

Estudio de técnicas de inteligencia artificial y visión por computador para la clasificación de canales de pollos en líneas de producción avícola.¹

Nelson Humberto Vera Caballero²
Carlos Daniel Pimentel Díaz³

Resumen

En el siguiente documento se presenta el desarrollo de una monografía teórica analítica, donde se abordaron los fundamentos teóricos de la visión por computador y los algoritmos de inteligencia artificial, tales como: YOLO / CNNs, Reconstrucción 3D + Machine Learning, Transformadores de Visión (Swin-Transformer) y Visión Hiperespectral. Así mismo, se realizaron evaluaciones de rendimiento, análisis y marco comparativos de las técnicas antes descritas, llegando a conclusión que el éxito de la automatización avícola no radica en el desarrollo de un algoritmo de inspección universal, sino en el diseño de arquitecturas industriales híbridas y multimodales.

Palabras claves: Visión por computador, Inteligencia artificial, Algoritmos de clasificación, Sector avícola, Automatización industrial.

Study of Artificial Intelligence and Computer Vision Techniques for the Classification of Chicken Carcasses in Poultry Production Lines**Abstract**

The following document presents the development of a theoretical-analytical monograph, where the theoretical foundations of computer vision and artificial intelligence algorithms were addressed, such as: YOLO / CNNs, 3D Reconstruction + Machine Learning, Vision Transformers (Swin-Transformer), and Hyperspectral Vision. Likewise, performance evaluations, analyses, and a comparative framework of the aforementioned techniques were carried out, concluding that the success of poultry automation does not lie in the development of a universal inspection algorithm, but in the design of hybrid and multimodal industrial architectures.

Keywords: Computer vision, Artificial intelligence, Classification algorithms, Poultry sector, Industrial automation.

¹ Artículo científico presentado como opción de grado para optar por el título de Especialista en Automatización Industrial.

² Autor de contacto: Nelson Humberto Vera Caballero, Ingeniero Electromecánico de las Unidades Tecnológicas de Santander (UTS). Correo electrónico: nelson.vera@ustabuca.edu.co

³ Director: Carlos Daniel Pimentel Díaz, Ingeniero Electrónico, M.Sc. en Inteligencia Artificial, Docente de la Universidad Santo tomas, Correo electrónico: carlos.pimentel@ustabuca.edu.co

Introducción

La automatización en la industria avícola ha evolucionado rápidamente, debido a la búsqueda incesante de mantener los estándares de calidad y seguridad alimentaria en líneas de producción que tienen como objetivo principal un masivo procesamiento de aves (Haffner et al, 2024). Históricamente, la inspección y clasificación de canales de pollo ha dependido de la evaluación visual humana, lo cual, hace que la operación sea susceptible a la fatiga y la subjetividad, comprometiendo la eficiencia frente a procesos que requieren velocidad (Barbut, 2010).

En respuesta a estos desafíos, el presente informe monográfico, de alcance estrictamente teórico y analítico, se enfoca en la recopilación, sistematización y análisis crítico de información proveniente de la literatura científica reciente para abordar la siguiente pregunta de investigación: ¿Qué técnicas de inteligencia artificial y visión por computador han sido reportadas para la clasificación de canales de pollo en entornos industriales y cuál es su potencial de aplicación en líneas de producción avícola?.

El objetivo general de este documento es evaluar dichas técnicas mediante una revisión bibliográfica rigurosa, estableciendo una comparación formal de sus rendimientos en términos de precisión, eficiencia y viabilidad, determinando así su aporte específico a los procesos de automatización industrial

Metodología de análisis y recolección de datos

La presente investigación se define como un estudio de tipo teórico-analítico y de diseño documental. Para su desarrollo, se recopiló y analizó información proveniente de artículos científicos indexados, tales como IEEE Xplore, MDPI, ScienceDirect, PubMed y Google Scholar. La estrategia de búsqueda se fundamentó en la selección de términos clave, entre los que destacan: visión por computador, inteligencia artificial, algoritmos de clasificación, sector avícola y automatización industrial. El período de búsqueda delimitado comprendió desde el año 2010 hasta la actualidad, asegurando así la vigencia de las tecnologías analizadas. Como criterios de selección documental, se incluyeron aquellos artículos vigentes que abordaran de manera directa el desarrollo de técnicas de visión artificial e inteligencia artificial dentro del sector avícola, priorizando las investigaciones que evaluaran métricas de precisión y viabilidad. Por el contrario, se aplicaron como criterios de exclusión aquellas fuentes metodológicamente imprecisas y estudios enfocados en áreas de producción ajenas a la industria avícola. Finalmente, tras la selección de la literatura de mayor relevancia, se realizó una lectura crítica de los documentos para extraer las evidencias conceptuales que sustentan sus aportes a la automatización del sector.

