

Prototipo para la detección del punto óptimo de cosecha del café Geisha en Panamá mediante visión artificial

Prototype for the detection of the optimal harvest point of Geisha coffee in Panama using computer vision

Zairy Rodríguez^{1,2}, José Monroy¹, Valentín Rodríguez^{1,2}, Giancarlo Ruiz^{1,2}, Yuraisma Moreno^{1,2,*}

¹Universidad Tecnológica de Panamá, Facultad de Ingeniería en Sistemas, Panamá

²Universidad Tecnológica de Panamá, Centro Regional de Chiriquí, Grupo de investigación en ingeniería de software aplicada, Panamá

*Autor de correspondencia: yuraisma.moreno@utp.ac.pa

Fecha de recepción: 10 de mayo de 2026. Fecha de aceptación: 1 de junio de 2026.

Resumen. El café Geisha de Panamá es reconocido mundialmente por su sabor excepcional y altos precios en subastas, y es uno de los granos más valorados a nivel internacional. Su calidad depende de una cosecha precisa y del manejo óptimo de factores como la humedad del suelo y la madurez del fruto. Frente a estos desafíos, se propuso el diseño, desarrollo y validación de un prototipo automatizado para optimizar la cosecha del café Geisha en Panamá. El sistema combina sensores ambientales y de humedad del suelo conectados a un microcontrolador ESP32, con un modelo de visión artificial YOLOv8n que identifica el estado de madurez de las cerezas de café. Se elaboraron diagramas de arquitectura de la aplicación y del sistema general, los cuales permitieron estructurar el funcionamiento del prototipo. Las pruebas de funcionamiento confirmaron lecturas estables y transmisión en tiempo real, con un retardo promedio inferior a 2 segundos y conectividad Wi-Fi superior al 95 %. Por su parte, el modelo de detección alcanzó un mAP@0.5 de 87.3 % y un mAP@0.5:0.95 de 62.7 %, evidenciando un desempeño robusto y competitivo en tareas de clasificación de madurez. Las principales ventajas incluyen operación en tiempo real, reducción de la dependencia de inspección manual, la generación de datos para decisiones informadas hacia una producción más eficiente, una cosecha más homogénea y la promoción del uso de tecnologías accesibles y sostenibles en la agricultura.

Palabras clave. Café Geisha, cosecha, optimización, sensor de humedad, visión artificial.

Abstract. Panama Geisha coffee is globally renowned for its exceptional flavor and record-breaking auction prices, making it one of the most highly valued coffee beans in the world. Its quality relies on precise harvesting and optimal management of factors such as soil moisture and fruit ripeness. In response to these challenges, this project presents the design, development and validation of an automated prototype to optimize Geisha coffee harvesting in Panama. The system integrates environmental and soil moisture sensors connected to an ESP32 microcontroller, with a YOLOv8n computer vision model for identifying the ripeness stages of coffee cherries. Architecture diagrams of both the application and the overall system were developed to organize the prototype's operation. Performance tests confirmed stable readings and real-time data transmission, with an average delay under 2 seconds and Wi-Fi connectivity above 95%. The detection model achieved a mAP@0.5 of 87.3% and a mAP@0.5:0.95 of 62.7%, demonstrating strong and competitive performance in ripeness classification tasks. Key benefits include real-time operation, reduced reliance on manual inspection, data generation for informed decisions leading to more efficient production, homogeneous harvesting, and promoting the use of affordable and sustainable technologies in agriculture.

Keywords. Geisha coffee, harvesting, optimization, soil moisture sensor, computer vision.

1. Introducción

El café Geisha, originario de Etiopía y cultivado con éxito en Panamá, se ha consolidado como una de las variedades más valoradas del mundo gracias a su perfil sensorial característico, que incluye notas florales, frutales, una acidez brillante y un cuerpo delicado. No obstante, la calidad final del grano depende en gran medida del momento preciso de la cosecha. Recolectar los frutos antes o después del punto óptimo puede afectar negativamente atributos fundamentales como el dulzor, el aroma y la complejidad del café [1]. A pesar de su importancia, muchos caficultores continúan utilizando métodos tradicionales basados en la observación visual del color del fruto, lo cual puede generar inconsistencias y pérdida de calidad [2].

