



RESEARCH ARTICLE



Detection of late blight in potato leaves using drone images and Deep Learning techniques

Detección del tizón tardío en folíolos de papa usando imágenes tomadas con dron y técnicas de Deep Learning

J. A. Cairampoma^{1*}, Delia Gamarra-Gamarra¹, F. E. Dionisio¹

1 Universidad Nacional del Centro del Perú, Av. Mariscal Castilla 3909, Huancayo, Perú.

* Corresponding author: jcairampoma@uncp.edu.pe (J. Cairampoma).

Received: 4 July 2025. Accepted: 26 January 2026. Published: 16 February 2026.

Abstract

Phytophthora infestans causes one of the most devastating diseases of the potato crop, also known as late blight. Since early identification of this pathogen is crucial for the effective control of the disease, this study aimed to propose an automated methodology for the identification of its lesions in potato leaflets, using convolutional neural networks called "Mask R-CNN". The evaluations were carried out during the rainy season, in crops conducted by farmers in the locality of Huasahuasi, in the central Andes of Peru. One hundred photographs (5472×3078 pixels) were taken with a Phantom 4 Pro unmanned aerial vehicle (UAV) at an altitude of 3 m in crops with a late blight incidence between 2 and 3. The images were divided into four parts and then passed thorough quality control, resulting in 200 photos (1825×1369 pixels). Of the total, 75% was used for model training and 25% for model validation. The models were evaluated under real conditions, using metrics such as accuracy and recall. It was determined that the Mask R-CNN neural network, based on the ResNet 101 deep neural network architecture, offers acceptable accuracy and effectiveness (73.5%) in the identification of late blight lesions at the leaflet level. This methodology constitutes a significant contribution to precision agriculture in the Andes, validating a non-invasive tool capable of overcoming the topographical limitations of the area. Its practical application would optimize the use of fungicides through targeted detection, thereby promoting more sustainable and profitable potato production systems for local farmers.

Keywords: Late blight detection; Unmanned aerial vehicle (UAV); Dron; Convolutional neural network; Mask R-CNN; Potato leaflets.

Resumen

Phytophthora infestans causa una de las enfermedades más devastadoras del cultivo de papa, también conocida como tizón tardío. Dado que la identificación temprana de este patógeno es crucial para el control efectivo de la enfermedad, este estudio tuvo como objetivo proponer una metodología automatizada para la identificación de sus lesiones en foliolos de papa, utilizando redes neuronales convolucionales llamadas "Mask R-CNN". Las evaluaciones se llevaron a cabo durante la temporada de lluvias, en cultivos realizados por agricultores en la localidad de Huasahuasi, en los Andes centrales del Perú. Se tomaron cien fotografías (5472×3078 píxeles) con un vehículo aéreo no tripulado (UAV) Phantom 4 Pro a una altitud de 3 m en cultivos con una incidencia de tizón tardío entre 2 y 3. Las imágenes se dividieron en cuatro partes y luego pasaron un riguroso control de calidad, dando como resultado 200 fotos (1825×1369 píxeles). Del total, el 75% se utilizó para el entrenamiento del modelo y el 25% para su validación. Los modelos se evaluaron en condiciones reales, utilizando métricas como la precisión y la recuperación. Se determinó que la red neuronal Mask R-CNN, basada en la arquitectura de red neuronal profunda ResNet 101, ofrece una precisión y efectividad aceptables (73,5%) en la identificación de lesiones de tizón tardío a nivel de foliol. Esta metodología constituye una contribución significativa a la agricultura de precisión en los Andes, al validar una herramienta no invasiva capaz de superar las limitaciones topográficas de la zona. Su aplicación práctica optimizaría el uso de fungicidas mediante la detección dirigida, promoviendo así sistemas de producción de papa más sostenibles y rentables para los agricultores locales.

Palabras clave: Detección del tizón tardío; Dron; Red neuronal convolucional; Mask R-CNN; Foliolos de papa.

DOI: <https://doi.org/10.17268/sci.agropecu.2026.020>

Cite this article:

Cairampoma, J. A., Gamarra-Gamarra, D., & Dionisio, F. E. (2026). Detección del tizón tardío en foliolos de papa usando imágenes tomadas con dron y técnicas de Deep Learning. *Scientia Agropecuaria*, 17(2), 293-303.

1. Introducción

Phytophthora infestans causa la enfermedad comúnmente llamada tizón tardío o ranchita, es considerada la enfermedad más destructiva a nivel

mundial del cultivo de papa (Ivanov et al., 2021). En el Perú, es la principal limitación en la producción de este tubérculo, ya que reduce drásticamente su rendimiento. Esta enfermedad es más prevalente y

dañina entre los 2800 y 3500 m s. n. m. (**Zevallos et al., 2021**). Su manejo resulta particularmente desafiante debido a las condiciones climáticas y otros factores (**Perez et al., 2022**). Dado que la papa es un alimento básico y una de las principales fuentes de ingresos para los agricultores en las zonas altoandinas (**Devaux et al., 2020**), es necesario desarrollar estrategias eficaces para controlar esta enfermedad.

Los síntomas iniciales se manifiestan en los folíolos en forma de pequeñas manchas irregulares (**Berhan, 2021**). En condiciones ambientales propicias adquiere un color que va desde castaño a marrón oscuro. Estas lesiones se delimitan claramente de las áreas sanas (**Duarte-Carvajalino et al., 2018**). Las lesiones pueden extenderse por toda la superficie foliar y avanzar a través del pecíolo hacia el tallo. En algunos cultivos se observa un halo verde claro alrededor del tejido necrótico. Asimismo, pueden manifestarse en hojas y tallos pocas horas después de la infección, dependiendo de las condiciones ambientales y la susceptibilidad del hospedante (**Majeed et al., 2017**).

La evaluación tradicional de esta enfermedad se basa en la medición de la incidencia y la severidad en el campo. Este método directo presenta varias desventajas: es invasivo y puede contribuir a la diseminación de la enfermedad, requiere personal técnico especializado, se limita a muestrear áreas reducidas del cultivo, lo que compromete su eficacia y representatividad. En las zonas altoandinas del Perú, como en Huasahuasi, donde las condiciones agroclimáticas y edáficas son ideales para el cultivo de papa y también para el desarrollo del hongo *P. infestans*. La evaluación tradicional resulta poco práctica debido a lo agreste de la zona y sus altas pendientes. Por lo tanto, es esencial buscar métodos de evaluación menos invasivos y más eficaces que puedan adaptarse a las condiciones particulares de estas regiones.