Marco conceptual y fundamentos teóricos

Es imperativo que, para comprender el presente documento, nos ocupemos de definir los conceptos científicos fundamentales que se tratan aquí:

Visión por computador (VC) y procesamiento de imágenes

La visión por computador es una disciplina científica que busca dotar a las máquinas de la capacidad de extraer información de alto nivel a partir de imágenes digitales o secuencias de video (Voulodimos et al, 2018). En el contexto industrial avícola, la VC involucra dos fases críticas: la adquisición de la imagen (mediante sensores RGB convencionales, escáneres de profundidad tridimensional o cámaras multiespectrales) y el procesamiento digital, donde se aplican algoritmos matemáticos para aislar la canal del pollo del fondo (segmentación) y extraer características macroscópicas de interés como color, textura, simetría y geometría (Jia et al, 2018) (Maram et al, 2024).

Inteligencia Artificial (IA) y Aprendizaje Profundo (Deep Learning)

La IA aplicada a la inspección agroindustrial se basa principalmente en el Aprendizaje Automático (Machine Learning) y, más recientemente, en el Aprendizaje Profundo (Deep Learning). Estas arquitecturas computacionales, inspiradas en redes neuronales biológicas, aprenden de forma autónoma a reconocer patrones complejos a partir de grandes conjuntos de datos de entrenamiento (imágenes de canales de aves previamente etiquetadas por expertos). Las métricas matemáticas estándar para evaluar el rendimiento de estos modelos incluyen la precisión media (Mean Average Precision o mAP) para tareas de detección y clasificación de imágenes (Jia et al, 2018), y el coeficiente de determinación (R^2) para validar modelos de regresión física encargados de la predicción de pesos u otras variables continuas (Hua et al, 2024).

Clasificación de canales en la industria avícola

Una "canal" se define formalmente como el cuerpo del ave de corral sacrificada, desangrada, desplumada y eviscerada. La clasificación industrial busca categorizar estas canales (usualmente en Grados A, B o C) o destinarlas a estaciones de despiece específicas según la presencia de defectos anatómicos o patológicos. Los defectos más comunes reportados en la literatura incluyen hematomas superficiales, dislocaciones óseas, contaminación fecal sutil y miopatías musculares internas (como la "pechuga de madera" o wooden breast). La detección automatizada y sin contacto físico de estas anomalías constituye el núcleo operativo de los sistemas de inspección modernos (Tran et al, 2024), (Zhu et al, 2024).

Estado del arte: técnicas reportadas en la literatura

La literatura científica reciente evidencia una transición acelerada desde algoritmos de procesamiento de imágenes clásicos (basados en filtros morfológicos fijos) hacia arquitecturas complejas de Deep Learning y análisis sensorial avanzado. Las principales técnicas aplicadas actualmente se categorizan en cuatro grupos tecnológicos:

Redes Neuronales Convolucionales (CNN) y Familia YOLO: Los algoritmos de detección de objetos en tiempo real, particularmente las iteraciones de la familia YOLO (como YOLOv7, YOLOv8 y el reciente YOLOv12), representan el estándar industrial para la monitorización de flujo continuo. Se utilizan principalmente para identificar desviaciones de calidad superficiales procesando los datos visuales directamente sobre la línea de producción a altas velocidades de fotogramas por segundo (6 et al, 2024), (Maram et al, 2024).

Arquitecturas de Transformadores de Visión (Vision Transformers): Modelos optimizados como Swin-Transformer y el framework especializado CarcassFormer han emergido para resolver tareas de clasificación morfológica de alta complejidad. A diferencia de las CNN tradicionales, estos modelos procesan las características globales y locales de las imágenes mediante mecanismos de "atención", permitiendo una segmentación anatómica detallada de los cortes y la detección de defectos patológicos sutiles (Tran et al, 2024), (Jia et al, 2018).

Reconstrucción 3D y Nubes de Puntos: La integración de cámaras de profundidad (basadas en tecnología Time-of-Flight o visión estéreo) con modelos de regresión avanzados permite capturar la topología volumétrica de las canales en movimiento. Esta técnica extrae medidas tridimensionales y dimensiones viscerales precisas sin necesidad de contacto físico con el alimento (Zhu et al, 2025).

