1098/rsos.211102)
- Kanazawa, A., Ostendorf, E., Kohzuma, K., Hoh, D., Strand, D. D., Sato-Cruz, M., Savage, L., Cruz, J. A., Fisher, N., Froehlich, J. E., & Kramer, D. M. (2017). Chloroplast ATP synthase modulation of the thylakoid proton motive force: implications for photosystem I and photosystem II photoprotection. *Frontiers in Plant Science*, 8. [HTPPS://doi.org/10.3389/fpls.2017.00719](https://doi.org/10.3389/fpls.2017.00719)
- Karadağ, K., Tenekeci, M. E., Taşaltın, R., & Bilgili, A. (2020). Detection of pepper fusarium disease using machine learning algorithms based on spectral reflectance. *Sustainable Computing: Informatics and Systems*, 28. [HTPPS://doi.org/10.1016/j.suscom.2019.01.001](https://doi.org/10.1016/j.suscom.2019.01.001)
- Kavga, A., Strati, I. F., Sinanoglou, V. J., Fotakis, C., Sotiroidis, G., Christodoulou, P., & Zoumpoulakis, P. (2019). Evaluating the experimental cultivation of peppers in low-energy-demand greenhouses. An interdisciplinary study. *Journal of the Science of Food and Agriculture*, 99(2), 781–789. [HTPPS://doi.org/10.1002/jsfa.9246](https://doi.org/10.1002/jsfa.9246)
- Kim, J. H., Bhandari, S. R., Chae, S. Y., Cho, M. C., & Lee, J. G. (2019). Application of maximum quantum yield, a parameter of chlorophyll fluorescence, for early determination of bacterial wilt in tomato seedlings. *Horticulture Environment and Biotechnology*, 60(6), 821–829. [HTPPS://doi.org/10.1007/s13580-019-00182-0](https://doi.org/10.1007/s13580-019-00182-0)

- Kim, J. Y. (2020). Roadmap to High Throughput Phenotyping for Plant Breeding. *Journal of Biosystems Engineering*, 45(1), 43–55. [HTPPs://doi.org/10.1007/s42853-020-00043-0](https://doi.org/10.1007/s42853-020-00043-0)
- Koide, D., Ide, R., & Oguma, H. (2019). Detection of autumn leaf phenology and color brightness from repeat photography: Accurate, robust, and sensitive indexes and modeling under unstable field observations. *Ecological Indicators*, 106. [HTPPs://doi.org/10.1016/j.ecolind.2019.105482](https://doi.org/10.1016/j.ecolind.2019.105482)
- Kramer, D. M., Johnson, G., Kiirats, O., & Edwards, G. E. (2004). New fluorescence parameters for the determination of Q A redox state and excitation energy fluxes. In *Photosynthesis Research* (Vol. 79).
- Kromdijk, J., & Walter, J. (2023). *Relaxing non-photochemical quenching (NPQ) to improve photosynthesis in crops* (pp. 113–130). [HTPPs://doi.org/10.19103/as.2022.0119.09](https://doi.org/10.19103/as.2022.0119.09)
- Kubota-Kawai, H., Mutoh, R., Shinmura, K., Sétif, P., Nowaczyk, M. M., Rögner, M., Ikegami, T., Tanaka, H., & Kurisu, G. (2018). X-ray structure of an asymmetrical trimeric ferredoxin-photosystem I complex. *Nature Plants*, 4(4), 218–224. [HTPPs://doi.org/10.1038/s41477-018-0130-0](https://doi.org/10.1038/s41477-018-0130-0)
- Kuhlgert, S., Austic, G., Zegarac, R., Osei-Bonsu, I., Hoh, D., Chilvers, M. I., Roth, M. G., Bi, K., TerAvest, D., Weebadde, P., & Kramer, D. M. (2016). MultispeQ Beta: A tool for large-scale plant phenotyping connected to the open photosynQ network. *Royal Society Open Science*, 3(10). [HTPPs://doi.org/10.1098/rsos.160592](https://doi.org/10.1098/rsos.160592)
- Kurbanov, R., & Litvinov, M. (2020). Development of a gimbal for the Parrot Sequoia multispectral camera for the UAV DJI Phantom 4 Pro. *IOP Conference Series: Materials Science and Engineering*, 1001(1). [HTPPs://doi.org/10.1088/1757-899X/1001/1/012062](https://doi.org/10.1088/1757-899X/1001/1/012062)
- Ledell, E., & Poirier, S. (2020). *H2O AutoML: Scalable Automatic Machine Learning*. [HTPPs://scinet.usda.gov/user/geospatial/#tools-and-software](https://scinet.usda.gov/user/geospatial/#tools-and-software)
- Lenk, S., Dieleman, J. A., Lefebvre, V., Heuvelink, E., Magán, J. J., Palloix, A., van Eeuwijk, F. A., & Barócsi, A. (2020). Phenotyping with fast fluorescence sensors approximates yield component measurements in pepper (*Capsicum annuum* L.). *Photosynthetica*, 58(Special Issue), 622–637. [HTPPs://doi.org/10.32615/ps.2020.016](https://doi.org/10.32615/ps.2020.016)
- 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. [HTPPs://doi.org/10.1007/s40858-021-00460-2](https://doi.org/10.1007/s40858-021-00460-2)

-
- Li, H. Y., Guo, W., Liu, D., & Li, M. Q. (2018). First report of fusarium semitectum causing root rot of greenhouse pepper (*Capsicum Annuum*) in China. In *Plant Disease* (Vol. 102, Issue 10, p. 2032). American Phytopathological Society.
HTPPs://doi.org/10.1094/PDIS-11-17-1704-PDN
- Li, Y., Tao, F., Hao, Y., Tong, J., Xiao, Y., He, Z., & Reynolds, M. (2023). Variations in phenological, physiological, plant architectural and yield-related traits, their associations with grain yield and genetic basis. *Annals of Botany*.
HTPPs://doi.org/10.1093/aob/mcad003
- 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.
HTPPs://doi.org/10.1109/ACCESS.2020.2980310
- 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*, 100138. HTPPs://doi.org/10.1016/j.atech.2022.100138
- Main, R., Cho, M. A., Mathieu, R., O’Kennedy, M. M., Ramoelo, A., & Koch, S. (2011). An investigation into robust spectral indices for leaf chlorophyll estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6), 751–761.
HTPPs://doi.org/10.1016/j.isprsjprs.2011.08.001
- 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), 88–99. HTPPs://doi.org/10.1016/j.sjbs.2019.05.007
- Martinelli, F., Scalenghe, R., Davino, S., Panno, S., Scuderi, G., Ruisi, P., Villa, P., Stroppiana, D., Boschetti, M., Goulart, L. R., Davis, C. E., & Dandekar, A. M. (2014). Advanced methods of plant disease detection. A review. In *Agronomy for Sustainable Development* (Vol. 35, Issue 1, pp. 1–25). Springer-Verlag France.
HTPPs://doi.org/10.1007/s13593-014-0246-1
- Mathieu, R., Pouget, M., Cervelle, B., & Escadafal, R. (1998). Relationships between Satellite-Based Radiometric Indices Simulated Using Laboratory Reflectance Data and Typic Soil Color of an Arid Environment. *Remote Sensing of Environment*, , 17–28.
HTPPs://doi.org/doi:10.1016/s0034-4257(98)00030-3
- Matias, F. I., Caraza-Harter, M. V., & Endelman, J. B. (2020). FIELDimageR: An R package to analyze orthomosaic images from agricultural field trials. *Plant Phenome Journal*, 3(1). HTPPs://doi.org/10.1002/ppj2.20005

- Meier, U., Bleiholder, H., Buhr, L., Feller, C., Hack, H., Heß, M., Lancashire, P. D., Schnock, U., Stauß, R., van den Boom, T., Weber, E., Zwerger, P., & Peter Zwerger, C. (2009). The BBCH system to coding the phenological growth stages of plants. *Journal Für Kulturpflanzen*, 61(2), 41–52. [HTPPS://www.zuechtungskunde.de/artikel.dll/meier-et-al_OTAyMjUy.PDF](https://www.zuechtungskunde.de/artikel.dll/meier-et-al_OTAyMjUy.PDF)
- Mezenner, A., Nemmour, H., Chibani, Y., & Hafiane, A. (2022). Tomato Plant Leaf Disease Classification based on CNN features and Support Vector Machines. *2022 2nd International Conference on Advanced Electrical Engineering, ICAEE 2022*. [HTPPS://doi.org/10.1109/ICAEE53772.2022.9962070](https://doi.org/10.1109/ICAEE53772.2022.9962070)
- Miyake, C. (2020). Molecular mechanism of oxidation of p700 and suppression of ROS production in photosystem I in response to electron-sink limitations in C3 plants. In *Antioxidants* (Vol. 9, Issue 3). MDPI. [HTPPS://doi.org/10.3390/antiox9030230](https://doi.org/10.3390/antiox9030230)
- Miyake, C., Amako, K., Shiraishi, N., & Sugimoto, T. (2009). Acclimation of tobacco leaves to high light intensity drives the plastoquinone oxidation system-relationship among the fraction of open PSII centers, non-photochemical quenching of Chl Fluorescence and the maximum quantum yield of PSII in the dark. *Plant and Cell Physiology*, 50(4), 730–743. [HTPPS://doi.org/10.1093/pcp/pcp032](https://doi.org/10.1093/pcp/pcp032)
- Moradi, S., Bokani, A., & Hassan, J. (2022). UAV-based Smart Agriculture: a Review of UAV Sensing and Applications. *2022 32nd International Telecommunication Networks and Applications Conference, ITNAC 2022*, 181–184. [HTPPS://doi.org/10.1109/ITNAC55475.2022.9998411](https://doi.org/10.1109/ITNAC55475.2022.9998411)
- Morellato, L. P. C., Alberton, B., Alvarado, S. T., Borges, B., Buisson, E., Camargo, M. G. G., Cancian, L. F., Carstensen, D. W., Escobar, D. F. E., Leite, P. T. P., Mendoza, I., Rocha, N. M. W. B., Soares, N. C., Silva, T. S. F., Staggemeier, V. G., Streher, A. S., Vargas, B. C., & Peres, C. A. (2016). Linking plant phenology to conservation biology. In *Biological Conservation* (Vol. 195, pp. 60–72). Elsevier Ltd. [HTPPS://doi.org/10.1016/j.biocon.2015.12.033](https://doi.org/10.1016/j.biocon.2015.12.033)
- Murchie, E. H., & Lawson, T. (2013). Chlorophyll fluorescence analysis: A guide to good practice and understanding some new applications. In *Journal of Experimental Botany* (Vol. 64, Issue 13, pp. 3983–3998). [HTPPS://doi.org/10.1093/jxb/ert208](https://doi.org/10.1093/jxb/ert208)
- Nabwire, S., Suh, H. K., Kim, M. S., Baek, I., & Cho, B. K. (2021). Review: Application of artificial intelligence in phenomics. In *Sensors* (Vol. 21, Issue 13). MDPI AG. [HTPPS://doi.org/10.3390/s21134363](https://doi.org/10.3390/s21134363)
- Naser, M. Z., & Alavi, A. H. (2021). Error Metrics and Performance Fitness Indicators for Artificial Intelligence and Machine Learning in Engineering and Sciences. *Architecture, Structures and Construction*. [HTPPS://doi.org/10.1007/s44150-021-00015-8](https://doi.org/10.1007/s44150-021-00015-8)

-
- Noon, S. K., Amjad, M., Qureshi, M. A., & Mannan, A. (2020). Use of deep learning techniques for identification of plant leaf stresses: A review. *Sustainable Computing: Informatics and Systems*, 28. [HTPPs://doi.org/10.1016/j.suscom.2020.100443](https://doi.org/10.1016/j.suscom.2020.100443)
- Nur Anisa, M., Rokhmatuloh, & Hernina, R. (2020). UAV application to estimate oil palm trees health using Visible Atmospherically Resistant Index (VARI) (Case study of Cikabayan Research Farm, Bogor City). *E3S Web of Conferences*, 211. [HTPPs://doi.org/10.1051/e3sconf/202021105001](https://doi.org/10.1051/e3sconf/202021105001)
- Nurcahyani, E., Sholekhah, Sumardi, & Qudus, H. I. (2021). Analysis of Total Carbohydrate and Chlorophyll Content of the Orchid Plantlet [*Phalaenopsis amabilis* (L.) Bl.] Resistant Fusarium Wilt Disease. *Journal of Physics: Conference Series*, 1751(1). [HTPPs://doi.org/10.1088/1742-6596/1751/1/012061](https://doi.org/10.1088/1742-6596/1751/1/012061)
- Ortiz, J. C. M., Carvajal, L. M. H., & Fernandez, V. B. (2019). Detection of significant wavelengths for identifying and classifying Fusarium oxysporum during the incubation period and water stress in *Solanum lycopersicum* plants using reflectance spectroscopy. *Journal of Plant Protection Research*, 59(2). [HTPPs://doi.org/10.24425/jppr.2019.129290](https://doi.org/10.24425/jppr.2019.129290)
- Panova, G. G., Heißner, A., Grosch, R., & Kläring, H. P. (2012). Pythium aphanidermatum May Reduce Cucumber Growth without Affecting Leaf Photosynthesis. *Journal of Phytopathology*, 160(1), 37–40. [HTPPs://doi.org/10.1111/j.1439-0434.2011.01849.x](https://doi.org/10.1111/j.1439-0434.2011.01849.x)
- Pérez-Gutiérrez, A., Garruña, R., Vázquez, P., Latournerie-Moreno, L., Andrade, J. L., & Us-Santamaría, R. (2017). Growth, phenology and chlorophyll fluorescence of habanero pepper (*Capsicum chinense* Jacq.) under water stress conditions. *Acta Agronómica*, 66(2). [HTPPs://doi.org/10.15446/acag.v66n2.55897](https://doi.org/10.15446/acag.v66n2.55897)
- Pramanik, K., Mohapatra, P. P., Pradhan, J., Acharya, L. K., & Jena, C. (2020). Factors Influencing Performance of Capsicum under Protected Cultivation: A Review. *International Journal of Environment and Climate Change*, 572–588. [HTPPs://doi.org/10.9734/ijecc/2020/v10i1230339](https://doi.org/10.9734/ijecc/2020/v10i1230339)
- Pugh, N. A., Han, X., Collins, S. D., Thomasson, J. A., Cope, D., Chang, A., Jung, J., Isakeit, T. S., Prom, L. K., Carvalho, G., Gates, I. T., Vree, A., Bagnall, G. C., & Rooney, W. L. (2018). Estimation of plant health in a sorghum field infected with anthracnose using a fixed-wing unmanned aerial system. *Journal of Crop Improvement*, 32(6), 861–877. [HTPPs://doi.org/10.1080/15427528.2018.1535462](https://doi.org/10.1080/15427528.2018.1535462)
- Qu, C., Boubin, J., Gafurov, D., Zhou, J., Aloysius, N., Nguyen, H., & Calyam, P. (2022). UAV Swarms in Smart Agriculture: Experiences and Opportunities. *2022 IEEE 18th International Conference on E-Science (e-Science)*, 148–158. [HTPPs://doi.org/10.1109/eScience55777.2022.00029](https://doi.org/10.1109/eScience55777.2022.00029)

- Rahaman, M. M., Ahsan, M. A., & Chen, M. (2019). Data-mining Techniques for Image-based Plant Phenotypic Traits Identification and Classification. *Scientific Reports*, 9(1). [HTPPs://doi.org/10.1038/s41598-019-55609-6](https://doi.org/10.1038/s41598-019-55609-6)
- Ramchiary, N., & Chittaranjan, K. (2019). *Compendium of Plant Genomes The Capsicum Genome* (N. Ramchiary & K. Chittaranjan, Eds.; 2019th ed.). Springer International Publishing. [HTPP://www.springer.com/series/11805](http://www.springer.com/series/11805)
- Ramírez-Gil, J. G., Henao-Rojas, J. C., & Morales-Osorio, J. G. (2020). Mitigation of the adverse effects of the El Niño (El Niño, La Niña) southern oscillation (ENSO) phenomenon and the most important diseases in Avocado cv. hass crops. *Plants*, 9(6). [HTPPs://doi.org/10.3390/plants9060790](https://doi.org/10.3390/plants9060790)
- Ramírez-Gil, J. G., & Morales-Osorio, J. G. (2020). Development and validation of severity scales of avocado wilt complex caused by *Phytophthora cinnamomi*, *Verticillium dahliae* and hypoxia/anoxia disorder and their physiological responses in avocado plants. *Agronomia Colombiana*, 38(1), 12–27. [HTPPs://doi.org/10.15446/agron.colomb.v38n1.78527](https://doi.org/10.15446/agron.colomb.v38n1.78527)
- Ravichandran, N. K., Wijesinghe, R. E., Shirazi, M. F., Park, K., Lee, S. Y., Jung, H. Y., Jeon, M., & Kim, J. (2016). In vivo monitoring on growth and spread of gray leaf spot disease in capsicum annum leaf using spectral domain optical coherence tomography. *Journal of Spectroscopy*, 2016. [HTPPs://doi.org/10.1155/2016/1093734](https://doi.org/10.1155/2016/1093734)
- Rekah, Y., Shtienberg, D., & Katan, J. (1999). *Spatial Distribution and Temporal Development of Fusarium Crown and Root Rot of Tomato and Pathogen Dissemination in Field Soil* (Vol. 89, Issue 9).
- Resti, Y., Saraswati, D. H., Zayanti, D. A., & Eliyati, N. (2022). CLASSIFICATION OF DISEASES AND PESTS OF MAIZE USING MULTINOMIAL LOGISTIC REGRESSION BASED ON RESAMPLING TECHNIQUE OF K-FOLD CROSS-VALIDATION. *Indonesian Journal of Engineering and Science*, 3(3), 069–076. [HTPPs://doi.org/10.51630/ijes.v3i3.83](https://doi.org/10.51630/ijes.v3i3.83)
- Richardson, A. J., & Wiegand, C. L. (1977). Distinguishing Vegetation from Soil Background Information* A gray mapping technique allows delineation of any Landsat scene into vegetative cover stages, degrees of soil brightness, and water. *Photogrammetric Engineering and Remote Sensing*, 43(12), 1541–1552.
- Ripley, B. D. (2007). *Pattern Recognition via Neural Networks*. Cambridge university press.
- Robles-Zazueta, C. A., Pinto, F., Molero, G., Foulkes, M. J., Reynolds, M. P., & Murchie, E. H. (2022). Prediction of Photosynthetic, Biophysical, and Biochemical Traits in Wheat

