

Detección de Enfermedades Fúngicas en taxo mediante segmentación con YOLOv11.

Detection of Fungal Diseases in taxum by segmentation with YOLOv11.

Manolo Muñoz-Espinoza, Walter Moreno-Castillo, Jorge Zúñiga-Moreno, Franck Palacios-Ruiz & Edison Aguilar-Salán

PUNTO CIENCIA.

julio - diciembre, V°6 - N°2; 2025

Recibido: 18-09-2025

Aceptado: 18-09-2025

Publicado: 30-12-2025

PAIS

- Ecuador, Ambato
- Ecuador, Ambato
- Ecuador, Quero
- Ecuador, Ambato
- Ecuador, Ambato

INSTITUCION

- Universidad Técnica de Ambato
- Universidad Técnica de Ambato
- Investigador Independiente
- Universidad Técnica de Ambato
- Universidad Técnica de Ambato

CORREO:

- ✉ mmunoz@uta.edu.ec
- ✉ we.moreno@uta.edu.ec
- ✉ jorgezu-iga.198708011@hotmail.com
- ✉ fp.palacios@uta.edu.ec
- ✉ eaguilar1928@uta.edu.ec

ORCID:

- 🌐 <https://orcid.org/0000-0001-5897-1211>
- 🌐 <https://orcid.org/0000-0003-3907-371X>
- 🌐 <https://orcid.org/0009-0001-6948-730X>
- 🌐 <https://orcid.org/0009-0004-6333-4806>
- 🌐 <https://orcid.org/0009-0002-3147-6944>

FORMATO DE CITA APA.

Muñoz-Espinoza, M., Moreno-Castillo, W., Zúñiga-Moreno, J., Palacios-Ruiz, F. & Aguilar-Salán, E. (2025). Detección de Enfermedades Fúngicas en taxo mediante segmentación con YOLOv11. *Revista G-ner@ndo*, V°6 (N°2). Pág. 1492 – 1506.

Resumen

Este estudio propone un sistema automatizado para la detección y segmentación de enfermedades fúngicas —específicamente *Colletotrichum* spp. y *Oidium*— en cultivos de taxo (*Passiflora mollissima* H.B.K.) en Ecuador, utilizando el modelo de visión por computadora YOLOv11 para segmentación. Se construyó un conjunto de datos compuesto por 2.715 imágenes, etiquetadas manualmente en cuatro clases: *Colletotrichum*, *Oidium*, tejido sano y fondo. El modelo YOLOv11-seg alcanzó una precisión de 0.684, un recall de 0.509 y un mAP50 de 0.424. El análisis de la matriz de confusión evidenció un mejor desempeño en la identificación de *Oidium* (101 detecciones correctas), frente a *Colletotrichum* (18) y tejido sano (28), con confusiones significativas entre patógenos y el fondo. Adicionalmente, se documentaron distribuciones morfométricas que permiten caracterizar cuantitativamente los patrones de infección. Este trabajo sienta las bases metodológicas para sistemas de monitoreo fitosanitario automatizados en cultivos de taxo, con potencial para mejorar la eficiencia y sostenibilidad del manejo integrado de plagas en la región andina.

Palabras clave: visión por computadora, segmentación de imágenes, aprendizaje profundo.

Abstract

This study proposes an automated system for the detection and segmentation of fungal diseases — specifically *Colletotrichum* spp. and *Oidium* — in taxo crops (*Passiflora mollissima* H.B.K.) in Ecuador, using the computer vision model YOLOv11 for segmentation. A dataset comprising 2,715 manually annotated images was constructed, labeled into four classes: *Colletotrichum*, *Oidium*, healthy tissue, and background. The YOLOv11-seg model achieved a precision of 0.684, a recall of 0.509, and an mAP50 of 0.424. Confusion matrix analysis revealed better performance in identifying *Oidium* (101 correct detections) compared to *Colletotrichum* (18) and healthy tissue (28), with significant confusion between pathogens and background elements. Additionally, morphometric distributions were documented, enabling quantitative characterization of infection patterns. This work establishes a methodological foundation for automated phytosanitary monitoring systems in taxo cultivation, with potential to improve the efficiency and sustainability of integrated pest management in the Andean region.