Visión Hiperespectral y Multimodal: Esta técnica de vanguardia fusiona imágenes RGB de alta resolución con el análisis del espectro electromagnético invisible (como el infrarrojo cercano o el ultravioleta). Se utiliza para evaluar la calidad a nivel químico y tisular, detectando contaminantes plásticos microscópicos y alteraciones estructurales internas de la carne que son invisibles al ojo humano (Biabianian et al, 2026), (Maram et al, 2024).

Evaluación de rendimiento: ventajas y desventajas tecnológicas

El análisis comparativo de la literatura demuestra que la implementación de estas tecnologías en líneas de producción exige la gestión de un estricto compromiso técnico (trade-off) entre precisión, eficiencia computacional y viabilidad operativa. Para comprender estas dinámicas, se desglosan a continuación las ventajas y desventajas cualitativas de cada técnica, seguidas de su correspondiente validación matricial y analítica.

Desglose cualitativo de técnicas

- *Modelos YOLO / CNN en Tiempo Real*

Ventajas: Presentan una altísima eficiencia computacional, reduciendo el tiempo de inferencia a unos pocos milisegundos por imagen. Su viabilidad industrial es excelente debido a su compatibilidad con cámaras RGB estándar de bajo costo, lo que permite seguir de forma fluida el ritmo de líneas ultrarrápidas que superan las 140 aves por minuto (Einsiedel et al, 2026).

Desventajas: Su principal debilidad radica en la sensibilidad ante variaciones en la iluminación de la planta y su incapacidad para detectar defectos profundos o anomalías químicas que se camuflan con el color de la piel del ave (Maram et al, 2024).

- *Vision Transformers (Swin-Transformer / CarcassFormer)*

Ventajas: Ofrecen una precisión superior en el estado del arte para tareas de segmentación y localización simultánea de múltiples defectos complejos o sutiles, reduciendo drásticamente los falsos negativos en la clasificación de cortes de alto valor (Tran et al, 2024).

Desventajas: Exigen un costo computacional masivo. Su procesamiento de "atención global" requiere tarjetas gráficas (GPUs) de grado industrial costosas, lo que eleva significativamente la inversión inicial en hardware para la planta (Jia et al, 2018).

- *Reconstrucción 3D e Imágenes de Profundidad*

Ventajas: Proporcionan una precisión geométrica y volumétrica excepcional para estimar el peso de la canal en pleno movimiento dinámico, eliminando por completo la necesidad de básculas mecánicas de contacto y mitigando los riesgos de contaminación cruzada (Hua et al, 2026).

Desventajas: El procesamiento en tiempo real de nubes de puntos densas es computacionalmente pesado, lo que puede generar cuellos de botella si la línea excede ciertas velocidades. Además, los sensores ópticos de profundidad requieren calibraciones geométricas periódicas debido a las vibraciones de la planta (Zhu et al, 2025).

- *Sistemas de Visión Hiperespectral*

Ventajas: En criterios de precisión es posible una identificación más químico-analítica, siendo la única tecnología capaz de detectar contaminación microbiológica, retención anómala de agua y cuerpos extraños transparentes o microscópicos sobre la carne (Biabadian et al, 2026), (Maram et al, 2024).

Desventajas: Generan volúmenes masivos de datos conocidos como "cubos espectrales". El procesamiento en tiempo real de estas estructuras de datos es sumamente lento y complejo, sumado al costo prohibitivo de las cámaras espectrales industriales (Biabadian et al, 2026).

Tabla 1. *Técnicas de visión por computador..*

<i>Técnica de IA y Visión por Computador</i>	<i>Precisión (Identificación y Clasificación)</i>	<i>Eficiencia (Velocidad y Costo Computacional)</i>	<i>Viabilidad Industrial (Implementación en Planta)</i>
Detección en Tiempo Real (YOLO / CNNs)	Media-Alta: Excelente para defectos superficiales evidentes. Disminuye ante variaciones de iluminación o si el defecto se camufla con la piel.	Muy Alta: Procesamiento en milisegundos por imagen. Ideal para el ritmo de líneas ultrarrápidas (>140 aves/min).	Muy Alta: Es el estándar actual. Requiere hardware accesible (cámaras RGB estándar) y es fácil de integrar sin detener la línea.
Reconstrucción 3D + Machine Learning	Alta: Precisión excepcional ($R^2 > 0.90$) para volumetría, estimación de peso y morfología. Totalmente inmune a cambios de luz.	Media-Baja: La generación y procesamiento de nubes de puntos 3D es más lenta (puede tomar >1 segundo por canal), lo que puede generar cuellos de botella.	Media: Altamente viable para reemplazar básculas de contacto, pero requiere calibración geométrica constante y mantenimiento especializado de los sensores de profundidad.
Transformadores de Visión (Swin-Transformer)	Muy Alta: Superior al estado del arte en tareas complejas de segmentación de cortes y	Media: Alto costo computacional. Procesar características globales de la imagen requiere mayor	Media-Alta: Excelente para estaciones de despiece robótico, pero su costo en hardware