-
- Canopies to Reduce the Phenotyping Bottleneck. *Frontiers in Plant Science*, 13. [HTPPs://doi.org/10.3389/fpls.2022.828451](https://doi.org/10.3389/fpls.2022.828451)
- Rodrigues, L., Magalhães, S. A., da Silva, D. Q., dos Santos, F. N., & Cunha, M. (2023). Computer Vision and Deep Learning as Tools for Leveraging Dynamic Phenological Classification in Vegetable Crops. *Agronomy*, 13(2). [HTPPs://doi.org/10.3390/agronomy13020463](https://doi.org/10.3390/agronomy13020463)
- 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. [HTPPs://doi.org/10.1016/j.compag.2021.106061](https://doi.org/10.1016/j.compag.2021.106061)
- Rojas, C. M., Senthil-Kumar, M., Tzin, V., & Mysore, K. S. (2014). Regulation of primary plant metabolism during plant-pathogen interactions and its contribution to plant defense. In *Frontiers in Plant Science* (Vol. 5, Issue FEB). Frontiers Research Foundation. [HTPPs://doi.org/10.3389/fpls.2014.00017](https://doi.org/10.3389/fpls.2014.00017)
- Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W., & Harlan, J. C. (1974). *I OF NATURAL VEGETATION*.
- Salaria, P., Jain, S., Bhardwaj, R. D., Rani, R., & Jhanji, S. (2023). Physiological and biochemical responses of chilli pepper (*Capsicum annuum* L.) to sudden wilt syndrome. *Physiological and Molecular Plant Pathology*, 126. [HTPPs://doi.org/10.1016/j.pmpp.2023.102038](https://doi.org/10.1016/j.pmpp.2023.102038)
- Saravia, D., Salazar, W., Valqui-Valqui, L., Quille-Mamani, J., Porrás-Jorge, R., Corredor, F. A., Barboza, E., Vásquez, H. V., Casas Diaz, A. V., & Arbizu, C. I. (2022). Yield Predictions of Four Hybrids of Maize (*Zea mays*) Using Multispectral Images Obtained from UAV in the Coast of Peru. *Agronomy*, 12(11). [HTPPs://doi.org/10.3390/agronomy12112630](https://doi.org/10.3390/agronomy12112630)
- Sarkar, S., Cazenave, A. B., Oakes, J., McCall, D., Thomason, W., Abbott, L., & Balota, M. (2021). Aerial high-throughput phenotyping of peanut leaf area index and lateral growth. *Scientific Reports*, 11(1). [HTPPs://doi.org/10.1038/s41598-021-00936-w](https://doi.org/10.1038/s41598-021-00936-w)
- Schneider, M., Vedder, L., Oyiga, B. C., Mathew, B., Schoof, H., Léon, J., & Naz, A. A. (2022). Transcriptome profiling of barley and tomato shoot and root meristems unravels physiological variations underlying photoperiodic sensitivity. *PLoS ONE*, 17(9 September). [HTPPs://doi.org/10.1371/journal.pone.0265981](https://doi.org/10.1371/journal.pone.0265981)
- Shaheen, N., Khan, U. M., Azhar, M. T., Tan, D. K. Y., Atif, R. M., Israr, M., Yang, S. H., Chung, G., & Rana, I. A. (2021). Genetics and genomics of fusarium wilt of chilies: A review. In *Agronomy* (Vol. 11, Issue 11). MDPI. [HTPPs://doi.org/10.3390/agronomy11112162](https://doi.org/10.3390/agronomy11112162)

- Shakoor, N., Lee, S., & Mockler, T. C. (2017). High throughput phenotyping to accelerate crop breeding and monitoring of diseases in the field. In *Current Opinion in Plant Biology* (Vol. 38, pp. 184–192). Elsevier Ltd. [HTPPs://doi.org/10.1016/j.pbi.2017.05.006](https://doi.org/10.1016/j.pbi.2017.05.006)
- Sharma, L. K., Bu, H., Denton, A., & Franzen, D. W. (2015). Active-optical sensors using red NDVI compared to red edge NDVI for prediction of corn grain yield in north Dakota, U.S.A. *Sensors (Switzerland)*, *15*(11), 27832–27853. [HTPPs://doi.org/10.3390/s151127832](https://doi.org/10.3390/s151127832)
- Singh, A., Ganapathysubramanian, B., Singh, A. K., & Sarkar, S. (2016). Machine Learning for High-Throughput Stress Phenotyping in Plants. In *Trends in Plant Science* (Vol. 21, Issue 2, pp. 110–124). Elsevier Ltd. [HTPPs://doi.org/10.1016/j.tplants.2015.10.015](https://doi.org/10.1016/j.tplants.2015.10.015)
- Singh, A., Jones, S., Ganapathysubramanian, B., Sarkar, S., Mueller, D., Sandhu, K., & Nagasubramanian, K. (2021). Challenges and Opportunities in Machine-Augmented Plant Stress Phenotyping. In *Trends in Plant Science* (Vol. 26, Issue 1, pp. 53–69). Elsevier Ltd. [HTPPs://doi.org/10.1016/j.tplants.2020.07.010](https://doi.org/10.1016/j.tplants.2020.07.010)
- Singh, A. K., Ganapathysubramanian, B., Sarkar, S., & Singh, A. (2018). Deep Learning for Plant Stress Phenotyping: Trends and Future Perspectives. In *Trends in Plant Science* (Vol. 23, Issue 10, pp. 883–898). Elsevier Ltd. [HTPPs://doi.org/10.1016/j.tplants.2018.07.004](https://doi.org/10.1016/j.tplants.2018.07.004)
- 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. [HTPPs://doi.org/10.1016/j.aiaa.2020.10.002](https://doi.org/10.1016/j.aiaa.2020.10.002)
- Sosa-Herrera, J. A., Alvarez-Jarquín, N., Cid-García, N. M., López-Araujo, D. J., & Vallejo-Pérez, M. R. (2022). Automated Health Estimation of Capsicum annum L. Crops by Means of Deep Learning and RGB Aerial Images. *Remote Sensing*, *14*(19). [HTPPs://doi.org/10.3390/rs14194943](https://doi.org/10.3390/rs14194943)
- Sosa-Herrera, J. A., Vallejo-Pérez, M. R., Álvarez-Jarquín, N., Cid-García, N. M., & López-Araujo, D. J. (2019). Geographic object-based analysis of airborne multispectral images for health assessment of Capsicum annum L. Crops. *Sensors (Switzerland)*, *19*(21). [HTPPs://doi.org/10.3390/s19214817](https://doi.org/10.3390/s19214817)
- Srikanth, D., Rekha, G. K., Lakshmi, A. P., & Vimatha, P. (2019). Impact of Climate Change in Capsicum Production: A Review. *Current Journal of Applied Science and Technology*, 1–5. [HTPPs://doi.org/10.9734/cjast/2019/v33i330075](https://doi.org/10.9734/cjast/2019/v33i330075)

-
- Srivastav, A. L., Dubei, A. K., Kumar, A., Narang, S. K., & Khan, M. A. (Eds.). (2022). *Visualization Techniques for Climate Change with Machine Learning and Artificial Intelligence*. Elsevier.
- Srivastava, A. K., Safaei, N., Khaki, S., Lopez, G., Zeng, W., Ewert, F., Gaiser, T., & Rahimi, J. (2022). Winter wheat yield prediction using convolutional neural networks from environmental and phenological data. *Scientific Reports*, *12*(1). [HTPPs://doi.org/10.1038/s41598-022-06249-w](https://doi.org/10.1038/s41598-022-06249-w)
- Stanton, C., Starek, M. J., Elliott, N., Brewer, M., Maeda, M. M., & Chu, T. (2017). Unmanned aircraft system-derived crop height and normalized difference vegetation index metrics for sorghum yield and aphid stress assessment. *Journal of Applied Remote Sensing*, *11*(2), 026035. [HTPPs://doi.org/10.1117/1.jrs.11.026035](https://doi.org/10.1117/1.jrs.11.026035)
- Stemkovski, M., Bell, J. R., Ellwood, E. R., Inouye, B. D., Kobori, H., Lee, S. D., Lloyd-Evans, T., Primack, R. B., Templ, B., & Pearse, W. D. (2023). Disorder or a new order: How climate change affects phenological variability. *Ecology*, *104*(1). [HTPPs://doi.org/10.1002/ecy.3846](https://doi.org/10.1002/ecy.3846)
- Sujatha, R., Chatterjee, J. M., Jhanjhi, N. Z., & Brohi, S. N. (2021). Performance of deep learning vs machine learning in plant leaf disease detection. *Microprocessors and Microsystems*, *80*. [HTPPs://doi.org/10.1016/j.micpro.2020.103615](https://doi.org/10.1016/j.micpro.2020.103615)
- Tang, R., Supit, I., Hutjes, R., Zhang, F., Wang, X., Chen, X., Zhang, F., & Chen, X. (2023). Modelling growth of chili pepper (*Capsicum annuum* L.) with the WOFOST model. *Agricultural Systems*, *209*, 103688. [HTPPs://doi.org/10.1016/j.agry.2023.103688](https://doi.org/10.1016/j.agry.2023.103688)
- Tanner, F., Tonn, S., de Wit, J., Van den Ackerveken, G., Berger, B., & Plett, D. (2022). Sensor-based phenotyping of above-ground plant-pathogen interactions. In *Plant Methods* (Vol. 18, Issue 1). BioMed Central Ltd. [HTPPs://doi.org/10.1186/s13007-022-00853-7](https://doi.org/10.1186/s13007-022-00853-7)
- Tayade, R., Yoon, J., Lay, L., Khan, A. L., Yoon, Y., & Kim, Y. (2022). Utilization of Spectral Indices for High-Throughput Phenotyping. In *Plants* (Vol. 11, Issue 13). MDPI. [HTPPs://doi.org/10.3390/plants11131712](https://doi.org/10.3390/plants11131712)
- Thakur, P. S., Khanna, P., Sheorey, T., & Ojha, A. (2022). Trends in vision-based machine learning techniques for plant disease identification: A systematic review. In *Expert Systems with Applications* (Vol. 208). Elsevier Ltd. [HTPPs://doi.org/10.1016/j.eswa.2022.118117](https://doi.org/10.1016/j.eswa.2022.118117)
- Tietz, S., Hall, C. C., Cruz, J. A., & Kramer, D. M. (2017). NPQ(T): a chlorophyll fluorescence parameter for rapid estimation and imaging of non-photochemical

quenching of excitons in photosystem-II-associated antenna complexes. *Plant Cell and Environment*, 40(8), 1243–1255. [HTPPs://doi.org/10.1111/pce.12924](https://doi.org/10.1111/pce.12924)

Truong, A., Walters, A., Goodsitt, J., Hines, K., Bruss, C. B., & Farivar, R. (2019). Towards automated machine learning: Evaluation and comparison of AutoML approaches and tools. *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI, 2019-November*, 1471–1479. [HTPPs://doi.org/10.1109/ICTAI.2019.00209](https://doi.org/10.1109/ICTAI.2019.00209)

Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [HTPPs://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)

Ubaidillah, A., Rochman, E. M. S., Fatah, D. A., & Rachmad, A. (2022). Classification of Corn Diseases using Random Forest, Neural Network, and Naive Bayes Methods. *Journal of Physics: Conference Series*, 2406(1). [HTPPs://doi.org/10.1088/1742-6596/2406/1/012023](https://doi.org/10.1088/1742-6596/2406/1/012023)

Uddin, M. N., & Gaskins, J. T. (2023). Shared Bayesian variable shrinkage in multinomial logistic regression. *Computational Statistics and Data Analysis*, 177. [HTPPs://doi.org/10.1016/j.csda.2022.107568](https://doi.org/10.1016/j.csda.2022.107568)

Velarde-Félix, S., Garzón-Tiznado, J. A., Hernández-Verdugo, S., López-Orona, C. A., & Retes-Manjarrez, J. E. (2018). Occurrence of *Fusarium oxysporum* causing wilt on pepper in Mexico. *Canadian Journal of Plant Pathology*, 40(2), 238–247. [HTPPs://doi.org/10.1080/07060661.2017.1420693](https://doi.org/10.1080/07060661.2017.1420693)

Velasco Belalcazar, M. lucia. (2016). *CARACTERIZACIÓN DE BACTERIAS ANTAGÓNICAS A Fusarium sp, ASOCIADAS A Capsicum frutescens EN GUACARÍ Y BOLIVAR, VALLE DEL CAUCA*. Universidad Nacional de Colombia sede Palmira.

Vincini, M., Frazzi, E., & D'Alessio, P. (2008). A broad-band leaf chlorophyll vegetation index at the canopy scale. *Precision Agriculture*, 9(5), 303–319. [HTPPs://doi.org/10.1007/s11119-008-9075-z](https://doi.org/10.1007/s11119-008-9075-z)

Wang, C., Wu, Y., Hu, Q., Hu, J., Chen, Y., Lin, S., & Xie, Q. (2022). Comparison of Vegetation Phenology Derived from Solar-Induced Chlorophyll Fluorescence and Enhanced Vegetation Index, and Their Relationship with Climatic Limitations. *Remote Sensing*, 14(13). [HTPPs://doi.org/10.3390/rs14133018](https://doi.org/10.3390/rs14133018)

WANG, F., HUANG, J., TANG, Y., & WANG, X. (2007). New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. *Rice Science*, 14(3), 195–203. [HTPPs://doi.org/10.1016/s1672-6308\(07\)60027-4](https://doi.org/10.1016/s1672-6308(07)60027-4)

-
- Wang, Y., Tan, S., Jia, X., Qi, L., Liu, S., Lu, H., Wang, C., Liu, W., Zhao, X., He, L., Chen, J., Yang, C., Wang, X., Chen, J., Qin, Y., Yu, J., & Ma, X. (2023). Estimating Relative Chlorophyll Content in Rice Leaves Using Unmanned Aerial Vehicle Multi-Spectral Images and Spectral–Textural Analysis. *Agronomy*, 13(6), 1541. [HTPPs://doi.org/10.3390/agronomy13061541](https://doi.org/10.3390/agronomy13061541)
- Wang, Z., Li, G., Sun, H., Ma, L., Guo, Y., Zhao, Z., Gao, H., & Mei, L. (2018). Effects of drought stress on photosynthesis and photosynthetic electron transport chain in young apple tree leaves. *Biology Open*, 7(11). [HTPPs://doi.org/10.1242/bio.035279](https://doi.org/10.1242/bio.035279)
- Wever, M., Tornede, A., Mohr, F., & Hullermeier, E. (2021). AutoML for Multi-Label Classification: Overview and Empirical Evaluation. In *IEEE Transactions on Pattern Analysis and Machine Intelligence* (Vol. 43, Issue 9, pp. 3037–3054). IEEE Computer Society. [HTPPs://doi.org/10.1109/TPAMI.2021.3051276](https://doi.org/10.1109/TPAMI.2021.3051276)
- Worrall, G., Judge, J., Boote, K., & Rangarajan, A. (2022). In-Season Crop Phenology using Remote Sensing and Model-guided Machine Learning. *Agronomy Journal*. [HTPPs://doi.org/10.1002/agj2.21230](https://doi.org/10.1002/agj2.21230)
- Xiao, Y., Dong, Y., Huang, W., Liu, L., & Ma, H. (2021). Wheat fusarium head blight detection using uav-based spectral and texture features in optimal window size. *Remote Sensing*, 13(13). [HTPPs://doi.org/10.3390/rs13132437](https://doi.org/10.3390/rs13132437)
- Xie, C., & Yang, C. (2020). A review on plant high-throughput phenotyping traits using UAV-based sensors. In *Computers and Electronics in Agriculture* (Vol. 178). Elsevier B.V. [HTPPs://doi.org/10.1016/j.compag.2020.105731](https://doi.org/10.1016/j.compag.2020.105731)
- Yalcin, H. (2015). Phenology Monitoring Of Agricultural Plants Using Texture Analysis. *Cuarta Conferencia Internacional Sobre Agro-Geoinformática (Agro-Geoinformatics)*, 338–342. [HTPPs://doi.org/doi:10.1109/Agro-Geoinformatics.2015.7248114](https://doi.org/doi:10.1109/Agro-Geoinformatics.2015.7248114)
- Yalcin, H. (2018). Phenology Recognition using Deep Learning. *Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*, 1–5. [HTPPs://doi.org/doi:10.1109/EBBT.2018.8391423](https://doi.org/doi:10.1109/EBBT.2018.8391423)
- Yamamoto, H., Cheuk, A., Shearman, J., Nixon, P. J., Meier, T., & Shikanai, T. (2023). Impact of engineering the ATP synthase rotor ring on photosynthesis in tobacco chloroplasts. *Plant Physiology*, 192(2), 1221–1233. [HTPPs://doi.org/10.1093/plphys/kiad043](https://doi.org/10.1093/plphys/kiad043)
- Yang, Q., Shi, L., Han, J., Yu, J., & Huang, K. (2020). A near real-time deep learning approach for detecting rice phenology based on UAV images. *Agricultural and Forest Meteorology*, 287. [HTPPs://doi.org/10.1016/j.agrformet.2020.107938](https://doi.org/10.1016/j.agrformet.2020.107938)

