



## Aplicación de inteligencia artificial en evaluación y clasificación de café: Una revisión sistemática

### Application of artificial intelligence in coffee evaluation and classification: A systematic review

**Vanessa del Rocio Rios Salazar**

Universidad Católica Sedes Sapientiae, Nueva Cajamarca, Perú

2021100254@ucss.pe ✉

ORCID: 0009-0005-4434-5558

**Nixon Omar Fernández Carrión**

Universidad Católica Sedes Sapientiae, Nueva Cajamarca, Perú

nfernandez@ucss.edu.pe

ORCID: 0000-0003-4510-8667



<https://doi.org/10.36825/RITI.14.33.002>

Recibido: Noviembre 16, 2025

Aceptado: Marzo 03, 2026

**Resumen:** Este estudio analiza cómo la evaluación y clasificación del café son procesos clave para asegurar la calidad y el valor comercial del producto; sin embargo, los métodos tradicionales basados en inspección humana presentan limitaciones de subjetividad, tiempo y consistencia. En los últimos años, la inteligencia artificial ha mostrado un crecimiento significativo en aplicaciones orientadas a automatizar estos procesos, especialmente mediante visión por computadora y aprendizaje automático. Ante la rápida expansión y dispersión de estos estudios, este trabajo tiene como motivación principal analizar y sintetizar de manera sistemática los avances en el uso de inteligencia artificial para la evaluación y clasificación del café. Para ello, se realizó una revisión sistemática siguiendo el protocolo PRISMA, considerando estudios originales publicados entre 2021 y 2025 en bases de datos científicas, periodo seleccionado por concentrar desarrollos recientes y consolidados. Se incluyeron 30 artículos, en los que predominan aplicaciones enfocadas en el control de calidad del grano, como clasificación, detección de defectos y autenticidad, empleando imágenes RGB y espectros NIR/UV-VIS junto con algoritmos como redes neuronales, SVM, *Random Forest* y XGBoost, con precisiones superiores al 90%. A pesar de estos resultados, persisten desafíos relacionados con la disponibilidad de datos, la generalización de modelos y costos computacionales.

**Palabras clave:** *Inteligencia Artificial, Visión por Computadora, Café, Clasificación de Calidad, Detección de Defectos.*

**Abstract:** This study analyzes how the evaluation and classification of coffee are key processes to ensure the quality and commercial value of the product; However, traditional methods based on human inspection present limitations of subjectivity, time and consistency. In recent years, artificial intelligence has shown significant growth in applications aimed at automating these processes, especially through computer vision and machine

learning. Given the rapid expansion and dispersion of these studies, the main motivation of this work is to systematically analyze and synthesize the advances in the use of artificial intelligence for the evaluation and classification of coffee. To this end, a systematic review was carried out following the PRISMA protocol, considering original studies published between 2021 and 2025 in scientific databases, a period selected to concentrate recent and consolidated developments. 30 articles were included, in which applications focused on grain quality control predominate, such as classification, defect detection and authenticity, using RGB images and NIR/UV-VIS spectra together with algorithms such as neural networks, SVM, Random Forest and XGBoost, with accuracies greater than 90%. Despite these results, challenges related to data availability, model generalization, and computational costs persist.

**Keywords:** *Artificial Intelligence, Computer Vision, Coffee, Quality Classification, Defect Detection.*

## 1. Introducción

El café es una de las bebidas más consumidas a nivel mundial y se distingue por su sabor y aroma; desde el punto de vista económico, constituye el segundo producto agrícola más importante después del petróleo [1]. Asimismo, las características de calidad sensorial de la bebida final dependen no solo de la recolección, sino también de las etapas de postcosecha, como el secado, el almacenamiento y otros procesos de transformación [2]. En este contexto, la calidad del grano adquiere un rol central, ya que el tamaño y la apariencia del café verde influyen directamente en su valor comercial; por ello, la evaluación adecuada del grano y la detección oportuna de defectos representan etapas críticas del control de calidad [3]. No obstante, de forma tradicional esta inspección se realiza mediante evaluación visual humana, un proceso que requiere experiencia consume tiempo y es susceptible a errores derivados de la fatiga o la distracción del evaluador [4].

En los países desarrollados ya se emplean máquinas clasificadoras automáticas que separan los granos de café por tamaño y eliminan aquellos defectuosos, como los negros, agrios o rotos [5]. En este sentido diversos investigadores han estudiado métodos para clasificar automáticamente la calidad de los granos de café crudos utilizaron análisis de textura e información de color RGB para extraer las características de los granos de café, y entrenaron una red neuronal para la clasificación utilizando los datos [6]. Cabe destacar que el aprendizaje profundo está logrando grandes avances en la resolución de problemas que han resistido los mejores intentos de la comunidad de inteligencia artificial durante muchos años [7].

A nivel Latinoamericano, gran parte de la agroindustria cafetera aún clasifica los granos manualmente, aunque algunos sectores ya usan maquinarias semiautomáticas que optimizan la etapa previa al tostado al clasificar los granos por forma y tamaño [8]. En el caso de Colombia, donde el café es vital para la economía, se desarrolló *HumiCafé*, una *app* móvil de bajo costo basada en aprendizaje supervisado y visión por computador, que tecnifica el secado del grano y garantiza una humedad óptima del 10% al 12%, superando los métodos tradicionales [9].

Por otro lado, la inteligencia artificial (IA) ha demostrado ser una herramienta de gran valor en el sector agrícola, donde se aplica para optimizar la eficiencia, la productividad y la calidad de los procesos, además de ofrecer soluciones a problemas complejos que tradicionalmente dependían de la intervención humana [10]. En particular, el uso de técnicas de procesamiento de imágenes y aprendizaje automático, como las redes neuronales convolucionales (CNN), las máquinas de vectores de soporte (SVM) y el algoritmo de los  $k$  vecinos más cercanos (KNN), ha permitido el desarrollo de sistemas capaces de analizar y clasificar cultivos con alta precisión [5]. Estos algoritmos se emplean principalmente en tareas como la detección de plagas, el monitoreo del crecimiento vegetal, la clasificación de frutos y granos, y la evaluación de la calidad de los productos agrícolas, mediante el reconocimiento de patrones visuales y estructurales en las imágenes capturadas [11].

Asimismo, como la mayor parte del mundo depende del café, los productores, tostadores e inversores están cada vez más comprometidos a mantener al mínimo la deforestación provocada por el café en Vietnam a través de la Inteligencia Artificial y la teledetección, la Alianza y sus socios están brindando información y oportunidades para cerrar brechas en el monitoreo de la pérdida de bosques debido a la producción de café [12]. Hoy en día, el gobierno, el sector privado y las organizaciones de investigación están haciendo uso de la tecnología y la inteligencia artificial (IA) en muchos escenarios y diferentes industrias para desarrollar soluciones innovadoras y sostenibles a algunos de los desafíos que enfrentan hoy los agricultores y productores [12].

## 2. Teorías

Por consiguiente, en cuanto a las teorías, se tiene que el reconocimiento de patrones (*pattern recognition*) surgió a finales de la década de 1950 con los aportes de Rosenblatt y Block sobre el Perceptrón, junto con colegas del M.I. [13]. Esta teoría explica cómo las máquinas aprenden a identificar regularidades en los datos y clasificarlas mediante descriptores estructurados llamados patrones, en el ámbito de la teledetección, este enfoque ha sido fundamental para mejorar la clasificación de imágenes geográficas, superando las limitaciones de los métodos basados solo en datos espectrales de píxeles [14]. Asimismo, la Teoría del Aprendizaje Estadístico (*Statistical Learning Theory*), introducida por Vapnik a finales de los sesenta, constituye la base estadística del aprendizaje automático, al centrarse en maximizar la precisión predictiva de los modelos y evitar el sobreajuste mediante métodos de regresión aplicados a grandes volúmenes de datos [15]. Esta teoría representa la base estadística del aprendizaje automático, al emplear métodos analíticos que maximizan la precisión predictiva y evitan el sobreajuste en problemas de big data mediante algoritmos de regresión [16].