Ante esta situación, el avance de las tecnologías digitales ha abierto nuevas oportunidades para mejorar la precisión y sostenibilidad de los procesos agrícolas. La visión artificial, por ejemplo, se ha aplicado con éxito en la identificación del estado de madurez del café mediante el análisis de color y textura de los frutos [3]. Estas soluciones permiten automatizar la clasificación del grano, reducir el margen de error humano y facilitar una cosecha más homogénea [4]. Además, la integración de inteligencia artificial en sistemas agrícolas permite correlacionar variables ambientales, fisiológicas y productivas para optimizar decisiones en tiempo real [5].

En los últimos años, se han desarrollado herramientas especializadas como Cromacafé® [2], diseñadas para identificar visualmente los estados de maduración del café de fruto rojo, demostrando la aplicabilidad práctica de la visión artificial en contextos reales de producción. Asimismo, algunos estudios han documentado la evolución de las tecnologías digitales en la industria cafetalera, señalando que su incorporación progresiva ha mejorado significativamente la trazabilidad, calidad y rendimiento de la producción [1].

Desde una perspectiva de sostenibilidad, el uso de sensores y modelos automatizados ha sido clave para optimizar el consumo de recursos como agua y energía en fincas cafeteras. Además, la integración de monitoreo inteligente y análisis de procesos puede mejorar la eficiencia de forma medible [6]. Paralelamente, se han desarrollado ontologías como *RustOnt*, capaces de predecir condiciones ambientales que favorecen enfermedades como la roya del café, lo que demuestra la utilidad de estas herramientas para anticipar riesgos y tomar medidas preventivas [7].

En el contexto panameño, la aplicación de visión artificial ha comenzado a implementarse en diversas áreas agrícolas, incluyendo la detección automatizada de plagas, el reconocimiento de especies, la determinación del estado de madurez de frutos y la clasificación de productos para exportación, lo que valida su potencial de expansión en la caficultura nacional [8], [9], [10], [11].

Sin embargo, el avance de estas tecnologías no está exento de desafíos tales como la implementación de la inteligencia artificial de manera ética y responsable, especialmente en zonas rurales donde el acceso a infraestructura digital puede ser limitado [12]. La formación técnica, la accesibilidad y la apropiación social de estas herramientas son factores clave para garantizar su adopción exitosa. En esta línea, es necesario diseñar soluciones que consideren tanto los beneficios productivos como los riesgos asociados a la automatización en el agro [13]. La incorporación de tecnología avanzada no debe desplazar el conocimiento tradicional del agricultor, sino integrarse como una herramienta complementaria para mejorar la toma de decisiones [14]. El impacto positivo de la inteligencia artificial dependerá en gran parte de su adaptación al contexto local y de su integración como complemento al conocimiento tradicional del productor [15]. La combinación de algoritmos inteligentes, sistemas de recomendación y sensores de calidad del suelo puede empoderar a los agricultores y transformar radicalmente la eficiencia del cultivo de café [16].

Con base en este panorama, el presente estudio tiene como objetivo diseñar y validar un prototipo automatizado que combine sensores de humedad del suelo y visión artificial para identificar el punto óptimo de cosecha del café Geisha en Panamá.

1.1 Justificación y antecedentes

En un mundo que exige mejoras constantes en sostenibilidad y cuidado ambiental, es fundamental optimizar el uso de los recursos naturales. El café Geisha de Panamá, reconocido mundialmente por su calidad y perfil sensorial único, depende en gran medida del momento exacto de cosecha para preservar sus propiedades. Sin embargo, los métodos tradicionales, basados en la observación del color y la experiencia de los caficultores, pueden generar inconsistencias y afectar el producto final.

En otras regiones cafetaleras, la incorporación de sensores de humedad y análisis avanzado de datos ha permitido mejorar la gestión de cultivos y optimizar la recolección. Investigaciones demuestran que el contenido de humedad del café influye directamente en su actividad de agua y, por ende, en su conservación y calidad [17]. Además, la tecnología aplicada a la cosecha ha mostrado resultados significativos en eficiencia y reducción del trabajo físico, como evidencian estudios sobre vibradores portátiles en cultivos de café [18].