- Yang, W., Feng, H., Zhang, X., Zhang, J., Doonan, J. H., Batchelor, W. D., Xiong, L., & Yan, J. (2020). Crop Phenomics and High-Throughput Phenotyping: Past Decades, Current Challenges, and Future Perspectives. In *Molecular Plant* (Vol. 13, Issue 2, pp. 187–214). Cell Press. [HTPPs://doi.org/10.1016/j.molp.2020.01.008](https://doi.org/10.1016/j.molp.2020.01.008)
- Ye, H., Huang, W., Huang, S., Cui, B., Dong, Y., Guo, A., Ren, Y., & Jin, Y. (2020). Recognition of banana Fusarium wilt based on UAV remote sensing. *Remote Sensing*, *12*(6). [HTPPs://doi.org/10.3390/rs12060938](https://doi.org/10.3390/rs12060938)
- Ye, H., Huang, W., Huang, S., Nie, C., Guo, J., & Cui, B. (2021). Application of UAV Remote Sensing in Monitoring Banana Fusarium Wilt. In M. Marghany (Ed.), *Recent Remote Sensing Sensor Applications*. [HTPPs://doi.org/10.5772/intechopen.99950](https://doi.org/10.5772/intechopen.99950)
- Zarco-Tejada, P. J., Berjón, A., López-Lozano, R., Miller, J. R., Martín, P., Cachorro, V., González, M. R., & De Frutos, A. (2005). Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sensing of Environment*, *99*(3), 271–287. [HTPPs://doi.org/10.1016/j.rse.2005.09.002](https://doi.org/10.1016/j.rse.2005.09.002)
- Zeng, L., Yang, X., & Zhou, J. (2020). The xanthophyll cycle as an early pathogenic target to deregulate guard cells during *Sclerotinia sclerotiorum* infection. *Plant Signaling and Behavior*, *15*(1). [HTPPs://doi.org/10.1080/15592324.2019.1691704](https://doi.org/10.1080/15592324.2019.1691704)
- Zhang, H., Wang, L., Jin, X., Bian, L., & Ge, Y. (2023). High-throughput phenotyping of plant leaf morphological, physiological, and biochemical traits on multiple scales using optical sensing. *The Crop Journal*. [HTPPs://doi.org/10.1016/j.cj.2023.04.014](https://doi.org/10.1016/j.cj.2023.04.014)
- Zhang, S., Li, X., Ba, Y., Lyu, X., Zhang, M., & Li, M. (2022). Banana Fusarium Wilt Disease Detection by Supervised and Unsupervised Methods from UAV-Based Multispectral Imagery. *Remote Sensing*, *14*(5). [HTPPs://doi.org/10.3390/rs14051231](https://doi.org/10.3390/rs14051231)
- Zhao, X., Zhang, J., Tang, A., Yu, Y., Yan, L., Chen, D., & Yuan, L. (2022). The Stress Detection and Segmentation Strategy in Tea Plant at Canopy Level. *Frontiers in Plant Science*, *13*. [HTPPs://doi.org/10.3389/fpls.2022.949054](https://doi.org/10.3389/fpls.2022.949054)
- Zhou, J., Zeng, L., Liu, J., & Xing, D. (2015). Manipulation of the Xanthophyll Cycle Increases Plant Susceptibility to *Sclerotinia sclerotiorum*. *PLoS Pathogens*, *11*(5). [HTPPs://doi.org/10.1371/journal.ppat.1004878](https://doi.org/10.1371/journal.ppat.1004878)
- Zhou, M., Zheng, H., He, C., Liu, P., Awan, G. M., Wang, X., Cheng, T., Zhu, Y., Cao, W., & Yao, X. (2023). Wheat phenology detection with the methodology of classification based on the time-series UAV images. *Field Crops Research*, *292*. [HTPPs://doi.org/10.1016/j.fcr.2022.108798](https://doi.org/10.1016/j.fcr.2022.108798)

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.

[HTPPs://doi.org/10.1016/j.jag.2018.10.012](https://doi.org/10.1016/j.jag.2018.10.012)

Zhu, Q., Chen, L., Chen, T., Xu, Q., He, T., Wang, Y., Deng, X., Zhang, S., Pan, Y., & Jin, A. (2021). Integrated transcriptome and metabolome analyses of biochar-induced pathways in response to *Fusarium* wilt infestation in pepper. *Genomics*, 113(4), 2085–2095. [HTPPs://doi.org/10.1016/j.ygeno.2021.04.031](https://doi.org/10.1016/j.ygeno.2021.04.031)

3. Conclusiones y recomendaciones

3.1 Conclusiones

Podemos concluir que se ha logrado exitosamente la implementación de herramientas de detección indirecta de parámetros fitosanitarios, fenológicos y productivos en el cultivo de ají Cayenne mediante el uso de plataformas de fenotipado e inteligencia artificial. Para esto, desarrollamos una metodología efectiva para la detección indirecta de parámetros fitosanitarios, y la estimación precisa de parámetros fenológicos y productivos del cultivo mediante el uso de tecnologías de fenotipado de alto rendimiento y herramientas de análisis de datos basadas en inteligencia artificial. Estos hallazgos subrayan el innegable potencial transformador del HTPP en combinación con técnicas de IA en el campo de la agricultura. La habilidad para identificar rasgos fenotípicos que permiten detectar con precisión enfermedades como la MV, así como para estimar de manera fiable la fenología y el número de frutos, ofrece una vía hacia una gestión de cultivos más eficiente y sostenible. La integración de la IA en estos procesos no solo amplifica la precisión, sino que también agiliza la toma de decisiones agrícolas cruciales. En última instancia, esta investigación fusiona la innovación tecnológica con el área agrícola, ilustrando cómo la sinergia entre ambos campos puede generar un impacto positivo tanto en la seguridad alimentaria global como en la protección de los cultivos. Las

técnicas de IA y el HTPP aportan enfoques valiosos para abordar los desafíos en la agricultura y asegurar un suministro de alimentos sostenible en un mundo en constante evolución.

3.2 Recomendaciones

Implementar diferentes técnicas de inteligencia artificial en la detección rápida y económica de enfermedades: Considerando los resultados prometedores en la detección indirecta de la enfermedad del marchitamiento vascular en el cultivo de ají Cayenne, se recomienda incorporar la inteligencia artificial en los sistemas de monitoreo agrícola para detectar y prevenir enfermedades. Esto ayudará a los agricultores a tomar medidas rápidas y efectivas para proteger sus cultivos y evitar pérdidas económicas.

Desarrollar herramientas de estimación de producción: Dado que la inteligencia artificial ha demostrado una notable precisión en la estimación de la fenología y el número de frutos en el cultivo de ají Cayenne, se sugiere la creación de herramientas específicas basadas en esta tecnología. Estas herramientas pueden ayudar a los agricultores a planificar la producción, gestionar sus recursos de manera más eficiente y tomar decisiones informadas en la comercialización de sus productos.

Investigar otros rasgos fotosintéticos relevantes: Los estudios han identificado varios rasgos fotosintéticos cruciales para la detección de enfermedades y la estimación de la producción en el ají Cayenne. Se recomienda continuar investigando y evaluando otros posibles rasgos fotosintéticos que puedan tener un impacto significativo en estas aplicaciones. Cuanta más información se obtenga sobre estos rasgos, más precisa será la inteligencia artificial en sus predicciones.

Validación en diferentes condiciones agrícolas: Es esencial validar los resultados de las técnicas de inteligencia artificial en diferentes condiciones agrícolas y regiones geográficas. Los cultivos pueden verse afectados por diversas variables ambientales, por lo que es importante evaluar cómo la inteligencia artificial se adapta a diferentes escenarios antes de su implementación generalizada.

Referencias

- Bannari, A., Morin, D., Bonn, F., & Huete, A. R. (1995). A review of vegetation indices. *Remote Sensing Reviews*, 13(1–2), 95–120. [HTPPs://doi.org/10.1080/02757259509532298](https://doi.org/10.1080/02757259509532298)
- Boiarskii, B. (2019). Comparison of NDVI and NDRE Indices to Detect Differences in Vegetation and Chlorophyll Content. *JOURNAL OF MECHANICS OF CONTINUA AND MATHEMATICAL SCIENCES*, spl1(4). [HTPPs://doi.org/10.26782/jmcms.spl.4/2019.11.00003](https://doi.org/10.26782/jmcms.spl.4/2019.11.00003)
- Broge, N. H., & Leblanc, E. (2000). Comparing prediction power and stability of broadband and hyperspectral vegetation indices for estimation of green leaf area index and canopy chlorophyll density. *Remote Sensing of Environment*. www.elsevier.com/locate/rse
- Crippen, R. E. (1990). Calculating the Vegetation Index Faster. *Remote Sensing of Environment*, 34, 71–73. [HTPPs://doi.org/doi:10.1016/0034-4257\(90\)90085-z](https://doi.org/doi:10.1016/0034-4257(90)90085-z)
- Eng, L. S., Ismail, R., Hashim, W., & Baharum, A. (2019). The use of VARI, GLI, And VGreen formulas in detecting vegetation in aerial images. *International Journal of Technology*, 10(7), 1385–1394. [HTPPs://doi.org/10.14716/ijtech.v10i7.3275](https://doi.org/10.14716/ijtech.v10i7.3275)
- Escadafal, R. (1994). SOIL SPECTRAL PROPERTIES AND THEIR RELATIONSHIPS WITH ENVIRON-MENTAL PARAMETERS-EXAMPLES FROM ARID REGIONS. In J. M. J. Hill (Ed.), *Imaging Spectrometry — a Tool for Environmental Observations: Vol. vol 4* (Springer, Dordrecht). [HTPPs://doi.org/HTPPs://doi.org/10.1007/978-0-585-33173-7_5](https://doi.org/HTPPs://doi.org/10.1007/978-0-585-33173-7_5)
- 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. In *J. Plant Physiol* (Vol. 160). [HTPP://www.urbanfischer.de/journals/jpp](http://www.urbanfischer.de/journals/jpp)
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). *Novel algorithms for remote estimation of vegetation fraction*. www.elsevier.com/locate/rse
- Gitelson, A. A., Viña, A., Ciganda, V., Rundquist, D. C., & Arkebauer, T. J. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, 32(8), 1–4. [HTPPs://doi.org/10.1029/2005GL022688](https://doi.org/10.1029/2005GL022688)
- Hazir, M. H. M., & Muda, T. M. T. (2020). The viability of remote sensing for extracting rubber smallholding information: A case study in Malaysia. *Egyptian Journal of Remote Sensing and Space Science*, 23(1), 35–47. [HTPPs://doi.org/10.1016/j.ejrs.2018.05.001](https://doi.org/10.1016/j.ejrs.2018.05.001)
- Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). *Overview of the radiometric and biophysical performance of the MODIS vegetation indices*. www.elsevier.com/locate/rse

- Main, R., Cho, M. A., Mathieu, R., O’Kennedy, M. M., Ramoelo, A., & Koch, S. (2011). An investigation into robust spectral indices for leaf chlorophyll estimation. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6), 751–761. [HTPPs://doi.org/10.1016/j.isprsjprs.2011.08.001](https://doi.org/10.1016/j.isprsjprs.2011.08.001)
- Mathieu, R., Pouget, M., Cervelle, B., & Escadafal, R. (1998). Relationships between Satellite-Based Radiometric Indices Simulated Using Laboratory Reflectance Data and Typic Soil Color of an Arid Environment. *Remote Sensing of Environment*, , 17–28. [HTPPs://doi.org/doi:10.1016/s0034-4257\(98\)00030-3](https://doi.org/10.1016/s0034-4257(98)00030-3)
- Richardson, A. J., & Wiegand, C. L. (1977). Distinguishing Vegetation from Soil Background Information* A gray mapping technique allows delineation of any Landsat scene into vegetative cover stages, degrees of soil brightness, and water. *Photogrammetric Engineering and Remote Sensing*, 43(12), 1541–1552.
- Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D. W., & Harlan, J. C. (1974). *I OF NATURAL VEGETATION*.
- Saravia, D., Salazar, W., Valqui-Valqui, L., Quille-Mamani, J., Porrás-Jorge, R., Corredor, F. A., Barboza, E., Vásquez, H. V., Casas Díaz, A. V., & Arbizu, C. I. (2022). Yield Predictions of Four Hybrids of Maize (*Zea mays*) Using Multispectral Images Obtained from UAV in the Coast of Peru. *Agronomy*, 12(11). [HTPPs://doi.org/10.3390/agronomy12112630](https://doi.org/10.3390/agronomy12112630)
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [HTPPs://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Vincini, M., Frazzi, E., & D’Alessio, P. (2008). A broad-band leaf chlorophyll vegetation index at the canopy scale. *Precision Agriculture*, 9(5), 303–319. [HTPPs://doi.org/10.1007/s11119-008-9075-z](https://doi.org/10.1007/s11119-008-9075-z)
- WANG, F., HUANG, J., TANG, Y., & WANG, X. (2007). New Vegetation Index and Its Application in Estimating Leaf Area Index of Rice. *Rice Science*, 14(3), 195–203. [HTPPs://doi.org/10.1016/s1672-6308\(07\)60027-4](https://doi.org/10.1016/s1672-6308(07)60027-4)
- Zarco-Tejada, P. J., Berjón, A., López-Lozano, R., Miller, J. R., Martín, P., Cachorro, V., González, M. R., & De Frutos, A. (2005). Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sensing of Environment*, 99(3), 271–287. [HTPPs://doi.org/10.1016/j.rse.2005.09.002](https://doi.org/10.1016/j.rse.2005.09.002)

A. Anexo A: tabla 1 de manejo integrado del sistema comercial de producción de ají

	Plaga o Enfermedad	Producto	Formulación y Concentración
Control Químico	Plagas de insectos	Aceite de semillas de neem	Formulación EC, 200g/L
		Spinetoram	Formulación SC, 60g/L
		Spiromesifen	Formulación SC, 240g/L
		<i>Bacillus thuringiensis</i>	Concentración 10×10^8 UFC
		Extractos de <i>Allium sativum</i>	-

		Extractos de Ruda graveolens	-
	Enfermedades	Azufre orgánico	Formulación SC, 500g/L
		<i>Bacillus subtilis</i> (QST 713)	Formulación SC, 1x10 ⁹ UFC/g
		Propineb	Formulación WP, 70g/Kg
		Kasugamicina	Formulación SL, 20g/L
		Oxicloruro de cobre	Formulación WP, 205g/Kg
		Myclobutanil	Formulación WP, 400g/Kg
		Dimetomorf	Formulación WP, 500g/Kg
Control	Plagas de insectos	Liberaciones del parasitoide	-
Biológico		<i>Trichogramma sp</i>	
Control	Plagas de insectos	Trampas cromáticas amarillas	Plástico
Cultural			
		Recolección de frutos afectados	-

B. Anexo B: Tabla 1 de índices de vegetación calculados a partir de las bandas

Índice	Abreviación	Fórmula	Características relacionadas	Referencias
Índice de pigmento verde azul	BGI	$\frac{Blue}{Green}$	Clorofila II, lai	(Zarco-Tejada et al., 2005)

Índice de brillo	BI	$\sqrt{\frac{Red^2 + Green^2 + Blue^2}{3}}$	Cobertura vegetal, contenido de agua	(Richardson & Wiegand, 1977)
Índice de vegetación de diferencia normalizada azul	BNDVI	$\frac{NIR - Blue}{NIR + Blue}$	-	(WANG et al., 2007)
Índice de contenido de clorofila del dosel	CCCI	$\frac{NIR - RedEdge}{NIR + RedEdge}$ $\frac{NIR - Red}{NIR + Red}$	-	(Saravia et al., 2022)
Índice de coloración	CI	$\frac{Red - Blue}{Red}$	-	(Escadafal, 1994)
Índice de clorofila verde II	CIgreen	$\frac{NIR}{Green} - 1$	Clorofila II	(Gitelson et al., 2005)
Índice rojo borde clorofila II	CIRE	Clorofila II	Clorofila II	(Gitelson et al., 2003)
Índice de clorofila RedEdge	Clrededge	$\frac{NIR}{RedEdge} - 1$	-	(Gitelson et al., 2005)
Índice de vegetación de clorofila II	CVI	$NIR \frac{Red}{Green^2}$	Clorofila II	(Vincini et al., 2008)
Índice de vegetación mejorado	EVI	$2.5 \frac{NIR - Red}{(NIR + 6Red - 7.5Blue) + 1}$	Clorofila II, biomasa, nitrógeno	(Huete et al., 2002)
NDVI verde-azul	GBNDVI	$\frac{NIR - (Green + Blue)}{NIR + (Green + Blue)}$	-	(WANG et al., 2007)
Índice de verdor de hoja	GLI	$\frac{2Green - Red - Blue}{2Green + Red + Blue}$	Clorofila II	(Eng et al., 2019)
Índice de vegetación de diferencia normalizada verde	GNDVI	$\frac{NIR - Green}{NIR + Green}$	Clorofila II, lai, nitrógeno, contenido proteína, contenido agua	((Gitelson et al., 2002)
NDVI verde-rojo	GRNDVI	$\frac{NIR - (Green + Red)}{NIR + (Green + Red)}$	-	(Main et al., 2011)
Ratio Simple NIR/G Índice de Vegetación de Ratio Verde	GRVI	$\frac{NIR}{Green}$	-	(Hazir & Muda, 2020)