Por su parte, la percepción computacional puede entenderse desde el enfoque de la visión propuesto por Poggio [17], quien planteó que “ver” es esencialmente una tarea de procesamiento de información orientada a representar de forma útil los aspectos del entorno para la acción. Esta teoría explica el proceso de detectar, organizar e interpretar la información visual para comprender el entorno, lo que ha inspirado modelos computacionales de gran complejidad y diversidad, sustentados en la ciencia cognitiva, la información y la inteligencia artificial [18]. En este contexto, la visión por computadora se aplica en la evaluación automática de cultivos, como en la detección, clasificación y mapeo de frutos de café según su madurez durante la cosecha mecanizada [19]. Además, la detección de objetos tarea esencial en visión por computadora permite identificar y localizar elementos dentro de una imagen; las características locales capturan detalles como bordes y texturas, mientras que las globales describen la estructura general y las relaciones espaciales [20].

Finalmente, este estudio plantea como objetivo general analizar y sintetizar la literatura científica relacionada con las aplicaciones de la inteligencia artificial en la evaluación y clasificación del café, con el propósito de reconocer las principales técnicas, metodologías, resultados, desafíos y tendencias de investigación en este ámbito. Para alcanzar dicho propósito, se han formulado los siguientes objetivos específicos: en primer lugar, identificar y clasificar los diferentes usos de la inteligencia artificial en la determinación de la calidad, la detección de defectos, el análisis sensorial y la estandarización de procesos; en segundo lugar, examinar las técnicas, algoritmos y modelos empleados en la clasificación de granos de café, destacando su precisión y eficiencia; y, finalmente, evaluar los resultados, limitaciones y retos que presenta la implementación de estas tecnologías en los procesos de evaluación y comercialización del café.

## 3. Materiales y Métodos

La naturaleza del tema abordado requirió de la realización de un estudio de investigación documental con un enfoque descriptivo, siguiendo las pautas establecidas en el protocolo PRISMA el cual consiste en una guía basada en evidencia para realizar revisiones sistemáticas y metaanálisis y cuyo objetivo principal es asegurar la transparencia y precisión en la presentación de los resultados de estas investigaciones [21]. Las revisiones sistemáticas cumplen muchas funciones críticas, pueden proporcionar síntesis del estado del conocimiento en un campo, a partir del cual se pueden identificar futuras prioridades de investigación; pueden abordar preguntas que de otro modo no podrían responderse mediante estudios individuales; pueden identificar problemas en la investigación primaria que deberían rectificarse en estudios futuros; y pueden generar o evaluar teorías sobre cómo o por qué ocurren los fenómenos [22].

### 3.1. Elaboración de la cadena de búsqueda

Para la identificación de los estudios se diseñó y aplicó una estrategia de búsqueda sistemática, cuya cadena de términos se presenta en la Tabla 1. Dicha estrategia fue ejecutada en las bases de datos *Scopus*, *ScienceDirect*, *IEEE Xplore* y *Springer Nature Link*, seleccionadas por su amplia cobertura en investigaciones científicas y tecnológicas. Posteriormente, los registros recuperados fueron sometidos a un proceso de selección mediante la aplicación de criterios de inclusión y exclusión definidos previamente (Tabla 2), con el fin de depurar los resultados y asegurar que únicamente se consideraran aquellos estudios que cumplieran con los objetivos y el alcance establecidos en la presente revisión sistemática.

**Tabla 1.** Ecuación de búsqueda.

| <b>Tópico</b>                              | <b>Términos buscados</b>                                                                                                                                                                                                                                                                                                                                    |
|--------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Temática/ IA Aprendizaje Automático</b> | ("artificial intelligence" OR "AI" OR "machine learning" OR "deep learning" OR "aprendizaje automático" OR "aprendizaje profundo" OR "redes neuronales" OR "neural networks" OR "convolutional neural networks" OR "CNN")                                                                                                                                   |
| <b>Aplicación</b>                          | ("coffee" OR "Coffea" OR "Arabica" OR "Robusta" OR "coffee beans" OR "coffee cherries" OR "coffee leaves" OR "coffee plant" OR "café" OR "granos de café" OR "cerezas de café" OR "fruta del café" OR "café verde" OR "café tostado")                                                                                                                       |
| <b>Contexto objetivo de evaluación</b>     | ("quality assessment" OR "defect detection" OR "coffee grading" OR "classification" OR "evaluación de calidad" OR "detección de defectos" OR "clasificación de café" OR "calidad del café")                                                                                                                                                                 |
| <b>Tecnología</b>                          | ("computer vision" OR "machine vision" OR "artificial vision" OR "image processing" OR "pattern recognition" OR "image segmentation" OR "object detection" OR "automated classification" OR "image analysis" OR "visión por computadora" OR "visión artificial" OR "procesamiento de imágenes" OR "segmentación de imágenes" OR "clasificación automática") |

Fuente: Elaboración propia.

### 3.2. Criterios de inclusión y exclusión de los estudios

El diseño de los términos de búsqueda, así como la definición de los criterios de inclusión y exclusión, se establecieron siguiendo las recomendaciones metodológicas propuestas en [21] y [22]. Estos criterios permiten determinar los elementos que un artículo debe presentar para ser considerado elegible dentro de la revisión de la literatura, así como aquellos aspectos que pueden descalificar un estudio para su inclusión, según los criterios de la Tabla 2, se consideraron estudios publicados entre 2021 y 2025, con el fin de incorporar los avances más recientes en el uso del reconocimiento facial en educación. Se priorizaron artículos en idioma inglés para asegurar la calidad y relevancia científica de las investigaciones analizadas.

**Tabla 2.** Criterios de inclusión y exclusión.


| <b>Criterio de inclusión</b>                                                                                                                                                    | <b>Criterio de exclusión</b>                                                                                            |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------|
| Publicaciones entre 2021 y 2025                                                                                                                                                 | Publicaciones anteriores a 2020                                                                                         |
| Escritas en inglés y español                                                                                                                                                    | Escritas en otros idiomas diferentes                                                                                    |
| Indexadas en <i>Scopus</i> , <i>ScienceDirect</i> , <i>IEEE explore</i> , <i>Springer Nature Link</i>                                                                           | Bases no Indexadas a dichas revistas                                                                                    |
| Estudios relacionados con la aplicación de inteligencia artificial, <i>machine learning</i> o <i>deep learning</i> en la evaluación, clasificación, calidad o defectos del café | Estudios no relacionados con café o que no apliquen técnicas de IA en el análisis, clasificación o evaluación del café. |
| Investigaciones empíricas, experimentales o estudios de aplicación tecnológica (ej. clasificación de granos, detección de defectos, control de calidad, madurez, enfermedades)  | Revisiones teóricas sin evidencia empírica o estudios generales de IA sin aplicación en café                            |
| Acceso abierto                                                                                                                                                                  | Sin acceso disponible o restringido                                                                                     |

Fuente: Elaboración propia.