Tecnologías como la visión artificial han demostrado ser efectivas en cultivos agrícolas al automatizar el análisis del estado de madurez de los frutos. Estas herramientas permiten detectar con mayor precisión las características físicas del grano, facilitando una cosecha más homogénea, eficiente y sostenible [19]. Aplicar estas estrategias en la producción de

café Geisha permitirá mejorar la precisión en la recolección, reducir desperdicios y garantizar una cosecha uniforme. Asimismo, al automatizar el monitoreo del cultivo, se evita someter a los trabajadores a tareas repetitivas que pueden ser realizadas de forma más eficiente por sistemas inteligentes. Este estudio contribuye a la eficiencia, calidad y sostenibilidad del sector cafetalero, apoyando los Objetivos de Desarrollo Sostenible (ODS) 9 “Industria, Innovación e Infraestructura” mediante la promoción de tecnologías innovadoras, y el ODS 12 “Producción y Consumo Responsables” al optimizar el uso de recursos y reducir desperdicios [20].

2. Metodología

Esta sección describe el enfoque experimental adoptado, también se detalla la red neuronal convolucional (CNN) empleada, los componentes de hardware y software utilizados, así como la arquitectura general del sistema.

2.1 Diseño y tipo de investigación

Se utilizó un enfoque aplicado y experimental, ya que se busca diseñar y validar un prototipo automatizado para optimizar la cosecha del café Geisha. Se utiliza una metodología cuantitativa para recolectar, procesar y analizar datos obtenidos en tiempo real, complementada con el entrenamiento y la validación de un modelo de CNN para la clasificación automática del estado de madurez.

2.2 CNN y visión artificial

Las redes neuronales convolucionales son ampliamente utilizadas en tareas de clasificación de imágenes debido a su capacidad para aprender patrones espaciales. Se empleó una CNN basada en la arquitectura YOLOv8n, la cual ha demostrado ser efectiva en tareas de detección de objetos [21]. Esta arquitectura fue seleccionada por su equilibrio entre precisión y eficiencia computacional, lo que la hace adecuada para implementaciones en dispositivos con recursos limitados como el ESP32.

2.3 Dispositivos y tecnologías utilizadas

Para el desarrollo del prototipo se seleccionaron componentes de hardware y software que aseguran su funcionalidad y viabilidad técnica.

A continuación, los componentes de hardware:

- Microcontrolador ESP32 con conectividad Wi-Fi
- Sensor DHT11 para medición de temperatura y humedad ambiental.
- Sensor capacitivo para medición de humedad del suelo.

A continuación, los componentes de software:

- Arduino IDE para programación del microcontrolador [22].
- Arduino IoT Cloud para visualización de datos en tiempo real [23].
- Python con OpenCV para procesamiento de imágenes.

- PyTorch para entrenamiento del modelo YOLOv8n [24].
- Django como *framework* web para el desarrollo de la plataforma [25].
- Tailwind CSS para el diseño de la interfaz de usuario [26].

También se utilizó un conjunto de 821 imágenes de cerezas de café Geisha en distintos estados de madurez, recolectadas en condiciones variadas. El dataset combinó imágenes propias con otras públicas de Roboflow [27], y se dividió en 88% para entrenamiento (726 imágenes), 8% para validación (66 imágenes) y 4% para prueba (29 imágenes).

2.4 Diagrama conceptual del sistema

En la figura 1 se presenta el sistema que se compone de dos módulos conectados a una plataforma web Django. El primero incluye un ESP32 con sensores ambientales y de humedad del suelo, que transmite los datos a Arduino IoT Cloud y luego los visualiza en un dashboard. El segundo módulo captura imágenes de las cerezas de café, las procesa mediante un modelo CNN YOLOv8n y envía los resultados de clasificación a la plataforma. Esta integración permite un monitoreo unificado y en tiempo real de las variables críticas del cultivo.




Figura 1. Esquema general del sistema con integración de sensores, visión artificial y plataforma web.

2.5 Diagrama de arquitectura del sistema

La figura 2 muestra el flujo de trabajo del sistema de visión artificial utilizado para clasificar el estado de madurez de las cerezas de café. Incluye la carga y preprocesamiento de imágenes con *OpenCV*, seguidos del entrenamiento e inferencia del modelo YOLOv8n desarrollado en *PyTorch*. El resultado es una clasificación automática con su respectivo porcentaje de confianza, que apoya la toma de decisiones sobre el momento óptimo para la cosecha.




Figura 2. Arquitectura del módulo de visión artificial.

3. Resultados

En esta sección se presentan los resultados obtenidos durante las pruebas del prototipo en condiciones reales de campo, evaluando el desempeño tanto del módulo de sensores como del sistema de visión artificial.