Índice de tono general	H	$\arctan\left(\frac{2Red - Green - Blue}{30.5} (Green - Blue)\right)$	Color de suelo	(Escadafal, 1994)
Índice de matiz de color primario	HI	$\frac{2Red - Green - Blue}{Green - Blue}$	Color de suelo	(Escadafal, 1994)
Índice de vegetación porcentual infrarrojo	IPVI	$\frac{NIR}{\frac{NIR + Red}{2}} (NDVI + 1)$	-	(Crippen, 1990)
Índice de diferencia normalizada de borde rojo	NDRE	$\frac{NIR - RedEdge}{NIR + RedEdge}$	Clorofila II	(Boiarskii, 2019)
Índice de vegetación de diferencia normalizada	NDVI	$\frac{NIR - Red}{NIR + Red}$	Clorofila II, lai, biomasa, rendimiento	(Rouse et al., 1974)
Índice de diferencia verde rojo normalizado	NGRDI	$\frac{Green - Red}{Green + Red}$	Clorofila, biomasa, contenido de agua	(Tucker, 1979)
NDVI panorámico	PNDVI	$\frac{NIR - (Green + Red + Blue)}{NIR + (Green + Red + Blue)}$	-	(WANG et al., 2007)
NDVI azul-rojo	RBNDVI	$\frac{NIR - (Red + Blue)}{NIR + (Red + Blue)}$	-	(WANG et al., 2007)
Relación índice de vegetación	RVI	$\frac{NIR}{Red}$	Biomasa, contenido agua, nitrógeno	(Pearson & Miller, 1972)
Índice de color del suelo	SCI	$\frac{Red - Green}{Red + Green}$	Color de suelo	(Mathieu et al., 1998)
Índice de saturación de pendiente espectral	SI	$\frac{Red - Blue}{Red + Blue}$	Color de suelo	(Escadafal, 1994)
Relación simple Relación rojo/NIR Índice de vegetación	SRRed/NIR	$\frac{Red}{NIR}$	-	(Bannari et al., 1995)
Índice de vegetación triangular	TVI	$0.5(120(NIR - GREEN) - 200(RED - GREEN))$	Verde lai, clorofila II, dosel	(Broge & Leblanc, 2000)
Índice visible de resistencia atmosférica	VARI	$\frac{Green - Red}{Green + Red - Blue}$	Dosel, biomasa, clorofila II	(Eng et al., 2019)

B. Anexo B: Tabla 2. de métricas de evaluación de modelos según su origen

Modelo	Métrica	Descripción
Regresión Logística Multinomial	Matriz de Confusión	Muestra los valores de Verdaderos Positivos, Falsos Positivos, Verdaderos Negativos y Falsos Negativos.
	Precisión	Proporción de predicciones correctas.
	Índice Kappa	Evalúa la concordancia teniendo en cuenta el acuerdo por azar.
	Sensibilidad	Proporción de casos reales correctamente identificados en una clase.
	Especificidad	Proporción de casos reales excluidos correctamente de una clase.
AutoML	Media del Error por Clase	mide el promedio de errores cometidos al clasificar las diferentes clases de un conjunto de datos. Ayuda a evaluar cuán precisamente un modelo clasifica las distintas categorías y proporciona una visión general de su rendimiento en todas las clases.
	Pérdida Logarítmica (Logloss)	mide qué tan bien un modelo puede estimar la probabilidad de que un evento ocurra. Cuanto más baja sea esta métrica, mejor es el rendimiento del modelo, ya que refleja la capacidad del modelo para predecir la probabilidad correcta de los eventos.
	Error Cuadrático Medio (MSE)	mide la cantidad promedio de error al cuadrado entre las predicciones de un modelo y los valores reales. Cuanto menor sea el MSE, mejor será el rendimiento del modelo, ya que indica una menor discrepancia entre las predicciones y los datos reales.
	Raíz del Error Cuadrático Medio (RMSE)	Esta métrica calcula la raíz cuadrada de la media de los errores al cuadrado entre las predicciones del modelo y los valores reales. mide la precisión de un modelo. Cuanto menor sea el valor del RMSE, mejor será la capacidad del modelo para predecir valores reales.
	Error absoluto medio (MAE)	mide el promedio de las diferencias absolutas entre las predicciones de un modelo y los valores reales. Cuanto menor sea el MAE, mejor será la capacidad del modelo para hacer predicciones precisas

	Error cuadrático (RMSLE)	logarítmico medio	mide la precisión de las predicciones de un modelo, pero enfatiza más los errores en predicciones de valores altos. Ayuda a evaluar el rendimiento en problemas donde las diferencias entre valores reales y predichos son amplias, como el pronóstico de número de frutos
		R^2	mide cuán bien se ajusta un modelo a los datos, donde un valor cercano a 1 indica un ajuste perfecto y 0 indica un ajuste deficiente.
	desviación media (MRD)	residual	mide la diferencia promedio entre las predicciones de un modelo y los valores reales en un conjunto de datos. Cuanto menor sea la MRD, mejor será el rendimiento del modelo, ya que indica que las predicciones se ajustan de manera más cercana a los valores reales.
	Importancia de Variables	de	Se determina calculando la influencia relativa de cada variable en el proceso de modelado.
	Matriz de Confusión		Muestra el desempeño del algoritmo en términos de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos.
	Tasa de Precisión (ACC)		Mide la proporción de predicciones correctas en el conjunto de datos de prueba.
	Área Bajo la Curva ROC (AUC)		mide la capacidad de un modelo de aprendizaje automático para discriminar entre clases. Cuanto mayor sea el valor de AUC (entre 0 y 1), mejor es la capacidad del modelo para clasificar correctamente las instancias.
Deep Learning	Matriz de Confusión (Entrenamiento)		Muestra los valores de Verdaderos Positivos, Falsos Positivos, Verdaderos Negativos y Falsos Negativos en el conjunto de entrenamiento.
	Matriz de Confusión (Prueba)		Muestra los valores de Verdaderos Positivos, Falsos Positivos, Verdaderos Negativos y Falsos Negativos en el conjunto de prueba.
	Error Medio (MSE)	Cuadrático	mide la magnitud de los errores cuadrados entre las predicciones de un modelo y los valores reales. Cuanto menor sea el MSE, mejor será el ajuste del modelo a los datos, ya que indica una menor discrepancia entre las predicciones y los valores observados.
	Raíz del Cuadrático (RMSE)	Error Medio	mide la precisión de un modelo al estimar valores reales. Cuanto más bajo sea el RMSE, mejor será la capacidad del modelo para predecir valores de manera precisa

Pérdida (Logloss)	Logarítmica	mide la calidad de las predicciones de un modelo. Cuanto más baja sea la Logloss, mejor será la capacidad del modelo para predecir probabilidades correctas de clases en tareas de clasificación.
Importancia Variables	de	El método Gedeon con H2O es una técnica de regularización para seleccionar las variables más importantes en redes profundas. Utiliza la norma de Frobenius de la matriz de pesos para reducir la complejidad del modelo y mejorar su generalización. H2O facilita la implementación del método Gedeon sin necesidad de conocimientos previos en programación.

C. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fitosanitarios asociados a MV utilizando variables fotosintéticas

model_id	mean_per_class_error	logloss	rmse	mse
GBM_grid_1_AutoML_2_20230907_103106_model_14	0.060991	0.1748442	0.2128085	0.0452874
GBM_grid_1_AutoML_2_20230907_103106_model_46	0.062151	0.1983589	0.2226578	0.0495765
GBM_grid_1_AutoML_2_20230907_103106_model_26	0.062205	0.1841561	0.219088	0.0479995
GBM_3_AutoML_2_20230907_103106	0.06307	0.1760318	0.213127	0.0454231
GBM_grid_1_AutoML_2_20230907_103106_model_48	0.063461	0.1823935	0.2177304	0.0474065
GBM_grid_1_AutoML_2_20230907_103106_model_7	0.063491	0.169935	0.213334	0.0455114
GBM_grid_1_AutoML_2_20230907_103106_model_53	0.063841	0.1755602	0.2170205	0.0470979
GBM_grid_1_AutoML_2_20230907_103106_model_39	0.064291	0.180947	0.2194261	0.0481478
GBM_grid_1_AutoML_2_20230907_103106_model_20	0.064629	0.1858029	0.2181165	0.0475748
GBM_grid_1_AutoML_2_20230907_103106_model_37	0.064651	0.1785735	0.2166019	0.0469164
GBM_grid_1_AutoML_2_20230907_103106_model_23	0.064687	0.1759414	0.2153057	0.0463566
GBM_grid_1_AutoML_2_20230907_103106_model_10	0.064893	0.200203	0.2220251	0.0492951
GBM_grid_1_AutoML_2_20230907_103106_model_41	0.065094	0.1834287	0.2178998	0.0474803
GBM_grid_1_AutoML_2_20230907_103106_model_19	0.065108	0.1750347	0.2169022	0.0470465
GBM_5_AutoML_2_20230907_103106	0.065202	0.1871731	0.2212209	0.0489387

GBM_grid_1_AutoML_2_20230907_103106_model_52	0.065338	0.1852566	0.2219167	0.049247
GBM_grid_1_AutoML_2_20230907_103106_model_33	0.065397	0.1857832	0.220483	0.0486127
GBM_grid_1_AutoML_2_20230907_103106_model_25	0.065462	0.1920527	0.2210775	0.0488752
GBM_4_AutoML_2_20230907_103106	0.06548	0.1738295	0.2136294	0.0456375
GBM_grid_1_AutoML_2_20230907_103106_model_22	0.065659	0.1854604	0.218949	0.0479386
GBM_grid_1_AutoML_2_20230907_103106_model_16	0.065796	0.185974	0.219089	0.048
GBM_grid_1_AutoML_2_20230907_103106_model_55	0.065948	0.1719276	0.2149823	0.0462174
GBM_grid_1_AutoML_2_20230907_103106_model_27	0.066279	0.1891332	0.2204135	0.0485821
GBM_grid_1_AutoML_2_20230907_103106_model_35	0.066954	0.195393	0.2226464	0.0495714
GBM_grid_1_AutoML_2_20230907_103106_model_21	0.067072	0.1777403	0.2178662	0.0474657
GBM_grid_1_AutoML_2_20230907_103106_model_8	0.067234	0.1751142	0.2167115	0.0469639
GBM_grid_1_AutoML_2_20230907_103106_model_34	0.067444	0.1902658	0.2215834	0.0490992
GBM_grid_1_AutoML_2_20230907_103106_model_24	0.067523	0.1888623	0.2225907	0.0495466
GBM_grid_1_AutoML_2_20230907_103106_model_18	0.067666	0.1765392	0.2169921	0.0470856
GBM_grid_1_AutoML_2_20230907_103106_model_1	0.067843	0.1808296	0.2161264	0.0467106
GBM_grid_1_AutoML_2_20230907_103106_model_50	0.067944	0.174565	0.2176959	0.0473915
DRF_1_AutoML_2_20230907_103106	0.067987	0.2012343	0.2342898	0.0548917
GBM_grid_1_AutoML_2_20230907_103106_model_28	0.068109	0.188367	0.2218891	0.0492348
GBM_grid_1_AutoML_2_20230907_103106_model_13	0.068114	0.2076557	0.2296404	0.0527347
GBM_grid_1_AutoML_2_20230907_103106_model_45	0.069039	0.1852084	0.2230101	0.0497335
GBM_2_AutoML_2_20230907_103106	0.069453	0.1854561	0.2195542	0.048204
GBM_grid_1_AutoML_2_20230907_103106_model_38	0.069579	0.1727421	0.216156	0.0467234
GBM_grid_1_AutoML_2_20230907_103106_model_15	0.069615	0.1806006	0.2173552	0.0472433
GBM_grid_1_AutoML_2_20230907_103106_model_12	0.069745	0.1881845	0.2211845	0.0489226
XRT_1_AutoML_2_20230907_103106	0.070048	0.2065208	0.2370951	0.0562141
GBM_grid_1_AutoML_2_20230907_103106_model_49	0.070739	0.2062649	0.2311331	0.0534225
GBM_grid_1_AutoML_2_20230907_103106_model_32	0.071615	0.1936893	0.2259228	0.0510411
GBM_grid_1_AutoML_2_20230907_103106_model_17	0.072023	0.2066281	0.2322363	0.0539337
GBM_grid_1_AutoML_2_20230907_103106_model_29	0.072101	0.2192163	0.239828	0.0575175
GBM_grid_1_AutoML_2_20230907_103106_model_36	0.07213	0.1824231	0.2200586	0.0484258
GBM_grid_1_AutoML_2_20230907_103106_model_9	0.072742	0.1922488	0.2244413	0.0503739
GBM_grid_1_AutoML_2_20230907_103106_model_54	0.073427	0.2312008	0.2457844	0.06041
GBM_grid_1_AutoML_2_20230907_103106_model_51	0.074166	0.2218788	0.2399945	0.0575974
GBM_grid_1_AutoML_2_20230907_103106_model_42	0.074594	0.1927859	0.2242792	0.0503012
GBM_1_AutoML_2_20230907_103106	0.075434	0.2312308	0.2455635	0.0603014
GBM_grid_1_AutoML_2_20230907_103106_model_5	0.07631	0.2298158	0.2443986	0.0597307
GBM_grid_1_AutoML_2_20230907_103106_model_4	0.093959	0.271091	0.2734868	0.074795
GBM_grid_1_AutoML_2_20230907_103106_model_47	0.106925	0.2799287	0.2808094	0.0788539
GBM_grid_1_AutoML_2_20230907_103106_model_6	0.107866	0.2961831	0.2909512	0.0846526

GBM_grid_1_AutoML_2_20230907_103106_model_40	0.109434	0.2930638	0.2886278	0.083306
GBM_grid_1_AutoML_2_20230907_103106_model_44	0.110785	0.2899049	0.2878207	0.0828407
GBM_grid_1_AutoML_2_20230907_103106_model_11	0.115352	0.3009062	0.294067	0.0864754
GBM_grid_1_AutoML_2_20230907_103106_model_2	0.123105	0.3176214	0.3044162	0.0926692
GBM_grid_1_AutoML_2_20230907_103106_model_31	0.123757	0.3097443	0.2997265	0.089836
GBM_grid_1_AutoML_2_20230907_103106_model_43	0.124686	0.2994102	0.2941832	0.0865438
GBM_grid_1_AutoML_2_20230907_103106_model_30	0.126306	0.3152319	0.3040711	0.0924592
GBM_grid_1_AutoML_2_20230907_103106_model_3	0.171678	0.3832666	0.3448295	0.1189074
GLM_1_AutoML_2_20230907_103106	0.327309	0.6214752	0.4576618	0.2094544

D. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fitosanitarios asociados a MV utilizando variables geométricas y espectrales

model_id	mean_per_class_error	logloss	rmse	mse
GBM_grid_1_AutoML_3_20230907_105616_model_53	0.5819252	1.120066	0.6564424	0.4309166
GBM_grid_1_AutoML_3_20230907_105616_model_22	0.5881005	1.150087	0.6589408	0.434203
DRF_1_AutoML_3_20230907_105616	0.5897332	2.885061	0.6673282	0.4453269
GBM_grid_1_AutoML_3_20230907_105616_model_60	0.5906097	1.126422	0.6575249	0.432339
GBM_grid_1_AutoML_3_20230907_105616_model_90	0.5910204	1.132242	0.6576996	0.4325687
GBM_grid_1_AutoML_3_20230907_105616_model_123	0.5915726	1.111357	0.6558385	0.4301241
GBM_grid_1_AutoML_3_20230907_105616_model_124	0.5916577	1.082197	0.653186	0.4266519
GBM_grid_1_AutoML_3_20230907_105616_model_81	0.5917423	1.142935	0.6603714	0.4360904
GBM_2_AutoML_3_20230907_105616	0.592088	1.109299	0.6559191	0.4302299
GBM_grid_1_AutoML_3_20230907_105616_model_21	0.5922885	1.176992	0.6619928	0.4382345
GBM_grid_1_AutoML_3_20230907_105616_model_99	0.5924819	1.160802	0.6611466	0.4371148
GBM_grid_1_AutoML_3_20230907_105616_model_19	0.5927173	1.161201	0.6612171	0.437208
GBM_grid_1_AutoML_3_20230907_105616_model_16	0.5927784	1.10753	0.656196	0.4305932
GBM_grid_1_AutoML_3_20230907_105616_model_120	0.5930109	1.128113	0.65765	0.4325035
GBM_grid_1_AutoML_3_20230907_105616_model_59	0.5930474	1.10363	0.6551886	0.4292721
GBM_grid_1_AutoML_3_20230907_105616_model_83	0.5934227	1.107634	0.6562672	0.4306867