### 3.3. Bases de datos y estrategia de búsqueda

Asimismo, en esta revisión se destaca la utilización de la base de datos *Scopus* reconocida en el mundo de la investigación académica, como una de las plataformas más importantes para acceder a literatura científica de alta calidad, esta base de datos, desarrollada por Elsevier, es reconocida por su amplia cobertura de publicaciones y su capacidad para proporcionar análisis detallados sobre el impacto de la investigación [23]. Esta plataforma,

junto con *ScienceDirect*, *IEEE Xplore* y *Springer Nature Link*, aseguró la recuperación de literatura relevante y confiable, permitiendo establecer un corpus de estudios sólidos y representativos para el desarrollo de la revisión.



**Figura 1.** Diagrama de flujo PRISMA del estudio. Fuente: Elaboración propia

En la revisión sistemática realizada en la Figura 1, se identificaron inicialmente 10,205 artículos, registrados en las cuatro bases de datos ya mencionadas, tras eliminar 365 duplicados quedaron 9,840 registros para cribado, de los que se excluyeron 6,223 por estar fuera del periodo (*Scopus*: 193; *ScienceDirect*: 2,893; *IEEE Xplore*: 1,980; *Springer Nature*: 1,157), quedando 3,617 artículos para evaluación de idoneidad; en esta fase se descartaron 2 575 por no ser investigaciones originales (*Scopus*: 545; *ScienceDirect*: 302; *IEEE Xplore*: 994; *Springer Nature*: 734), 762 por no estar en acceso abierto (*Scopus*: 50; *ScienceDirect*: 376; *IEEE Xplore*: 95; *Springer Nature*: 241) y 250 por no estar directamente relacionados con el objetivo del estudio, de modo que 30 artículos cumplieron todos los criterios y fueron finalmente incluidos para el análisis.

#### 4. Resultados

La presente sección expone los resultados obtenidos a partir del proceso de búsqueda, selección y análisis de los artículos incluidos en la revisión sistemática, el propósito fue identificar la cantidad y procedencia de los estudios que cumplen con los criterios de inclusión definidos, así como mostrar de forma estructurada las etapas de depuración seguidas durante el proceso de revisión. Durante la búsqueda sistemática, se consultaron distintas bases de datos científicas con el objetivo de recopilar estudios relacionados con la aplicación de inteligencia artificial en la evaluación y clasificación del café. En total, se identificaron 30 artículos distribuidos entre las bases *Scopus*, *ScienceDirect*, *IEEE Xplore* y *Springer Nature Link*.

Tal y como se muestra en la Tabla 3, los resultados muestran que *Scopus* concentró la mayor cantidad de artículos (50%), seguida de *Springer Nature Link* con un 20%, *ScienceDirect* con un 16.67% y *IEEE Xplore* con

un 13.33%. Esta distribución evidencia que las bases de datos con mayor cobertura en áreas científicas y tecnológicas, como *Scopus*, reúnen un volumen más amplio de investigaciones relevantes sobre la aplicación de inteligencia artificial en el sector cafetalero.

**Tabla 3.** Cantidad de artículos incluidos según base de datos.

| Base de datos        | Cantidad de artículos | %           |
|----------------------|-----------------------|-------------|
| IEE Xplore           | 4                     | 13.33%      |
| ScienceDirect        | 5                     | 16.67%      |
| Scopus               | 15                    | 50%         |
| Springer Nature Link | 6                     | 20%         |
| <b>Total</b>         | <b>30</b>             | <b>100%</b> |

Fuente: Elaboración propia.

En la distribución de los estudios por año se aprecia un aumento gradual de la producción científica entre 2021 y 2025. Según la Tabla 4, en 2021 se publicaron 3 artículos (10%), lo que evidencia un interés inicial en el uso de inteligencia artificial en este campo. En 2022 las publicaciones crecieron a 7 (23.33%), mientras que en 2023 descendieron a 3 (10%), posiblemente por ajustes en los enfoques de investigación. Posteriormente, 2024 y 2025 registraron 8 (26.67%) y 9 (30%) estudios, respectivamente, consolidando una tendencia de crecimiento sostenido. En conjunto, estos datos muestran la progresiva maduración del campo y la consolidación de la inteligencia artificial como herramienta clave para la evaluación y mejora de la calidad del café.

**Tabla 4.** Artículos incluidos según año de publicación.

| Año          | Cantidad de artículos | %           |
|--------------|-----------------------|-------------|
| 2021         | 3                     | 10%         |
| 2022         | 7                     | 23.33%      |
| 2023         | 3                     | 10.00%      |
| 2024         | 8                     | 26.67%      |
| 2025         | 9                     | 30%         |
| <b>Total</b> | <b>30</b>             | <b>100%</b> |

Fuente: Elaboración propia.

La Tabla 5 resume la procedencia de los 30 estudios incluidos, organizados por país o región. La distribución es amplia y confirma el carácter global del uso de algoritmos de inteligencia artificial y aprendizaje automático en la evaluación y clasificación del café. Indonesia concentra el mayor número de trabajos (16.13%), seguida de Perú y China (9.68% cada uno). En un segundo grupo se sitúan India, Tailandia, Colombia e India/Corea, con 6.45% por país. Además, colaboraciones entre Japón/Bangladés, Turquía/Bulgaria, España/Colombia y consorcios que integran Pakistán, Corea, Jordania, Iraq e India representan 3.23% cada uno. En conjunto, los datos evidencian un esfuerzo de investigación en expansión, sustentado en la cooperación internacional y el interés de los países productores.

**Tabla 5.** Distribución de estudios por país.

| País             | Cantidad de artículos | %      |
|------------------|-----------------------|--------|
| India            | 2                     | 6.45%  |
| Indonesia        | 5                     | 16.13% |
| Perú             | 3                     | 9.68%  |
| China            | 3                     | 9.68%  |
| Tailandia        | 2                     | 6.45%  |
| Taiwán           | 1                     | 3.23%  |
| Japón/ Banglares | 1                     | 3.23%  |
| India/Corea      | 2                     | 6.45%  |

|                                           |           |             |
|-------------------------------------------|-----------|-------------|
| República de Corea                        | 1         | 3.23%       |
| Pakistán / Corea / Jordania / Iraq/ india | 1         | 3.23%       |
| Colombia                                  | 2         | 6.45%       |
| Turquía/Bulgaria                          | 1         | 3.23%       |
| España/Colombia                           | 1         | 3.23%       |
| Irán                                      | 1         | 3.23%       |
| Australia                                 | 1         | 3.23%       |
| Bangladesh/Japón                          | 1         | 3.23%       |
| Italia                                    | 1         | 3.23%       |
| Brasil                                    | 1         | 3.23%       |
| Vietnam                                   | 1         | 3.23%       |
| <b>Total</b>                              | <b>30</b> | <b>100%</b> |

Fuente: Elaboración propia.

La Tabla 6 muestra que se identificaron seis aplicaciones de IA en café: clasificación de calidad/grado con diez estudios (33.3%), detección de defectos y autenticidad con cinco cada una (16.7%), enfermedades en planta y granulometría de molienda con cuatro cada una (13.3%), y predicción de rendimiento con dos (6.7 %). El foco se concentra en grano verde con veinte estudios (66.7 %), seguido de en planta y molienda con cuatro cada uno (13.3 %), y cultivo/producción con dos (6.7 %). Predominan entradas RGB, UV-Vis/NIR, IoT y SIG, con salidas en clase o localización *bbox*, evaluadas con *accuracy*, F1, mAP, *precision/recall*, R<sup>2</sup>, RMSE y AUC. En suma, prevalecen las tareas de clasificación del grano, mientras que las orientadas a campo y predicción productiva siguen siendo incipientes.

