

**Implementación de modelo yolo, para la detección temprana de la enfermedad mancha en
red en cultivo de cebada cervecera municipio Paipa, Boyacá**

Frank Johan Ramirez Garcia

Asesor

Isaac Esteban Camargo

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas Tecnologías e Ingenierías ECBTI

Especialización en Analítica y Ciencia de Datos.

2025

Resumen

La Mancha en Red, causada por el hongo *Pyrenophora teres*, limita la producción de cebada cervecera en Paipa, Boyacá. Su diagnóstico tradicional depende de la inspección visual, un método tardío y subjetivo. Este estudio evaluó el desempeño y la generalización de modelos de Deep Learning basados en Visión por Computador para la detección temprana de la enfermedad en condiciones reales de campo.

Se implementó la arquitectura YOLOv11 mediante aprendizaje por transferencia, utilizando imágenes primarias recolectadas en campo y optimizadas con aumento de datos (mosaic augmentation). Se evaluaron comparativamente las variantes YOLOv11 Nano y Small usando métricas de precisión, sensibilidad (Recall), mAP y tiempo de inferencia.

Los resultados mostraron que YOLOv11 Small alcanzó alta precisión pero sufrió sobreajuste, limitando su generalización. En contraste, YOLOv11 Nano demostró mayor sensibilidad para identificar focos infecciosos y un menor tiempo de inferencia, ideal para entornos con restricciones computacionales.

Se concluye que YOLOv11 Nano es una alternativa viable y eficiente para la detección temprana de la enfermedad. Este trabajo resalta la importancia de equilibrar la complejidad del modelo con el tamaño del *dataset*, sentando las bases para sistemas de alerta fitosanitaria en agricultura de precisión.

Palabras clave: Cebada, Fitopatología, YOLOv11, Automatización, Diagnóstico.

Abstract

Net blotch, caused by the fungus *Pyrenophora teres*, limits malting barley production in Paipa, Boyacá. Traditional diagnosis relies on visual inspection, a delayed and subjective method. This study evaluated the performance and generalization of Deep Learning models based on Computer Vision for the early detection of the disease under real field conditions.

The YOLOv11 architecture was implemented using transfer learning, utilizing primary images collected in the field and optimized with data augmentation (mosaic augmentation). The YOLOv11 Nano and Small variants were comparatively evaluated using precision, recall, mAP, and inference time metrics.

The results showed that YOLOv11 Small achieved high precision but suffered from overfitting, limiting its generalization. In contrast, YOLOv11 Nano demonstrated higher sensitivity in identifying infectious foci and a shorter inference time, making it ideal for environments with computational constraints.

It is concluded that YOLOv11 Nano is a viable and efficient alternative for early disease detection. This work highlights the importance of balancing model complexity with dataset size, laying the groundwork for phytosanitary alert systems in precision agriculture.

Keywords: Barley, Phytopathology, YOLOv11, Automation, Diagnosis.

Tabla de Contenido

Introducción	7
Justificación	9
Objetivos.....	11
Objetivo General.....	11
Objetivos Específicos	11
Marco de Referencia	12
La Transformación Tecnológica en la Agricultura, Hacia una Agricultura de Precisión	
Impulsada por IA.....	12
El Cultivo de Cebada Cervecera Importancia, Vulnerabilidad y Relevancia Agronómica.....	13
Modelos de Machine Learning Aplicados a la Detección y Prevención de Enfermedades	
Agrícolas.....	14
Estrategias de Optimización del Entrenamiento, Transfer Learning y Generación de Datos	
Sintéticos	15
Estado del Arte en la Aplicación de Machine Learning para la Prevención de Enfermedades	
en Cultivos.....	16
Retos y Oportunidades para la Implementación de Soluciones de Machine Learning en el	
Contexto Agrícola Local	18
Metodología	20
Tipo y Diseño de Investigación.....	20
Caracterización del Corpus de Datos e Imágenes	20
Proceso Operativo de Análisis de Datos.....	21
Diagrama de Flujo Operativo del Proceso.....	21

Documentación Visual del Proceso Experimental.....	22
Sintomatología y Contraste Visual	22
Etiquetado y Definición del Ground Truth.....	22
Métricas de Rendimiento y Comparativa de Modelos	22
Mosaicos de Entrenamiento (Aumentación de Datos).....	23
Resultados y Discusión.....	24
Análisis Comparativo de Rendimiento Técnico	24
Desempeño del Modelo yolov11 Small.....	24
Desempeño del Modelo Yolov11 Nano Sensibilidad y Robustez Operativa.....	25
Síntesis Interpretativa de los Resultados	25
Conclusiones.....	31
Recomendaciones	33
Aplicación en el Sector Productivo y Transferencia Tecnológica	33
Sugerencias para Trabajos Futuros y Profundización Técnica.....	33
Referencias Bibliográficas	35

Lista de Figuras

Figura 1 <i>Diagrama de Flujo Proceso Metodológico</i>	26
Figura 2 <i>Hoja de cebada con lesiones foliares necróticas características de Pyrenophora teres</i>	26
Figura 3 <i>Hoja de Cebada sin Síntomas de Patógenos, Utilizada como Referencia de Tejido Sano</i>	27
Figura 4 <i>Anotación de Patología en Ejemplar Completo de Cebada</i>	27
Figura 5 <i>Etiquetado Manual en Entorno de Cultivo Real</i>	28
Figura 6 <i>Gráficas de Métricas y Funciones de Pérdida para el Modelo</i>	28
Figura 7 <i>Gráficas de Desempeño para el Modelo Small</i>	29
Figura 8 <i>Muestra de Batch de Entrenamiento con Técnica de Mosaico</i>	29
Figura 9 <i>Comparativa Resultados Modelo Nano Vs Small</i>	30
Figura 10 <i>Resumen Métricas Comparativas</i>	30

Introducción

La seguridad alimentaria global y la eficiencia de los sistemas agroindustriales contemporáneos están estrechamente vinculadas a la adopción de estrategias de manejo fitosanitario basadas en datos y tecnologías digitales. En este contexto, la cebada se consolida como un cultivo estratégico a nivel mundial, tanto por su valor nutricional como por su papel central en la industria cervecera y maltera. Sin embargo, su productividad se ve comprometida por la incidencia de enfermedades foliares, entre las cuales la Mancha en Red, causada por el hongo necrotrófico *Pyrenophora teres*, constituye una de las principales limitantes. Estudios internacionales reportan pérdidas de rendimiento que oscilan entre el 10% y el 40% bajo condiciones epidemiológicas severas (McLean et al., 2019; Liu et al., 2022).