GBM_grid_1_AutoML_3_20230907_105616_model_1	0.5937538	1.17345	0.6619187	0.4381364
GBM_grid_1_AutoML_3_20230907_105616_model_115	0.5940523	1.129051	0.6577027	0.4325728
GBM_grid_1_AutoML_3_20230907_105616_model_102	0.5947549	1.20038	0.6640471	0.4409586
GBM_grid_1_AutoML_3_20230907_105616_model_109	0.5948114	1.12298	0.6573072	0.4320528
GBM_grid_1_AutoML_3_20230907_105616_model_96	0.594964	1.193626	0.6631014	0.4397034
GBM_grid_1_AutoML_3_20230907_105616_model_118	0.5949707	1.079885	0.6536787	0.4272959
GBM_grid_1_AutoML_3_20230907_105616_model_57	0.5950642	1.106305	0.655469	0.4296396
GBM_grid_1_AutoML_3_20230907_105616_model_58	0.5951161	1.137617	0.6593226	0.4347062
GBM_grid_1_AutoML_3_20230907_105616_model_67	0.5951313	1.171038	0.6624407	0.4388277
GBM_grid_1_AutoML_3_20230907_105616_model_24	0.5957119	1.18682	0.6638798	0.4407364
GBM_grid_1_AutoML_3_20230907_105616_model_78	0.5958424	1.157523	0.6611161	0.4370746
GBM_grid_1_AutoML_3_20230907_105616_model_23	0.5961776	1.159755	0.6607592	0.4366027
GBM_grid_1_AutoML_3_20230907_105616_model_86	0.5964845	1.096385	0.6549634	0.428977
GBM_grid_1_AutoML_3_20230907_105616_model_12	0.5966664	1.149194	0.6607835	0.4366349
GBM_grid_1_AutoML_3_20230907_105616_model_61	0.59728	1.112285	0.6563182	0.4307536
GBM_grid_1_AutoML_3_20230907_105616_model_66	0.5972969	1.158298	0.6615065	0.4375909
GBM_grid_1_AutoML_3_20230907_105616_model_18	0.5973244	1.153391	0.6605834	0.4363705
GBM_grid_1_AutoML_3_20230907_105616_model_88	0.5974074	1.112915	0.6561017	0.4304695
GBM_grid_1_AutoML_3_20230907_105616_model_92	0.5974431	1.139522	0.6587401	0.4339385
GBM_grid_1_AutoML_3_20230907_105616_model_73	0.5974658	1.156831	0.6610514	0.436989
GBM_grid_1_AutoML_3_20230907_105616_model_10	0.5977142	1.108581	0.6561981	0.4305959
GBM_grid_1_AutoML_3_20230907_105616_model_101	0.5980728	1.122383	0.6575606	0.432386
GBM_grid_1_AutoML_3_20230907_105616_model_65	0.5982522	1.077587	0.6532971	0.4267971
GBM_grid_1_AutoML_3_20230907_105616_model_122	0.5983394	1.110083	0.6575542	0.4323775
GBM_grid_1_AutoML_3_20230907_105616_model_95	0.5984393	1.07731	0.6533713	0.4268941
GBM_grid_1_AutoML_3_20230907_105616_model_97	0.5988483	1.082268	0.6533466	0.4268618
GBM_grid_1_AutoML_3_20230907_105616_model_14	0.5988747	1.18398	0.6634977	0.4402292
GBM_grid_1_AutoML_3_20230907_105616_model_98	0.5990209	1.151877	0.6605788	0.4363643
GBM_grid_1_AutoML_3_20230907_105616_model_62	0.5991122	1.149431	0.6603668	0.4360843
GBM_grid_1_AutoML_3_20230907_105616_model_5	0.600145	1.082842	0.653648	0.4272558
GBM_grid_1_AutoML_3_20230907_105616_model_76	0.6005601	1.085042	0.6541035	0.4278514
GBM_grid_1_AutoML_3_20230907_105616_model_112	0.600665	1.135431	0.658827	0.434053
GBM_grid_1_AutoML_3_20230907_105616_model_77	0.6006933	1.20255	0.664499	0.441559
GBM_grid_1_AutoML_3_20230907_105616_model_125	0.6006962	1.077129	0.6533607	0.4268802
GBM_1_AutoML_3_20230907_105616	0.600986	1.083063	0.6539888	0.4277014
GBM_grid_1_AutoML_3_20230907_105616_model_9	0.6009944	1.098609	0.6549962	0.42902
GBM_grid_1_AutoML_3_20230907_105616_model_100	0.601245	1.137282	0.6591516	0.4344808
GBM_grid_1_AutoML_3_20230907_105616_model_52	0.6013412	1.106217	0.6562706	0.4306911
GBM_grid_1_AutoML_3_20230907_105616_model_17	0.6015684	1.103542	0.6558952	0.4301985

GBM_grid_1_AutoML_3_20230907_105616_model_103	0.6016214	1.128733	0.6591129	0.4344298
GBM_grid_1_AutoML_3_20230907_105616_model_71	0.6018315	1.103254	0.65556	0.429759
GBM_grid_1_AutoML_3_20230907_105616_model_84	0.6019381	1.095202	0.6553232	0.4294485
GBM_grid_1_AutoML_3_20230907_105616_model_72	0.6019504	1.079001	0.6534574	0.4270065
GBM_grid_1_AutoML_3_20230907_105616_model_108	0.6020758	1.127713	0.6587409	0.4339396
GBM_grid_1_AutoML_3_20230907_105616_model_111	0.602147	1.077911	0.6538621	0.4275356
GBM_grid_1_AutoML_3_20230907_105616_model_2	0.6022468	1.076827	0.6529728	0.4263735
GBM_grid_1_AutoML_3_20230907_105616_model_110	0.602248	1.115029	0.657372	0.4321379
GBM_grid_1_AutoML_3_20230907_105616_model_56	0.6024368	1.078111	0.6540661	0.4278025
GBM_grid_1_AutoML_3_20230907_105616_model_20	0.6025779	1.109529	0.6567282	0.4312919
GBM_grid_1_AutoML_3_20230907_105616_model_63	0.6029356	1.164681	0.6622952	0.438635
GBM_3_AutoML_3_20230907_105616	0.6029935	1.117108	0.656449	0.4309253
GBM_4_AutoML_3_20230907_105616	0.6030607	1.138414	0.6590065	0.4342895
GBM_grid_1_AutoML_3_20230907_105616_model_91	0.6034877	1.118054	0.6583106	0.4333728
XRT_1_AutoML_3_20230907_105616	0.6040651	2.625621	0.6676734	0.4457877
GBM_grid_1_AutoML_3_20230907_105616_model_70	0.604187	1.12099	0.6576204	0.4324646
GBM_grid_1_AutoML_3_20230907_105616_model_25	0.6047325	1.089463	0.6545384	0.4284206
GBM_grid_1_AutoML_3_20230907_105616_model_87	0.6050512	1.11858	0.657073	0.4317449
GBM_grid_1_AutoML_3_20230907_105616_model_94	0.6050737	1.078412	0.6538982	0.4275829
GBM_grid_1_AutoML_3_20230907_105616_model_15	0.6060435	1.102529	0.6554391	0.4296004
GBM_grid_1_AutoML_3_20230907_105616_model_105	0.6061081	1.137541	0.6599692	0.4355594
GBM_grid_1_AutoML_3_20230907_105616_model_80	0.6061675	1.186783	0.6630143	0.4395879
GBM_grid_1_AutoML_3_20230907_105616_model_7	0.6063094	1.144856	0.6597809	0.4353108
GBM_grid_1_AutoML_3_20230907_105616_model_3	0.6067093	1.07623	0.6540303	0.4277556
GBM_grid_1_AutoML_3_20230907_105616_model_89	0.6073568	1.08392	0.6539709	0.4276779
GBM_grid_1_AutoML_3_20230907_105616_model_113	0.6073655	1.102236	0.6566839	0.4312338
GBM_grid_1_AutoML_3_20230907_105616_model_68	0.607456	1.07756	0.653465	0.4270166
GBM_grid_1_AutoML_3_20230907_105616_model_74	0.6075374	1.096314	0.6557794	0.4300466
GBM_grid_1_AutoML_3_20230907_105616_model_75	0.6079548	1.178265	0.6637842	0.4406095
GBM_5_AutoML_3_20230907_105616	0.6080056	1.103335	0.6566593	0.4312015
GBM_grid_1_AutoML_3_20230907_105616_model_11	0.6091289	1.077772	0.6533388	0.4268516
GBM_grid_1_AutoML_3_20230907_105616_model_114	0.6092232	1.079853	0.6539864	0.4276982
GBM_grid_1_AutoML_3_20230907_105616_model_51	0.6092329	1.099276	0.6555624	0.429762
GBM_grid_1_AutoML_3_20230907_105616_model_54	0.6102801	1.083572	0.6556951	0.429936
GBM_grid_1_AutoML_3_20230907_105616_model_106	0.6103896	1.076499	0.6544677	0.4283279
GBM_grid_1_AutoML_3_20230907_105616_model_116	0.6105396	1.079618	0.65445	0.4283048
GBM_grid_1_AutoML_3_20230907_105616_model_119	0.6107258	1.075771	0.6534713	0.4270248
GBM_grid_1_AutoML_3_20230907_105616_model_69	0.6107945	1.078779	0.6551612	0.4292361
GBM_grid_1_AutoML_3_20230907_105616_model_117	0.6108446	1.076349	0.6544962	0.4283652

GBM_grid_1_AutoML_3_20230907_105616_model_79	0.6110131	1.078835	0.6539736	0.4276814
GBM_grid_1_AutoML_3_20230907_105616_model_107	0.6111334	1.08023	0.6538168	0.4274764
GBM_grid_1_AutoML_3_20230907_105616_model_4	0.6112278	1.073898	0.6532272	0.4267058
GBM_grid_1_AutoML_3_20230907_105616_model_6	0.6118379	1.077579	0.6540131	0.4277332
GBM_grid_1_AutoML_3_20230907_105616_model_8	0.6123326	1.163231	0.6626994	0.4391705
GBM_grid_1_AutoML_3_20230907_105616_model_93	0.6123681	1.074252	0.6525825	0.4258639
GBM_grid_1_AutoML_3_20230907_105616_model_13	0.612396	1.081449	0.6544898	0.4283568
GBM_grid_1_AutoML_3_20230907_105616_model_85	0.6127265	1.087196	0.6542153	0.4279977
GBM_grid_1_AutoML_3_20230907_105616_model_64	0.613239	1.200068	0.6652869	0.4426066
GBM_grid_1_AutoML_3_20230907_105616_model_55	0.6133825	1.077981	0.6542203	0.4280042
GBM_grid_1_AutoML_3_20230907_105616_model_121	0.6142286	1.077681	0.654254	0.4280483
GBM_grid_1_AutoML_3_20230907_105616_model_82	0.6180651	1.104823	0.6567962	0.4313813
GBM_grid_1_AutoML_3_20230907_105616_model_104	0.6190784	1.082438	0.6553503	0.429484
GLM_1_AutoML_3_20230907_105616	0.6275262	1.081029	0.6562934	0.4307211

E. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros fitosanitarios asociados a MV utilizando variables fotosintéticas, espectrales y geométricas.

model_id	mean_per_c	logloss	rmse	mse
GBM_grid_1_AutoML_1_20230829_145858_model_25	0.108682	0.2601153	0.2716591	0.0737987
GBM_4_AutoML_1_20230829_145858	0.110194	0.2721163	0.2758099	0.0760711
GBM_grid_1_AutoML_1_20230829_145858_model_23	0.1104005	0.2709577	0.2727747	0.074406
GBM_5_AutoML_1_20230829_145858	0.1111661	0.2682669	0.2755617	0.0759343
GBM_3_AutoML_1_20230829_145858	0.1113477	0.2661913	0.2731754	0.0746248
GBM_grid_1_AutoML_1_20230829_145858_model_7	0.1152387	0.2709867	0.2743397	0.0752623
GBM_2_AutoML_1_20230829_145858	0.1152986	0.2697321	0.277413	0.076958
GBM_grid_1_AutoML_1_20230829_145858_model_26	0.1261429	0.2929208	0.293672	0.0862432
GBM_grid_1_AutoML_1_20230829_145858_model_15	0.1286408	0.2836173	0.2887561	0.0833801
GBM_grid_1_AutoML_1_20230829_145858_model_1	0.1306842	0.301625	0.2901635	0.0841949
GBM_grid_1_AutoML_1_20230829_145858_model_21	0.1338043	0.310427	0.2966084	0.0879766
GBM_grid_1_AutoML_1_20230829_145858_model_19	0.1356813	0.293561	0.2917912	0.0851421
GBM_grid_1_AutoML_1_20230829_145858_model_13	0.1363929	0.3079067	0.3040473	0.0924448
GBM_grid_1_AutoML_1_20230829_145858_model_9	0.1409185	0.3133364	0.3057687	0.0934945
GBM_grid_1_AutoML_1_20230829_145858_model_14	0.1451128	0.3298563	0.309282	0.0956554
GBM_grid_1_AutoML_1_20230829_145858_model_8	0.1461787	0.3169798	0.3055768	0.0933772
GBM_grid_1_AutoML_1_20230829_145858_model_16	0.1506002	0.3260046	0.3136667	0.0983868
GBM_grid_1_AutoML_1_20230829_145858_model_10	0.1527791	0.3318499	0.3177535	0.1009673
GBM_grid_1_AutoML_1_20230829_145858_model_18	0.1538597	0.32842	0.3137008	0.0984082
GBM_grid_1_AutoML_1_20230829_145858_model_24	0.1543436	0.3486145	0.3195318	0.1021006
GBM_grid_1_AutoML_1_20230829_145858_model_22	0.1580212	0.3512741	0.3221744	0.1037963
GBM_grid_1_AutoML_1_20230829_145858_model_12	0.1610411	0.3369902	0.3184807	0.1014299
GBM_grid_1_AutoML_1_20230829_145858_model_27	0.1634217	0.3377399	0.3225199	0.1040191
GBM_1_AutoML_1_20230829_145858	0.1670208	0.3523882	0.3306714	0.1093436
GBM_grid_1_AutoML_1_20230829_145858_model_17	0.1726545	0.3615409	0.3350509	0.1122591
GBM_grid_1_AutoML_1_20230829_145858_model_5	0.1731521	0.3582099	0.3348104	0.112098
GBM_grid_1_AutoML_1_20230829_145858_model_20	0.1735132	0.3528567	0.33099	0.1095544
GBM_grid_1_AutoML_1_20230829_145858_model_4	0.1912554	0.3969361	0.3537744	0.1251564
GBM_grid_1_AutoML_1_20230829_145858_model_6	0.2063264	0.4055209	0.3601872	0.1297348
DRF_1_AutoML_1_20230829_145858	0.2213738	0.4871189	0.3819231	0.1458652
GBM_grid_1_AutoML_1_20230829_145858_model_3	0.2280837	0.4547632	0.3841549	0.147575
GBM_grid_1_AutoML_1_20230829_145858_model_11	0.2352558	0.4471727	0.3813773	0.1454486
XRT_1_AutoML_1_20230829_145858	0.236727	0.4830452	0.3864836	0.1493696
GBM_grid_1_AutoML_1_20230829_145858_model_2	0.2398526	0.4580756	0.3862711	0.1492053
GLM_1_AutoML_1_20230829_145858	0.3331018	0.6146195	0.4547657	0.2068118

F. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fenológicos PF utilizando variables fotosintéticas

model_id	mean_class_error	logloss	rmse	mse
GBM_grid_1_AutoML_8_20230908_115057_model_12	0.0782735	0.1968688	0.2190188	0.0479692
GBM_grid_1_AutoML_8_20230908_115057_model_4	0.0806798	0.2038768	0.22178	0.0491864
GBM_grid_1_AutoML_8_20230908_115057_model_8	0.0814592	0.2154422	0.2237986	0.0500858
GBM_3_AutoML_8_20230908_115057	0.0818265	0.2073958	0.2225204	0.0495153
GBM_grid_1_AutoML_8_20230908_115057_model_33	0.0821175	0.1950687	0.2189654	0.0479458
GBM_grid_1_AutoML_8_20230908_115057_model_20	0.0826194	0.1922026	0.2195308	0.0481938
GBM_grid_1_AutoML_8_20230908_115057_model_31	0.0826744	0.2130396	0.2234247	0.0499186
GBM_grid_1_AutoML_8_20230908_115057_model_11	0.0835347	0.1964199	0.2253484	0.0507819
GBM_grid_1_AutoML_8_20230908_115057_model_18	0.0835553	0.2075162	0.2233257	0.0498744
GBM_2_AutoML_8_20230908_115057	0.0836105	0.2092083	0.2220143	0.0492904
GBM_grid_1_AutoML_8_20230908_115057_model_28	0.0838745	0.2315797	0.230959	0.053342
GBM_grid_1_AutoML_8_20230908_115057_model_32	0.0842109	0.2163705	0.2279631	0.0519672
GBM_grid_1_AutoML_8_20230908_115057_model_19	0.0842207	0.207375	0.2251372	0.0506868
GBM_5_AutoML_8_20230908_115057	0.0843284	0.2147899	0.2246678	0.0504756
GBM_4_AutoML_8_20230908_115057	0.0843319	0.2013028	0.2218998	0.0492395
GBM_grid_1_AutoML_8_20230908_115057_model_3	0.0845368	0.2038685	0.2223871	0.049456
GBM_grid_1_AutoML_8_20230908_115057_model_14	0.0847829	0.2063879	0.2250003	0.0506251
GBM_grid_1_AutoML_8_20230908_115057_model_9	0.0851502	0.2022916	0.2237429	0.0500609
GBM_grid_1_AutoML_8_20230908_115057_model_30	0.0853468	0.2019628	0.2235515	0.0499753
GBM_grid_1_AutoML_8_20230908_115057_model_22	0.0854109	0.2157588	0.2283122	0.0521265
GBM_grid_1_AutoML_8_20230908_115057_model_10	0.0854153	0.2313146	0.2345599	0.0550184
GBM_grid_1_AutoML_8_20230908_115057_model_29	0.0856768	0.2321357	0.2319485	0.0538001
GBM_grid_1_AutoML_8_20230908_115057_model_13	0.0862765	0.2487445	0.2370404	0.0561881
GBM_grid_1_AutoML_8_20230908_115057_model_2	0.0865586	0.2343281	0.2327688	0.0541813
GBM_grid_1_AutoML_8_20230908_115057_model_24	0.0866021	0.2517945	0.2398606	0.0575331
GBM_grid_1_AutoML_8_20230908_115057_model_27	0.0872648	0.2493654	0.2399184	0.0575609
GBM_grid_1_AutoML_8_20230908_115057_model_23	0.0878679	0.2587154	0.2460636	0.0605473
GBM_grid_1_AutoML_8_20230908_115057_model_26	0.0878868	0.1981032	0.2231665	0.0498033
GBM_grid_1_AutoML_8_20230908_115057_model_6	0.0879837	0.2116181	0.2291656	0.0525169
GBM_grid_1_AutoML_8_20230908_115057_model_7	0.0880123	0.2007466	0.2230887	0.0497685
GBM_1_AutoML_8_20230908_115057	0.0880192	0.2397763	0.233795	0.0546601
GBM_grid_1_AutoML_8_20230908_115057_model_17	0.0882775	0.193635	0.2218695	0.0492261

GBM_grid_1_AutoML_8_20230908_115057_model_5	0.0883315	0.2150919	0.2315149	0.0535992
GBM_grid_1_AutoML_8_20230908_115057_model_15	0.0887731	0.2013422	0.2249944	0.0506225
DRF_1_AutoML_8_20230908_115057	0.0892702	0.2644363	0.2595195	0.0673504
GBM_grid_1_AutoML_8_20230908_115057_model_21	0.0895763	0.209572	0.2253941	0.0508025
XRT_1_AutoML_8_20230908_115057	0.0897363	0.2702121	0.2632058	0.0692773
GBM_grid_1_AutoML_8_20230908_115057_model_1	0.0898295	0.2555911	0.2461931	0.060611
GBM_grid_1_AutoML_8_20230908_115057_model_25	0.0904248	0.2717237	0.2519518	0.0634797
GBM_grid_1_AutoML_8_20230908_115057_model_16	0.0921355	0.2041175	0.2273091	0.0516694
GLM_1_AutoML_8_20230908_115057	0.480673	0.9294129	0.5641487	0.3182638

G. Anexo: tabla de rendimiento de los modelos AutoML para predecir parámetros fenológicos PF utilizando variables espectrales y geométricas

model_id	mean_class_error	logloss	rmse	mse
GLM_1_AutoML_7_20230908_112108	0.75	1.263108	0.702171	0.4930441
GBM_grid_1_AutoML_7_20230908_112108_model_106	0.750492	1.28879	0.7069142	0.4997277
GBM_grid_1_AutoML_7_20230908_112108_model_126	0.7518443	1.290367	0.7073132	0.5002919
GBM_grid_1_AutoML_7_20230908_112108_model_67	0.7524536	1.289556	0.707241	0.5001898
GBM_grid_1_AutoML_7_20230908_112108_model_124	0.753265	1.295408	0.7080026	0.5012676
GBM_grid_1_AutoML_7_20230908_112108_model_127	0.7543849	1.291252	0.7074191	0.5004418
GBM_grid_1_AutoML_7_20230908_112108_model_107	0.7544301	1.29774	0.7083685	0.5017859
GBM_grid_1_AutoML_7_20230908_112108_model_115	0.7567446	1.29496	0.7077166	0.5008628
GBM_grid_1_AutoML_7_20230908_112108_model_105	0.7571189	1.291947	0.7072247	0.5001667
GBM_grid_1_AutoML_7_20230908_112108_model_10	0.758837	1.308921	0.7101483	0.5043106
GBM_grid_1_AutoML_7_20230908_112108_model_122	0.759442	1.319958	0.712402	0.5075166
GBM_grid_1_AutoML_7_20230908_112108_model_102	0.7633391	1.326642	0.7133412	0.5088556
GBM_grid_1_AutoML_7_20230908_112108_model_27	0.7635488	1.331215	0.713991	0.5097831
GBM_grid_1_AutoML_7_20230908_112108_model_118	0.7635627	1.319818	0.71216	0.5071718
GBM_grid_1_AutoML_7_20230908_112108_model_129	0.7637655	1.332061	0.7141491	0.5100089

GBM_grid_1_AutoML_7_20230908_112108_model_85	0.7644667	1.323188	0.7128569	0.508165
GBM_grid_1_AutoML_7_20230908_112108_model_29	0.7652686	1.313276	0.711506	0.5062407
GBM_grid_1_AutoML_7_20230908_112108_model_108	0.7653652	1.324839	0.7130426	0.5084298
GBM_grid_1_AutoML_7_20230908_112108_model_89	0.7656964	1.310698	0.7109694	0.5054775
GBM_grid_1_AutoML_7_20230908_112108_model_100	0.7667345	1.324814	0.7129305	0.5082698
GBM_grid_1_AutoML_7_20230908_112108_model_98	0.7674295	1.321553	0.7127083	0.5079531
GBM_grid_1_AutoML_7_20230908_112108_model_74	0.7677928	1.32648	0.713093	0.5085016
GBM_grid_1_AutoML_7_20230908_112108_model_73	0.7687214	1.328984	0.7135112	0.5090983
GBM_grid_1_AutoML_7_20230908_112108_model_1	0.7693588	1.326252	0.7132285	0.5086948
GBM_grid_1_AutoML_7_20230908_112108_model_79	0.7694397	1.330029	0.7137783	0.5094795
GBM_grid_1_AutoML_7_20230908_112108_model_23	0.7696857	1.324763	0.7132286	0.5086951
GBM_grid_1_AutoML_7_20230908_112108_model_32	0.7700955	1.341859	0.7156471	0.5121508
GBM_grid_1_AutoML_7_20230908_112108_model_130	0.7701673	1.350037	0.717267	0.514472
GBM_grid_1_AutoML_7_20230908_112108_model_71	0.7705392	1.336224	0.7146965	0.5107911
GBM_grid_1_AutoML_7_20230908_112108_model_103	0.7708548	1.354314	0.7175964	0.5149445
GBM_grid_1_AutoML_7_20230908_112108_model_116	0.7711347	1.32984	0.7140711	0.5098975
GBM_grid_1_AutoML_7_20230908_112108_model_22	0.7711496	1.340412	0.7152704	0.5116117
GBM_grid_1_AutoML_7_20230908_112108_model_72	0.7719798	1.328192	0.7135228	0.5091148
GBM_grid_1_AutoML_7_20230908_112108_model_24	0.7720119	1.335022	0.7148421	0.5109992
GBM_grid_1_AutoML_7_20230908_112108_model_123	0.7722745	1.340986	0.7159749	0.51262
GBM_grid_1_AutoML_7_20230908_112108_model_25	0.7735012	1.328882	0.7143788	0.5103371
GBM_1_AutoML_7_20230908_112108	0.7735365	1.350947	0.7171121	0.5142498
GBM_grid_1_AutoML_7_20230908_112108_model_112	0.7735551	1.351373	0.717041	0.5141477
GBM_grid_1_AutoML_7_20230908_112108_model_94	0.7736588	1.361086	0.7180642	0.5156162
GBM_grid_1_AutoML_7_20230908_112108_model_128	0.7738698	1.34201	0.7159932	0.5126463
GBM_grid_1_AutoML_7_20230908_112108_model_93	0.7741311	1.348277	0.7164849	0.5133506
GBM_grid_1_AutoML_7_20230908_112108_model_109	0.7745141	1.344211	0.7163754	0.5131938
GBM_grid_1_AutoML_7_20230908_112108_model_13	0.774696	1.335223	0.7148595	0.5110241
GBM_5_AutoML_7_20230908_112108	0.7767168	1.37088	0.7195739	0.5177866
GBM_grid_1_AutoML_7_20230908_112108_model_2	0.7771973	1.351529	0.7175536	0.5148832
GBM_grid_1_AutoML_7_20230908_112108_model_81	0.7773135	1.366712	0.7188262	0.5167111
GBM_grid_1_AutoML_7_20230908_112108_model_80	0.777675	1.349824	0.7171735	0.5143378
GBM_grid_1_AutoML_7_20230908_112108_model_28	0.7777044	1.355242	0.7180824	0.5156423
GBM_grid_1_AutoML_7_20230908_112108_model_83	0.778495	1.342615	0.7163377	0.5131397
GBM_grid_1_AutoML_7_20230908_112108_model_121	0.778723	1.353383	0.7173762	0.5146286
GBM_grid_1_AutoML_7_20230908_112108_model_69	0.7822676	1.396014	0.7235254	0.523489
GBM_grid_1_AutoML_7_20230908_112108_model_101	0.7828864	1.359647	0.718693	0.5165196
GBM_grid_1_AutoML_7_20230908_112108_model_4	0.7840296	1.417668	0.7260855	0.5272001
GBM_grid_1_AutoML_7_20230908_112108_model_119	0.7841297	1.383388	0.7217623	0.5209408

GBM_grid_1_AutoML_7_20230908_112108_model_97	0.7855228	1.427641	0.7272546	0.5288993
GBM_grid_1_AutoML_7_20230908_112108_model_30	0.7855796	1.394742	0.7228967	0.5225796
GBM_grid_1_AutoML_7_20230908_112108_model_8	0.7867943	1.391399	0.7225156	0.5220288
GBM_2_AutoML_7_20230908_112108	0.7872059	1.387177	0.7223419	0.5217778
GBM_grid_1_AutoML_7_20230908_112108_model_31	0.7875488	1.416354	0.7259971	0.5270718
GBM_grid_1_AutoML_7_20230908_112108_model_113	0.7880822	1.452654	0.730392	0.5334725
GBM_grid_1_AutoML_7_20230908_112108_model_131	0.7885154	1.451525	0.7297056	0.5324703
GBM_grid_1_AutoML_7_20230908_112108_model_86	0.7891325	1.417694	0.7261	0.5272212
GBM_3_AutoML_7_20230908_112108	0.7896662	1.416345	0.7257163	0.5266642
GBM_grid_1_AutoML_7_20230908_112108_model_99	0.7913949	1.435754	0.7279312	0.5298839
GBM_grid_1_AutoML_7_20230908_112108_model_76	0.7914213	1.397884	0.7246091	0.5250583
GBM_grid_1_AutoML_7_20230908_112108_model_6	0.7919014	1.415753	0.7254544	0.526284
GBM_grid_1_AutoML_7_20230908_112108_model_95	0.7922409	1.436985	0.7283696	0.5305222
GBM_grid_1_AutoML_7_20230908_112108_model_110	0.7922633	1.382714	0.7216627	0.5207971
GBM_grid_1_AutoML_7_20230908_112108_model_91	0.7924934	1.497719	0.7345814	0.5396098
GBM_grid_1_AutoML_7_20230908_112108_model_132	0.7927786	1.471774	0.7327562	0.5369316
GBM_grid_1_AutoML_7_20230908_112108_model_70	0.7932092	1.428314	0.7277414	0.5296076
GBM_grid_1_AutoML_7_20230908_112108_model_104	0.7936815	1.43671	0.7294022	0.5320275
GBM_grid_1_AutoML_7_20230908_112108_model_17	0.7944224	1.528974	0.7378072	0.5443595
GBM_grid_1_AutoML_7_20230908_112108_model_19	0.79509	1.469456	0.7326161	0.5367263
GBM_grid_1_AutoML_7_20230908_112108_model_75	0.7956912	1.443826	0.7294757	0.5321348
GBM_grid_1_AutoML_7_20230908_112108_model_88	0.7959968	1.485069	0.7340237	0.5387907
GBM_grid_1_AutoML_7_20230908_112108_model_3	0.7960948	1.422034	0.726982	0.5285028
GBM_grid_1_AutoML_7_20230908_112108_model_92	0.7961782	1.490898	0.734814	0.5399516
GBM_grid_1_AutoML_7_20230908_112108_model_20	0.7963717	1.482706	0.7338098	0.5384769
GBM_grid_1_AutoML_7_20230908_112108_model_14	0.7972321	1.492306	0.7349597	0.5401658
GBM_grid_1_AutoML_7_20230908_112108_model_18	0.7973577	1.471894	0.7329734	0.53725
GBM_grid_1_AutoML_7_20230908_112108_model_111	0.7975119	1.469453	0.7326734	0.5368104
GBM_grid_1_AutoML_7_20230908_112108_model_68	0.7975499	1.495785	0.7358913	0.5415359
GBM_4_AutoML_7_20230908_112108	0.7977078	1.46516	0.7314194	0.5349744
GBM_grid_1_AutoML_7_20230908_112108_model_117	0.797745	1.552343	0.7402903	0.5480297
GBM_grid_1_AutoML_7_20230908_112108_model_125	0.7978373	1.52422	0.7384037	0.54524
GBM_grid_1_AutoML_7_20230908_112108_model_84	0.7985618	1.575956	0.7411274	0.5492698
GBM_grid_1_AutoML_7_20230908_112108_model_15	0.7993534	1.489917	0.734988	0.5402073
GBM_grid_1_AutoML_7_20230908_112108_model_26	0.7994031	1.525258	0.7367425	0.5427896
GBM_grid_1_AutoML_7_20230908_112108_model_90	0.7994563	1.497861	0.7342705	0.5391531
GBM_grid_1_AutoML_7_20230908_112108_model_9	0.8000972	1.522263	0.7380107	0.5446598
GBM_grid_1_AutoML_7_20230908_112108_model_5	0.8005836	1.550239	0.7391753	0.5463801
GBM_grid_1_AutoML_7_20230908_112108_model_114	0.8009118	1.506323	0.7364863	0.5424121

GBM_grid_1_AutoML_7_20230908_112108_model_21	0.8009124	1.449994	0.7305677	0.5337292
GBM_grid_1_AutoML_7_20230908_112108_model_77	0.8011862	1.582153	0.741843	0.550331
GBM_grid_1_AutoML_7_20230908_112108_model_78	0.801278	1.552752	0.7382164	0.5449635
GBM_grid_1_AutoML_7_20230908_112108_model_82	0.8015357	1.574792	0.7411948	0.5493697
GBM_grid_1_AutoML_7_20230908_112108_model_120	0.8015784	1.554215	0.7399477	0.5475226
GBM_grid_1_AutoML_7_20230908_112108_model_12	0.8023485	1.490978	0.7343531	0.5392744
GBM_grid_1_AutoML_7_20230908_112108_model_66	0.8035606	1.506342	0.7368739	0.5429832
GBM_grid_1_AutoML_7_20230908_112108_model_65	0.8035758	1.521683	0.7384944	0.545374
DRF_1_AutoML_7_20230908_112108	0.8036854	3.730617	0.7499782	0.5624673
GBM_grid_1_AutoML_7_20230908_112108_model_7	0.8046676	1.48936	0.7346841	0.5397608
GBM_grid_1_AutoML_7_20230908_112108_model_87	0.8047438	1.600496	0.7440834	0.5536601
GBM_grid_1_AutoML_7_20230908_112108_model_16	0.8047932	1.498911	0.7367883	0.542857
GBM_grid_1_AutoML_7_20230908_112108_model_11	0.8049031	1.587024	0.7428191	0.5517802
GBM_grid_1_AutoML_7_20230908_112108_model_96	0.8050214	1.560847	0.7403251	0.5480813
XRT_1_AutoML_7_20230908_112108	0.8138172	3.54164	0.7503696	0.5630546

H. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros fenológicos utilizando variables fotosintéticas, espectrales y geométricas

model_id	mean_class_error	logloss	rmse	mse
GBM_2_AutoML_11_20230908_130150	0.1004869	0.2531106	0.2457564	0.0603962
GBM_3_AutoML_11_20230908_130150	0.1016561	0.2565295	0.246204	0.0606164
GBM_4_AutoML_11_20230908_130150	0.1030367	0.2503744	0.2438434	0.0594596
GBM_5_AutoML_11_20230908_130150	0.1175191	0.2716313	0.2622295	0.0687643
GBM_grid_1_AutoML_11_20230908_130150_model_3	0.1240152	0.2748447	0.2605056	0.0678631
GBM_grid_1_AutoML_11_20230908_130150_model_2	0.1410648	0.3175267	0.2876016	0.0827147
GBM_1_AutoML_11_20230908_130150	0.1543168	0.3354723	0.2974967	0.0885043
GBM_grid_1_AutoML_11_20230908_130150_model_1	0.2283307	0.4364921	0.3621624	0.1311616
DRF_1_AutoML_11_20230908_130150	0.3421694	0.6227372	0.4523561	0.2046261
XRT_1_AutoML_11_20230908_130150	0.3517957	0.652915	0.4603015	0.2118775
GLM_1_AutoML_11_20230908_130150	0.4837973	0.9498884	0.5675277	0.3220877

I. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros productivos PP utilizando variables fotosintéticas

model_id	rmse	mse	mae	rmsle	mean_residual_deviance
GBM_grid_1_AutoML_1_20230907_155047_model_11	2.023953	4.096387	0.7250945	0.3712783	4.096387
GBM_grid_1_AutoML_1_20230907_155047_model_56	2.075506	4.307727	0.9884529	NA	4.307727
GBM_grid_1_AutoML_1_20230907_155047_model_6	2.084634	4.345701	0.9571783	NA	4.345701
GBM_grid_1_AutoML_1_20230907_155047_model_85	2.085421	4.348979	0.7700618	0.389384	4.348979
GBM_grid_1_AutoML_1_20230907_155047_model_58	2.090128	4.368634	0.7484023	0.3918407	4.368634
GBM_grid_1_AutoML_1_20230907_155047_model_46	2.094367	4.386373	0.7666314	0.3919179	4.386373
GBM_4_AutoML_1_20230907_155047	2.099081	4.406142	0.915268	NA	4.406142
GBM_grid_1_AutoML_1_20230907_155047_model_45	2.101974	4.418295	0.759867	0.4101184	4.418295
GBM_grid_1_AutoML_1_20230907_155047_model_50	2.108858	4.447283	0.8165364	0.3924643	4.447283
GBM_grid_1_AutoML_1_20230907_155047_model_9	2.122324	4.504259	0.9662809	0.4296962	4.504259
GBM_grid_1_AutoML_1_20230907_155047_model_65	2.124782	4.5147	0.9284836	0.4105708	4.5147
GBM_grid_1_AutoML_1_20230907_155047_model_12	2.127372	4.525712	0.9127809	0.4136452	4.525712
GBM_grid_1_AutoML_1_20230907_155047_model_18	2.130259	4.538005	1.0427177	NA	4.538005
GBM_grid_1_AutoML_1_20230907_155047_model_20	2.135566	4.560644	0.8631618	0.4068998	4.560644
GBM_grid_1_AutoML_1_20230907_155047_model_81	2.136477	4.564534	0.8585722	NA	4.564534
GBM_3_AutoML_1_20230907_155047	2.138997	4.575309	0.985729	NA	4.575309
GBM_grid_1_AutoML_1_20230907_155047_model_49	2.139831	4.578876	1.0489765	NA	4.578876
GBM_grid_1_AutoML_1_20230907_155047_model_30	2.140505	4.581759	0.9908227	NA	4.581759
GBM_grid_1_AutoML_1_20230907_155047_model_34	2.141375	4.585487	1.0395005	NA	4.585487
GBM_grid_1_AutoML_1_20230907_155047_model_67	2.141493	4.585992	0.9626056	NA	4.585992
GBM_grid_1_AutoML_1_20230907_155047_model_17	2.142132	4.588729	0.9667591	NA	4.588729
GBM_grid_1_AutoML_1_20230907_155047_model_14	2.145217	4.601957	1.0458161	NA	4.601957
GBM_grid_1_AutoML_1_20230907_155047_model_33	2.146373	4.606915	0.9506616	0.4266759	4.606915
GBM_grid_1_AutoML_1_20230907_155047_model_15	2.151709	4.629852	1.0550866	NA	4.629852
GBM_grid_1_AutoML_1_20230907_155047_model_63	2.154239	4.640745	1.0083812	0.4360834	4.640745
GBM_grid_1_AutoML_1_20230907_155047_model_4	2.154844	4.643351	1.0053861	NA	4.643351

GBM_grid_1_AutoML_1_20230907_155047_model_37	2.161182	4.67071	1.0552078	NA	4.67071
GBM_grid_1_AutoML_1_20230907_155047_model_60	2.161319	4.671298	0.9880462	0.4531411	4.671298
GBM_grid_1_AutoML_1_20230907_155047_model_55	2.16785	4.699573	0.7510511	0.3920219	4.699573
GBM_2_AutoML_1_20230907_155047	2.168042	4.700405	1.0510477	NA	4.700405
GBM_grid_1_AutoML_1_20230907_155047_model_64	2.175072	4.730938	0.8080631	0.3912363	4.730938
GBM_grid_1_AutoML_1_20230907_155047_model_26	2.175566	4.733087	0.9091561	0.4017191	4.733087
GBM_grid_1_AutoML_1_20230907_155047_model_82	2.177418	4.741149	1.04441	NA	4.741149
GBM_grid_1_AutoML_1_20230907_155047_model_62	2.180294	4.753684	1.0910759	NA	4.753684
GBM_grid_1_AutoML_1_20230907_155047_model_59	2.185366	4.775824	0.8184051	0.4120893	4.775824
GBM_grid_1_AutoML_1_20230907_155047_model_7	2.185625	4.776957	0.9994565	NA	4.776957
GBM_grid_1_AutoML_1_20230907_155047_model_88	2.191412	4.802285	0.9221171	NA	4.802285
GBM_5_AutoML_1_20230907_155047	2.191745	4.803748	1.1070478	NA	4.803748
GBM_grid_1_AutoML_1_20230907_155047_model_16	2.19982	4.839208	1.0389825	NA	4.839208
GBM_grid_1_AutoML_1_20230907_155047_model_54	2.205754	4.86535	1.0379678	NA	4.86535
GBM_grid_1_AutoML_1_20230907_155047_model_52	2.210426	4.885982	0.7746333	0.414526	4.885982
GBM_grid_1_AutoML_1_20230907_155047_model_69	2.217414	4.916924	1.2263025	NA	4.916924
GBM_grid_1_AutoML_1_20230907_155047_model_5	2.221026	4.932958	0.7771586	0.4021317	4.932958
GBM_grid_1_AutoML_1_20230907_155047_model_78	2.221424	4.934727	1.1530816	NA	4.934727
GBM_grid_1_AutoML_1_20230907_155047_model_36	2.231574	4.979923	1.1387528	NA	4.979923
GBM_grid_1_AutoML_1_20230907_155047_model_19	2.232634	4.984654	1.1851045	NA	4.984654
GBM_grid_1_AutoML_1_20230907_155047_model_79	2.243815	5.034705	1.1719789	NA	5.034705
GBM_grid_1_AutoML_1_20230907_155047_model_43	2.261064	5.112412	1.2360168	NA	5.112412
GBM_grid_1_AutoML_1_20230907_155047_model_3	2.298183	5.281644	1.2977943	NA	5.281644
GBM_grid_1_AutoML_1_20230907_155047_model_22	2.307688	5.325426	1.2637489	NA	5.325426
GBM_grid_1_AutoML_1_20230907_155047_model_8	2.309613	5.334312	1.3205959	NA	5.334312
GBM_grid_1_AutoML_1_20230907_155047_model_39	2.312072	5.345676	1.3279135	NA	5.345676
GBM_grid_1_AutoML_1_20230907_155047_model_21	2.313987	5.354535	1.3104026	NA	5.354535
GBM_grid_1_AutoML_1_20230907_155047_model_31	2.314684	5.35776	1.2680712	NA	5.35776
GBM_grid_1_AutoML_1_20230907_155047_model_72	2.350724	5.525901	1.3412494	NA	5.525901
GBM_grid_1_AutoML_1_20230907_155047_model_32	2.357785	5.559148	1.3466769	NA	5.559148
GBM_grid_1_AutoML_1_20230907_155047_model_38	2.359723	5.568291	1.3980853	NA	5.568291
GBM_grid_1_AutoML_1_20230907_155047_model_44	2.420531	5.85897	1.4627152	NA	5.85897
XRT_1_AutoML_1_20230907_155047	2.421697	5.864617	1.4875747	0.5278784	5.864617
GBM_grid_1_AutoML_1_20230907_155047_model_87	2.44772	5.991332	1.5234052	NA	5.991332
DRF_1_AutoML_1_20230907_155047	2.449207	5.998615	1.4844473	0.5306241	5.998615
GBM_grid_1_AutoML_1_20230907_155047_model_80	2.551516	6.510233	1.6245747	NA	6.510233
GBM_grid_1_AutoML_1_20230907_155047_model_71	2.552643	6.515985	1.6101333	NA	6.515985
GBM_grid_1_AutoML_1_20230907_155047_model_61	2.609198	6.807916	1.7152151	NA	6.807916
GBM_grid_1_AutoML_1_20230907_155047_model_86	2.611042	6.817538	1.6572914	NA	6.817538

GBM_grid_1_AutoML_1_20230907_155047_model_47	2.614133	6.83369	1.7122441	NA	6.83369
GBM_grid_1_AutoML_1_20230907_155047_model_41	2.614552	6.835881	1.6954938	NA	6.835881
GBM_grid_1_AutoML_1_20230907_155047_model_89	2.871378	8.244813	1.9924882	NA	8.244813
GBM_grid_1_AutoML_1_20230907_155047_model_29	3.025846	9.155743	2.131511	NA	9.155743
GBM_grid_1_AutoML_1_20230907_155047_model_42	3.092777	9.565268	2.1851632	NA	9.565268
GBM_grid_1_AutoML_1_20230907_155047_model_76	3.131734	9.807761	2.2347419	NA	9.807761
GBM_grid_1_AutoML_1_20230907_155047_model_28	3.235088	10.465797	2.3169979	NA	10.465797
GBM_grid_1_AutoML_1_20230907_155047_model_2	3.239335	10.493291	2.3348587	NA	10.493291
GBM_grid_1_AutoML_1_20230907_155047_model_10	3.247741	10.547824	2.3137435	NA	10.547824
GBM_grid_1_AutoML_1_20230907_155047_model_73	3.357874	11.275316	2.4284569	NA	11.275316
GBM_1_AutoML_1_20230907_155047	3.465655	12.010768	2.5146441	NA	12.010768
GBM_grid_1_AutoML_1_20230907_155047_model_83	3.466206	12.014581	2.5300719	NA	12.014581
GBM_grid_1_AutoML_1_20230907_155047_model_48	3.573935	12.773012	2.6071549	NA	12.773012
GBM_grid_1_AutoML_1_20230907_155047_model_77	3.592451	12.905703	2.6412527	NA	12.905703
GBM_grid_1_AutoML_1_20230907_155047_model_53	3.609936	13.031639	2.6456109	NA	13.031639
GBM_grid_1_AutoML_1_20230907_155047_model_91	3.628385	13.165179	2.6721778	NA	13.165179
GBM_grid_1_AutoML_1_20230907_155047_model_92	3.754336	14.095036	2.7986788	NA	14.095036
GBM_grid_1_AutoML_1_20230907_155047_model_57	3.772318	14.230386	2.8063546	NA	14.230386
GBM_grid_1_AutoML_1_20230907_155047_model_24	3.786508	14.337646	2.8129229	NA	14.337646
GBM_grid_1_AutoML_1_20230907_155047_model_51	3.790598	14.368633	2.7984802	NA	14.368633
GBM_grid_1_AutoML_1_20230907_155047_model_13	3.818213	14.578752	2.8359838	NA	14.578752
GBM_grid_1_AutoML_1_20230907_155047_model_27	3.845658	14.789088	2.8680661	NA	14.789088
GBM_grid_1_AutoML_1_20230907_155047_model_40	3.894308	15.165636	2.9259967	NA	15.165636
GBM_grid_1_AutoML_1_20230907_155047_model_68	3.906649	15.261904	2.8983461	NA	15.261904
GBM_grid_1_AutoML_1_20230907_155047_model_84	3.916449	15.338571	2.9215579	NA	15.338571
GBM_grid_1_AutoML_1_20230907_155047_model_1	3.939115	15.516623	2.9343103	NA	15.516623
GBM_grid_1_AutoML_1_20230907_155047_model_70	3.966775	15.735301	2.9636974	NA	15.735301
GBM_grid_1_AutoML_1_20230907_155047_model_90	3.990021	15.92027	3.0029636	NA	15.92027
GBM_grid_1_AutoML_1_20230907_155047_model_25	4.015323	16.12282	2.9958624	NA	16.12282
GBM_grid_1_AutoML_1_20230907_155047_model_23	4.022283	16.178759	3.0078182	NA	16.178759
GBM_grid_1_AutoML_1_20230907_155047_model_66	4.157549	17.285214	3.1123811	NA	17.285214
GBM_grid_1_AutoML_1_20230907_155047_model_74	4.249332	18.056819	3.2095904	NA	18.056819
GBM_grid_1_AutoML_1_20230907_155047_model_75	4.295494	18.451266	3.2437189	NA	18.451266
GBM_grid_1_AutoML_1_20230907_155047_model_35	4.31354	18.606629	3.257975	NA	18.606629
GLM_1_AutoML_1_20230907_155047	5.244894	27.508914	4.1442861	NA	27.508914

J. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros productivos PP utilizando variables espectrales y geométricas

model_id	rmse	mse	mae	rmsle	mean_residual_deviance
GLM_1_AutoML_13_20230908_135642	6.259919	39.18659	5.410781	1.24388	39.18659
GBM_grid_1_AutoML_13_20230908_135642_model_103	6.297186	39.65455	5.448222	1.248802	39.65455
GBM_grid_1_AutoML_13_20230908_135642_model_64	6.300406	39.69511	5.452862	1.249766	39.69511
GBM_grid_1_AutoML_13_20230908_135642_model_123	6.307483	39.78434	5.459606	1.25013	39.78434
GBM_grid_1_AutoML_13_20230908_135642_model_104	6.31043	39.82153	5.451176	1.246913	39.82153
GBM_grid_1_AutoML_13_20230908_135642_model_124	6.320028	39.94275	5.458698	1.249688	39.94275
GBM_grid_1_AutoML_13_20230908_135642_model_102	6.322324	39.97177	5.468009	1.250857	39.97177
GBM_grid_1_AutoML_13_20230908_135642_model_112	6.328296	40.04733	5.473295	1.252307	40.04733
GBM_grid_1_AutoML_13_20230908_135642_model_25	6.329023	40.05653	5.469553	1.25021	40.05653
GBM_grid_1_AutoML_13_20230908_135642_model_121	6.329607	40.06393	5.472697	1.25152	40.06393
GBM_grid_1_AutoML_13_20230908_135642_model_95	6.330665	40.07732	5.475754	1.251549	40.07732
GBM_grid_1_AutoML_13_20230908_135642_model_119	6.334022	40.11983	5.481351	1.253438	40.11983
GBM_grid_1_AutoML_13_20230908_135642_model_97	6.337013	40.15774	5.488928	1.25335	40.15774
GBM_grid_1_AutoML_13_20230908_135642_model_27	6.337646	40.16576	5.487155	1.254138	40.16576
GBM_grid_1_AutoML_13_20230908_135642_model_99	6.337858	40.16844	5.483203	1.252227	40.16844
GBM_grid_1_AutoML_13_20230908_135642_model_82	6.338949	40.18228	5.486846	1.253148	40.18228
GBM_grid_1_AutoML_13_20230908_135642_model_69	6.339238	40.18594	5.485615	1.253588	40.18594
GBM_grid_1_AutoML_13_20230908_135642_model_1	6.340352	40.20006	5.481274	1.252075	40.20006
GBM_grid_1_AutoML_13_20230908_135642_model_86	6.341246	40.2114	5.482009	1.252306	40.2114
GBM_grid_1_AutoML_13_20230908_135642_model_113	6.342301	40.22478	5.483859	1.253973	40.22478
GBM_grid_1_AutoML_13_20230908_135642_model_80	6.342465	40.22687	5.487523	1.253409	40.22687
GBM_grid_1_AutoML_13_20230908_135642_model_13	6.342795	40.23105	5.494951	1.253514	40.23105
GBM_grid_1_AutoML_13_20230908_135642_model_23	6.345437	40.26457	5.495382	1.255359	40.26457
GBM_grid_1_AutoML_13_20230908_135642_model_10	6.346142	40.27352	5.487272	1.253359	40.27352
GBM_grid_1_AutoML_13_20230908_135642_model_24	6.346514	40.27824	5.49474	1.25453	40.27824
GBM_grid_1_AutoML_13_20230908_135642_model_125	6.348372	40.30183	5.489832	1.253391	40.30183
GBM_grid_1_AutoML_13_20230908_135642_model_120	6.349041	40.31032	5.497119	1.25523	40.31032
GBM_grid_1_AutoML_13_20230908_135642_model_29	6.349099	40.31105	5.499775	1.256556	40.31105
GBM_grid_1_AutoML_13_20230908_135642_model_77	6.350948	40.33455	5.500214	1.254945	40.33455
GBM_grid_1_AutoML_13_20230908_135642_model_106	6.355106	40.38738	5.498399	1.254463	40.38738
GBM_1_AutoML_13_20230908_135642	6.359185	40.43923	5.502778	1.255866	40.43923