Recientemente, se han propuesto técnicas novedosas para la identificación de enfermedades en diversos cultivos. Entre estas innovaciones destaca la visión por computadora, una técnica basada en algoritmos de aprendizaje profundo (DL, *Deep Learning*) (**Matsuo et al., 2022**) que forman parte de las redes neuronales artificiales (ANN, por sus siglas en inglés). Estas redes simulan la estructura y el proceso neuronal humano con el objetivo de reconocer patrones (**Baba, 2024; Bai et al., 2021**). La literatura más actual de 2025 evidencia un avance significativo hacia modelos más robustos y ligeros capaces de operar en entornos complejos. Por ejemplo, **Alanazi (2025)** demostraron la eficacia de

la arquitectura YOLOv10 en la agricultura de precisión, logrando detecciones en tiempo real con alta fidelidad para enfermedades foliares. Asimismo, **MK & Matharasi (2025)** presentaron mejoras significativas en la predicción de enfermedades de la papa utilizando técnicas avanzadas de Deep Learning. En el caso específico de la papa, estudios recientes han comenzado a integrar modelos híbridos (como EfficientNet combinado con Vision Transformers) que superan en precisión a las redes convencionales (**Sinamenye et al., 2025**).

Por ejemplo, **Yu et al. (2022)** usaron DL para el reconocimiento automático de enfermedades en hojas de soja, logrando resultados muy satisfactorios. Este algoritmo también fue usado por **Kunduracioglu & Pacal (2024)** en el diagnóstico de enfermedades de la uva. **Ganesh et al. (2019)** y **Yu et al. (2019)** lo usaron en la caracterización de la calidad y madurez de los frutales. También se han mejorado las técnicas de monitoreo en el campo mediante el uso de diversos equipos como las cámaras fotográficas convencionales, cámaras hiperespectrales, el uso de drones o satelitales (**Abbas et al., 2023; Jadhav et al., 2023; Wang et al., 2021**).

En este contexto, el presente estudio tuvo como objetivo proponer una nueva metodología automatizada para la identificación de síntomas del *P. infestans* en folíolos de papa en condiciones de cultivos de agricultores de la localidad de Huasahuasi, basada en el uso de DRON para el muestreo y la aplicación de técnicas de DL para la detección de las lesiones. Esta técnica tiene el potencial de superar las limitaciones de los métodos tradicionales al ofrecer una evaluación no invasiva, eficiente y a gran escala, adaptada a las condiciones específicas de la topografía agreste y las particularidades agroclimáticas de la zona de estudio.

2. Metodología

2.1. Área de estudio

El presente estudio se realizó en campos de agricultores del agroecosistema de Huasahuasi, situado en la provincia de Tarma, en la región de Junín (**Figura 1**). Geográficamente, se ubica en los Andes centrales del Perú, en el flanco oriental, entre las latitudes sur de 11°15'14.44" y 11°15'24.16", con las longitudes oeste 75°41'11.60" y 75°41'20.68", a una altitud de 3480 m s. n. m. Esta zona presenta un clima templado semiseco con alta humedad durante todo el año. La temperatura media anual oscila entre 6 y 9 °C, con temperaturas máximas anuales que varían entre 14 y 18 °C. Los meses más cálidos van de octubre a marzo.

Las lluvias acontecen durante todo el año, con un período de abundancia en los meses de diciembre a marzo (80-93 mm mensuales) y un período seco de junio a agosto. Estas condiciones climáticas son propias de las "yungas" o regiones de bosque nuboso y son ideales para el cultivo de papa, así como también para el desarrollo de *P. infestans*. El área de estudio presenta una pendiente pronunciada (~40%); de acuerdo con Ditzler et al. (2017) estas tierras se clasifican como muy escarpadas. En este agroecosistema, las áreas de siembra son pequeñas, con campos de cultivo que tienen una extensión promedio de 2,7 mil m².

2.2. Detección del tizón tardío en folíolos de papa

Para cumplir con el objetivo propuesto, el presente estudio sigue tres fases (**Figura 2**), las cuales se pasan a describir a continuación.

A. Procesamiento de datos

A1. Selección de áreas de evaluación

El cultivo de la papa se siembra en la localidad de Huasahuasi desde septiembre hasta noviembre. Sin embargo, el día de siembra de cada parcela se realiza según el criterio de cada agricultor. Por lo tanto, durante los meses de evaluación se encontraron cultivos de papa en distintas fases fenológicas y con diferentes niveles de incidencia de *P. infestans*. En

estas condiciones seleccionamos las parcelas con cultivos que presentaban síntomas claramente visibles del tizón tardío en los folíolos. Correspondiendo a una incidencia de la enfermedad entre el 2 y 3, en la escala del 1 al 9 propuesta por Henfling (1987). Para garantizar que las lesiones evaluadas fueran causadas exclusivamente por *P. infestans*, la identificación visual fue validada al momento del etiquetado por expertos fitopatólogos, quienes confirmaron la presencia de signos característicos (como la esporulación blanquecina en el envés de las hojas húmedas) y descartaron síntomas similares provocados por otros patógenos como *Alternaria solani*.

A2. Toma de fotografías con el dron

Las evaluaciones se llevaron a cabo entre los meses de enero y marzo. Durante este periodo de evaluaciones se registraron temperaturas mínimas de 7,9 °C y máximas de 22,2 °C, con una humedad relativa promedio del 83,15% y una acumulación de lluvias de 289 mm. Estas condiciones agroclimáticas contribuyeron de manera significativa al desarrollo de la ranchería en el área de estudio (Ortiz et al., 2004). Para las evaluaciones de campo se utilizó un dron del tipo Phantom 4 Pro, provisto con un sensor CMOS de 1" con una resolución efectiva de 5472×3078 (20 megápixeles).