Keywords: computer vision, image segmentation, deep learning.

Introducción

La producción de taxo (*Passiflora mollissima* H.B.K) se concentra principalmente en los valles interandinos de Perú, Colombia, Ecuador y Bolivia (Calixto-Cotos & Apaza, 2021). En Colombia, entre 2019 y 2023 la producción alcanzó un total de 72.274 toneladas, posicionándolo como uno de los cultivos importantes dentro de género *Passiflora* (Pardo Solórzano et al., 2024). En Ecuador, los cultivos de taxo representan una fuente de ingreso significativa para pequeños y medianos agricultores, en provincias como Tungurahua se cultivan en extensiones entre 660 m² y 28216 m² (Landa LLamuca & Valle Velástegui, 2019).

Esta fruta presenta diversas propiedades y beneficios que la hacen valiosa tanto nutricional como funcionalmente, propiedades que la hacen rica en nutrientes como vitaminas, minerales y carbohidratos (Chaparro-Rojas et al., 2014). Su versatilidad permite la obtención de múltiples productos y subproducto comerciales como néctar, jugos, mermelada, gelatinas, bebidas y alimentos funcionales, cosméticos, productos farmacéuticos (Chañi-Paucar et al., 2024)

Entre las enfermedades fúngicas que afectan significativamente al taxo destacan *Colletotrichum* spp. y *Oidium* (Ardiles R. et al., 2015). *Colletotrichum* spp. causa antracnosis, caracterizada por lesiones necróticas en hojas, tallos y frutos que pueden llevar a la pérdida total de la cosecha en casos severos (Freeman, 2008). Por su parte, *Oidium*, también conocido como oídio o mildiu polvoriento, se manifiesta como un crecimiento blanquecino pulverulento sobre la superficie de hojas, tallos y frutos jóvenes, reduciendo significativamente la capacidad fotosintética de la planta y afectando el desarrollo de los frutos (Pfeufer et al., 2024)

La identificación temprana y precisa de estas enfermedades resulta crucial para implementar medidas de control efectivas. Los métodos tradicionales de detección se basan en la inspección visual por parte de expertos, lo cual presenta limitaciones significativas: subjetividad

en el diagnóstico, tiempo considerable requerido para la evaluación, y disponibilidad limitada de personal especializado en zonas rurales (Khakimov et al., 2022).

En los últimos años, la visión por computadora y por ende el deep learning ha emergido como herramientas prometedoras para la detección automatizada de enfermedades en plantas (Kotwal et al., 2023) (Dhanya et al., 2022). Estas tecnologías permiten procesar grandes volúmenes de imágenes en tiempo real, ofreciendo diagnósticos consistentes y objetivos. Las técnicas basadas en redes neuronales convolucionales, particularmente arquitecturas como YOLO (You Only Look Once), han demostrado eficacia excepcional en tareas de detección y segmentación de imágenes agrícolas (Redmon, 2016) ;(Preanto et al., 2024).

Recientemente, la versión YOLOv11 ha introducido mejoras significativas en precisión y velocidad de detección, convirtiéndola en una opción viable para aplicaciones en la agricultura de precisión (Khan & Jensen, 2025) Entre sus innovaciones más relevantes se encuentran el optimizador adaptativo mejorado, la arquitectura backbone híbrida y los módulos de atención espacial, que en conjunto proporcionan una mayor capacidad para identificar patrones complejos en condiciones de iluminación variable y fondos heterogéneos, características comunes en entornos agrícolas (Sapkota & Karkee, 2024).