Tradicionalmente, la detección de esta enfermedad se ha basado en inspecciones visuales, un enfoque que resulta tardío, subjetivo y costoso. En respuesta, la FAO y centros del CGIAR han promovido la Agricultura de Precisión, integrando sensores remotos y modelos de Inteligencia Artificial (IA) para automatizar el monitoreo (FAO, 2021). En Estados Unidos, investigaciones pioneras han demostrado que el uso de visión por computador en cereales permite detectar síntomas en etapas tempranas, reduciendo significativamente la aplicación innecesaria de fungicidas y mejorando la rentabilidad del productor (Polder et al., 2020; Singh et al., 2021).

El estado del arte ha evolucionado desde el procesamiento de imágenes clásico hacia el aprendizaje profundo. Inicialmente, se emplearon redes neuronales convolucionales como AlexNet, VGG y DenseNet para la clasificación de hojas enfermas en entornos controlados (Mohanty et al., 2016). Posteriormente, surgieron modelos de detección de dos etapas como

Faster R-CNN, que mejoraron la precisión al localizar lesiones específicas, aunque su alto costo computacional limita el despliegue en tiempo real (Ren et al., 2015).

En años recientes, los modelos de una sola etapa como SSD y la familia YOLO (han transformado el campo al ofrecer un equilibrio superior entre precisión y velocidad.

Investigaciones en trigo y cebada evidencian que versiones sucesivas de YOLO (v3, v5, v8) superan a arquitecturas tradicionales en escenarios de iluminación variable y fondos complejos (Wang et al., 2020; Zhang et al., 2023). En particular, YOLOv11 introduce mejoras en eficiencia y generalización, siendo ideal para dispositivos de borde (Ultralytics, 2024).

A pesar de estos avances, persiste una brecha en la validación de estas tecnologías en regiones andinas. En Colombia, y específicamente en Boyacá, la detección en cebada cervecera continúa siendo predominantemente manual (AGROSAVIA, 2020). Este estudio propone la implementación de un modelo YOLOv11 entrenado con imágenes primarias mediante transfer learning, para evaluar su desempeño en la detección temprana de la Mancha en Red en Paipa, Boyacá. Este enfoque busca cerrar la brecha tecnológica y sentar las bases para un Sistema de Alerta Fitosanitaria que fortalezca la sostenibilidad del cultivo en la región.

Justificación

Históricamente, la detección de enfermedades foliares en cebada se ha basado en inspecciones visuales. Este método, aunque tradicional, presenta limitaciones críticas: la subjetividad del evaluador y la detección tardía. Como señala Zadoks et al. (2014), para cuando un técnico identifica la Mancha en Red visualmente, el daño fisiológico suele ser irreversible, comprometiendo el rendimiento del grano.

La respuesta tecnológica comenzó con el uso de Redes Neuronales Convolucionales (CNN) clásicas (AlexNet, VGG). Si bien superaron el monitoreo manual (Mohanty et al., 2016), estas investigaciones se estancaron en la "clasificación" de hojas aisladas en fondos blancos, una condición que no existe en los cultivos de Boyacá. La evolución hacia modelos de detección de objetos como YOLO (Wang et al., 2020) permitió finalmente localizar múltiples lesiones en una sola hoja bajo condiciones de campo, un avance vital para proteger la hoja bandera, responsable de gran parte del llenado del grano.

Sin embargo, persiste una "brecha de validación". La mayoría de los antecedentes exitosos se basan en la base de datos PlantVillage, la cual es demasiado "limpia" para la realidad de Paipa. En el departamento de Boyacá, la dependencia de fungicidas químicos es alta debido a la falta de herramientas de precisión.

Por lo tanto, este proyecto se justifica al proponer el uso de YOLOv11. Este modelo no es solo "el más nuevo"; según Ultralytics (2024), es el primero diseñado para maximizar la velocidad de inferencia en dispositivos de borde (celulares o cámaras de campo) sin necesidad de internet constante, una limitación real en las zonas rurales de Colombia.

En conclusión, esta investigación no solo aporta un avance académico en *Deep Learning*, sino que responde a una necesidad ambiental (reducción de químicos) y productiva

para los agricultores de Paipa, transformando un diagnóstico artesanal en un sistema de alerta temprana de precisión.

Objetivos

Objetivo General

Estimar el desempeño del modelo YOLOv11 en detección temprana de Mancha en Red en cebada cervecera de Paipa, Boyacá.

Objetivos Específicos

Consolidar un conjunto de datos de imágenes de cebada con sintomatología de Mancha en Red mediante técnicas de aumento de datos

Entrenar la arquitectura de detección de objetos YOLOv11 mediante aprendizaje por transferencia o transfer learning para la identificación de la enfermedad.

Validar el modelo YOLOv11 a través de métricas estándar de visión por computador en condiciones reales de campo.

Proponer lineamientos técnicos para la integración del modelo YOLOv11 en un sistema de alerta fitosanitaria en el municipio de Paipa.

Marco de Referencia

La Transformación Tecnológica en la Agricultura, Hacia una Agricultura de Precisión Impulsada por IA

El sector agrícola global se encuentra inmerso en una profunda transformación digital, impulsada por la necesidad imperante de optimizar la producción, minimizar el impacto ambiental y garantizar la seguridad alimentaria en un contexto de cambio climático y crecimiento demográfico sostenido. En esta era, la inteligencia artificial (IA), y específicamente el machine learning (ML), emerge como una herramienta disruptiva y fundamental para la toma de decisiones estratégicas en el campo.

La integración de estas tecnologías no solo promueve una mayor eficiencia en el manejo de los cultivos, sino que también habilita la capacidad predictiva y preventiva, crucial para mitigar riesgos fitosanitarios que impactan directamente la productividad y la calidad. En cultivos de alto valor añadido como la cebada cervecera, donde la integridad del grano es un requisito sine qua non para la industria, la anticipación y prevención de enfermedades a través de modelos predictivos puede generar un impacto económico y ambiental considerable

Puntos Clave:

- La IA y el ML son pilares de la agricultura moderna, permitiendo optimizar recursos y reducir pérdidas.
- La predicción temprana de enfermedades mejora la sostenibilidad, la rentabilidad y la resiliencia agrícola.
- La adopción de estas tecnologías exige una adaptación y análisis contextualizado a las particularidades locales.