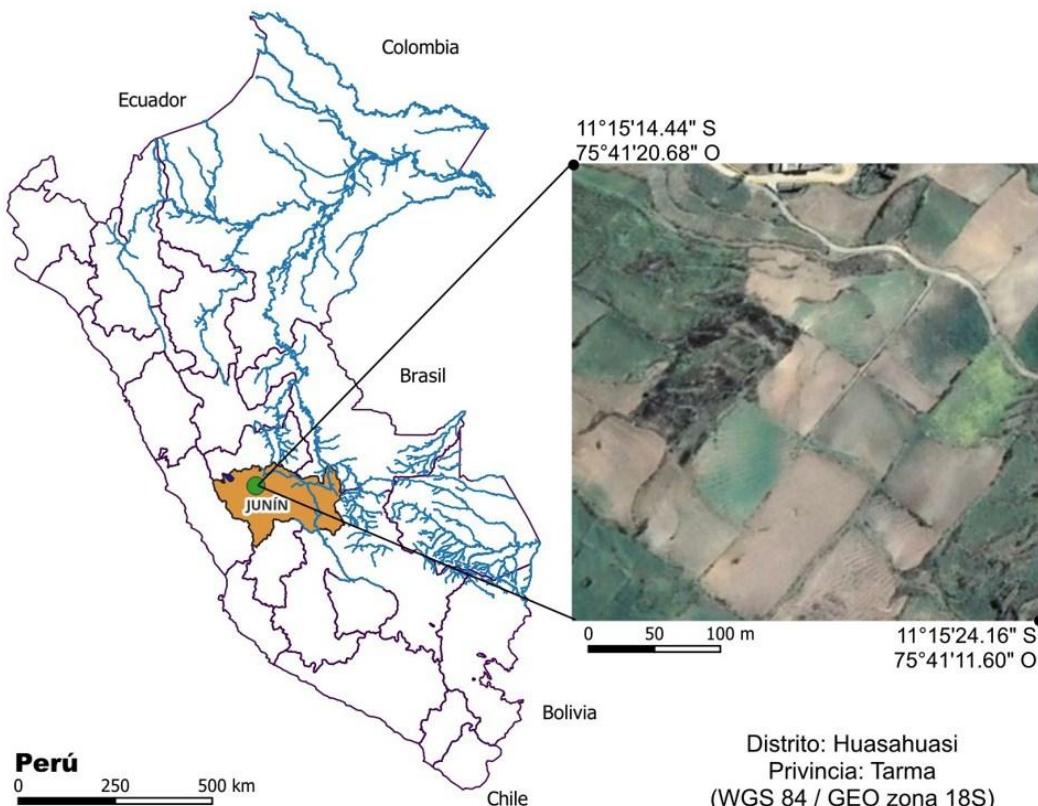


Figura 1. Ubicación de las áreas de estudio.

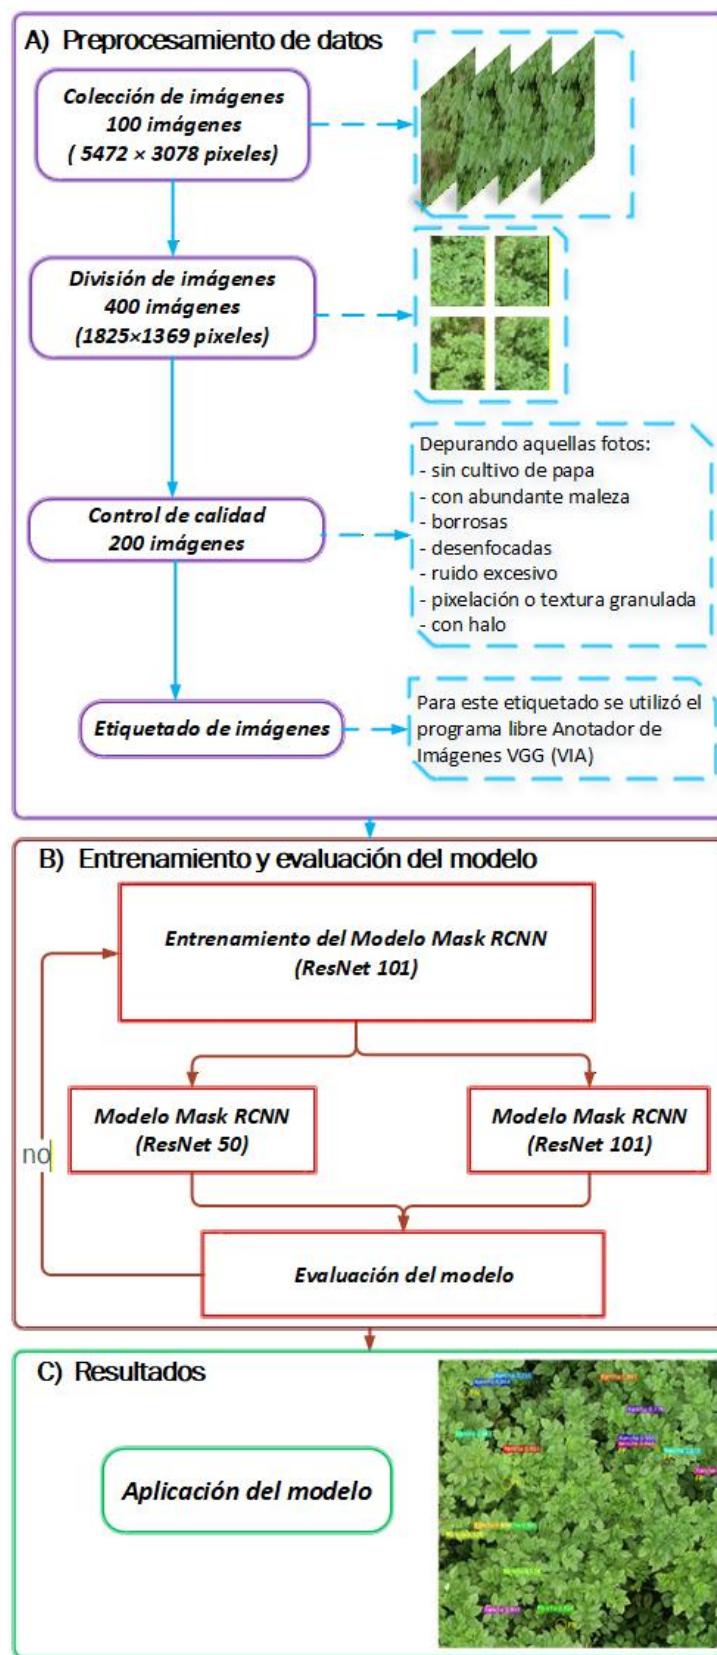


Figura 2. Flujograma para la detección del tizón tardío en foliolos de papa. A) Procesamiento de imágenes obtenidos con dron. B) Segmentación de instancias de lesiones de tizón tardío (*Phytophthora infestans*) en foliolos de papa utilizando Mask R-CNN con backbone ResNet-50 y ResNet-101 y C) aplicación de la red neuronal Mask R-CNN entrenada.

Los vuelos se realizaron a una altura de tres metros sobre el dosel del cultivo, manteniendo la cámara perpendicular al follaje. Para optimizar la calidad de las imágenes, las operaciones de vuelo se realizaron los días con menor presencia de niebla y preferentemente en ausencia de viento, típicamente entre las 11:00 a.m. y las 12:30 p.m. En total, se tomaron 100 fotografías durante todo el periodo de recolección de datos en campo.

A3. Procesamiento de imágenes

Las fotografías se dividieron en cuatro partes, con el objetivo de optimizar el proceso de entrenamiento y validación de la ANN Mask R-CNN. Las 400 imágenes resultantes de este proceso se sometieron a un riguroso control de calidad mediante inspección visual, con la finalidad de eliminar las que presentaban espacios sin cultivos de papa, con exceso de maleza, mal enfocadas, fotos pixeladas, con textura granulada o presencia de halo. Así, se obtuvieron 200 imágenes RGB de calidad con dimensiones de 1369×1825 píxeles. De este conjunto de imágenes, 150 se destinaron al entrenamiento del modelo y los 50 restantes al proceso de validación.