3.1 Módulo de sensores del prototipo

El prototipo automatizado se evaluó en un entorno controlado y en pruebas preliminares de campo para verificar la lectura de variables ambientales y de suelo. El microcontrolador ESP32, junto con el sensor DHT11 y el sensor capacitivo de humedad, permitió la captura de datos en tiempo real y su transmisión a Arduino IoT Cloud mediante una conexión Wi-Fi estable.

3.1.1 Lectura de temperatura y humedad ambiental

Durante las pruebas se registraron temperaturas promedio entre 26°C y 30°C y niveles de humedad ambiental entre 65% y 78%, valores acordes con las condiciones climáticas de zonas cafetaleras de Panamá. El sensor DHT11 demostró una respuesta adecuada para el monitoreo agrícola, con mediciones estables que reflejan las variaciones del microclima en plantaciones de café Geisha, coincidiendo con los rangos reportados para condiciones óptimas de esta variedad [28].

3.1.2 Lectura de humedad del suelo

El sensor capacitivo demostró buena estabilidad y repetibilidad durante las pruebas. La lectura se obtuvo como valor analógico y se transformó en porcentaje de humedad del suelo usando una escala calibrada entre 2000, correspondiente a suelo completamente húmedo, y 3344, correspondiente a suelo completamente seco. La conversión se realizó mediante la ecuación 1.

$$H_s = \frac{R_{max} - R_{soil}}{R_{max} - R_{min}} \times 100 \quad (1)$$

Donde H_s es el porcentaje de humedad del suelo en porcentaje (%), R_{max} representa el valor máximo del sensor para suelo seco, R_{min} es el valor mínimo para suelo completamente húmedo y R_{soil} es la lectura analógica actual.

Los valores típicos se ubicaron entre 35% y 70%, permitiendo interpretar la condición del suelo de acuerdo con los rangos definidos en la tabla 1.

Tabla 1. Rangos de interpretación del porcentaje de humedad del suelo

Porcentaje de humedad (%)	Interpretación
> 80%	Exceso de humedad / posible encharcamiento
60% – 79%	Muy húmedo, monitorear drenaje
40% – 59%	Humedad ideal para plántones de Geisha
25% – 39%	Ligeramente seco, pronto a regar
< 25%	Críticamente seco

3.1.3 Visualización con Arduino IoT Cloud

El sistema transmite todos los datos a Arduino IoT Cloud, donde se almacenan y visualizan en tiempo real mediante un dashboard integrado que muestra simultáneamente la temperatura, humedad ambiental y porcentaje de humedad del suelo (figura 3). La plataforma proporcionó una interfaz intuitiva para el monitoreo continuo, permitiendo la creación de dashboards personalizados que facilitan la interpretación de los datos por parte de los caficultores. La capacidad de almacenamiento histórico resultó especialmente útil para identificar patrones de comportamiento y establecer correlaciones entre las condiciones ambientales y del suelo con los ciclos de riego.




Figura 3. Panel de monitoreo en tiempo real del sistema.

3.2 Módulo de visión artificial

El módulo de visión artificial, implementado con YOLOv8n entrenado en PyTorch, fue evaluado utilizando el conjunto de prueba del dataset de cerezas de café Geisha. Se aplicaron métricas estándar de detección de objetos, incluyendo precisión, recall y mAP, para verificar la capacidad del modelo de identificar automáticamente los cuatro estados de madurez definidos.

3.2.1 Resultados del modelo

Los resultados del modelo en el conjunto de validación demostraron un desempeño robusto del modelo YOLOv8n para la tarea de clasificación de madurez en cerezas de café. Como se observa en la tabla 2, el modelo alcanzó un mAP@0.5 general de 87.30% y un mAP@0.5:0.95 de 62.73%, indicando una alta capacidad de detección y localización precisa de los objetos de interés.

Tabla 2. Resultados de rendimiento del modelo YOLOv8n por clase en el conjunto de validación

Clase	Precisión	Recall	mAP@0.5
Sobremaduro	0.961	0.672	0.896
Maduro	0.865	0.870	0.929
Semi-maduro	0.700	0.761	0.808
Inmaduro	0.717	0.843	0.860

El análisis por clases reveló variaciones en el rendimiento según el estado de madurez. La clase “sobremaduro” presentó la mayor precisión con 96.1%, mientras que “maduro” obtuvo el mejor mAP@0.5 con 92.9%. El modelo demostró alta precisión en la identificación de frutos individuales incluso bajo variaciones de luz.