El Cultivo de Cebada Cervecera Importancia, Vulnerabilidad y Relevancia Agronómica

La cebada cervecera (*Hordeum vulgare*) representa un cereal de significativo valor económico y estratégico para las industrias alimentaria, cervecera y forrajera a nivel global. Sin embargo, su producción es intrínsecamente vulnerable a una variedad de enfermedades que pueden comprometer severamente tanto el rendimiento como la calidad del grano, con patologías como la mancha reticular (*Pyrenophora teres*), el oídio (*Blumeria graminis* f. sp. *hordei*), las royas (ej. *Puccinia hordei*) y el complejo *Fusarium* spp. siendo particularmente devastadoras.

La incidencia y severidad de estas enfermedades están influenciadas por una compleja interacción de factores, incluyendo condiciones climáticas (humedad, temperatura), prácticas agronómicas (rotación de cultivos, densidad de siembra) y la susceptibilidad genética de las variedades. Los métodos tradicionales de monitoreo y detección, a menudo basados en la observación visual y muestreos esporádicos, resultan insuficientes para una prevención oportuna y eficiente, lo que subraya la necesidad de adoptar enfoques más avanzados basados en el análisis de datos y la automatización.

Puntos Clave:

- La cebada es un cultivo fundamental para la industria cervecera y la economía agrícola.
- Las enfermedades impactan directamente su rendimiento, calidad y valor comercial.
- La variabilidad climática y la limitada eficacia del monitoreo tradicional demandan soluciones predictivas precisas y adaptativas.

Modelos de Machine Learning Aplicados a la Detección y Prevención de Enfermedades Agrícolas

El machine learning, como subcampo de la inteligencia artificial, capacita a los sistemas para aprender patrones y tomar decisiones a partir de datos, sin ser explícitamente programados para cada tarea. En el ámbito agrícola, su aplicación se extiende desde la predicción de rendimientos hasta la identificación temprana y pronóstico de plagas y enfermedades. La sinergia de diversos paradigmas de ML, tales como las redes neuronales convolucionales (CNN), árboles de decisión, redes recurrentes (RNN) y métodos de ensemble learning, ha demostrado una eficacia notable en el análisis de grandes volúmenes de datos heterogéneos, provenientes de diversas fuentes como sensores multiespectrales, imágenes satelitales, drones y cámaras de campo.

Estos modelos se entrenan con conjuntos de datos etiquetados para ejecutar tareas específicas de clasificación (ej., distinguir hojas sanas de enfermas), regresión (ej., predecir la severidad de una enfermedad), segmentación (ej., delimitar áreas afectadas) o predicción temporal (ej., pronosticar brotes). Por ejemplo, arquitecturas de CNN como ResNet, EfficientNet o VGG16 son ampliamente utilizadas para la clasificación y detección de enfermedades foliares a partir de imágenes. Por otro lado, modelos basados en redes recurrentes como Long Short-Term Memory (LSTM) o Gated Recurrent Units (GRU), o incluso métodos estadísticos como Prophet o ARIMA, son idóneos para analizar series temporales de datos climáticos, ambientales y fenológicos, permitiendo prever las condiciones favorables para el desarrollo de patógenos. Algoritmos de ensemble learning como Random Forest o XGBoost, por su capacidad de manejar datos complejos y variables, son excelentes para clasificar las condiciones de riesgo fitosanitario con alta precisión.

Puntos Clave:

- Los modelos de ML, particularmente CNNs, son eficaces para la detección visual de enfermedades.
- Las redes RNN (LSTM, GRU) y otros modelos de series temporales son clave para la predicción de brotes basada en datos climáticos y fenológicos.
- Algoritmos de ensemble learning (Random Forest, XGBoost) optimizan la clasificación de riesgos.

Estrategias de Optimización del Entrenamiento, Transfer Learning y Generación de Datos Sintéticos

Una de las barreras recurrentes en la implementación de modelos de machine learning en aplicaciones agrícolas específicas, especialmente en contextos locales, es la escasez de grandes volúmenes de datos etiquetados de alta calidad. Para subsanar esta limitación, se han popularizado técnicas avanzadas como el transfer learning y la generación de datos sintéticos.

El transfer learning permite reutilizar modelos pre-entrenados en tareas similares con bases de datos masivas (como ImageNet para visión artificial o PlantVillage para enfermedades de plantas), ajustando luego sus capas finales con un conjunto de datos más pequeño y específico del dominio (en este caso, imágenes de cebada). Esta estrategia reduce drásticamente la necesidad de grandes datasets locales y acelera el proceso de entrenamiento, mejorando la robustez y generalización del modelo.

Complementariamente, las Redes Generativas Adversarias (GANs) ofrecen una solución para la expansión de datasets limitados mediante la creación de datos sintéticos que imitan las características de los datos reales. Estas GANs pueden generar imágenes de hojas enfermas con diferentes grados de severidad o bajo diversas condiciones, lo que permite entrenar modelos más robustos y menos propensos al sobreajuste, mejorando la capacidad de detección temprana de síntomas o la segmentación precisa de áreas afectadas.

Puntos Clave:

- El transfer learning es vital para entrenar modelos precisos con datasets locales limitados.
- Las GANs complementan los datos reales con datos sintéticos, mejorando la robustez y capacidad de generalización de los modelos.
- Ambas técnicas minimizan la dependencia de extensas y costosas campañas de recolección de datos.

Estado del Arte en la Aplicación de Machine Learning para la Prevención de Enfermedades en Cultivos

Esta sección es crucial para un marco de referencia de investigación, ya que posiciona su trabajo en el contexto de la literatura existente. Debería mencionar estudios clave y tendencias.

Detección visual y clasificación: Investigaciones recientes han explorado el uso de CNNs (ej. VGG, ResNet, Inception, EfficientNet) para la detección de enfermedades foliares en diversos cultivos. Se pueden citar estudios que demuestran alta precisión en la clasificación de enfermedades específicas de cebada (ej., mancha reticular, oídio) a partir de imágenes de hojas. Mencionar la adopción de redes profundas para la extracción automática de características.

Predicción basada en factores ambientales: Trabajos que emplean modelos de ML (ej.SVM, Random Forest, redes neuronales) para predecir la aparición y severidad de enfermedades basándose en datos climáticos (temperatura, humedad, precipitación) y fenológicos del cultivo. Resaltar cómo los modelos de series temporales (LSTM, GRU) están siendo usados para capturar dinámicas temporales en el desarrollo de patógenos.

Integración de datos multi-fuente: Destacar la tendencia de integrar datos de sensores (temperatura, humedad del suelo, etc.), teledetección (imágenes satelitales, drones con cámaras multispectrales o hiperspectrales) y datos agronómicos para construir modelos predictivos más robustos y completos.