B. Entrenamiento y evaluación del modelo

B1. Entrenamiento del modelo

Con la finalidad de identificar las lesiones ocasionadas por *P. infestans* en las imágenes, se implementó la red neuronal convolucional del tipo Mask R-CNN (Rosebrock, 2017). Esta combina las estructuras de detección de objetos de última generación Faster R-CNN propuesta por Ren et al. (2015) y la red neuronal convolucional FCN que segmenta imágenes (Shelhamer et al., 2017). Faster R-CNN proporciona dos resultados para cada objeto identificado; un recuadro delimitador y una etiqueta de clase, mientras que FCN indica los píxeles correspondientes a la lesión identificada.

El entrenamiento y la validación de la red neuronal se realizaron en un ordenador equipado con una tarjeta gráfica Nvidia Quadro P1000 y con un procesador Intel Core i9-9900K de novena generación. Se creó un entorno virtual denominado "Mask R-CNN" desarrollado en Python 3.6. Además, se utilizaron las librerías de código abierto TensorFlow-gpu V1.5 y Keras V2.1, ambas especializadas en técnicas de aprendizaje profundo. En la ejecución de Mask R-CNN se usaron dos arquitecturas de redes neuronales profundas; ResNet-50 y ResNet-101. El algoritmo se implementó utilizando el repositorio de Matterport Inc., con licencia MIT. Además, para optimizar el proceso de entrenamiento se utilizó el modelo preentrenado MS COCO (Abdulla, 2021).

B2. Evaluación del modelo

Para determinar la precisión de los cuadros delimitadores predichos por el modelo Mask R-CNN con relación a la posición correcta de una lesión ocasionada por *P. Infestans* en la foto, el modelo asigna una clase binaria a cada cuadro delimitador: (1) probabilidad de que el cuadro delimitador enmarque una lesión; y (2) probabilidad de que el cuadro delimitador enmarque un área sin lesión. La disyunción entre ambas posibilidades se estableció mediante el umbral IoU (*Intersection over Union*). En el presente trabajo este valor se definió en 0,7 (Ecuación 1). Yan et al. (2019) concluyeron que el rendimiento de Mask R-CNN es sensible al IoU, especialmente cuando se trata de objetos pequeños como en nuestro caso. El uso de un umbral de IoU más alto (p. ej., > 0,8) podría mejorar la precisión, pero también podría hacer que el modelo pase por alto algunos casos reales. Por el contrario, elegir un umbral de IoU más bajo (p. ej., 0,6) podría aumentar la cantidad de falsos positivos. En este contexto, la elección del valor del umbral de IoU en el presente trabajo se justifica debido a la naturaleza irregular y a las dimensiones de las lesiones causadas por *P. infestans*. El objetivo es garantizar que las predicciones del modelo no solo detecten adecuadamente los daño, sino que también reflejen con precisión la extensión real de las lesiones.

$$\text{IoU} = \frac{\text{A} \cap \text{B}}{\text{A} \cup \text{B}} \begin{cases} > 0,7 \rightarrow \text{Con } P. \text{ infestans} \\ < 0,3 \rightarrow \text{Sin } P. \text{ infestans} \end{cases} \quad (1)$$

La relación $\text{A} \cap \text{B}$ en la Ecuación 1 está determinada por el área en común entre el cuadro delimitador predicho por Mask R-CNN y el recuadro que encierra un área dañada por el tizón tardío. Por su parte, la relación $\text{A} \cup \text{B}$ está determinada por la unión de ambos recuadros. El IoU permite establecer los siguientes criterios de identificación: si el IoU es igual o superior a 0,7, el modelo considera que el cuadro delimitador predicho por Mask R-CNN ha ubicado un área con tizón tardío y lo clasifica como un verdadero positivo. Por otro lado, si la IoU es menor de 0,3, el modelo considera que la detección es incorrecta y lo clasifica como falso positivo. Finalmente, en el caso de no cumplir ninguna de las condiciones anteriores ($0,3 < \text{IoU} < 0,7$), el modelo considera la detección neutra. Además, se definieron las métricas de evaluación del rendimiento. La métrica de precisión indica la capacidad de la ANN para detectar con precisión solo los casos relevantes y se calcula como la relación entre los verdaderos positivos y el total de lesiones identificadas. La métrica de recuperación, también llamada tasa de verdaderos positivos, evalúa la aptitud de la ANN para detectar la mayoría de los casos relevantes; se

calcula como la relación entre el número de verdaderos positivos detectados y el total de los casos positivos (**Padilla et al., 2020**).

C. Aplicación del modelo

Una vez entrenada y validada la red neuronal, se procedió a la fase de inferencia o aplicación del modelo en nuevas imágenes no vistas por el sistema, simulando el escenario de operación real en campo para la detección automatizada de *P. infestans*. Inicialmente, las nuevas imágenes capturadas por el dron (imágenes de prueba) se sometieron al mismo preprocesamiento que las de entrenamiento, incluyendo la normalización de dimensiones y ajustes de contraste, garantizando así que la entrada fuera consistente con los tensores esperados por la arquitectura ResNet-101.

A continuación, la imagen procesada se introdujo en la red Mask R-CNN, donde la red troncal (ResNet-101) extrajo los mapas de características y la Red de Propuesta de Regiones (RPN) sugirió áreas candidatas. Posteriormente, las cabeceras de la red predijeron simultáneamente la caja delimitadora (*bounding box*), la clase del objeto (tizón tardío) y la máscara de segmentación a nivel de píxel. Seguidamente, para evitar detecciones redundantes sobre una misma lesión, se aplicó el algoritmo

de Supresión de No Máximos (*Non-Maximum Suppression*), conservando únicamente aquellas detecciones cuyo índice de confianza superaba el umbral preestablecido de 0,7 (70%). De este modo, se descartaron predicciones de baja certeza o falsos positivos generados por ruido de fondo, tal como sugieren implementaciones estándar en agricultura de precisión (**Bondre & Patil, 2024; Ren et al., 2017**). Por último, el sistema superpuso las máscaras generadas y las cajas delimitadoras sobre la imagen original, etiquetando cada lesión con su porcentaje de probabilidad (ej. "Rancha 0,992"). Esto permitió cuantificar visualmente la severidad y distribución espacial de la enfermedad en el folíolo, validando la utilidad del modelo para el monitoreo fitosanitario (**Feng et al., 2023**).

3. Resultados y discusión

3.1. Etiquetado de imágenes

Las lesiones etiquetadas abarcaron en promedio 600 píxeles, lo que representa el 0,02% del total de una imagen procesada. Como era de esperar, las formas de las lesiones encontradas en las imágenes fueron ovoides, redondas y algunas amorfas. Estas se enmarcaron con un polígono siguiendo el contorno de la lesión (**Figura 3**).