3.2.2 Análisis de rendimiento

Para un análisis más profundo del rendimiento, se generaron gráficos clave que resumen la capacidad de clasificación del modelo, incluyendo matrices de confusión y curvas de precisión-recall que permiten evaluar el comportamiento del sistema en diferentes escenarios.

La matriz de confusión mostrada en la figura 4 muestra que el modelo identificó correctamente 23 instancias de “sobremaduro”, 163 de “maduro”, 97 de “semi-maduro” y 218 de “inmaduro”. Los valores fuera de la diagonal revelan las confusiones del modelo.




Figura 4. Matriz de confusión con recuentos absolutos de las detecciones del modelo.

La matriz normalizada de la figura 5 muestra que el modelo logró un Recall del 85% para “maduro” y 88% para “inmaduro”, indicando alta capacidad de detección para estas categorías.




Figura 5. Matriz de confusión normalizada mostrando las proporciones de clasificación por clase.

La figura 6 muestra la Curva Precision-Recall (PR) del modelo. Se observa que la clase “maduro” presenta una curva PR consistentemente alta, reflejando su excelente mAP@0.5 de 0.929. Por otro lado, clases como “semi-maduro” e “inmaduro” muestran un rendimiento respetable, pero con un margen para optimización, lo que se alinea con sus mAP@0.5 ligeramente inferiores.




Figura 6. Curvas Precision-Recall por clase del modelo YOLOv8n.

3.3 Aplicación web

En una segunda etapa del proyecto, se desarrolló una plataforma web utilizando Django como framework backend y Tailwind CSS para el diseño de la interfaz, centralizando las funcionalidades del prototipo para visualizar datos de sensores en tiempo real y ejecutar el modelo de visión artificial. Esta solución facilita la interpretación de los resultados, mejora la toma de decisiones y puede ser escalada para incluir nuevos módulos, como detección de plagas, enfermedades o estrés hídrico. Entre sus principales funcionalidades, se destacan:

3.3.1 Análisis por imagen

El análisis por imagen permite cargar fotografías de plantaciones para obtener diagnóstico automatizado del estado de madurez mediante una interfaz intuitiva. El sistema muestra los resultados del modelo YOLOv8n, donde cada cereza se presenta con un bounding box de color distintivo según su madurez, como se observa en la Figura 7, complementado con estadísticas de conteo y porcentajes por categoría. Adicionalmente, la plataforma incluye funcionalidad de cámara en vivo que permite análisis instantáneos utilizando la cámara del dispositivo directamente en campo, procesando frames en tiempo real con detecciones superpuestas dinámicamente.




Figura 7. Resultados del análisis de madurez con bounding boxes coloreados por categoría y panel estadístico.

3.3.2 Dashboard de sensores

Visualiza en tiempo real las condiciones ambientales del cultivo mediante tres widgets principales, incluyendo indicadores de rango óptimo. Como se observa en la Figura 8, la interfaz incluye gráficos de tendencia de 24 horas y estado de conectividad de sensores, proporcionando una herramienta integral para el monitoreo continuo.




Figura 8. Dashboard mostrando monitoreo en tiempo real de variables ambientales.

4. Discusión

Los resultados experimentales del módulo de sensores muestran que el sistema logró mantener una transmisión de datos estable con un retardo promedio inferior a 2 segundos y una conectividad Wi-Fi superior al 95% durante sesiones prolongadas de monitoreo. La frecuencia de transmisión establecida de cada 30 segundos demuestra que la integración de hardware y software es robusta y adecuada para su uso en campo.

El módulo de visión artificial, basado en la arquitectura YOLOv8n, alcanzó un rendimiento competitivo al obtener un mAP@0.5 de 87.30% y un mAP@0.5:0.95 de 62.73%, cifras que se sitúan dentro de los rangos considerados de alto desempeño en la literatura de detección de objetos [29]. Comparado con *benchmarks* reconocidos como COCO [29], donde un mAP@0.5 superior a 70% ya se considera excelente, los resultados confirman que el modelo propuesto es efectivo para la clasificación automática del estado de madurez de las cerezas de café.