Desarrollo de sistemas de apoyo a la decisión: Mencionare ejemplos de plataformas o prototipos que utilizan modelos de ML para proporcionar recomendaciones en tiempo real a los agricultores sobre el manejo de enfermedades.

Brechas de investigación: Identifique qué aspectos específicos aún no han sido completamente abordados en la literatura existente, o qué limitaciones tienen los estudios previos, para justificar la novedad y la contribución de su proyecto. Por ejemplo, la falta de modelos adaptados a condiciones agroclimáticas específicas de su región, o la escasez de datasets públicos para cebada en Colombia.

Puntos Clave:

- Recopilación de estudios relevantes que apliquen ML a la prevención de enfermedades en cultivos, preferiblemente cebada.
- Identificación de las arquitecturas y algoritmos de ML más utilizados y sus rendimientos.
- Análisis de las fuentes de datos empleadas (imágenes, sensores, clima).

- Detección de vacíos en la literatura o áreas con potencial de mejora que su investigación abordará.

Retos y Oportunidades para la Implementación de Soluciones de Machine Learning en el Contexto Agrícola Local

A pesar del inmenso potencial transformador de las tecnologías de machine learning en la agricultura, su adopción efectiva en contextos agrícolas locales, particularmente en regiones en desarrollo, enfrenta desafíos significativos. Estos incluyen, entre otros, la brecha en la infraestructura digital (conectividad, acceso a equipos), la limitada capacitación técnica y digital de los agricultores y extensionistas, la interoperabilidad de datos y sistemas, y la escasa integración con políticas públicas agrícolas existentes.

Superar estos obstáculos requiere un enfoque holístico e interdisciplinario que amalgama conocimientos agronómicos, computacionales, de ingeniería y socioeconómicos. Es fundamental fortalecer las capacidades locales mediante programas de formación y extensión, fomentar la creación de alianzas estratégicas entre instituciones académicas, centros de investigación, productores, empresas tecnológicas y entidades gubernamentales. Asimismo, el desarrollo de plataformas accesibles y user-friendly, que traduzcan los complejos resultados de los modelos de ML en recomendaciones prácticas y accionables para los agricultores, es un factor clave para asegurar que los beneficios de estas soluciones tecnológicas se materialicen efectivamente en el campo.

Puntos Clave:

- La infraestructura digital y la capacitación son barreras críticas para la adopción de ML en la agricultura.

- La colaboración multi-actor (academia, productores, gobierno, industria) es esencial.
- El desarrollo de herramientas accesibles y adaptadas a las necesidades de los agricultores es fundamental para el éxito de la implementación.

Metodología

Tipo y Diseño de Investigación

La presente investigación es de tipo aplicada con un enfoque cuantitativo y un diseño experimental de carácter tecnológico. El estudio se centra en la manipulación de variables técnicas (arquitectura del modelo, hiperparámetros y técnicas de aumento de datos) para evaluar su impacto en la capacidad de detección de la Mancha en Red. A diferencia de un plan de trabajo cronológico, esta metodología describe el flujo lógico y técnico para la validación científica de un Sistema de Alerta Temprana.

Caracterización del Corpus de Datos e Imágenes

El dataset se compone de imágenes primarias recolectadas en campo, las cuales presentan las siguientes características técnicas y biológicas:

- **Atributos de la Patología:** Las imágenes capturan síntomas de *Pyrenophora teres* en diversas etapas. Se observan lesiones necróticas de color café oscuro con patrones de reticulación (estrías longitudinales y transversales) y, en algunos casos, halos cloróticos (amarillamiento) periféricos que indican el avance del hongo.
- **Variabilidad Fenotípica:** Las capturas incluyen variaciones en la arquitectura de la hoja, desde estados tempranos (plántula) hasta etapas críticas de hoja bandera.
- **Condiciones Ambientales:** Para garantizar la robustez, las imágenes presentan condiciones de iluminación natural (sol directo, nubosidad) y fondos complejos que incluyen suelo desnudo, rastros de cosecha y otras hojas sanas, simulando el entorno real de los cultivos en Paipa, Boyacá.

Proceso Operativo de Análisis de Datos

El análisis de datos no se limita a la ejecución del modelo, sino que sigue un pipeline de ingeniería de visión artificial dividido en cuatro fases experimentales:

- Fase de ingeniería de etiquetas: Se realiza el etiquetado manual o labeling mediante bounding boxes. Esta etapa es crucial para el análisis, ya que define la "verdad de campo" contra la cual se medirá el modelo.
- Fase de transformación espacial (Preprocesamiento): Las imágenes se normalizan a un tamaño de 640×640 píxeles y se someten a un análisis de distribución de clases para asegurar que la partición (Train 50%, Val 20%, Test 30%) sea representativa.
- Fase de entrenamiento experimental (fine-tuning): Se utiliza el modelo YOLOv11n. El análisis consiste en ajustar la tasa de aprendizaje y el tamaño de lote para minimizar las funciones de pérdida de caja y de clasificación.
- Fase de inferencia y validación cruzada: Se somete al modelo a datos nunca antes vistos o conjunto de prueba para estimar métricas de precisión y sensibilidad, determinando si el sistema es apto para operar en el entorno agrícola de Paipa.

Diagrama de Flujo Operativo del Proceso

Para visualizar la operatividad del análisis, se presenta el siguiente esquema que sintetiza el flujo desde la captura hasta la alerta fitosanitaria: (Vease la Figura 1)

Documentación Visual del Proceso Experimental

En esta sección se presenta el soporte gráfico del estudio, abarcando desde la caracterización biológica de la patología hasta la validación estadística de los modelos entrenados.

Sintomatología y Contraste Visual

Se describen las características morfológicas de la Mancha en Red en comparación con el tejido foliar sano. Estas imágenes representan los patrones de entrada que el modelo debe codificar. Se enfatizan las lesiones necróticas de tonalidad marrón oscuro y sus patrones reticulados (estrías), que se diferencian claramente de la coloración verde uniforme y la textura lisa del tejido sano. (Veanse las figuras 2 y 3.)

Etiquetado y Definición del Ground Truth

Esta fase documenta el proceso de supervisión manual, donde se delimitan las lesiones mediante *bounding boxes*. Este procedimiento establece el "Ground Truth" o verdad de campo, proporcionando al algoritmo la referencia espacial necesaria para aprender a localizar la patología en entornos de alta complejidad visual. (Veanse las figuras 4 y 5.)

Métricas de Rendimiento y Comparativa de Modelos

El respaldo estadístico del sistema se presenta mediante las curvas de entrenamiento. Estas gráficas permiten evaluar la eficiencia del aprendizaje y la capacidad de generalización de las dos arquitecturas evaluadas:

Modelo Nano: (Vease la figura 6.)