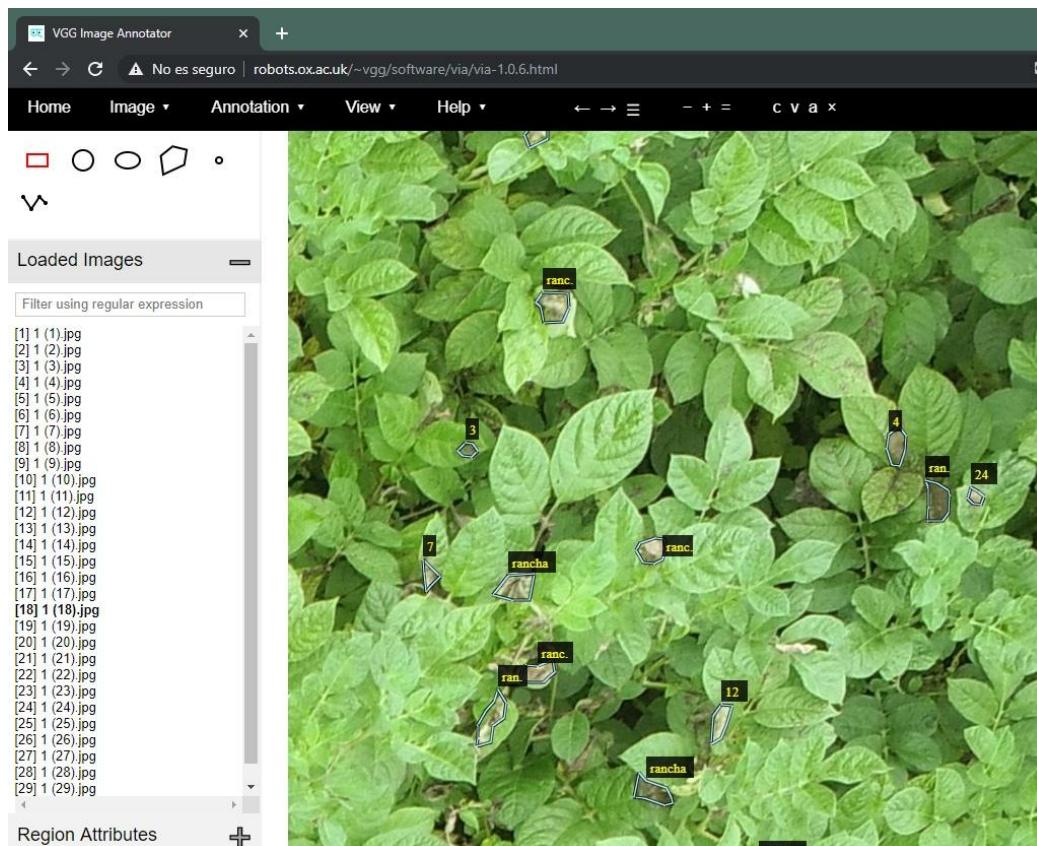


Figura 3. Etiquetado de folíolos con tizón tardío en el programa VIA ejecutado en Google.

Este procedimiento se realizó en el programa VIA de libre disponibilidad, ejecutado en la plataforma de Google. El número de lesiones etiquetadas en cada imagen para el entrenamiento fluctuó entre 20 y 30. En consecuencia, al final del proceso de etiquetado de las 150 imágenes se obtuvieron alrededor de 3,7 mil lesiones identificadas. Con el propósito de evitar la disminución de la precisión o el aumento de los falsos positivos y negativos, se ha tenido cuidado de enmarcar los píxeles correspondientes a la enfermedad, tratando de que ningún píxel quedara fuera del polígono delimitador y evitando enmarcar píxeles de áreas sanas.

3.2. Identificación de lesiones

La red neuronal Mask R-CNN permite identificar las lesiones ocasionadas por *P. infestans* mediante un conjunto de cuadros delimitadores de diferentes tamaños que pasan por cada píxel de la imagen, efectuando un barrido completo. La Figura 4a muestra una imagen con quince cuadros delimitadores para un solo píxel. Los rectángulos con una tonalidad de color similar ostentan tres relaciones diferentes entre su ancho y su altura (1:1, 1:2 y 2:1). Existen cinco grupos con diferentes tonalidades y dimensiones (322, 642, 1282, 2562 y 5122 píxeles). Estas relaciones y dimensiones de los cuadros delimitadores confieren la capacidad de capturar las formas descritas del tizón tardío en los folíolos de la papa (Zand et al., 2022).

Posteriormente, el algoritmo propone regiones de interés en función de los cuadros delimitadores. La red neuronal convolucional clasifica y refina estas regiones, permitiendo la detección precisa de las áreas con ranchas, generando máscaras de segmentación precisas para cada lesión identificada. Por ejemplo, en la parte central de la Figura 4b se observa un folíolo con una lesión causada por *P. infestans*. La red neuronal Mask R-CNN lo identifica con una probabilidad mayor del 80%, asignándole la etiqueta de ranchas. Este procedimiento facilita la detección de la ranchas y permite la delimitación eficaz de las áreas dañadas dentro de la imagen, incluso cuando las lesiones podrían ser difícilmente perceptibles en una inspección visual.

Se usaron los modelos Mask R-CNN con las arquitecturas ResNet-50 y ResNet-101 en cultivos de papa conducidos por agricultores de la localidad de Huasahuasi. Para ello, se tomaron fotografías con el dron siguiendo el mismo protocolo establecido en la toma de fotos para el proceso de entrenamiento y validación de las ANN. La diferencia es que se escogieron áreas con cultivos que mostraron una incidencia de la enfermedad de uno, que corresponde a la etapa temprana del desarrollo de *P. infestans*.

La fotografía utilizada para describir la aplicación del modelo Mask R-CNN presentaba 15 lesiones con un tamaño medio de 300 píxeles que no superaban la mitad de un folíolo.