El presente estudio tiene como objetivo principal desarrollar y validar un sistema de detección temprana basado en YOLOv11 para la identificación y segmentación de hojas de taxo afectadas por *Colletotrichum* spp. y *Oidium* en cultivos ecuatorianos. Específicamente, esta investigación busca: (1) crear un conjunto de datos etiquetado de imágenes de hojas de taxo con diferentes niveles de infección, (2) implementar y optimizar un modelo YOLOv11 adaptado a las características particulares de estas patologías y (3) evaluar la precisión y eficiencia del sistema en condiciones de campo reales. La relevancia de este trabajo radica en su potencial para contribuir significativamente a la adopción de tecnologías de agricultura de precisión entre pequeños y medianos productores, promoviendo la detección temprana de enfermedades,

reduciendo el uso indiscriminado de agroquímicos y fortaleciendo la sostenibilidad de los sistemas productivos de taxo en la región andina ecuatoriana.

Métodos y Materiales

Obtención y Preparación de Datos

Se recolectaron imágenes de plantas de taxo (*Passiflora mollissima* H.B.K) que presentaban síntomas de infecciones fúngicas por *Colletotrichum* spp. y *Oidium*, así como tejido sano y muestras de fondo. Se constituyó un conjunto de datos compuesto por 2715 imágenes, distribuidas estratégicamente en tres subconjuntos: entrenamiento (2715 imágenes, 92.3%), validación (113 imágenes, 3.85%) y prueba (113 imágenes, 3.85%).

Las imágenes fueron capturadas en condiciones de campo utilizando una cámara digital de un celular, manteniendo condiciones de iluminación natural para reducir variaciones en la calidad de imagen. Se estableció una distancia focal constante de 30 cm desde la superficie foliar.

Segmentación y Etiquetado de Imágenes

El proceso de segmentación se realizó manualmente utilizando la plataforma Roboflow (Roboflow: Computer Vision Tools for Developers and Enterprises, 2025) para delimitar con precisión las áreas afectadas por los patógenos. Se establecieron cuatro categorías de etiquetas: *Colletotrichum*, *Oidium*, Sana (tejido sano) y background (fondo). La segmentación manual permitió generar máscaras precisas que identificaban el contorno exacto de las lesiones, diferenciando:

- *Colletotrichum*: Lesiones necróticas con bordes definidos y centro oscuro
 - *Oidium*: Áreas con micelio blanco pulverulento y clorosis asociada
-

- Sana: Tejido foliar sin alteraciones visibles
- Background: Elementos no foliares presentes en las imágenes

Arquitectura del Modelo YOLOv11

Se implementó la arquitectura YOLOv11n-seg para la segmentación de imágenes y detección. La configuración del modelo incluyó las siguientes especificaciones (Khanam & Hussain, 2024):

- Backbone: Utiliza capas convolucionales iniciales para la extracción de características de la imagen. Introduce el bloque C3k2, que reemplaza al bloque C2f de versiones anteriores. Este bloque es más eficiente computacionalmente, utilizando dos convoluciones más pequeñas en lugar de una grande, lo que contribuye a un procesamiento más rápido.
 - Cuello (Neck): Combina características a diferentes escalas y las transmite a la cabeza para predicciones. Utiliza el bloque C3k2 para mejorar la eficiencia del proceso de agregación de características.
 - Cabeza (Head): Genera las predicciones finales de detección y clasificación. Incluye múltiples bloques C3k2 para procesar y refinar los mapas de características. Utiliza capas CBS (Convolution-BatchNorm-Silu) para estabilizar el flujo de datos y mejorar el rendimiento del modelo.
 - Tamaño de entrada: 640x640 píxeles (redimensionamiento dinámico)
 - Detección final: Cada rama de detección termina con capas Conv2D que reducen las características a los resultados necesarios para coordenadas de cuadro delimitador y predicciones de clase.
-

Entrenamiento y Optimización

El entrenamiento del modelo YOLOv11n-seg se realizó en Google Colab, Python 3 y el acelerador de hardware GPU T4, con una duración de 1.327 horas, utilizando los siguientes parámetros de optimización:

- Optimizador: Adam con learning rate inicial de 0.001
- Batch size: 64
- Épocas: 60
- Aumento de datos: Rotación ($\pm 15^\circ$), cambios de escala ($\pm 10\%$), cambios de brillo ($\pm 15\%$), flips horizontales
- Estrategia de regularización: Weight decay (0.0005) y dropout (0.0)

Métricas de Evaluación

- El rendimiento del modelo se evaluó mediante las siguientes métricas:
 - Precision: Proporción de detecciones correctas entre todas las detecciones realizadas
 - Recall (Sensibilidad): Proporción de instancias reales correctamente identificadas
 - mAP50: Mean Average Precision con umbral IOU de 0.5
 - Matriz de confusión: Para analizar el rendimiento específico por clase
-

Análisis de Resultados

Rendimiento General del Modelo

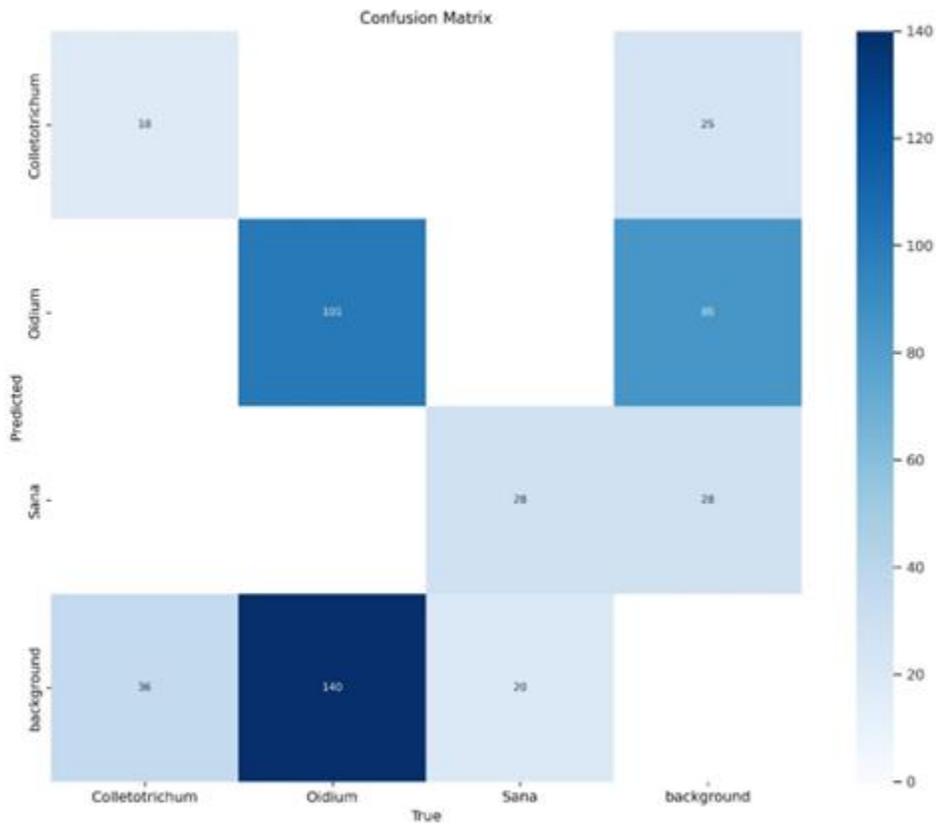
El modelo YOLOv11 para segmentación implementado alcanzó métricas de evaluación significativas en la detección y segmentación de enfermedades fúngicas en taxo, con una precisión de 0.68433, recall de 0.50905 y mAP50 de 0.42432. Estos valores representan un equilibrio aceptable entre la capacidad del modelo para identificar correctamente las regiones afectadas (precisión) y su habilidad para capturar la mayoría de las instancias patogénicas presentes (recall).

Análisis de la Matriz de Confusión

La matriz de confusión de la Figura 1 revela patrones relevantes en la capacidad discriminativa del modelo. Se observó que *Oidium* presenta el mayor número de detecciones correctas (101) entre los patógenos estudiados, lo que indica una caracterización morfológica distintiva que facilita su reconocimiento algorítmico. Sin embargo, se evidenciaron 85 confusiones entre *Oidium* y background, sugiriendo que las estructuras miceliares pulverulentas características de este patógeno pueden confundirse con elementos texturales del fondo en determinadas condiciones lumínicas.