**Tabla 6.** Sistema de Clasificación de usos de IA en café.

| Uso de la IA                      | Datos de entrada típicos            | Salida del modelo                                                 | Segmento del café  | Métricas habituales            | Frecuencia | Artículos                                                |
|-----------------------------------|-------------------------------------|-------------------------------------------------------------------|--------------------|--------------------------------|------------|----------------------------------------------------------|
| Clasificación de calidad/grado    | Imagen RGB de grano/tostado; color. | Clase de grado, óptimo/sobre/inferior.                            | Grano verde        | <i>Accuracy</i> , F1.          | 10         | [24], [25], [1], [26], [2], [27], [27]                   |
| Detección de defectos             | Imagen RGB; visión por comp.        | Localización/clase de defecto ( <i>bbox</i> o etiqueta).          | Grano verde        | mAP, <i>precision/recall</i> . | 5          | [28], [5], [7], [29], [8], [30], [31], [32], [33], [34]. |
| Detección de enfermedades         | Imagen de planta/hoja/cereza.       | Enfermedad presente/ausente                                       | Cultivo/producción | <i>Accuracy</i> , F1.          | 4          | [39], [40]                                               |
| Granulometría de molienda         | Imagen de molido y textura.         | Clase de granulometría.                                           | En planta          | <i>Accuracy</i> .              | 4          | [41], [42], [42], [43]                                   |
| Predicción de rendimiento/aptitud | Variables SIG/clima/suelo /área.    | SIG/clima/suelo /área.<br>Rendimiento/aptitud (numérica o clase). | Molienda           | R <sup>2</sup> , RMSE, AUC.    | 2          | [6], [44], [45], [46],                                   |

Fuente: Elaboración propia.

La Tabla 7 muestra que el 50 % de los estudios aplica IA en grano verde detección de defectos, autenticación y clasificación de calidad Cultivo/Producción y tueste concentran 10 % cada uno; almacenamiento y planificación del cultivo, 6.7 % cada uno; y cosecha, secado, molienda, extracción y enfoques metodológicos, 3.3 % cada uno. En síntesis, la IA se centra en el control de calidad del grano, con expansión gradual hacia etapas de cultivo y postcosecha.

**Table 7.** Estudios consolidados según etapa del proceso del café.

| Etapa del proceso del café     | Qué se evalúa / aplicación típica                                            | Frecuencia | %    | Estudios                                                                             |
|--------------------------------|------------------------------------------------------------------------------|------------|------|--------------------------------------------------------------------------------------|
| Grano verde control de calidad | Detección/ clasificación de defectos, especie/origen, calidad de grano crudo | 15         | 50%  | [47], [28], [5], [39], [6], [25], [29], [30], [33], [1], [45], [35], [37], [3], [24] |
| Cultivo / producción           | Sanidad vegetal y plagas en plantas/hojas/cereza                             | 3          | 10%  | [41], [42], [43]                                                                     |
| Tueste                         | Nivel de tueste y perfil aromático                                           | 3          | 10%  | [8], [44], [31]                                                                      |
| Almacenamiento                 | Isotermas de sorción y humedad                                               | 2          | 6.7% | [2], [38]                                                                            |
| Cosecha / selección de frutos  | Madurez/selección por color                                                  | 1          | 3.3% | [34]                                                                                 |
| Poscosecha secado              | Medición de humedad en grano                                                 | 1          | 3.3% | [9]                                                                                  |
| Molienda / granulometría       | Clasificación del tamaño de partícula tras la molienda                       | 1          | 3.3% | [32]                                                                                 |
| Bebida / extracción            | Calidad de la bebida en tiempo real (espresso)                               | 1          | 3.3% | [36]                                                                                 |

Fuente: Elaboración propia.

La Tabla 8 muestra el desempeño y la frecuencia de uso de los algoritmos aplicados en la evaluación del café. Las redes neuronales convolucionales (CNN) son las más empleadas, con una participación del 37% y precisiones entre 91 y 99.5%, seguidas por las redes neuronales artificiales (ANN), que representan el 17% y alcanzan rendimientos cercanos al 99%. Los modelos de máquinas de vectores de soporte (SVM) y *Random Forest* (RF) registran cerca del 10% de uso cada uno, con exactitudes alrededor del 96%. Por su parte, los enfoques estadísticos o híbridos presentan menor presencia, aunque mantienen precisiones elevadas, entre 86.6 y 10 %.

**Tabla 8.** Modelos de evaluación de granos de café.

| Algoritmo/Modelo                       | Precisión (%) promedio | Eficiencia                                 | Frecuencia | Estudios                                                       |
|----------------------------------------|------------------------|--------------------------------------------|------------|----------------------------------------------------------------|
| Naive Bayes                            | 94%                    | mAP 0.5 = 99.50                            | 1          | [39]                                                           |
| Redes Neuronales Artificiales (ANN)    | 97–99 %                | 98.78–99.84 (CV); 88.63 (test externo)     | 5          | [34], [40], [1], [44], [26]                                    |
| <i>Transformers</i> (Swin)             | 96.34 %                | mAP = 98.51; F1 = 96.35                    | 1          | [3]                                                            |
| Modelos estadísticos (PLS-DA)          | 86.6–100 %             | <i>Accuracy</i> = 86.6–100 %; $R^2 > 0.95$ | 2          | [36], [37]                                                     |
| XGBoost ( <i>Boosting</i> )            | 98.56–99 %             | $R^2 = 0.97–0.99$ ; RPD = 11.19            | 1          | [45]                                                           |
| Redes Neuronales Convolucionales (CNN) | 91–99.5 %              | <i>Accuracy</i> = 96–99 %; F1 $\approx$ 96 | 11         | [8], [6], [25], [32], [35], [31], [43], [28], [29], [24], [47] |
| <i>Random Forest</i>                   | 96 %                   | <i>Accuracy</i> = 96 %; F1 $\approx$ 95    | 3          | [42], [38], [38]                                               |
| Algoritmos de emparejamiento           | 93–99 %                | <i>Accuracy</i> = 98.56; F1 = 87.24        | 2          | [41], [30].                                                    |
| <i>Support Vector Machines</i> (SVM)   | 96–99 %                | <i>Accuracy</i> = 93.66–99 %; F1 = 87–96   | 3          | [5], [2], [38]                                                 |

Fuente: Elaboración propia.



La Tabla 9 resume los modelos de inteligencia artificial con mejor rendimiento. Cerca del 40% de los estudios empleó redes neuronales convolucionales (CNN), con arquitecturas como YOLOv8 y MobileNetV3 que alcanzaron valores de *mean Average Precision* (mAP) cercanos a 1.0 y exactitudes alrededor del 99%. En aproximadamente el 20% de los trabajos se aplicaron enfoques espectroscópicos basados en análisis discriminante por mínimos cuadrados parciales (PLS-DA) y *Extreme Gradient Boosting* (XGBR), logrando precisiones de hasta 100% y coeficientes de determinación ( $R^2$ ) mayores a 0.97. Otro 23% utilizó máquinas de vectores de soporte (SVM), XGBoost y redes neuronales clásicas, con exactitudes entre 97 y 99%. En conjunto, las CNN dominan el análisis visual del café, mientras que los modelos basados en árboles y regresión se consolidan para datos espectrales.