<i>Técnica de IA y Visión por Computador</i>	<i>Precisión (Identificación y Clasificación)</i>	<i>Eficiencia (Velocidad y Costo Computacional)</i>	<i>Viabilidad Industrial (Implementación en Planta)</i>
	detección de enfermedades sutiles.	capacidad de cálculo que una CNN tradicional.	(GPUs industriales) limita su uso generalizado en toda la planta.
Visión Hiperespectral	Máxima: Única tecnología capaz de detectar características invisibles al ojo humano (contaminación fecal sutil, patógenos, composición química).	Baja: Genera enormes "cubos de datos" (decenas de bandas espectrales por imagen). El procesamiento en tiempo real es extremadamente pesado y complejo.	Baja: Costo prohibitivo de los equipos de captura y servidores de procesamiento. Se limita estrictamente a Puntos de Control Crítico (PCC) muy específicos.

Nota: El cuadro lo que hace es comparar las diferentes técnicas de visión por computador que se utilizan en la clasificación de canales de pollos.

Análisis del Compromiso Tecnológico (Trade-off).

El análisis cruzado de la matriz comparativa revela que la ingeniería de automatización aplicada a la avicultura debe gestionar de forma estratégica las variables expuestas. Las arquitecturas de detección de objetos en tiempo real, ejemplificadas por los modelos de la familia YOLO, sacrifican cierta profundidad analítica a cambio de maximizar la eficiencia y la aplicabilidad industrial en entornos de alta velocidad. Estas redes convolucionales logran identificar desviaciones de calidad superficiales en escalas de milisegundos, lo que las consolida como herramientas altamente viables para la clasificación continua en bandas transportadoras masivas (Einsiedel et al, 2026).

Por el contrario, cuando las exigencias operativas se trasladan hacia una precisión superior en la segmentación anatómica y la localización simultánea de múltiples defectos morfológicos sutiles, los Transformadores de Visión (como CarcassFormer o los modelos Swin-Transformer optimizados) demuestran un rendimiento teórico muy superior al de las CNN tradicionales (Tran et al, 2024). No obstante, este incremento en la precisión introduce la desventaja de una menor eficiencia computacional inicial, lo que restringe su viabilidad inmediata a sub-estaciones equipadas con hardware de procesamiento masivo (Jia et al, 2018).

Desde una perspectiva física y volumétrica, los sistemas de reconstrucción tridimensional aportan la ventaja de una inmunidad total frente a los cambios de iluminación ambiental de las plantas de beneficio. Su alta fiabilidad matemática (reflejada en coeficientes de determinación R^2 superiores a 0.93 para el monitoreo dinámico del peso) contrasta con la desventaja del alto costo de procesamiento de nubes de puntos, lo que exige optimizaciones algorítmicas previas para no ralentizar el flujo de producción general (Hua et al, 2026), (Zhu et al, 2025).

Finalmente, en el extremo de máxima sensibilidad sanitaria se posiciona la visión hiperespectral; si bien su precisión para el diagnóstico de anomalías microbiológicas, químicas y detección de contaminantes plásticos es insuperable (Maram et al, 2024), sus inmensas demandas de almacenamiento y procesamiento de datos imponen una baja viabilidad económica y operativa para flujos generales, limitando su aplicación a puntos de inspección sanitaria específicos y aislados dentro del ecosistema automatizado (Biabianian et al, 2026).

Marco comparativo y aporte a la automatización avícola

El análisis de la literatura académica demuestra que la viabilidad futura de la automatización integral en las plantas avícolas modernas no depende de la imposición de una sola tecnología, sino del aporte sinérgico y coordinado de múltiples enfoques arquitectónicos:

Aporte de los Sistemas YOLO / CNN: Inspección y filtrado de flujo continuo. Funcionan como la primera línea de defensa automatizada en las etapas iniciales del proceso, descartando en milisegundos aquellas canales de baja categoría (Grado C) o con daños macroscópicos severos sin alterar la velocidad de la línea (Einsiedel et al, 2026).