5. Conclusiones

Los resultados confirman la estabilidad del sistema de monitoreo y la efectividad del modelo de clasificación bajo condiciones de campo variables, superando las métricas de desempeño establecidas para este estudio. Las principales ventajas incluyen operación en tiempo real, reducción de la dependencia de inspección manual y generación de datos para decisiones informadas hacia una cosecha más uniforme y sostenible. Las limitaciones identificadas se relacionan con la necesidad de infraestructura de red estable y dependencia de bases de datos representativas para el entrenamiento del modelo. Los resultados son útiles para investigadores y productores interesados en la digitalización de la caficultura, sirviendo como base para futuras implementaciones a mayor escala o adaptaciones a otros cultivos. Para trabajos futuros, se recomienda incorporar aprendizaje continuo para actualizar el

modelo con nuevas imágenes de campo y ampliar la detección hacia reconocimiento de plagas, enfermedades o estrés hídrico, aumentando significativamente el valor agronómico de la solución.

AGRADECIMIENTOS

A los caficultores que colaboraron con la recopilación de datos en campo, en fincas del sector de Potrerillos Arriba (Chiriquí) y de San Carlos. Asimismo, al estudiante Steven Espinosa por su acompañamiento técnico y orientación durante el desarrollo del proyecto.

CONFLICTO DE INTERESES

Los autores declaran no tener conflictos de interés.

REFERENCIAS

- [1] E. Largo Avila, C. H. Suárez Rodríguez y E. Arango Espinal, “Transformación digital: Evolución de las aplicaciones de inteligencia artificial en la industria del café”, Ing. Desarro., vol. 43, n.º 1, pp. 64–83, enero de 2025. <https://doi.org/10.14482/inde.43.01.445.864>
- [2] A. E. Peñuela-Martínez, Á. Guerrero y J. R. Sanz-Urbe, “Cromacafé® Herramienta para identificar los estados de madurez de las variedades de café de fruto rojo”, Av. Tec. Cenicafe, vol. 535, pp. 1–8, febrero de 2022. <https://doi.org/10.38141/10779/0535>
- [3] F. Eron, M. Noman, R. R. de Oliveira y A. Chalfun-Junior, “Computer vision-aided intelligent monitoring of coffee: Towards sustainable coffee production”, Sci. Hortic., vol. 327, p. 112847, marzo de 2024. <https://doi.org/10.1016/j.scienta.2024.112847>
- [4] Z. L. Sandoval Niño, “Caracterización y clasificación de café cereza usando visión artificial”, UNIV. NAC. COLOMB. SEDE MANIZALES, 2005.
- [5] C. A. Hernández-Salazar, O. A. González-Estrada, y G. González-Silva, “Integración de la inteligencia artificial y la agricultura de precisión en cultivos de café”, Rev. UIS ing., vol. 23, n.º 4, pp. 145–158, dic. 2024.
- [6] C. Méndez Rodríguez, J. Salazar Benítez, C. F. Rengifo Rodas, J. C. Corrales y A. Figueroa Casas, “A multidisciplinary approach integrating energy analysis and process modeling for agricultural systems sustainable management—coffee farm validation”, Sustainability, vol. 14, n.º 14, p. 8931, julio de 2022. <https://doi.org/10.3390/su14148931>
- [7] C. Suarez, D. Griol, C. Figueroa, J. C. Corrales y D. C. Corrales, “RustOnt: An ontology to explain weather favorable conditions of the coffee rust”, Sensors, vol. 22, n.º 24, p. 9598, diciembre de 2022. <https://doi.org/10.3390/s22249598>
- [8] R. Atencio y E. Cruz, “Situación actual de la aplicación y potenciales usos de la visión artificial en la entomología agrícola en Panamá”, IDT, vol. 18, n.º 2, pp. 124–135, jul. 2022.