Modelo Small: (Vease la figura 7.)

Mosaicos de Entrenamiento (Aumentación de Datos)

Para compensar el tamaño acotado del dataset, se empleó la técnica de Mosaic Augmentation. Esta técnica combina cuatro imágenes de entrenamiento en una sola muestra, forzando al modelo a detectar lesiones en diferentes escalas y posiciones, lo que mejora significativamente la detección en condiciones de campo. (Vease la figura 8.)

Resultados y Discusión

Análisis Comparativo de Rendimiento Técnico

El análisis experimental de las arquitecturas YOLOv11 en sus variantes *Nano* y *Small* evidencia comportamientos diferenciados que responden tanto a la complejidad del modelo como a las limitaciones intrínsecas del conjunto de datos utilizado.

Desempeño del Modelo yolov11 Small

El modelo YOLOv11 Small (Veanse las figuras 9 y 10.) alcanzó un valor de precisión (Precision) igual a 1.0, lo que indica que todas las detecciones realizadas por el modelo corresponden efectivamente a lesiones de Mancha en Red. Sin embargo, este resultado, lejos de interpretarse únicamente como un desempeño óptimo, constituye un indicador claro de sobreajuste (overfitting).

Este comportamiento se confirma al observar el valor significativamente menor del Recall (0.56), lo que implica que el modelo solo detecta una fracción de las lesiones reales presentes en las imágenes. En términos prácticos, el modelo *Small* aprende de forma excesivamente específica los patrones visuales presentes en el conjunto de entrenamiento, limitando su capacidad para generalizar frente a variaciones fenotípicas, condiciones de iluminación no vistas o síntomas en estados incipientes.

La mayor profundidad y capacidad paramétrica del modelo *Small*, que en contextos con grandes volúmenes de datos suele traducirse en mejores resultados, resulta contraproducente en escenarios de datasets reducidos, como el abordado en esta investigación. Este fenómeno concuerda con lo reportado en la literatura sobre aprendizaje profundo aplicado a agricultura de precisión, donde arquitecturas más complejas tienden a memorizar los datos cuando la diversidad del conjunto de entrenamiento es limitada.

Desempeño del Modelo Yolov11 Nano Sensibilidad y Robustez Operativa

En contraste, el modelo YOLOv11 *Nano* presentó un Recall del 80%, superando de manera significativa al modelo *Small*. Este resultado indica una mayor capacidad del modelo para identificar la mayoría de los focos infecciosos presentes en las imágenes, característica fundamental en sistemas de detección temprana, donde la omisión de lesiones representa un riesgo agronómico mayor que la generación de falsas alarmas.

No obstante, el bajo valor de precisión (0.0102) evidencia la presencia de un número elevado de falsos positivos. Este comportamiento se interpreta como una consecuencia directa de la estrategia de priorización de sensibilidad adoptada por el modelo *Nano*, favorecida por su menor complejidad y mayor tolerancia a variaciones visuales.

Adicionalmente, el tiempo de inferencia promedio de 6.84 ms posiciona al modelo *Nano* como una alternativa altamente viable para su implementación en dispositivos de borde, tales como teléfonos móviles o cámaras de campo, alineándose con las condiciones tecnológicas reales del entorno agrícola del municipio de Paipa.

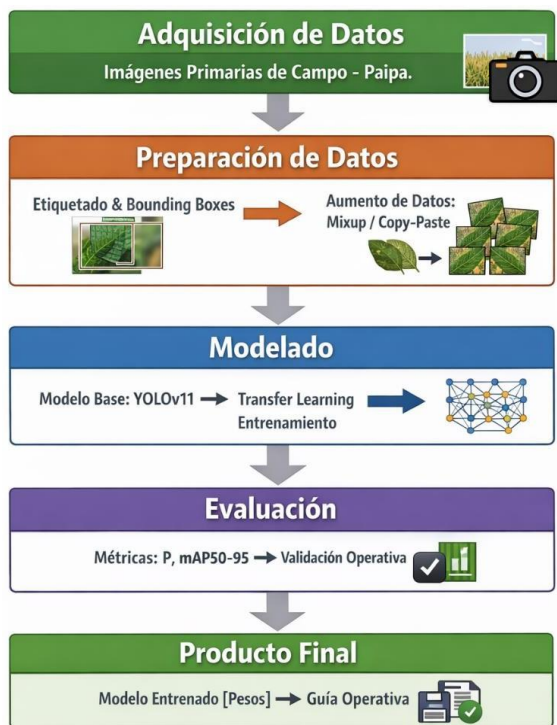
Síntesis Interpretativa de los Resultados

Los resultados confirman que, bajo las condiciones experimentales del estudio, el modelo YOLOv11 Nano presenta un mejor equilibrio funcional entre sensibilidad, velocidad y capacidad de generalización, mientras que el modelo *Small*, a pesar de su elevada precisión, muestra una limitada utilidad práctica debido al sobreajuste.

Desde una perspectiva fitosanitaria, resulta preferible un modelo con mayor Recall que garantice la detección temprana de la enfermedad, aun a costa de una menor precisión, especialmente cuando el sistema está concebido como una herramienta de alerta temprana y no como un diagnóstico definitivo.

Figura 1

Diagrama de Flujo Proceso Metodológico

**Figura 2**

*Hoja de cebada con lesiones foliares necróticas características de *Pyrenophora teres**




Nota tomada de Ignacio Scandola (@ing.nicolas.scandola). (2025, 14 de enero).Instagram.