**Tabla 9.** Mejores modelos por tipo de tarea (precisión/eficiencia destacada).

| Estudios | Tarea                         | Modelo / familia | Métrica principal | Valor         |
|----------|-------------------------------|------------------|-------------------|---------------|
| [35]     | Detección de defectos         | YOLOv8 (CNN)     | mAP               | 0.995         |
| [28]     | Detección de localización     | MobileNetV3      | <i>Accuracy</i>   | 98.78–99.84%  |
| [3]      | Clasificación de calidad      | Swin-HSSAM       | mAP / F1          | 98.51         |
| [24]     | Defectos multiescala          | CNN-Inception    | <i>Accuracy</i>   | 96 %          |
| [37]     | Autenticidad (especie/origen) | PLS-DA (UV–VIS)  | <i>Accuracy</i>   | 100% - 88,96% |
| [45]     | Parámetros químicos           | XGBR (NIRS)      | $R^2$ / RPD       | 0.97–0.99     |
| [49]     | Humedad / almacenamiento      | SVM              | $R^2$             | > 0.99        |
| [42]     | Enfermedades en planta        | XGBoost + SHAP   | <i>Accuracy</i>   | 98.56%        |
| [44]     | Perfil de tueste / aroma      | ANN + E-nose     | <i>Accuracy</i>   | 97–99%        |

Fuente: Elaboración propia.

La Tabla 10 muestra que siete de los treinta estudios (23%) emplearon múltiples algoritmos de inteligencia artificial para comparar su desempeño en la evaluación y clasificación del café. De estos, el 57% evaluó entre tres y cuatro modelos, principalmente combinaciones de máquinas de vectores de soporte (SVM), *Random Forest*, *Naive Bayes*, *Decision Tree*, regresión por mínimos cuadrados parciales (PLSR) y *Extreme Gradient Boosting* (XGBR). El 29% restante comparó entre dos y tres algoritmos, destacando redes neuronales convolucionales (CNN),  $k$  vecinos más cercanos (kNN) y redes neuronales artificiales (ANN). En conjunto, los resultados evidencian una tendencia creciente hacia la evaluación comparativa y la selección del modelo más adecuado según el tipo de dato y la tarea analizada.

**Tabla 10.** Estudios que emplean tipos de algoritmos más utilizado

| Estudio | N.º de algoritmos | Algoritmos probados                                     |
|---------|-------------------|---------------------------------------------------------|
| [39]    | 4                 | MLP, <i>Naive Bayes</i> , SVM, <i>Decision Tree</i>     |
| [49]    | 4                 | SVM, <i>Random Forest</i> , kNN, <i>Regression Tree</i> |
| [45]    | 4                 | XGBR, SVR, Ridge, PLSR                                  |
| [42]    | 4                 | XGBoost, <i>Random Forest</i> , SVM                     |
| [5]     | 3                 | CNN, SVM, kNN                                           |
| [2]     | 3                 | SVM, <i>Random Forest</i> , ANN                         |
| [30]    | 2                 | VGG-based + LGBM (híbrido)                              |
| [25]    | 2                 | AlexNet vs. CNN                                         |

Fuente: Elaboración propia.

La Tabla 11 resume la eficiencia computacional y la viabilidad de los modelos de inteligencia artificial aplicados al café. De los 30 estudios revisados, solo una cuarta parte reporta métricas de eficiencia como tiempo de inferencia, tamaño del modelo o hardware utilizado. Los modelos ligeros, como MobileNetV3 y CNN cuantizadas, muestran buen desempeño en entornos de bajo costo, con tamaños cercanos a 5.6 MB y tiempos de inferencia del orden de cientos de milisegundos por imagen. En contraste, arquitecturas más complejas, como Swin-HSSAM o VGGBM-Net, alcanzan mayores niveles de precisión, pero dependen del uso de GPU, lo que limita su implementación en campo. En conjunto, los resultados evidencian la necesidad de optimizar los modelos mediante técnicas como cuantización, poda o destilación para equilibrar precisión y eficiencia en aplicaciones agrícolas reales.

**Tabla 11.** Requisitos computacionales y viabilidad de despliegue de los modelos de IA en café.

| Estudio | Entorno / hardware             | Viabilidad                | Consideraciones prácticas                                      |
|---------|--------------------------------|---------------------------|----------------------------------------------------------------|
| [5]     | Raspberry Pi 3 ( <i>edge</i> ) | Prototipo de campo        | SVM/kNN penalizan en <i>edge</i> ; CNN optimizada rinde mejor. |
| [28]    | Web app (CPU)                  | 5.63 MB modelo cuantizado | Listo para móvil/ <i>edge</i> ; caída por cambio de dominio    |
| [29]    | App web/móvil                  | Despliegue ligero         | Precisión afectada por iluminación y HW disponible.            |
| [3]     | PC-GPU                         | Tiempo real básico        | Swin-HSSAM; no apto para microcontrolador sin cuantización.    |
| [30]    | PC-GPU                         | Laboratorio               | Recomendable cuantización para <i>edge</i> .                   |

Fuente: Elaboración propia.

La Tabla 12 sintetiza las principales limitaciones identificadas en la implementación de algoritmos de inteligencia artificial para la evaluación del café. Predominan las restricciones asociadas al tamaño y calidad de los datasets y al cambio de dominio, seguidas por los altos costos de hardware y la complejidad de los modelos avanzados. Asimismo, se reportan dependencias en sensores y calibración, confusión entre clases visualmente similares, costos de etiquetado y falta de estandarización de métricas, lo que evidencia desafíos técnicos y operativos para la adopción de estas tecnologías en entornos reales.

**Tabla 12.** Principales limitaciones identificadas en la implementación de tecnologías.

| Algoritmos / Tecnologías         | Categoría de limitación          | Descripción breve                                                         | Frecuencia | %     |
|----------------------------------|----------------------------------|---------------------------------------------------------------------------|------------|-------|
| CNN, ANN, YOLOv8                 | Tamaño/calidad del dataset       | Conjuntos pequeños, desbalanceados o con ruido.                           | 9          | 30%   |
| MobileNetV3, CNN, YOLOv8, HV-GNN | Cambio de dominio                | Caída en test externo o al cambiar iluminación/equipo/escenario.          | 6          | 20%   |
| YOLOv8, HV-GNN                   | Costo de hardware                | Requiere GPU o no alcanza tiempo real en edge.                            | 4          | 13.3% |
| Swin Transformer, VGGBM-Net.     | Complejidad del modelo           | Modelos pesados, difíciles de actualizar.                                 | 3          | 10%   |
| PLS-DA, NIRS                     | Sensores y calibración           | Dependencia de preprocesado (NIR, UV-VIS).                                | 3          | 10%   |
| CNN, Inception, ResNe            | Confusión entre clases similares | Defectos visualmente parecidos generan errores.                           | 2          | 6.7%  |
| YOLOv8, CNN                      | Etiquetado costoso               | Anotación manual lenta o inconsistente.                                   | 1          | 3.3%  |
| CNN, Random Forest, PLS-DA       | Métricas                         | Dificulta comparar (Accuracy, mAP, F1, R <sup>2</sup> , RPD; CV vs test). | 1          | 3.3%  |

Fuente: Elaboración propia.

## 5. Discusión de Resultados

En la revisión se observó que la mayoría de los estudios sobre IA en café se enfocan en la clasificación de calidad o grado, que reúne el 33.3% de los trabajos y constituye el eje más consolidado al definir valor comercial y trazabilidad. La detección de defectos representa el 16.7%, donde las redes neuronales convolucionales (CNN) destacan por precisiones superiores al 98% en la identificación de imperfecciones [25]. Por otro lado, la autenticidad de especie u origen ocupa una posición relevante con 16.7 %, sustentada en técnicas espectroscópicas y modelos estadísticos como PLS-DA y SVM, que logran exactitudes cercanas al 100% [37].