Colletotrichum mostró un desempeño moderado con 18 detecciones correctas, pero con 36 confusiones con background. Esta tendencia sugiere que las lesiones necróticas tempranas de *Colletotrichum* pueden presentar características visuales que se confunden con variaciones naturales del tejido foliar o sombras en la imagen.

La clase Sana presentó confusiones simétricas con background (28 en ambas direcciones), lo que indica un desafío persistente en la delimitación precisa del tejido foliar sano respecto a elementos del entorno.

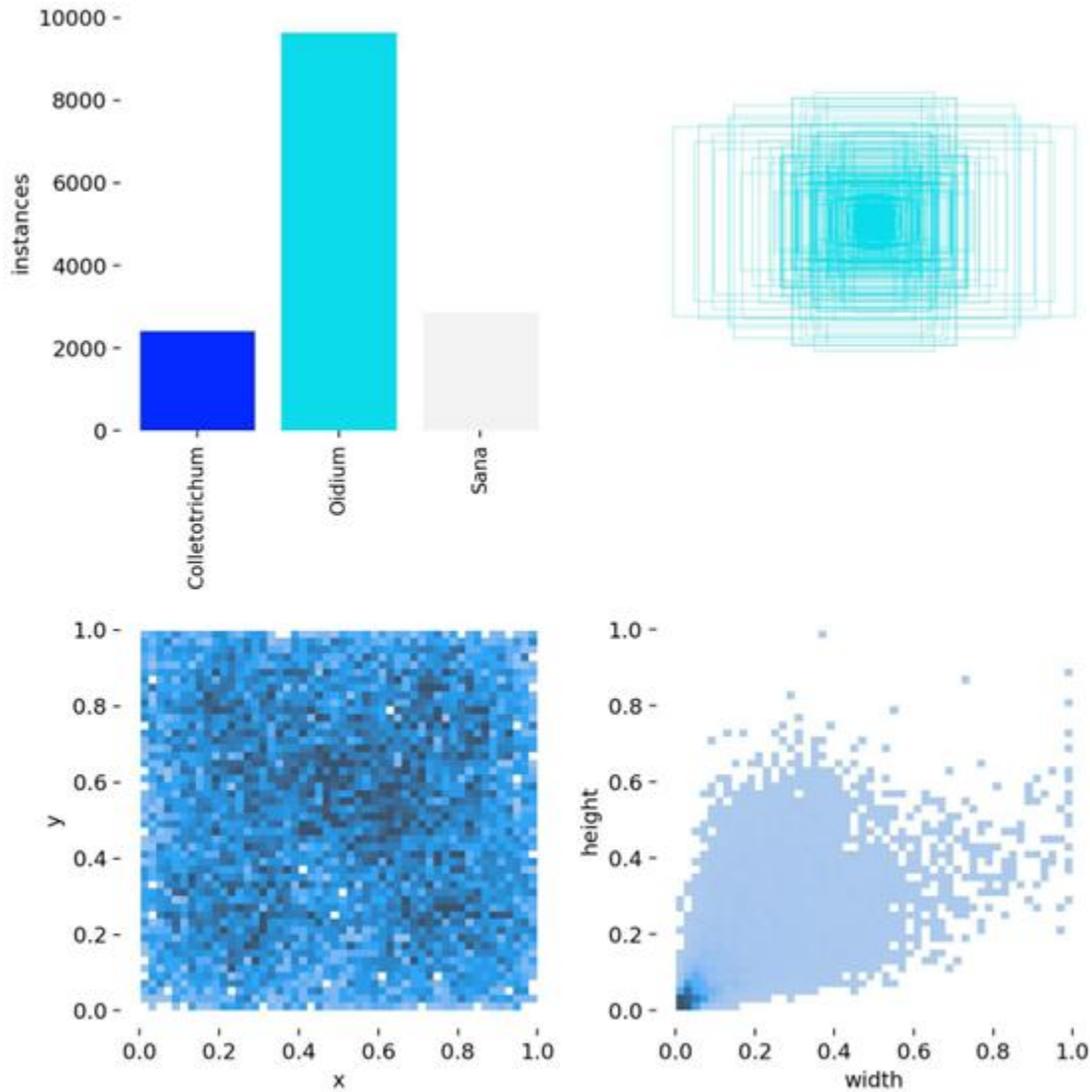
Figura 1.*Matriz de confusión.*

Distribución de Instancias y Características Morfométricas

El análisis de la distribución de instancias de la Figura 2 revela un marcado predominio de Oidium (aproximadamente 9500 instancias) sobre Colletotrichum (aproximadamente 2400 instancias) y Sana (aproximadamente 2800 instancias). Este desbalance de clases podría explicar parcialmente las diferencias en rendimiento observadas en la matriz de confusión, favoreciendo la precisión en la detección de Oidium.