GBM_grid_1_AutoML_13_20230908_135642_model_28	6.362334	40.47929	5.508567	1.256265	40.47929
GBM_grid_1_AutoML_13_20230908_135642_model_127	6.3628	40.48522	5.504988	1.256366	40.48522
GBM_grid_1_AutoML_13_20230908_135642_model_71	6.363296	40.49154	5.504866	1.255501	40.49154
GBM_grid_1_AutoML_13_20230908_135642_model_115	6.363813	40.49811	5.501747	1.256079	40.49811
GBM_grid_1_AutoML_13_20230908_135642_model_2	6.364497	40.50683	5.503791	1.256232	40.50683
GBM_grid_1_AutoML_13_20230908_135642_model_105	6.369269	40.56759	5.503765	1.254352	40.56759
GBM_grid_1_AutoML_13_20230908_135642_model_70	6.379106	40.693	5.517033	1.257993	40.693
GBM_grid_1_AutoML_13_20230908_135642_model_126	6.383157	40.74469	5.519253	1.258314	40.74469
GBM_grid_1_AutoML_13_20230908_135642_model_76	6.383832	40.75331	5.527973	1.259869	40.75331
GBM_grid_1_AutoML_13_20230908_135642_model_90	6.38778	40.80374	5.521047	1.258528	40.80374
GBM_grid_1_AutoML_13_20230908_135642_model_100	6.40362	41.00635	5.533987	1.259535	41.00635
GBM_grid_1_AutoML_13_20230908_135642_model_22	6.405667	41.03257	5.533257	1.26061	41.03257
GBM_grid_1_AutoML_13_20230908_135642_model_118	6.408687	41.07127	5.538452	1.260724	41.07127
GBM_grid_1_AutoML_13_20230908_135642_model_68	6.41472	41.14863	5.549183	1.263152	41.14863
GBM_grid_1_AutoML_13_20230908_135642_model_109	6.421969	41.24169	5.538043	1.260385	41.24169
GBM_grid_1_AutoML_13_20230908_135642_model_61	6.429183	41.3344	5.555921	1.262872	41.3344
GBM_grid_1_AutoML_13_20230908_135642_model_116	6.434531	41.40319	5.566542	1.266086	41.40319
GBM_grid_1_AutoML_13_20230908_135642_model_73	6.438698	41.45683	5.564615	1.264678	41.45683
GBM_grid_1_AutoML_13_20230908_135642_model_91	6.438857	41.45888	5.565633	1.26393	41.45888
GBM_grid_1_AutoML_13_20230908_135642_model_78	6.44002	41.47386	5.564298	1.263747	41.47386
GBM_grid_1_AutoML_13_20230908_135642_model_98	6.459301	41.72256	5.57943	1.266621	41.72256
GBM_grid_1_AutoML_13_20230908_135642_model_8	6.462123	41.75904	5.585916	1.267465	41.75904
GBM_5_AutoML_13_20230908_135642	6.466808	41.81961	5.586232	1.267257	41.81961
GBM_grid_1_AutoML_13_20230908_135642_model_107	6.470706	41.87003	5.591466	1.268954	41.87003
GBM_grid_1_AutoML_13_20230908_135642_model_3	6.480702	41.99949	5.604268	1.269249	41.99949
GBM_grid_1_AutoML_13_20230908_135642_model_67	6.482316	42.02042	5.597756	1.268566	42.02042
GBM_2_AutoML_13_20230908_135642	6.483175	42.03156	5.590958	1.268867	42.03156
GBM_grid_1_AutoML_13_20230908_135642_model_60	6.484541	42.04927	5.60319	1.269041	42.04927
GBM_grid_1_AutoML_13_20230908_135642_model_66	6.49127	42.13659	5.599159	1.26772	42.13659
GBM_grid_1_AutoML_13_20230908_135642_model_72	6.493572	42.16647	5.613536	1.270196	42.16647
GBM_grid_1_AutoML_13_20230908_135642_model_101	6.494087	42.17317	5.608406	1.269662	42.17317
GBM_grid_1_AutoML_13_20230908_135642_model_21	6.499366	42.24176	5.603975	1.270221	42.24176
GBM_grid_1_AutoML_13_20230908_135642_model_59	6.502828	42.28677	5.60706	1.271357	42.28677
GBM_grid_1_AutoML_13_20230908_135642_model_19	6.517682	42.48018	5.62671	1.273105	42.48018
GBM_grid_1_AutoML_13_20230908_135642_model_4	6.522336	42.54087	5.62519	1.273919	42.54087
GBM_3_AutoML_13_20230908_135642	6.522587	42.54414	5.630159	1.274142	42.54414
GBM_grid_1_AutoML_13_20230908_135642_model_94	6.53118	42.65631	5.628766	1.274469	42.65631
GBM_grid_1_AutoML_13_20230908_135642_model_83	6.538695	42.75454	5.63127	1.275757	42.75454
GBM_grid_1_AutoML_13_20230908_135642_model_108	6.539084	42.75962	5.629004	1.272868	42.75962

GBM_grid_1_AutoML_13_20230908_135642_model_96	6.546524	42.85698	5.647113	1.2765	42.85698
GBM_grid_1_AutoML_13_20230908_135642_model_92	6.550594	42.91028	5.653688	1.277047	42.91028
GBM_grid_1_AutoML_13_20230908_135642_model_128	6.55673	42.99072	5.653164	1.277775	42.99072
GBM_grid_1_AutoML_13_20230908_135642_model_65	6.562528	43.06678	5.641559	1.276793	43.06678
GBM_grid_1_AutoML_13_20230908_135642_model_6	6.565537	43.10628	5.661395	1.278447	43.10628
GBM_grid_1_AutoML_13_20230908_135642_model_18	6.581063	43.31039	5.672101	1.280155	43.31039
GBM_grid_1_AutoML_13_20230908_135642_model_15	6.582494	43.32923	5.662247	1.278298	43.32923
GBM_grid_1_AutoML_13_20230908_135642_model_129	6.585325	43.36651	5.673895	1.279744	43.36651
GBM_4_AutoML_13_20230908_135642	6.590756	43.43806	5.68045	1.281875	43.43806
GBM_grid_1_AutoML_13_20230908_135642_model_85	6.592281	43.45817	5.672481	1.279632	43.45817
GBM_grid_1_AutoML_13_20230908_135642_model_14	6.603164	43.60178	5.684709	1.28288	43.60178
GBM_grid_1_AutoML_13_20230908_135642_model_16	6.606113	43.64073	5.681983	1.281974	43.64073
GBM_grid_1_AutoML_13_20230908_135642_model_7	6.607285	43.65621	5.685182	1.28284	43.65621
GBM_grid_1_AutoML_13_20230908_135642_model_89	6.609961	43.69159	5.684227	1.282657	43.69159
GBM_grid_1_AutoML_13_20230908_135642_model_111	6.611021	43.7056	5.687884	1.282168	43.7056
GBM_grid_1_AutoML_13_20230908_135642_model_63	6.6158	43.76881	5.702525	1.285732	43.76881
GBM_grid_1_AutoML_13_20230908_135642_model_110	6.61652	43.77834	5.685492	1.28019	43.77834
GBM_grid_1_AutoML_13_20230908_135642_model_12	6.617821	43.79556	5.691918	1.28295	43.79556
GBM_grid_1_AutoML_13_20230908_135642_model_20	6.618931	43.81025	5.695223	1.282957	43.81025
GBM_grid_1_AutoML_13_20230908_135642_model_26	6.625256	43.89402	5.701753	1.284272	43.89402
GBM_grid_1_AutoML_13_20230908_135642_model_9	6.634373	44.0149	5.703517	1.285094	44.0149
GBM_grid_1_AutoML_13_20230908_135642_model_87	6.635224	44.0262	5.708989	1.286832	44.0262
GBM_grid_1_AutoML_13_20230908_135642_model_17	6.645935	44.16845	5.714673	1.287111	44.16845
GBM_grid_1_AutoML_13_20230908_135642_model_62	6.648649	44.20453	5.707065	1.285788	44.20453
GBM_grid_1_AutoML_13_20230908_135642_model_122	6.65781	44.32644	5.718965	1.287733	44.32644
GBM_grid_1_AutoML_13_20230908_135642_model_88	6.662275	44.38591	5.723069	1.288447	44.38591
GBM_grid_1_AutoML_13_20230908_135642_model_75	6.678081	44.59677	5.734436	1.290506	44.59677
GBM_grid_1_AutoML_13_20230908_135642_model_117	6.708994	45.0106	5.759896	1.29429	45.0106
GBM_grid_1_AutoML_13_20230908_135642_model_5	6.724775	45.2226	5.768799	1.296775	45.2226
GBM_grid_1_AutoML_13_20230908_135642_model_114	6.733466	45.33956	5.766386	1.294491	45.33956
GBM_grid_1_AutoML_13_20230908_135642_model_93	6.741545	45.44844	5.771394	1.292967	45.44844
GBM_grid_1_AutoML_13_20230908_135642_model_79	6.744258	45.48501	5.776486	1.298382	45.48501
GBM_grid_1_AutoML_13_20230908_135642_model_74	6.756412	45.6491	5.790888	1.301238	45.6491
GBM_grid_1_AutoML_13_20230908_135642_model_81	6.764589	45.75967	5.797019	1.30195	45.75967
GBM_grid_1_AutoML_13_20230908_135642_model_11	6.769233	45.82251	5.776943	1.299104	45.82251
GBM_grid_1_AutoML_13_20230908_135642_model_84	6.771302	45.85053	5.797498	1.302685	45.85053
XRT_1_AutoML_13_20230908_135642	6.840831	46.79696	5.829002	1.311625	46.79696
DRF_1_AutoML_13_20230908_135642	6.872505	47.23133	5.859676	1.315052	47.23133

K. Anexos: tabla de rendimiento de los modelos AutoML para predecir parámetros productivos utilizando variables fotosintéticas, espectrales y geométricas.

model_id	rmse	mse	mae	rmsle	mean_residual_deviance
GBM_grid_1_AutoML_14_20230908_141317_model_46	2.327293	5.416293	1.275421	0.4667268	5.416293
GBM_grid_1_AutoML_14_20230908_141317_model_6	2.436798	5.937986	1.489666	NA	5.937986
GBM_grid_1_AutoML_14_20230908_141317_model_5	2.485897	6.179684	1.326677	0.4896647	6.179684
GBM_grid_1_AutoML_14_20230908_141317_model_50	2.488972	6.194983	1.564161	0.5272693	6.194983
GBM_grid_1_AutoML_14_20230908_141317_model_12	2.577902	6.645578	1.659724	NA	6.645578
GBM_4_AutoML_14_20230908_141317	2.587579	6.695567	1.672685	NA	6.695567
GBM_3_AutoML_14_20230908_141317	2.663629	7.09492	1.743475	NA	7.09492
GBM_2_AutoML_14_20230908_141317	2.671366	7.136195	1.770259	NA	7.136195
GBM_grid_1_AutoML_14_20230908_141317_model_30	2.678944	7.176743	1.755239	NA	7.176743
GBM_grid_1_AutoML_14_20230908_141317_model_52	2.72811	7.442585	1.776937	0.5993675	7.442585
GBM_grid_1_AutoML_14_20230908_141317_model_26	2.730058	7.453217	1.79864	NA	7.453217
GBM_grid_1_AutoML_14_20230908_141317_model_43	2.777266	7.713204	1.874451	NA	7.713204
GBM_grid_1_AutoML_14_20230908_141317_model_22	2.783424	7.74745	1.90094	NA	7.74745
GBM_5_AutoML_14_20230908_141317	2.807904	7.884326	1.878243	NA	7.884326
GBM_grid_1_AutoML_14_20230908_141317_model_4	2.812661	7.911064	1.898849	NA	7.911064
GBM_grid_1_AutoML_14_20230908_141317_model_7	2.816206	7.931019	1.912293	NA	7.931019
GBM_grid_1_AutoML_14_20230908_141317_model_31	2.843192	8.083739	1.950434	NA	8.083739
GBM_grid_1_AutoML_14_20230908_141317_model_11	2.859197	8.175006	1.884726	NA	8.175006
GBM_grid_1_AutoML_14_20230908_141317_model_49	2.914087	8.491902	2.000354	NA	8.491902
GBM_grid_1_AutoML_14_20230908_141317_model_3	2.920715	8.530579	2.040888	NA	8.530579
GBM_grid_1_AutoML_14_20230908_141317_model_18	2.942304	8.657151	2.025929	NA	8.657151
GBM_grid_1_AutoML_14_20230908_141317_model_8	2.983239	8.899716	2.072224	NA	8.899716
GBM_grid_1_AutoML_14_20230908_141317_model_33	3.018999	9.114353	2.080832	NA	9.114353
GBM_grid_1_AutoML_14_20230908_141317_model_37	3.047289	9.28597	2.127365	NA	9.28597
DRF_1_AutoML_14_20230908_141317	3.103843	9.633844	2.186889	0.658252	9.633844
GBM_grid_1_AutoML_14_20230908_141317_model_54	3.125996	9.771854	2.202453	NA	9.771854
GBM_grid_1_AutoML_14_20230908_141317_model_34	3.138331	9.849119	2.238742	NA	9.849119
GBM_grid_1_AutoML_14_20230908_141317_model_32	3.139649	9.857397	2.215296	NA	9.857397
XRT_1_AutoML_14_20230908_141317	3.141736	9.870506	2.259846	0.6772114	9.870506
GBM_grid_1_AutoML_14_20230908_141317_model_14	3.14308	9.878952	2.248404	NA	9.878952
GBM_grid_1_AutoML_14_20230908_141317_model_19	3.191603	10.186333	2.298521	NA	10.186333
GBM_grid_1_AutoML_14_20230908_141317_model_41	3.226037	10.407315	2.310353	NA	10.407315
GBM_grid_1_AutoML_14_20230908_141317_model_20	3.236233	10.473207	2.291268	NA	10.473207

GBM_grid_1_AutoML_14_20230908_141317_model_9	3.276561	10.735852	2.332712	NA	10.735852
GBM_grid_1_AutoML_14_20230908_141317_model_36	3.319329	11.017947	2.397477	NA	11.017947
GBM_grid_1_AutoML_14_20230908_141317_model_21	3.32898	11.082106	2.4267	NA	11.082106
GBM_grid_1_AutoML_14_20230908_141317_model_17	3.347399	11.205078	2.41555	NA	11.205078
GBM_grid_1_AutoML_14_20230908_141317_model_39	3.354144	11.250283	2.443995	NA	11.250283
GBM_grid_1_AutoML_14_20230908_141317_model_47	3.360225	11.291115	2.451268	NA	11.291115
GBM_grid_1_AutoML_14_20230908_141317_model_15	3.374182	11.385101	2.449086	NA	11.385101
GBM_grid_1_AutoML_14_20230908_141317_model_45	3.382557	11.44169	2.416455	0.7305621	11.44169
GBM_grid_1_AutoML_14_20230908_141317_model_44	3.42444	11.726788	2.498098	NA	11.726788
GBM_grid_1_AutoML_14_20230908_141317_model_16	3.474184	12.069951	2.51005	NA	12.069951
GBM_grid_1_AutoML_14_20230908_141317_model_38	3.544254	12.561737	2.592981	NA	12.561737
GBM_grid_1_AutoML_14_20230908_141317_model_10	3.570844	12.750924	2.622185	NA	12.750924
GBM_grid_1_AutoML_14_20230908_141317_model_28	3.710349	13.766692	2.753592	NA	13.766692
GBM_grid_1_AutoML_14_20230908_141317_model_2	3.747025	14.040197	2.766951	NA	14.040197
GBM_grid_1_AutoML_14_20230908_141317_model_42	3.822838	14.614088	2.838611	NA	14.614088
GBM_1_AutoML_14_20230908_141317	3.839192	14.739392	2.84764	NA	14.739392
GBM_grid_1_AutoML_14_20230908_141317_model_53	3.905736	15.254776	2.900122	NA	15.254776
GBM_grid_1_AutoML_14_20230908_141317_model_29	3.911458	15.299501	2.921702	NA	15.299501
GBM_grid_1_AutoML_14_20230908_141317_model_48	3.970132	15.761951	2.951817	NA	15.761951
GBM_grid_1_AutoML_14_20230908_141317_model_51	4.048573	16.390941	3.026255	NA	16.390941
GBM_grid_1_AutoML_14_20230908_141317_model_24	4.098955	16.801434	3.065747	NA	16.801434
GBM_grid_1_AutoML_14_20230908_141317_model_13	4.108357	16.878594	3.076948	NA	16.878594
GBM_grid_1_AutoML_14_20230908_141317_model_40	4.126938	17.031617	3.115963	NA	17.031617
GBM_grid_1_AutoML_14_20230908_141317_model_23	4.158964	17.296986	3.111386	NA	17.296986
GBM_grid_1_AutoML_14_20230908_141317_model_27	4.164244	17.340932	3.132136	NA	17.340932
GBM_grid_1_AutoML_14_20230908_141317_model_1	4.182328	17.491866	3.150853	NA	17.491866
GBM_grid_1_AutoML_14_20230908_141317_model_25	4.189654	17.553204	3.147339	NA	17.553204
GBM_grid_1_AutoML_14_20230908_141317_model_35	4.282242	18.337593	3.244334	NA	18.337593
GLM_1_AutoML_14_20230908_141317	5.254621	27.611043	4.144945	NA	27.611043