Por lo tanto, considerando los estudios consolidados según etapas del proceso se concentra en el control temprano del grano, donde destacan los estudios de detección de defectos, autenticidad y clasificación, porque definen calidad y precio, donde resaltan dos frentes: cultivo/campo, con trabajos de diagnóstico en hojas/cereza, y tueste, con modelos que buscan caracterizar el nivel y el perfil aromático [3]. Finalmente, aparecen aportes puntuales en almacenamiento (humedad y sorción) y en planificación con herramientas SIG/MCDM, el resto de las etapas cosecha, postcosecha-secado, molienda, y enfoques transversales metodológicos se observa como líneas todavía exploratorias, la evidencia perfila a la IA como filtro preventivo en las primeras etapas y apunta a oportunidades para integrar lo sensorial y el proceso en las fases posteriores [45].

A partir de lo anterior, en los modelos de evaluación de granos de café las tareas visuales están lideradas por las CNN, con 11 estudios que reportan precisiones entre 91 y 99.5%, gracias a su capacidad para capturar texturas, bordes y patrones multiescala propios de defectos y grado. De forma complementaria, MobileNetV3, como variante ligera, alcanza 99.57 % de exactitud, lo que refuerza su viabilidad en dispositivos *edge* cuando se aplican técnicas de compresión y cuantización[33]. Asimismo, los Transformers (*Swin*), al incorporar autoatención desplazada que modela dependencias de largo alcance en la imagen, reportan mAP 98.51 y F1 96.35, consolidando su eficacia en detección de defectos cuando hay variabilidad de iluminación o forma [28].

En paralelo, los modelos se organizan por tipo de dato: en visión, YOLOv8, MobileNetV3 cuantizada, Swin-HSSAM y CNN-*Inception* alcanzan precisiones y mAP/F1 en torno al 96–99 % en detección de defectos y clasificación de calidad, en datos espectrales o tabulares, PLS-DA (UV-VIS), XGBR sobre NIRS, SVM, XGBoost, SHAP y ANN logran aciertos o  $R^2$  muy altos en autenticidad, parámetros químicos, humedad, sanidad vegetal y perfil de tueste [28]. En síntesis, CNN/Transformers dominan las tareas visuales, mientras que PLS-DA, SVM y XGBoost son especialmente adecuados para espectros o variables tabulares, manteniendo alta precisión con muestras moderadas [38].

Por consiguiente, en el estudio que emplean tipos de algoritmos más utilizados se muestra que los estudios comparan varios algoritmos en un mismo trabajo, configurando un *benchmarks* mixto: en visión destacan CNN/AlexNet/VGG e incluso híbridos (VGG+LGBM) [29]. Mientras que en espectros/tabulares son recurrentes SVM, Random Forest, kNN, árboles (*Decision/Regresión Tree*), y *boosting* (XGBoost/XGBR/LGBM). En síntesis, SVM y *Random Forest* son los *baselines* más repetidos, *boosting* aparece con fuerza, y la elección del modelo está guiada por el tipo de dato (imagen vs. Espectral tabular), lo que sugiere mantener métricas y validaciones homogéneas para comparar resultados con rigor [9].

En el caso de viabilidad computacional, la evidencia sugiere una arquitectura dual: modelos ligeros para cribado en *edge* (CNN compactas o variantes cuantizadas en hardware económico) y modelos más pesados (*Transformers/GNN*) para verificación en estación con GPU, reportando siempre latencia y tamaño del modelo junto con la métrica de exactitud [8]. Por último, para adopción operativa, la combinación de explicabilidad (Grad-CAM/SHAP) y protocolos de captura (fondo, distancia, iluminación) reduce la dependencia de personal experto y facilita el uso sostenido. En conjunto esto respalda datos bien curados, validación externa, elección de modelo por contexto (*edge* vs GPU), métricas técnicas y operativas; con ello, los beneficios reportados mejor detección, clasificación más consistente y automatización de tareas críticas [42].

## 6. Conclusiones

Esta revisión sistemática ofrece un mapa integral y actualizado del uso de la inteligencia artificial (IA) en la evaluación y clasificación del café, articulando con claridad las aplicaciones, técnicas y métricas predominantes, así como los desafíos de adopción. En consecuencia, el corpus analizado permite sostener que el campo se encuentra en una fase de consolidación: existe masa crítica de evidencia, se observan patrones metodológicos consistentes y emergen líneas de investigación con potencial de transferencia tecnológica. En síntesis, el aporte

central del estudio es doble: una taxonomía operativa de usos a lo largo de la cadena de valor y una síntesis comparativa de desempeño y eficiencia que sirve como referencia para decisiones técnicas y de gestión.

Asimismo, los hallazgos confirman una concentración de la evidencia en tareas de clasificación de calidad/grado y detección de defectos, con énfasis en el grano verde y abordajes de visión por computadora y espectroscopía. Por su parte, aplicaciones como autenticidad/origen presentan avances relevantes, mientras que etapas como cultivo (diagnóstico temprano de enfermedades) y fases finales (p. ej., bebida/análisis sensorial asistido) aún exhiben menor tracción. En conjunto, el objetivo se cumple al delimitar con precisión dónde la IA ya agrega valor (control de calidad y estandarización) y dónde existen oportunidades nítidas para extender su alcance (sensorial en campo, trazabilidad de extremo a extremo y fusión multimodal de datos).

Por otra parte, metodológicamente, las CNN y la familia de modelos de visión profunda lideran en tareas de inspección y clasificación, alcanzando métricas altas en escenarios controlados; no obstante, modelos clásicos (SVM, *Random Forest*, PLS-DA, XGBoost) siguen siendo competitivos cuando existe ingeniería de atributos de calidad o datos espectrales bien curados. Asimismo, la eficiencia computacional emerge como dimensión crítica: técnicas de destilación, cuantización y poda permiten reducir latencia y huella de memoria con pérdidas acotadas de desempeño, habilitando despliegues en *edge*/CPU. En consecuencia, el objetivo se cumple al demostrar que la selección de técnica debe balancear capacidad predictiva, validez externa y restricciones de implementación real.

Finalmente, si bien las precisiones internas son elevadas, persisten brechas de generalización asociadas al cambio de dominio, la heterogeneidad de adquisición y el tamaño/calidad de los conjuntos de datos; a esto se suman restricciones de hardware/costo en entornos productivos. En efecto, estas limitaciones explican la caída típica entre validación interna y pruebas externas y orientan una agenda clara: estandarizar protocolos de captura y partición, promover *datasets* abiertos y representativos, reportar métricas comparables (*Accuracy*/F1/mAP y, cuando corresponda,  $R^2$ /RPD) e incorporar prácticas de MLOps (monitoreo de deriva, validación cruzada entre fincas/lotés). Por ende, con ello, la adopción industrial de la IA en café es viable y escalable, con beneficios directos en consistencia, trazabilidad y eficiencia operativa.

### 6.1. Trabajo futuro y limitaciones

A pesar del grado de madurez alcanzado por el campo, los diferentes enfoques presentan limitaciones específicas. Los métodos basados en visión por computadora dependen fuertemente de condiciones controladas de iluminación, fondo y adquisición, lo que afecta su robustez frente a cambios de dominio. En los enfoques espectroscópicos, la necesidad de sensores especializados y procesos de calibración introduce costos adicionales y limita su adopción en contextos productivos de pequeña escala. Por su parte, los modelos de aprendizaje profundo, si bien logran altos niveles de precisión, requieren grandes volúmenes de datos y recursos computacionales, lo que restringe su despliegue directo en entornos de borde sin estrategias de optimización.