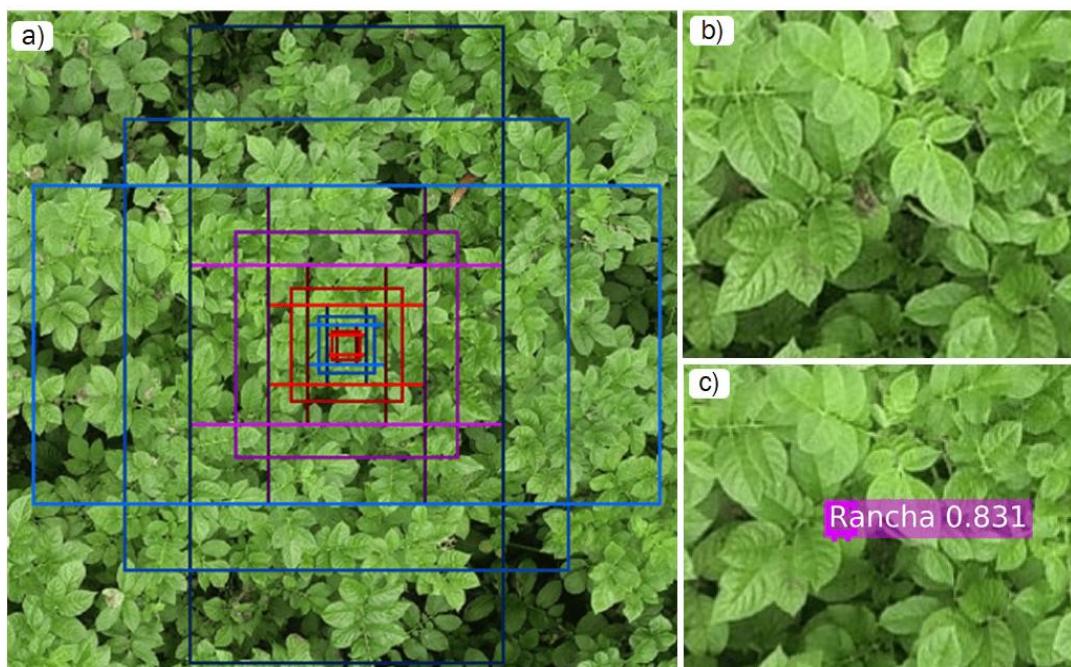


Figura 4. Proceso de detección de lesiones ocasionadas por *P. infestans*. a) Cuadros delimitadores definidos para un píxel. b) Folíolo con lesión. c) Resultado de la identificación de una lesión ocasionada por *P. infestans*.



Figura 5. Resultado de la aplicación del modelo Mask R-CNN con arquitectura ResNet-50.

Por tratarse de un área minúscula, no es fácil observarlas a simple vista; por lo que no podrían detectarse en una evaluación de campo. Comparativamente, en estudios como el de [Lin et al. \(2022\)](#) se ha logrado una alta precisión en la detección de frutas y flores en el cultivo de fresa en condiciones complejas, en las que el tamaño del objetivo es muy pequeño en comparación con la foto analizada. Este reporte refuerza aún más la metodología.

Al aplicar Mask R-CNN con arquitectura ResNet 50 se encontraron tres falsos positivos y trece fueron verdaderos positivos, además de tres FN en la imagen seleccionada (**Figura 5**). Este resultado concuerda con la curva de precisión y la tasa de verdaderos positivos determinados en la etapa de validación del modelo, lo que indica que, al detectar un gran número de lesiones, el número de falsos positivos también aumenta. En este sentido, podemos resaltar que uno de los verdadero positivo es una hoja seca de eucalipto (*Eucalyptus globulus*) del tipo falciforme, a pesar del tamaño de su área y forma, que difiere notablemente de una lesión

producida por el tizón tardío. En consecuencia, este modelo no tiene una buena performance en la detección de lesiones ocasionadas por *P. infestans* en hojas del cultivo de papa.

La **Figura 6** muestra la misma imagen, ahora con las lesiones identificadas aplicando el modelo Mask R-CNN con arquitectura ResNet 101. Este modelo detectó once lesiones ocasionadas por *P. infestans*, en las que no existe ningún falso positivo y todos son verdadero positivo. Además, se observó 4 FN. Debido a su notable precisión al momento de identificar las lesiones ocasionadas por *P. infestans* en la imagen de evaluación, con un reducido número de falsos positivos y falsos negativos, demostrando un elevado nivel de recuperación, consideramos que el modelo Mask R-CNN con arquitectura ResNet 101 es superior al modelo con arquitectura ResNet 50.

Al comparar las redes neuronales Mask R-CNN con las arquitecturas ResNet 50 y ResNet 101, se evidenció que ANN basada en ResNet 101 tuvo un mejor performance que la basada en ResNet 50 al ofrecer

un mejor rendimiento a la hora de identificar las lesiones ocasionadas por *P. infestans*. Esta superioridad se debe a que ResNet 101 logra mejor entrenamiento en comparación con la ResNet 50. Esta diferencia también se observa en la alta precisión que logra a medida que aumenta la tasa de verdaderos positivos. Esta capacidad de capturar una amplia gama de formas y tamaños de lesiones es crucial para la detección precisa del tizón tardío, dadas las características irregulares y variadas de las lesiones. El resultado de un mejor entrenamiento se refleja en la performance de la red neuronal para detectar la mayoría de las lesiones, al tiempo que se reducen los falsos positivos y los falsos negativos. Esto se corrobora con la diferencia en la métrica de precisión alcanzada en las arquitecturas Resnet 101 (73,5%) y Resnet 50 (64,5%). Nuestros resultados concuerdan con los reportados por **Hindarto (2023)**, quien prueba estas arquitecturas para la detección de enfermedades de las hojas del maíz. Adicionalmente, hay que considerar que ResNet-50 suele ofrecer un mejor rendimiento en aplicaciones prácticas, especialmente cuando el conjunto de datos no es tan

grande o diverso como para beneficiarse de la mayor complejidad, por lo que es ideal comparar ambas arquitecturas. Por ejemplo, **Phan et al. (2023)** reportaron que ResNet-50 produjo una precisión del 98% en la clasificación de tomates en comparación con el 97% de ResNet-101.

Recientemente, se han publicado trabajos, como los de **Bondre & Patil (2024)** y **Feng et al. (2023)**, que confirman nuestros resultados y proporcionan un soporte adicional a nuestros hallazgos, lo que nos permite proponer la red neuronal Mask R-CNN con arquitectura ResNet 101 como un método fiable para la detección de lesiones ocasionadas por *P. Infestans* en el cultivo de papa. Sin embargo, a diferencia de estos estudios nuestro planteamiento de usar drones para la evaluación en campo muestra la innovación de nuestro método para superar las complejidades inherentes de la zona de estudio con terrenos irregulares y vegetación densa que a menudo obstaculizan los métodos de evaluación tradicionales. Para ello, aprovechamos el poder de las tecnologías emergentes de agricultura de precisión.



Figura 6. Resultado de la aplicación del modelo Mask R-CNN con arquitectura ResNet-101.