Figura 2.

Distribución de instancias.



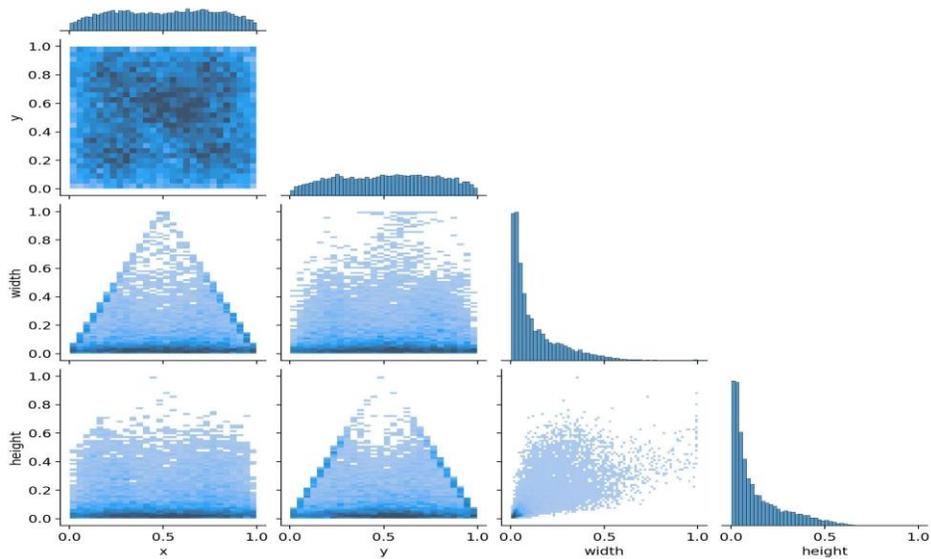
Las visualizaciones de características morfométricas de la Figura 3 demuestran patrones distintivos:

1. La distribución bidimensional (x,y) del conjunto de datos muestra una concentración espacial relativamente homogénea, indicando una cobertura adecuada de las regiones foliares.

2. La relación entre anchura y altura de las lesiones presenta una distribución triangular con predominio de lesiones pequeñas de forma proporcional, pero también instancias de lesiones elongadas horizontalmente (anchura>altura), particularmente en infecciones avanzadas de Oidium que siguen patrones de dispersión paralelos a las nervaduras.
3. Los histogramas marginales revelan una concentración significativa de valores de altura y anchura en el rango inferior (0.0-0.2), consistente con la presencia predominante de lesiones iniciales o microcolonias fúngicas.

Figura 3.

Características morfométricas.