- [9] K. Santamaría, M. Sole y K. Rodríguez, "Reconocimiento de tipos de serpientes en Panamá por medio de visión artificial", Universidad Tecnológica de Panamá, Facultad de Ingeniería de Sistemas Computacionales, Jornada de Iniciación Científica, 2021.
- [10] A. Villalba, T. Requena, F. Solanilla y J. C. Rangel, "Prototipo de un sistema que determine el estado de madurez de un plátano utilizando Deep Learning y Visión Artificial", Universidad Tecnológica de Panamá, Facultad de Ingeniería de Sistemas Computacionales, Jornada de Iniciación Científica, 2019.
- [11] D. Cáceres, "Sistema Inteligente de Clasificación de la Citrullus Lanatus (sandía) para Exportación Empleando Procesamiento de Imágenes", Proyecto FID18-060, Secretaría Nacional de Ciencia, Tecnología e Innovación (SENACYT), Panamá, 2019-2021.
- [12] R. Dara, S. M. Hazrati Fard y J. Kaur, "Recommendations for ethical and responsible use of artificial intelligence in digital agriculture", *Frontiers Artif. Intell.*, vol. 5, julio de 2022. <https://doi.org/10.3389/frai.2022.884192>
- [13] R. C. d. Oliveira y R. D. d. S. e. Silva, "Artificial Intelligence in Agriculture: Benefits, Challenges, and Trends", *Appl. Sci.*, vol. 13, n.º 13, p. 7405, junio de 2023. <https://doi.org/10.3390/app13137405>
- [14] E. Vera Medranda y T. Zambrano Solórzano, "Impact of Drones on Agriculture: Applications and Benefits in Crop production", *Rev. Cient. Multi. G-nerando*, vol. 6, n.º 1, pp. 3960–, abr. 2025.
- [15] O. Mendez, "La inteligencia artificial y sus beneficios en una agricultura sostenible," en *Inteligencia artificial transformación, retos y prospectiva social*, pp. 261-276, Nov. 2024. DOI: 10.61728/AE24001137.
- [16] R. Selvanarayanan, S. Rajendran, S. Algburi, O. I. Khalaf y H. Hamam, "Empowering coffee farming using counterfactual recommendation based RNN driven IoT integrated soil quality command system," *Scientific Reports*, vol. 14, art. 6269, Mar. 2024. DOI: 10.1038/s41598-024-56954-x.
- [17] V. Osorio, J. Pabón y C. R. Gómez, "Efecto del porcentaje de humedad del café en la actividad de agua", *Rev. Cenicafe*, vol. 75, n.º 1, 2024, art. n.º e75104. <https://doi.org/10.38141/10778/75104>
- [18] H. Araque-Salazar, C. E. Oliveros-Tascón, J. R. Sanz-Uribe, and C. A. Ramírez-Gómez, "Desempeño de vibradores portátiles del tallo en la cosecha del café," *Revista Facultad Nacional de Agronomía Medellín*, 2005.
- [19] C. E. Oliveros-Tascón and J. R. Sanz-Uribe, "Ingeniería y café en Colombia," *Revista de Ingeniería*, Universidad de los Andes, vol. 33, pp. 99-114, Enero-Junio 2011.
- [20] Organización de las Naciones Unidas, "Objetivos de Desarrollo Sostenible," Naciones Unidas, [En línea]. Disponible en: <https://www.un.org/sustainabledevelopment/es/objetivos-de-desarrollo-sostenible/> [Consultado: 1 de junio de 2026].
- [21] J. Redmon, S. Divvala, R. Girshick, y A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection", in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2016.
- [22] Arduino, "Arduino IDE," [En línea]. Disponible en: <https://www.arduino.cc/en/software>. [Consultado: 1 de junio de 2026].
- [23] Arduino, "Arduino IoT Cloud," [En línea]. Disponible en: <https://cloud.arduino.cc/>. [Consultado: 1 de junio de 2026].
- [24] PyTorch, "PyTorch: An Open Source Machine Learning Framework," [En línea]. Disponible en: <https://pytorch.org/>. [Consultado: 1 de junio de 2026].
- [25] Django Software Foundation, "Django: The Web Framework for Perfectionists with Deadlines." [En línea]. Disponible en: <https://www.djangoproject.com/>. [Consultado: 1 de junio de 2026].
- [26] Tailwind CSS, "Rapidly Build Modern Websites Without Ever Leaving Your HTML." [En línea]. Disponible en: <https://tailwindcss.com/>. [Consultado: 1 de junio de 2026].
- [27] Roboflow, "Roboflow Universe: Free Computer Vision Datasets and Models." [En línea]. Disponible en: <https://universe.roboflow.com/>. [Consultado: 1 de junio de 2026].
- [28] C. I. Silva Rincon, E. Alarcón Gutiérrez, J. A. García Pérez, L. R. Sánchez-Velásquez y L. G. Iglesias Andreu, "Variedad de café Geisha y su estatus en el mundo y en México", *Rev. Mex. Cienc. Agric.*, vol. 15, n.º 7, diciembre de 2024, art. n.º e3403. <https://doi.org/10.29312/remexca.v15i7.3403>
- [29] T. Y. Lin, M. Maire, S. Belongie et al., "Microsoft COCO: Common Objects in Context," in *Proc. Eur. Conf. Comput. Vis. (ECCV)*, 2014, pp. 740–755.