El uso de imágenes capturadas con drones nos permitió superar los límites de lo que es posible para la detección de enfermedades de manera automatizada y escalable. Por tanto, los desafíos que imponen estos agroecosistemas con alta incidencia de *P. infestans* y de difícil acceso requieren el desarrollo de enfoques innovadores para el monitoreo y manejo del tizón tardío. De acuerdo con **Grados et al. (2020)**, existe una oportunidad significativa para mejorar los rendimientos del cultivo de papa en zonas altoandinas mediante un uso más racional de insumos y mejores prácticas agrícolas. Teniendo en cuenta que el cultivo de papa debe abordar las cargas ambientales dentro de las limitaciones socioeconómicas locales. Al proponer una herramienta automatizada y precisa para la detección temprana del tizón tardío, nuestra propuesta puede contribuir a mejorar la productividad del cultivo de papa, al tiempo que facilita prácticas de manejo más racionales y sostenibles, como la aplicación controlada de pesticidas, de acuerdo con las recomendaciones de **Babli et al. (2022)**. Esta integración de innovaciones tecnológicas y enfoques de intensificación sostenible es crucial para potenciar el desarrollo del sector papero en estos entornos desafiantes de las zonas altoandinas.

4. Conclusiones

El uso del dron Phantom 4 Pro, combinado con redes neuronales profundas como Mask R-CNN, ha demostrado ser una técnica promisoria en la evaluación de la incidencia del tizón tardío en los folíolos de papa en campos de agricultores de Huasahuasi (3480 m s. n. m.). El modelo basado en la arquitectura ResNet 101 alcanzó una precisión del 73,5% con un IoU del 70%, lo que le permitió identificar lesiones de aproximadamente 400 píxeles en imágenes RGB de 2,4 megapíxeles.

Al comparar las arquitecturas ResNet50 y ResNet101, se concluye que ResNet101 generalmente ofrece una precisión ligeramente superior para la identificación del tizón tardío en cultivos de papa. Aunque requiere más recursos computacionales y tiempo de procesamiento en comparación con las 50 capas de ResNet50, el incremento marginal en el rendimiento justifica su aplicación, especialmente si el tamaño del conjunto de datos es el adecuado. En general, la aplicación de técnicas avanzadas de visión por computadora se ha convertido en un enfoque prometedor para la detección y el seguimiento de enfermedades en el cultivo de papa. Aquí hemos resaltado la ventaja que ofrece esta metodología sobre los métodos tradicionales de evaluación y diagnóstico. En particular, el uso del

dron para la recopilación de imágenes representa una ventaja clave de nuestro método. Esta propuesta de captura de datos permite superar las limitaciones inherentes a los entornos agrestes y de alta pendiente, donde los métodos de inspección manual a menudo son ineficientes e impracticables. La capacidad de identificar lesiones es particularmente notable, ya que proporciona información detallada sobre el alcance y la distribución de los síntomas de la enfermedad, lo cual es crucial para implementar intervenciones oportunas y específicas.

Finalmente, como proyecciones futuras, se recomienda la implementación de estos algoritmos en plataformas de *edge computing* integradas a los drones para permitir la toma de decisiones en tiempo real. Asimismo, sería valioso expandir el entrenamiento del modelo incorporando diversas variedades de papa nativa y condiciones de iluminación variables, así como explorar la fusión de imágenes RGB con sensores multiespectrales. Esto no solo refinaría la precisión diagnóstica, sino que sentaría las bases para sistemas de aplicación automatizada de agroquímicos (drones pulverizadores), optimizando recursos y reduciendo el impacto ambiental en los Andes.

Agradecimientos

Los autores del proyecto de investigación agradecen a la Universidad Nacional del Centro del Perú (UNCP) por su financiamiento a través de la IV Convocatoria para el financiamiento de Proyectos de Investigación con fondos canon, sobre canon y regalías mineras.

Conflictos de interés: los autores declaran no tener conflictos de interés.

Contribución de los autores

J.A. Cairampoma: Supervisión, Administración del proyecto, Obtención de fondos, Metodología, Programación. Delia Gamarra-Gamarra: Metodología, Investigación, Redacción – revisión y edición. F.E. Dionisio: Asistente, Procesamiento de datos, Metodología, Investigación.

ORCID

J. A. Cairampoma  <https://orcid.org/0000-0002-1998-6178>
D. Gamarra-Gamarra  <https://orcid.org/0000-0002-6262-237X>
F. E. Dionisio  <https://orcid.org/0000-0002-9769-6782>

Referencias bibliográficas

- Abbas, A., Zhang, Z., Zheng, H., Alami, M. M., Alrefaei, A. F., Abbas, Q., Naqvi, S. A. H., Rao, M. J., Mosa, W. F. A., & Abbas, Q. (2023). Drones in plant disease assessment, efficient monitoring, and detection: a way forward to smart agriculture. *Agronomy*, 13(6), 1524. <https://doi.org/10.3390/agronomy13061524>
- Abdulla, W. (2021). *Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow*. https://github.com/matterport/Mask_RCNN
- Alanazi, R. (2025). A YOLOv10-based Approach for Banana Leaf Disease Detection. *Engineering, Technology & Applied Science Research*, 15(3), 23522-23526. <https://doi.org/10.48084/etasr.11138>