Como trabajo futuro, se identifica la necesidad de desarrollar conjuntos de datos más amplios, balanceados y representativos de escenarios reales, así como de promover su apertura y estandarización. Asimismo, resulta relevante avanzar hacia enfoques multimodales que integren información visual, espectral y contextual, y explorar técnicas de aprendizaje transferido y adaptación de dominio para mejorar la generalización. Finalmente, la adopción de protocolos de evaluación homogéneos y prácticas de MLOps permitirá fortalecer la reproducibilidad y facilitar la transferencia efectiva de estas soluciones hacia aplicaciones industriales en la cadena del café.

## 7. Referencias

- [1] Aghdamifar, E., Rasooli Sharabiani, V., Taghinezhad, E., Rezvanivand Fanaei, A., Szymanek, M. (2023). Non-destructive method for identification and classification of varieties and quality of coffee beans based on soft computing models using VIS/NIR spectroscopy. *European Food Research and Technology*, 249 (6), 1599–1612. <https://doi.org/10.1007/s00217-023-04240-x>
- [2] Collazos-Escobar, G. A., Hurtado-Cortés, V., Bahamón-Monje, A. F., Gutiérrez-Guzmán, N. (2025). Mathematical modeling of water sorption isotherms in specialty coffee beans processed by wet and semidry postharvest methods. *Scientific Reports*, 15 (1), 1–12. <https://doi.org/10.1038/s41598-024-83702-y>
- [3] Jiao, Y., Zhao, Y., Jia, A., Wang, T., Li, J., Xiang, K., Deng, H., He, M., Jiang, R., Zhang, Y. (2025). Swin-HSSAM: A green coffee bean grading method by Swin transformer. *PLoS ONE*, 20 (5), 1–20. <https://doi.org/10.1371/journal.pone.0322198>

- [4] Chen, S. Y., Chiu, M. F., Zou, X. W. (2022). Real-time defect inspection of green coffee beans using NIR snapshot hyperspectral imaging. *Computers and Electronics in Agriculture*, 197, 1-14.  
<https://doi.org/10.1016/j.compag.2022.106970>
- [5] Gope, H. L., Fukai, H. (2022). Peaberry and normal coffee bean classification using CNN, SVM, and KNN: Their implementation in and the limitations of Raspberry Pi 3. *AIMS Agriculture and Food*, 7 (1), 149–167.  
<https://doi.org/10.3934/AGRFOOD.2022010>
- [6] Wang, P., Tseng, H. W., Chen, T. C., Hsia, C. H. (2021). Deep convolutional neural network for coffee bean inspection. *Sensors and Materials*, 33 (7), 2299–2310. <https://doi.org/10.18494/SAM.2021.3277>
- [7] Wallelign, S., Polceanu, M., Jemal, T., Buche, C. (2019). Coffee grading with convolutional neural networks using small datasets with high variance. *Journal of WSCG*, 27 (2), 113–120.  
<https://doi.org/10.24132/JWSCG.2019.27.2.4>
- [8] Vilcamiza, G., Trelles, N., Vines, L., Oliden, J. (2022). *A coffee bean classifier system by roast quality using convolutional neural networks and computer vision implemented in an NVIDIA Jetson Nano*. Congreso Internacional de Innovación y Tendencias en Ingeniería (CONIITI), Bogotá, Colombia.  
<https://doi.org/10.1109/CONIITI57704.2022.9953636>
- [9] Tovar, Y. T., Calvo, A. F., Bejarano, A. (2022). Desarrollo de un sistema de clasificación de imágenes digitales para medir la humedad en granos de café. *Información Tecnológica*, 33 (3), 117–128.  
<https://doi.org/10.4067/s0718-07642022000300117>
- [10] Gracia Loor, J. M., Panchano Valencia, A. M. (2025). Desafíos y Oportunidades de la Inteligencia Artificial en la Educación: Una Revisión Sistemática. *Revista Multidisciplinaria ASCE Magazine*, 4 (2), 185–200.  
<https://doi.org/10.70577/asce/185.200/2025>
- [11] Zhang, X., Wu, F., Li, Z. (2021). Application of convolutional neural network to traditional data. *Expert Systems with Applications*, 168. <https://doi.org/10.1016/j.eswa.2020.114185>
- [12] Alliance of Bioversity International and CIAT [CGIAR]. (2021). *Applying AI to coffee farming in Vietnam*. <https://alliancebioversityciat.org/stories/ai-sustainable-coffee-vietnam>
- [13] Cover, T. (1973). Book Reviews. *IEEE Transaction on Information Theory*, 19 (6), 827-833.  
<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1055089>
- [14] Omali, T. U., Umoru, K. (2023). Pattern Recognition in Remote Sensing Image Analysis: Theory, Methods, and a Case Study of Rijiyar Donor in Katsina, Nigeria. *International Journal of Scientific Research in Computer Science and Engineering*, 11(6), 61-65. <https://ijsrcse.isroset.org/index.php/j/article/view/562>
- [15] Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE Transactions on Neural Networks*, 10 (5), 988–999. <https://doi.org/10.1109/72.788640>
- [16] Chapman, B. P., Weiss, A., Duberstein, P. (2016). Statistical Learning Theory for High Dimensional Prediction: Application to Criterion-Keyed Scale Development. *Psychological Methods*, 21 (4), 603–620.  
<https://doi.org/10.1037/met0000088>
- [17] Poggio, T. (1981). Marr ' s computational approach to visual perception. *Trends Neurosci.*, 4, 258–262.  
[https://doi.org/10.1016/0166-2236\(81\)90081-3](https://doi.org/10.1016/0166-2236(81)90081-3)
- [18] Wei, B., Zhao, Y., Hao, K., Gao, L. (2021). Visual sensation and perception computational models for deep learning: State of the art, challenges and prospects. *ArXiv Preprint*.  
<https://doi.org/10.48550/arXiv.2109.03391>
- [19] Cuoto Bazame, H., Molin, J. P., Althoff, D., Martello, M. (2022). Detection of coffee fruits on tree branches using computer vision. *Scientia Agricola*, 80, 1–8. <https://doi.org/10.1590/1678-992X-2022-0064>
- [20] Hua, J., Wang, Z., Tian, X., Zou, Q., Xiao, J., Ma, J. (2025). Full Perception Head: Bridging the Gap Between Local and Global Features. *IEEE/CAA Journal of Automatica Sinica*, 12 (7), 1391-1406.  
<https://doi.org/10.1109/JAS.2025.125333>
- [21] Alcoba Meriles, D. (2024). PRISMA y metaanálisis en la investigación científica. *Fides et Ratio - Revista de Difusión Cultural y Científica de La Universidad La Salle En Bolivia*, 28 (28), 13–20.  
[http://www.scielo.org.bo/scielo.php?script=sci\\_arttext&pid=S2071-081X2024000200013](http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S2071-081X2024000200013)
- [22] Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *Systematic Reviews*, 10 (1), 1–11.  
<https://doi.org/10.1186/s13643-021-01626-4>