En la Figura 4, se muestran diferentes resultados del modelo Yolov11

(Rayamajhi & Mahmud, 2023), reportó valores de precisión del 99.82%, un recall del 92.21% utilizando un modelo Mask R-CNN en detección y segmentación de antracnosis en cornejo florido, así mismo (Chen et al., 2024) reportó precisión: 90.18%, recall: 82.77% mAP50: 88.61% utilizando un modelo YOLO para la detección de antracnosis en fruta de lichi, en este mismo sentido (Yumang et al., 2023) reportó un mAP50: 60.68% y exactitud: 83.33% en un modelo de detección de antracnosis en hojas de árboles de mango.

Conclusiones

El presente estudio demuestra la viabilidad de implementar sistemas de segmentación basados en YOLOv11 para la identificación automatizada de enfermedades fúngicas en taxo, alcanzando una precisión de 0.68433. Los resultados confirman la capacidad del modelo para discriminar entre infecciones causadas por *Colletotrichum* spp. y *Oidium* con un nivel de confiabilidad aceptable para aplicaciones de monitoreo en campo.

La matriz de confusión revela patrones de error informativos que sugieren áreas específicas de mejora, particularmente en la discriminación entre patógenos y elementos del fondo. La segmentación manual realizada en Roboflow proporcionó un conjunto de datos etiquetado de alta calidad, factor determinante para el entrenamiento efectivo del modelo.

Las distribuciones morfométricas documentadas constituyen una caracterización cuantitativa valiosa de los patrones de infección de *Colletotrichum* spp. y *Oidium* en taxo, aportando conocimiento base para futuros sistemas de diagnóstico. La predominancia numérica de instancias de *Oidium* refleja la mayor prevalencia de este patógeno en las condiciones agroecológicas evaluadas.

Si bien el valor de mAP50 (0.42432) indica margen de mejora, representa un avance significativo considerando las complejidades inherentes a la segmentación de lesiones fúngicas

en condiciones de campo. Futuras investigaciones deberían enfocarse en incorporar información temporal y espectral complementaria para mejorar la sensibilidad del sistema, particularmente para detección de infecciones incipientes.

Este trabajo establece las bases metodológicas para el desarrollo de sistemas de monitoreo fitosanitario aplicables al cultivo de taxo, con potencial de adaptación a otros cultivos de importancia en la región andina, contribuyendo a estrategias de manejo integrado más eficientes y sostenibles.

Referencias bibliográficas

- Ardiles R., S., Sepúlveda, M., R., & Calle Z., I. (2015). Plagas y enfermedades que afectan al Tumbo (*Passiflora Mollissima*) Y Locoto (*Capsicum Pubescens*).
<https://biblioteca.inia.cl/server/api/core/bitstreams/eea3a4fa-6860-4eb1-90bd-cf5ef7b2d60e/content>
- Calixto-Cotos, D., & Apaza, M. R. (2021). Aprovechamiento de los residuos del fruto de *Passiflora tripartita*. *Scientia Agropecuaria*, 12(3), 445–453.
<https://doi.org/10.17268/sci.agropecu.2021.049>
- Chañi-Paucar, L. O., Chagua-Rodríguez, P., Cuadrado-Campó, W. J., Román, G., Calderón, L., Cesar, J., Santivañez, M., Fernando, C., Angolini, F., & Meireles, M. A. A. (2024). Tumbo, an Andean fruit: Uses, nutrition, processing, and biomolecules. *Heliyon*, 10, e30327. <https://doi.org/10.1016/j.heliyon.2024.e30327>
- Chaparro-Rojas, D. C., Maldonado, M. E., Franco-Londoño, M. C., & Urango-Marchena, L. A. (2014). Características nutricionales y antioxidantes de la fruta curuba larga (*Passiflora mollissima* Bailey). *Perspectivas En Nutrición Humana*, 16(2).
<https://doi.org/10.17533/udea.penh.v16n2a07>
- Chen, J. S., Liu, M., Li, J. S., & Chen, J. X. (2024). LFA-YOLO: Detection of Lychee Fruit Anthracnose Based on UAV Images and Deep Learning. *Applied Engineering in Agriculture*, 40(5), 515–523. <https://doi.org/10.13031/AEA.16017>
- Dhanya, V. G., Subeesh, A., Kushwaha, N. L., Vishwakarma, D. K., Nagesh Kumar, T., Ritika, G., & Singh, A. N. (2022). Deep learning based computer vision approaches for smart agricultural applications. *Artificial Intelligence in Agriculture*, 6, 211–229.
<https://doi.org/10.1016/J.AIIA.2022.09.007>
- Freeman, S. (2008). Management, Survival Strategies, and Host Range of *Colletotrichum acutatum* on Strawberry. *HortScience*, 43(1), 66–68.
<https://doi.org/10.21273/HORTSCI.43.1.66>
- Khakimov, A., Salakhutdinov, I., Omolikhov, A., & Utaganov, S. (2022). Traditional and current-prospective methods of agricultural plant diseases detection: A review. *IOP Conference Series: Earth and Environmental Science -3rd International Conference on Agriculture and Bio-Industry (ICAGRI 2021)*. <https://doi.org/10.1088/1755-1315/951/1/012002>
- Khan, A. T., & Jensen, S. M. (2025). LEAF-Net: A Unified Framework for Leaf Extraction and Analysis in Multi-Crop Phenotyping Using YOLOv11. *Agriculture 2025*, Vol. 15, Page 196, 15(2), 196. <https://doi.org/10.3390/AGRICULTURE15020196>
-