- Baba, A. (2024). Neural networks from biological to artificial and vice versa. *Biosystems*, 235, 105110. <https://doi.org/https://doi.org/10.1016/j.biosystems.2023.105110>
- Babli, D., Yadav, P. S., & Sheeren Parveen, V. K. (2022). Efficacy of different eco-friendly methods against late blight of potato, *Phytophthora infestans*: A review. *Pharma Innov. J*, 11, 1949-1961.
- Bai, X., Wang, X., Liu, X., Liu, Q., Song, J., Sebe, N., & Kim, B. (2021). Explainable deep learning for efficient and robust pattern recognition: A survey of recent developments. *Pattern Recognition*, 120, 108102. <https://doi.org/https://doi.org/10.1016/j.patcog.2021.108102>
- Berhan, M. (2021). Review on epidemiology, sampling techniques, management strategies of late blight (*Phytophthora infestans*) of potato and its yield loss. *Asian Journal of Advances in Research*, 4(1), 199-207. https://doi.org/10.1007/978-3-030-28683-5_1
- Bondre, S., y Patil, D. (2024). Crop disease identification segmentation algorithm based on Mask-RCNN. *Agronomy Journal*, 116(3), 1088-1098. <https://doi.org/https://doi.org/10.1002/agj2.21387>
- Devaux, A., Goffart, J.-P., Petsakos, A., Kromann, P., Gatto, M., Okello, J., Suarez, V., & Hareau, G. (2020). Global food security, contributions from sustainable potato agri-food systems. *The potato crop: Its agricultural, nutritional and social contribution to humankind*, 3-35. https://doi.org/10.1007/978-3-030-28683-5_1
- Ditzler, C., Scheffe, K., & Monger, H. C. (2017). *Soil survey manual*. USDA Handbook 18. Government Printing Office.
- Duarte-Carvajalino, J., Alzate, D., Ramirez, A., Santa-Sepulveda, J., Fajardo-Rojas, A., Soto-Suárez, M., 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), 1513. <https://doi.org/10.3390/rs10101513>
- Feng, J., Hou, B., Yu, C., Yang, H., Wang, C., Shi, X., & Hu, Y. (2023). Research and Validation of Potato Late Blight Detection Method Based on Deep Learning. *Agronomy*, 13(6), 1659. <https://doi.org/10.3390/agronomy13061659>
- Ganesh, P., Volle, K., Burks, T. F., & Mehta, S. S. (2019). Deep Orange: Mask R-CNN based Orange Detection and Segmentation. *IFAC-PapersOnLine*, 52(30), 70-75. <https://doi.org/10.1016/j.ifacol.2019.12.499>
- Grados, D., García, S., & Schrevens, E. (2020). Assessing the potato yield gap in the Peruvian Central Andes. *Agricultural Systems*, 181, 102817. <https://doi.org/https://doi.org/10.1016/j.agsy.2020.102817>
- Hindarto, D. (2023). Comparison of Detection with Transfer Learning Architecture RestNet18, RestNet50, RestNet101 on Corn Leaf Disease. *Jurnal Teknologi Informasi Universitas Lambung Mangkurat (JTULM)*, 8(2), 41-48. <https://doi.org/10.20527/jtulm.v8i2.174>
- Ivanov, A. A., Ukladov, E. O., & Golubeva, T. S. (2021). Phytophthora infestans: An Overview of Methods and Attempts to Combat Late Blight. *Journal of Fungi*, 7(12), 1071. <https://doi.org/10.3390/jof7121071>
- Jadhav, P., Kachave, V., Mane, A., & Joshi, K. (2023). Crop detection using satellite image processing. *I-Manager's Journal on Image Processing*, 10(2), 50-60. <https://doi.org/10.26634/jip.10.2.19800>
- Kunduracioglu, I., & Pacal, I. (2024). Advancements in deep learning for accurate classification of grape leaves and diagnosis of grape diseases. *Journal of Plant Diseases and Protection*, 131(3), 1061-1080. <https://doi.org/10.1007/s41348-024-00896-z>
- Lin, P., Zhang, H., Zhao, F., Wang, X., Liu, H., & Chen, Y. (2022). Boosted Mask R-CNN algorithm for accurately detecting strawberry plant canopies in the fields from low-altitude drone images. *Food Science and Technology*, 42, e95922. <https://doi.org/10.1590/fst.95922>
- Majeed, A., Muhammad, Z., Ullah, Z., Ullah, R., & Ahmad, H. (2017). Late blight of potato (*Phytophthora infestans*) I: Fungicides application and associated challenges. *Turkish Journal of Agriculture-Food Science and Technology*, 5(3), 261-266. <https://doi.org/10.24925/turjaf.v5i3.261-266.1038>
- Matsuo, Y., LeCun, Y., Sahani, M., Precup, D., Silver, D., Sugiyama, M., Uchibe, E., & Morimoto, J. (2022). Deep learning, reinforcement learning, and world models. *Neural Networks*, 152, 267-275. <https://doi.org/https://doi.org/10.1016/j.neunet.2022.03.037>
- MK, D., & Matharasi, P. B. (2025). Leaf Disease Predictions Using Deep Learning Techniques - Potato. *International Journal of Information Technology, Research and Applications*, 4(3), 33-42. <https://doi.org/10.5946/ijitra.v4i3.166>
- Ortiz, O., Garrett, K. A., Health, J. J., Orrego, R., & Nelson, R. J. (2004). Management of potato late blight in the Peruvian highlands: evaluating the benefits of farmer field schools and farmer participatory research. *Plant Disease*, 88(5), 565-571. <https://doi.org/10.1094/PDIS.2004.88.5.565>
- Padilla, R., Netto, S. L., & da Silva, E. A. B. (2020). A Survey on Performance Metrics for Object-Detection Algorithms. *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, 237-242. <https://doi.org/10.1109/IWSSIP48289.2020.9145130>
- Perez, W., Forbes, G. A., Arias, R., Pradel, W., Kawarazuka, N., & Andrade-Piedra, J. (2022). Farmer Perceptions Related to Potato Production and Late Blight Management in Two Communities in the Peruvian Andes. *Frontiers in Sustainable Food Systems*, 6, 873490. <https://doi.org/10.3389/fsufs.2022.873490>
- Phan, Q.-H., Nguyen, V.-T., Lien, C.-H., Duong, T.-P., Hou, M. T.-K., & Le, N.-B. (2023). Classification of tomato fruit using yolov5 and convolutional neural network models. *Plants*, 12(4), 790. <https://doi.org/10.3390/plants12040790>
- Ren, S., He, K., Girshick, R., & Sun, J. (2016). Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Rosebrock, A. (2017). *Deep Learning for Computer Vision with Python: ImageNet Bundle*. PyImageSearch.
- Shelhamer, E., Long, J., & Darrell, T. (2017). Fully convolutional networks for semantic segmentation. *IEEE transactions on pattern analysis and machine intelligence*, 39(4), 640-651.
- Sinamenye, J. H., Chatterjee, A., & Shrestha, R. (2025). Potato plant disease detection: leveraging hybrid deep learning models. *BMC Plant Biology*, 25(1), 647. <https://doi.org/10.1186/s12870-025-06679-4>
- Wang, F., Wang, C., Song, S., Xie, S., & Kang, F. (2021). Study on starch content detection and visualization of potato based on hyperspectral imaging. *Food Science & Nutrition*, 9(8), 4420-4430. <https://doi.org/https://doi.org/10.1002/fsn3.2415>
- Yan, J., Wang, H., Yan, M., Diao, W., Sun, X., & Li, H. (2019). IoU-Adaptive Deformable R-CNN: Make Full Use of IoU for Multi-Class Object Detection in Remote Sensing Imagery. *Remote Sensing*, 11(3). <https://doi.org/10.3390/rs11030286>
- Yu, M., Ma, X., Guan, H., Liu, M., & Zhang, T. (2022). A Recognition Method of Soybean Leaf Diseases Based on an Improved Deep Learning Model. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.878834>
- Yu, Y., Zhang, K., Yang, L., & Zhang, D. (2019). Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN. *Computers and Electronics in Agriculture*, 163, 104846. <https://doi.org/10.1016/j.compag.2019.06.001>
- Zand, M., Etemad, A., y Greenspan, M. (2022). Objectbox: From centers to boxes for anchor-free object detection. *European Conference on Computer Vision*, 390-406.
- Zevallos, E., Inga, J., Alvarez, F., Marmolejo, K., Paitan, R., Viza, I., Becerra, D., Rixi, G., & Silva-Diaz, C. (2021). First signs of late blight resistance in traditional native potatoes of Pasco—Peru, a preliminary assay. *Agriculture & Food Security*, 10(1), 33. <https://doi.org/10.1186/s40066-021-00330-9>