<https://www.instagram.com/p/DQ-IQMpdNzu/>

Figura 3

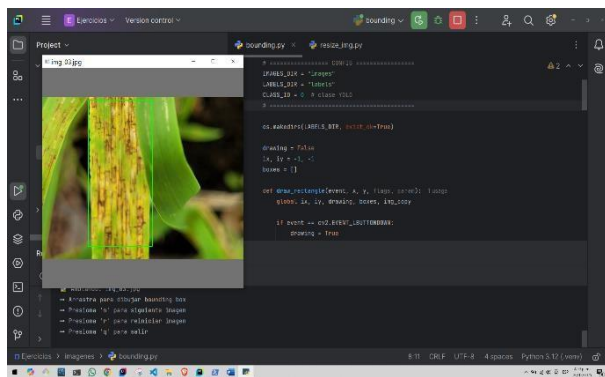
Hoja de Cebada sin Síntomas de Patógenos, Utilizada como Referencia de Tejido Sano



Nota. Tomada de Facultad de Ciencias Agrarias, UNMdP. (2023). En Patógenos y tratamiento (p. 12). <https://fca.mdp.edu.ar/wp-content/uploads/2023/09/IDE07-2022-PATOGENOS-Y-TRATAMIENTO.pdf>

Figura 4

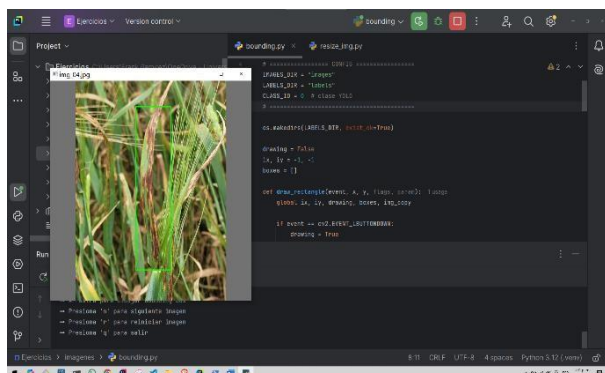
Anotación de Patología en Ejemplar Completo de Cebada



Nota. Se observa la delimitación de múltiples focos infecciosos en una planta con infección avanzada.

Figura 5

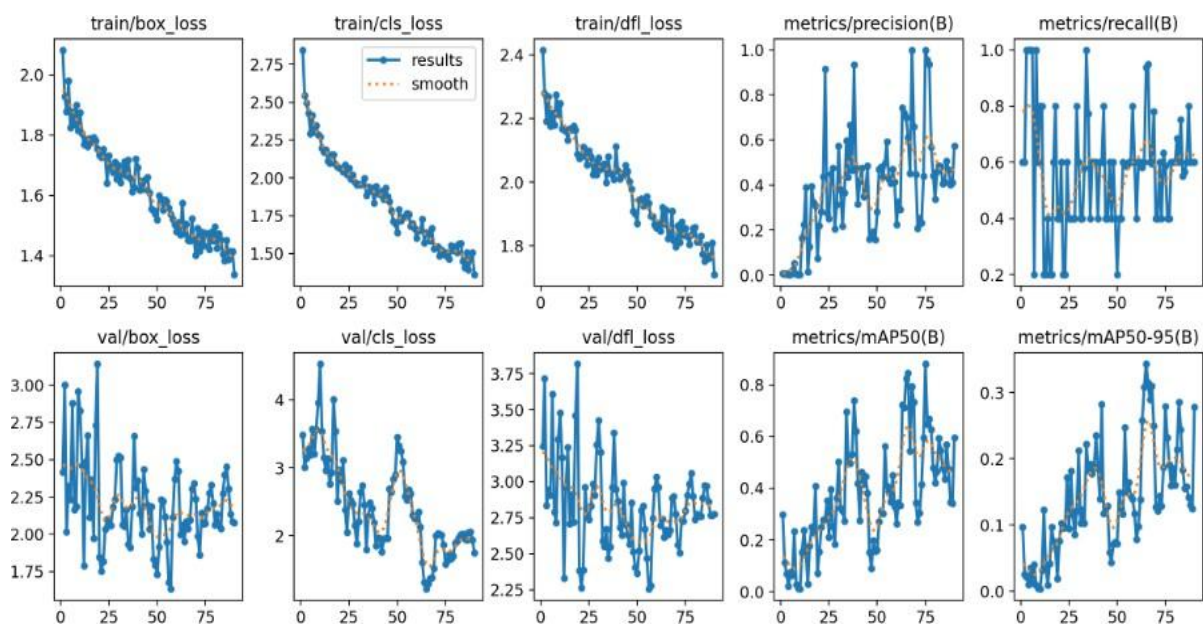
Etiquetado Manual en Entorno de Cultivo Real



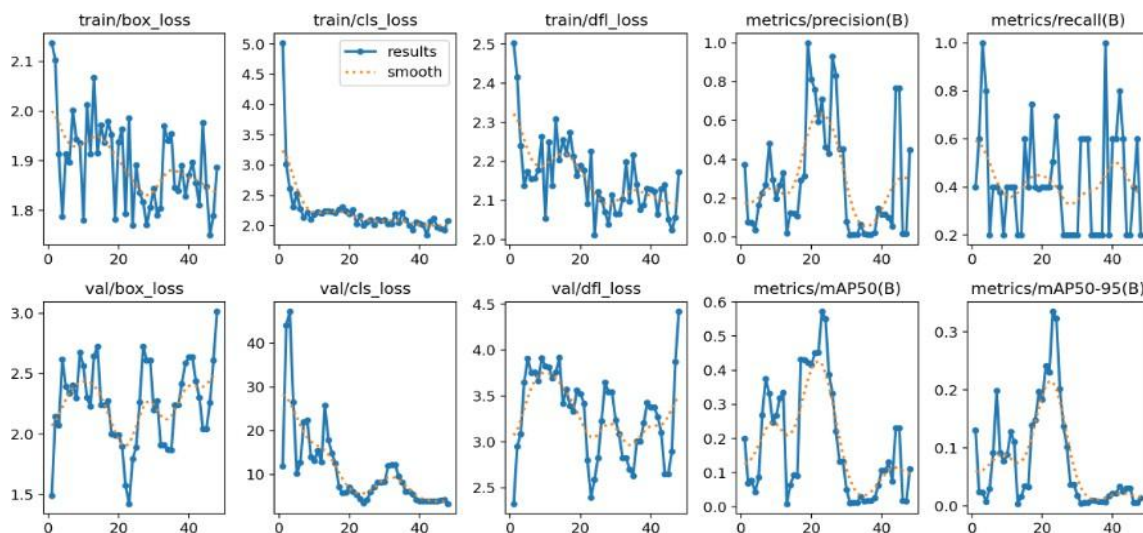
Nota. Se ilustra la generación de etiquetas sobre imágenes con fondos complejos (suelo y rastrojo), optimizando la robustez del modelo YOLOv11n.

Figura 6


Gráficas de Métricas y Funciones de Pérdida para el Modelo



Nota. Se evalúa la precisión (P), sensibilidad (R) y el mAP. La convergencia rápida de las curvas de pérdida (Box y Cls Loss)

Figura 7*Gráficas de Desempeño para el Modelo Small*

Nota. A diferencia de la versión nano, esta arquitectura presenta una mayor profundidad en la extracción de características, lo que se refleja en una curva de mAP50 con menor oscilación en las épocas finales.