- Khanam, R., & Hussain, M. (2024). YOLOV11: AN OVERVIEW OF THE KEY ARCHITECTURAL ENHANCEMENTS.
- Kotwal, J., Kashyap, D. R., & Pathan, D. S. (2023). Agricultural plant diseases identification: From traditional approach to deep learning. *Materials Today: Proceedings*, 80, 344–356. <https://doi.org/10.1016/J.MATPR.2023.02.370>
- Landa LLamuca, D. O., & Valle Velástegui, L. (2019). Diagnostico situacional del taxo (*Passifloramollissima*B.H.K.) en la Provincia de Tungurahua. *Centrosur*, 1, 17–22. <http://centrosuragraria.com/index.php/revista>
- Pardo Solórzano, M. V., Costa, G. M., & Castellanos, L. (2024). *Passiflora* By-Products: Chemical Profile and Potential Use as Cosmetic Ingredients. *Scientia Pharmaceutica*, 92(4), 57. <https://doi.org/10.3390/SCIPHARM92040057/S1>
- Pfeufer, E., Gauthier, N., & Bradley, C. A. (2024). Hoja Informativa de Fitopatología Mildiu Polvoriento College of Agriculture, Food and Environment Cooperative Extension Service Fitopatóloga de Extensión Recursos Naturales y Agrícolas • Ciencias de Familia y Consumidor Desarrollo Juvenil/4-H Desarrollo Comunitario y Económico.
- Preanto, S. A., Ahad, Md. T., Emon, Y. R., Mustofa, S., & Alamin, M. (2024). A Semantic Segmentation Approach on Sweet Orange Leaf Diseases Detection Utilizing YOLO. <https://arxiv.org/abs/2409.06671v1>
- Rayamajhi, A., & Mahmud, M. S. (2023). Detection and Segmentation of Anthracnose Leaf Spots in Flowering Dogwood Using Deep Learning for Site-Specific Management. 2023 ASABE Annual International Meeting, 1-. <https://doi.org/10.13031/AIM.202300422>
- Redmon, J. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.
- Roboflow: Computer vision tools for developers and enterprises. (2025). <https://roboflow.com/>
- Sapkota, R., & Karkee, M. (2024). Comparing YOLOv11 and YOLOv8 for instance segmentation of occluded and non-occluded immature green fruits in complex orchard environment. <https://arxiv.org/abs/2410.19869v3>
- Yumang, A. N., Samilin, C. J. N., & Sinlao, J. C. P. (2023). Detection of Anthracnose on Mango Tree Leaf Using Convolutional Neural Network. 2023 15th International Conference on Computer and Automation Engineering, ICCAE 2023, 220–224. <https://doi.org/10.1109/ICCAE56788.2023.10111489>
-