- [23]Universidad Americana de Europa [UNADE]. (2025). *Scopus: la herramienta clave para la investigación académica*. <https://unade.edu.mx/scopus-la-herramienta-clave-para-la-investigacion-academica/>
- [24]Chang, S. J., Liu, K. H. (2024). Multiscale Defect Extraction Neural Network for Green Coffee Bean Defects Detection. *IEEE Access*, 12, 15856–15866. <https://doi.org/10.1109/ACCESS.2024.3356596>
- [25]Chang, S. J., Huang, C. Y. (2021). Deep learning model for the inspection of coffee bean defects. *Applied Sciences*, 11 (17), 1-22. <https://doi.org/10.3390/app11178226>
- [26]Laudari, S., Marks, B., Rognon, P. (2022). Classifying grains using behaviour-informed machine learning. *Scientific Reports*, 12, 1–7. <https://doi.org/10.1038/s41598-022-18250-4>
- [27]Collazos-Escobar, G. A., Gutiérrez-Guzmán, N., Váquiro, H. A., García-Pérez, J. V., Cárcel, J. A. (2025). Analysis of Machine Learning Algorithms for the Computer Simulation of Moisture Sorption Isotherms of Coffee Beans. *Food and Bioprocess Technology*, 18, 5419-5430. <https://doi.org/10.1007/s11947-025-03785-x>
- [28]Arwatchananukul, S., Xu, D., Charoenkwan, P., Aung Moon, S., Saengrayap, R. (2024). Implementing a deep learning model for defect classification in Thai Arabica green coffee beans. *Smart Agricultural Technology*, 9, 1-15. <https://doi.org/10.1016/j.atech.2024.100680>
- [29]Thai, H. D., Ko, H. J., Huh, J. H. (2024). Coffee Bean Defects Automatic Classification Realtime Application Adopting Deep Learning. *IEEE Access*, 12, 126503-126517. <https://doi.org/10.1109/ACCESS.2024.3452552>
- [30]Hashmi, M. S. A., Qadri, A. M., Raza, A., Ullah, S., Smerat, A., Kim, C., Syafrudin, M., Fitriyani, N. L. (2025). VGGBM-Net: A Novel Pixel-Based Transfer Features Engineering for Automated Coffee Bean Diseases Classification. *IEEE Access*, 13, 83580-83590. <https://doi.org/10.1109/ACCESS.2025.3569078>
- [31]Anto, I. A. F., Wibowo, J. W., Salim, T. I., Munandar, A. (2024). Implementation of Image Processing and CNN for Roasted-Coffee Level Classification. *Indonesian Journal of Electrical Engineering and Informatics*, 12 (4), 1005-1018. <https://doi.org/10.52549/ijeei.v12i4.5531>
- [32]Leonard, F., Akbar, H. (2022). Coffee Grind Size Detection By Using Convolutional Neural Network (CNN) Architecture. *Journal of Applied Science, Engineering, Technology, and Education*, 4 (1), 133-145. <https://doi.org/10.35877/454ri.asci842>
- [33]Korkmaz, A., Talan, T., Koşunalp, S., Iliev, T. (2025). Comparison of deep learning models in automatic classification of coffee bean species. *PeerJ Computer Science*, 11, 1–29. <https://doi.org/10.7717/peerj-cs.2759>
- [34]Portillo Mendoza, P. M., Ponce Alvino, J. P. (2022). Clasificación óptima de los frutos de café por su madurez mediante algoritmo de control. *Revista De Investigación en Ciencias Agronómicas y Veterinaria, ALFA*, 6 (18), 441-452. <https://doi.org/10.33996/revistaalfa.v6i18.181>
- [35]Gope, H. L., Fukai, H., Ruhad, F. M., Barman, S. (2024). Comparative analysis of YOLO models for green coffee bean detection and defect classification. *Scientific Reports*, 14, 1-16. <https://doi.org/10.1038/s41598-024-78598-7>
- [36]Grasso, S., Di Loreto, M. V., Zompanti, A., Ciarrocchi, D., De Gara, L., Pennazza, G., Vollero, L., Santonico, M. (2025). Intelligent Electrochemical Sensing: A New Frontier in On-the-Fly Coffee Quality Assessment. *Chemosensors*, 13 (1), 1–18. <https://doi.org/10.3390/chemosensors13010024>
- [37]Quan, N. M., Phung, H. M., Uyen, L., Dat, L. Q., Ngoc, L. G., Hoang, N. M., Tu, T. K. M., Dung, N. H., Ai, C. T. D., Trinh, D. N. T. (2023). Species and geographical origin authenticity of green coffee beans using UV–VIS spectroscopy and PLS–DA prediction model. *Food Chemistry Advances*, 2, 1-8. <https://doi.org/10.1016/j.focha.2023.100281>
- [38]Collazos-Escobar, G. A., Hurtado-Cortés, V., Bahamón-Monje, A. F., Gutiérrez-Guzmán, N. (2025). Mathematical modeling of water sorption isotherms in specialty coffee beans processed by wet and semidry postharvest methods. *Scientific Reports*, 15, 1–12. <https://doi.org/10.1038/s41598-024-83702-y>
- [39]Ilhamsyah, I., Rahman, A. Y., Istiadi, I. (2021). Klasifikasi Kualitas Biji Kopi Menggunakan MultilayerPerceptron Berbasis Fitur Warna LCH. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5 (6), 1008–1017. <https://doi.org/10.29207/resti.v5i6.3438>
- [40]Kittichotsatsawat, Y., Tippayawong, N., Tippayawong, K. Y. (2022). Prediction of arabica coffee production using artificial neural network and multiple linear regression techniques. *Scientific Reports*, 12, 1–14. <https://doi.org/10.1038/s41598-022-18635-5>

- [41] Maruthai, S., Selvanarayanan, R., Thanarajan, T., Rajendran, S. (2025). Hybrid vision GNNs based early detection and protection against pest diseases in coffee plants. *Scientific Reports*, 15, 1–16. <https://doi.org/10.1038/s41598-025-96523-4>
- [42] Selvanarayanan, R., Rajendran, S., Alotaibi, Y. (2024). Early Detection of Colletotrichum Kahawae Disease in Coffee Cherry Based on Computer Vision Techniques. *CMES - Computer Modeling in Engineering and Sciences*, 139 (1), 759-782. <https://doi.org/10.32604/cmes.2023.044084>
- [43] Bordin Yamashita, J. V. Y., Leite, J. P. R. R. (2023). Coffee disease classification at the edge using deep learning. *Smart Agricultural Technology*, 4, 1-9. <https://doi.org/10.1016/j.atech.2023.100183>
- [44] Astuti, S. D., Wicaksono, I. R., Soelistiono, S., Permatasari, P. A. D., Yaqubi, A. K., Susilo, Y., Putra, C. D., Syahrom, A. (2024). Electronic nose coupled with artificial neural network for classifying of coffee roasting profile. *Sensing and Bio-Sensing Research*, 43, 1-8. <https://doi.org/10.1016/j.sbsr.2024.100632>
- [45] Munawar, A. A., Zulfahrizal, Mörlein, D. (2024). Prediction accuracy of near infrared spectroscopy coupled with adaptive machine learning methods for simultaneous determination of chlorogenic acid and caffeine on intact coffee beans. *Case Studies in Chemical and Environmental Engineering*, 10, 1-7. <https://doi.org/10.1016/j.cscee.2024.100913>
- [46] Liu, X., Tan, Y., Dong, J., Wu, J., Wang, X., Sun, Z. (2025). Assessing habitat selection parameters of Arabica coffee using BWM and BCM methods based on GIS. *Scientific Reports*, 15, 1–19. <https://doi.org/10.1038/s41598-024-84073-0>
- [47] León León, R. A., Davila, M. A. R., Lara Guerra, B. A., Manosalva Ruiz, A., Sotomayor Montenegro, C. A. (2025). Development of an artificial vision algorithm with neural networks to detect coffee berry borer in coffee beans. *Acta Scientiarum - Technology*, 47 (1), 1–8. <https://doi.org/10.4025/actascitechnol.v47i1.71113>