Figura 8*Muestra de Batch de Entrenamiento con Técnica de Mosaico*

Nota. Se evidencia la variabilidad de ángulos, zooms y combinaciones de imágenes que fortalecen la resiliencia del algoritmo ante el ruido visual del entorno agrícola de Paipa.

Figura 9

Comparativa Resultados Modelo Nano Vs Small

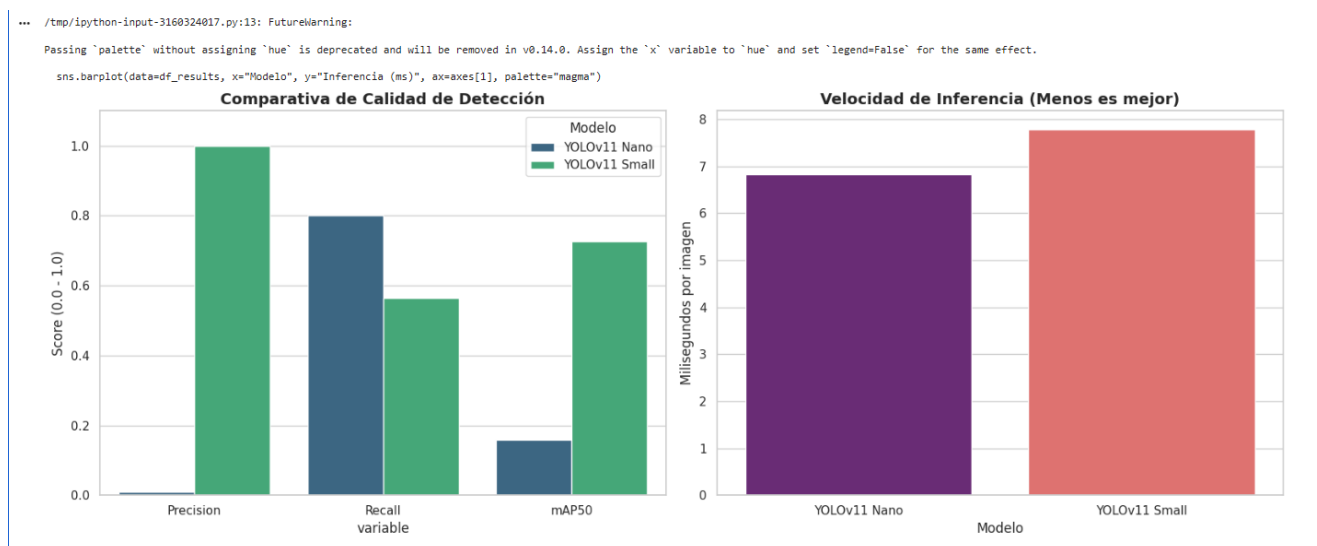


Figura 10

Resumen Métricas Comparativas

```

### RESUMEN DE MÉTRICAS COMPARATIVAS ###

```

	Modelo	mAP50	mAP50-95	Precision	Recall	Inferencia (ms)	Loss Final
0	YOLOv11 Nano	0.1578	0.0543	0.0102	0.8000	6.84 ms	0.0000
1	YOLOv11 Small	0.7266	0.2142	1.0000	0.5644	7.79 ms	0.0000

Conclusiones

La presente investigación demuestra que la aplicación de modelos de Visión por Computador basados en Deep Learning constituye una alternativa técnicamente viable y científicamente sólida para la detección temprana de la Mancha en Red (*Pyrenophora teres*) en cultivos de cebada cervecera del municipio de Paipa, Boyacá.

En particular, el estudio confirma que la arquitectura YOLOv11, ajustada mediante técnicas de *transfer learning* y fortalecida con estrategias de aumento de datos, es capaz de identificar y localizar lesiones foliares en condiciones reales de campo, caracterizadas por fondos complejos y variabilidad ambiental.

El análisis comparativo entre las variantes *Nano* y *Small* permitió evidenciar un aspecto crítico en la implementación de modelos de aprendizaje profundo en contextos agrícolas locales: la relación directa entre la complejidad del modelo y el tamaño del dataset disponible. El modelo YOLOv11 *Small*, si bien alcanzó valores perfectos de precisión, presentó un marcado sobreajuste, limitando su capacidad de generalización y reduciendo su utilidad operativa para la detección temprana de la enfermedad.

Por el contrario, el modelo YOLOv11 *Nano* mostró una mayor sensibilidad en la identificación de focos infecciosos, lo cual resulta prioritario desde el punto de vista agronómico, dado que la omisión de lesiones puede derivar en pérdidas significativas de rendimiento. Su alta velocidad de inferencia refuerza además su idoneidad para ser desplegado en sistemas de monitoreo en tiempo real y dispositivos de bajo costo.

Se concluye, por tanto, que la selección de arquitecturas livianas y robustas, combinada con técnicas de aumento de datos, representa una estrategia más adecuada para escenarios con restricciones de datos, como los presentes en la agricultura regional colombiana. Asimismo, el

estudio pone de manifiesto que el sobreajuste no debe interpretarse únicamente como una falla técnica, sino como una señal metodológica que orienta la toma de decisiones sobre el diseño del modelo y la necesidad de ampliar los conjuntos de datos primarios.

Finalmente, esta investigación sienta bases metodológicas y tecnológicas para el desarrollo futuro de sistemas de alerta fitosanitaria inteligentes, contribuyendo a la reducción del uso indiscriminado de fungicidas, al fortalecimiento de la agricultura de precisión y a la sostenibilidad del cultivo de cebada cervecera en el altiplano cundiboyacense.

Recomendaciones

Aplicación en el Sector Productivo y Transferencia Tecnológica

Adopción de monitoreo inteligente: Se recomienda a los productores del municipio de Paipa la integración progresiva de herramientas de visión artificial con sensores de bajo costo para el monitoreo de humedad y temperatura. Esta sinergia permitirá correlacionar la presencia visual de la "Mancha en Red" con variables climáticas, optimizando los tiempos de respuesta ante brotes fúngicos.

Capacitación y alfabetización digital: Es imperativo que las entidades de extensión agrícola implementen programas de formación técnica para los agricultores. El enfoque debe centrarse en la interpretación de los resultados de modelos como YOLO, asegurando que un índice de confianza del 71% se traduzca en decisiones agronómicas precisas y no en aplicaciones innecesarias de fungicidas.

Sugerencias para Trabajos Futuros y Profundización Técnica

Consolidación de Datasets Regionales: Dada la limitante identificada en este proyecto respecto al volumen de datos primarios, se recomienda a la academia priorizar la creación de un banco de imágenes específico para las variedades de cebada del altiplano cundiboyacense. Este dataset debe incluir diversas condiciones de iluminación y etapas fenológicas para reducir la dependencia de técnicas de aumentación sintética.