Aporte de los Transformadores de Visión: Guiado robótico y segmentación de alto valor. Su capacidad para aislar y delimitar con precisión las distintas partes del ave suministra las coordenadas vectoriales exactas requeridas por los brazos robóticos automatizados en las estaciones de despiece, maximizando el rendimiento comercial de los cortes primarios (Grados A y B) (Tran et al, 2024), (Jia et al, 2018).

Aporte de la Reconstrucción 3D: Metrología óptica y pesaje dinámico. Sustituye los complejos e higiénicamente vulnerables sistemas de pesaje mecánico por una calibración volumétrica visual continua. Esto optimiza los flujos logísticos de empaque automatizado y reduce los vectores de contaminación cruzada por contacto directo (Hua et al, 2026), (Zhu et al, 2024).

Aporte de la Visión Hiperespectral: Garantía de inocuidad automatizada. Actúa como un Punto de Control Crítico (PCC) inteligente e invisible en las fases finales del empaque, mitigando de forma automatizada el riesgo de retiros sanitarios del mercado mediante la detección temprana de polímeros extraños o contaminación biológica tisular (Biabadian et al, 2026), (Maram et al, 2024).

Conclusiones

A partir de la revisión de la literatura científica y académica actual, se da respuesta concluyente al interrogante de investigación: las técnicas de inteligencia artificial y visión por computador reportadas (sistemas YOLO, Transformadores de Visión, Reconstrucción 3D y Análisis Hiperespectral) poseen un potencial de aplicación alto en la industria avícola moderna.

La evaluación integral de sus rendimientos concluye que el éxito de la automatización avícola no radica en el desarrollo de un algoritmo de inspección universal, sino en el diseño de arquitecturas industriales híbridas y multimodales. Mientras que las redes de inferencia ultrarrápida (CNN/YOLO) viabilizan la clasificación masiva y cualitativa en tiempo real para mantener la competitividad en velocidad, los sistemas complejos (Transformadores, modelado óptico 3D y sensores espectrales) aportan el rigor analítico indispensable para tareas de alta precisión morfológica y bioseguridad alimentaria. En definitiva, la integración de la inteligencia artificial dota a los sistemas de automatización avícola de niveles de precisión, velocidad y trazabilidad sanitaria imposibles de alcanzar mediante la inspección manual tradicional, consolidándose como el pilar técnico de la industria alimentaria del futuro.

Referencias

- [1] E. K. D. R. Oto Haffner, «Applications of Machine Learning and Computer Vision in Industry 4.0,» *Applied Sciences*, vol. 2431, n° 14(6), p. 10, 2024.
- [2] S. Barbut, «Past and future of poultry meat harvesting technologies,» *World's Poultry Science Journal*, vol. 66, n° 3, p. 399–410, 2010.
- [3] N. D. A. D. E. P. Athanasios Voulodimos, «Deep Learning for Computer Vision: A Brief Review,» *Computational Intelligence and Neuroscience*, vol. 7068349, p. 13, 2018.
- [4] B. Z. L. H. A. M. S. S. L. G. B. J. G. T. R. R. & D. W. Zhen Jia, «Computer vision classification detection of chicken parts based on optimized Swin-Transformer,» *CyTA - Journal of Food*, vol. 22, n° 2347480, p. 14, 2024.
- [5] R. Maram, S. Samiappan y S.-C. Yoon, «Detection and Classification of Plastic Contaminants on Chicken Meat using Color and Hyperspectral Imaging,» *IEEE*, 2024.
- [6] P. Z. A. Z. R. C. H. B. W. Z. Q. F. a. G. C. Tian Hua, «Multi-Scale Feature Fusion and Attention-Enhanced R2U-Net for Dynamic Weight Monitoring of Chicken Carcasses,» *Animals*, vol. 16, 2026.
- [7] S. T. A. F. F. M. T. K. N. L. Minh Tran, «CarcassFormer: an end-to-end transformer-based framework for simultaneous localization, segmentation and classification of poultry carcass defect,» *Poultry Science*, vol. 103, 2024.
- [8] Y. C. L. C. J. Y. K. W. J. B. Z. H. D. F. Zhengwei Zhu, «Predictive method for poultry carcass visceral dimensions using 3D point cloud and Genetic Algorithm-based wavelet neural network,» *Poultry Science*, vol. 104, 2025.
- [9] M. V. F. K. B. D. J. M. a. C. K. Daniel Einsiedel, «Automated Detection of Quality Deviations in Poultry Processing Using Step-Specific YOLOv12 Models,» *Foods*, vol. 15, 2026.
- [10] S. V. S. a. N. M. Arash Biabani, «Assessment of Chicken Meat Quality Through Categorized,» *Journal of World's Poultry Research*, 2026.