Exploración de Arquitecturas y Generación Sintética: Para investigaciones futuras, se sugiere el uso de Redes Generativas Adversarias para sintetizar imágenes de patologías en etapas iniciales. Esto permitiría fortalecer el entrenamiento de la red sin necesidad de esperar a brotes masivos en campo, mejorando la capacidad de generalización ante síntomas atípicos.

Implementación de IA Explicable (XAI): Se recomienda profundizar en técnicas de aplicabilidad que permitan visualizar qué características morfológicas están priorizando los modelos de aprendizaje profundo para sus predicciones. Esto aumentaría la confianza de los fitopatólogos en las herramientas de detección automática.

Referencias Bibliográficas

- Agritotal. (2020, 29 de junio). Avances clave para el control de la mancha en red de la cebada.
<https://www.agritotal.com/nota/avances-clave-para-el-control-de-la-mancha-en-red-de-la-cebada/>
- AGROSAVIA. (2020a). *Manual de enfermedades en cereales de clima frío moderado en Colombia*. Corporación Colombiana de Investigación Agropecuaria.
- AGROSAVIA. (2020b). *Manual técnico para el cultivo de cebada (Hordeum vulgare L.) en el Altiplano Cundiboyacense*. Corporación Colombiana de Investigación Agropecuaria.
- Cuthill. (s. f.). Mancha en red en cebada: una enfermedad que no podemos descuidar.
<https://www.cuthill.com.ar/mancha-en-red-en-cebada-una-enfermedad-que-no-podemos-descuidar/>
- Engormix. (s. f.). Cebada (Hordeum vulgare ssp. vulgare).
https://www.engormix.com/ganaderia/verdeos/cebada-hordeum-vulgare-ssp_a48897/
- Facultad de Agronomía de la Universidad de Buenos Aires (FAUBA). (s. f.). Mancha en red de la cebada (Drechslera teres). *Herbario Virtual de Fitopatología*.
https://herbariofitopatologia.agro.uba.ar/?page_id=97
- FAO. (2021). *Digital agriculture in action: Innovations for sustainable food systems*. Food and Agriculture Organization of the United Nations.
- Formento, A. N. (2022). *Patógenos y tratamiento de semillas en cereales de invierno* [Archivo PDF]. Facultad de Ciencias Agrarias, Universidad Nacional de Mar del Plata.
<https://fca.mdp.edu.ar/wp-content/uploads/2023/09/IDE07-2022-PATOGENOS-Y-TRATAMIENTO.pdf>

Jocher, G., & Qiu, J. (2024). *YOLOv11: Real-time object detection and segmentation*.

Ultralytics. <https://docs.ultralytics.com/models/yolo11/>

Liu, S., Wang, X., & Liu, G. (2022). Impact of fungal diseases on cereal crops: A global perspective on yield loss and control. *Frontiers in Plant Science*, 13, Artículo 852104.

<https://doi.org/10.3389/fpls.2022.852104>

Liu, Z., Shi, G., Oliver, R. P., & Friesen, T. L. (2022). Historical and future perspectives of the barley net blotch fungus *Pyrenophora teres*. *Molecular Plant Pathology*, 23(1), 3–12.

<https://doi.org/10.1111/mpp.13146>

McLean, M. S., Martin, A., Gupta, S., Hollaway, G. J., & Sutherland, M. W. (2019a). Validation of a molecular method for the detection and quantification of *Pyrenophora teres* in barley leaves. *Plant Disease*, 103(8), 1957–1963. <https://doi.org/10.1094/PDIS-10-18-1755-RE>

McLean, M. S., Martin, A., Gupta, S., Sutherland, M. W., & Hollaway, G. J. (2019b). Loss of grain yield and quality of barley due to net form net blotch and spot form net blotch in Australia. *Plant Disease*, 103(6), 1184–1191.

Mohanty, S. P., Hughes, D. P., & Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*, 7, Artículo 1419.

<https://doi.org/10.3389/fpls.2016.01419>

Pérez, M., & Carmona, M. (s. f.). *Manejo de enfermedades de trigo y cebada* [Archivo PDF].

Facultad de Agronomía (UBA) – BASF.

https://posgrado.agro.unlp.edu.ar/pluginfile.php/92061/mod_resource/content/2/enfermedades-Trigo-Cebada-FAUBA-BASF.pdf

- Polder, G., van de Westelaken, J., & van der Heijden, G. (2020). Deep learning for plant health monitoring in agricultural fields. *Computers and Electronics in Agriculture*, 175, Artículo 105525. <https://doi.org/10.1016/j.compag.2020.105525>
- Polder, G., van de Zedde, R., & Buijs, J. J. (2020). Deep learning for machine vision in agriculture: A review of recent applications in the United States and Europe. *Computers and Electronics in Agriculture*, 178, Artículo 105742. <https://doi.org/10.1016/j.compag.2020.105742>
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 28, 91–99.
- Singh, A. K., Ganapathysubramanian, B., Sarkar, S., & Singh, A. (2021). Deep learning for plant stress phenotyping: Trends and future perspectives. *Trends in Plant Science*, 26(5), 469–481. <https://doi.org/10.1016/j.tplants.2020.12.004>
- Ultralytics. (2024). *YOLO11 documentation: Real-time object detection and predictive analytics*. <https://docs.ultralytics.com/models/yolo11/>
- Wang, D., Wang, J., & Li, W. (2020a). Single-shot object detection in agricultural environments: A review. *Frontiers in Plant Science*, 11, Artículo 563. <https://doi.org/10.3389/fpls.2020.00563>
- Wang, D., Wang, J., & Li, W. (2020b). Efficient crop disease detection based on YOLOv3 and optimized feature extraction. *Agricultural Engineering*, 51(3), 202–214.
- Zadoks, J. C., Chang, T. T., & Konzak, C. F. (2014). *The history of plant pathology and cereal growth stages*. Cambridge University Press.

Zhang, Y., Liu, X., & Chen, J. (2023a). Performance comparison of YOLO versions for disease detection in complex field backgrounds. *Journal of Agricultural Engineering*, 54(2), 112–125.

Zhang, Y., Sun, L., & Zheng, J. (2023b). Performance comparison of YOLOv5 and YOLOv8 in complex agricultural backgrounds for cereal disease monitoring. *Biosystems Engineering*, 228, 45–59. <https://doi.org/10.1016/j.biosystemseng.2023.02.004>