

Revisión sistemática de literatura sobre la aplicación de la visión por computador en
ingeniería industrial

Oscar Daniel Melendez García

Trabajo de Grado para Optar el Título de Ingeniería Industrial

Director

Ivan David Ortiz Pineda

Doctorado en Ciencias de la Computación

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Industrial

Bucaramanga

2026

Agradecimientos

Quiero agradecerle en primer lugar a mis padres, Magda Angelina García Sánchez y Jesús Azdrubal Melendez Sarmiento, he sido testigo de los sacrificios que han hecho para tenerme en donde estoy ahora, a ellos muchas gracias por el amor incondicional que los caracteriza.

Para Ángela María, mil gracias pues ha sido un pilar en mi vida.

Asimismo, quiero agradecer al profesor Iván David Ortiz por el acompañamiento y la asesoría brindada durante este proceso.

Tabla de Contenido

	Pág.
Introducción	12
1. Planteamiento del problema.....	13
2. Marco referencial.....	15
2.1. Marco de antecedentes.....	15
2.2. Marco teórico.....	16
2.2.1. Componentes clave en la visión por computador	16
2.2.1.1. Inteligencia artificial (IA).	17
2.2.1.2. Internet de las cosas (IoT).....	17
2.2.1.3. Visión por computador (VC).	17
2.2.1.4. Machine learning.	18
2.2.1.5. Deep learning.....	18
2.2.1.6. Redes neuronales convolucionales (CNN).	18
2.2.1.7. Modelos YOLO.	18
2.2.1.8. Transfer learning.....	19
2.2.1.9. Mecanismos de atención.....	19
2.2.1.10. Métricas de evaluación de modelos.	19
2.2.1.11. Gemelos digitales (Digital twins).	20

VISION POR COMPUTADOR EN INGENIERIA INDUSTRIAL	4
2.2.2. Intersección con la ingeniería industrial	20
2.2.3. Revisión sistemática de literatura y metodología PRISMA	21
2.2.4. Escala de madurez tecnológica (TRL)	22
3. Objetivos	24
3.1. Objetivo general	24
3.2. Objetivos específicos	24
3.3. Tabla de cumplimiento de objetivos	25
4. Metodología	26
4.1. Fase 1: Delimitación conceptual y formulación del protocolo	26
4.2. Fase 2: Búsqueda sistemática y proceso de selección	27
4.3. Fase 3: Análisis bibliométrico y extracción de información	27
4.4. Fase 4: Síntesis y análisis de resultados	29
5. Desarrollo metodológico	30
5.1. Protocolo de búsqueda	30
5.1.1. Estrategia de búsqueda	31
5.1.3. Criterios de inclusión y exclusión	33
5.2. Análisis bibliométrico	34
5.3. Recolección y clasificación de artículos	42
5.3.1. Fase de identificación	43
5.3.2. Fase de cribado	44

5.3.3. Fase de evaluación de elegibilidad.....	45
5.3.4. Fase de inclusión.....	46
5.4. Análisis de resultados	46
5.4.1. Tendencia temporal.....	46
5.4.2. Areas de aplicación.....	48
5.4.2.1 Control de calidad, inspección y manufactura general.	48
5.4.2.2 Ergonomía y seguridad y salud en el trabajo.	49
5.4.2.3 Logística, gestión de inventarios y cadena de suministro.	50
5.4.2.4 Categoría otros.	51
5.4.3. Sectores industriales de aplicación	51
5.4.4. Modelos y metodologías empleadas	53
5.4.4.1 Familias de modelos.	53
5.4.4.2 Metodologías de diseño.	57
5.4.5. Generalidades del dataset.....	58
5.4.6 Vacíos de investigación identificados.....	60
5.4.7 Método de validación y madurez tecnológica.....	62
5.4.8 Limitaciones declaradas.....	65
5.4.8.1 Dataset de tamaño insuficiente y desbalance de clases.....	65
5.4.8.2 Sensibilidad a condiciones de iluminación.	65
5.4.8.3 Oclusión de objetos y puntos clave.....	66

5.4.8.4 Altos costos computacionales.....	66
5.5 Identificación de tendencias y vacíos.....	67
5.5.1. La visión por computador como habilitador de la Industria 4.0	67
5.5.2. La tendencia de micro-innovación sobre YOLO	68
5.5.3. El vacío de privacidad en aplicaciones de monitoreo de trabajadores.....	69
5.5.4. La brecha de adopción en PYMEs y economías emergentes.....	70
5.5.5. Líneas de acción sugeridas.....	71
5.5.6. Síntesis	72
6. Conclusiones.....	73
7. Recomendaciones	75
Referencias bibliográficas.....	77

Lista de Tablas

	Pág.
TABLA 1. <i>NIVELES DE MADUREZ TECNOLÓGICA</i>	22
TABLA 2. <i>CUMPLIMIENTO DE LOS OBJETIVOS ESPECÍFICOS DEL PROYECTO</i>	25
TABLA 3. <i>SECTOR INDUSTRIAL Y SUS APLICACIONES</i>	52
TABLA 4. <i>DISTRIBUCIÓN DE FAMILIAS DE MODELOS</i>	53
TABLA 5. <i>DISTRIBUCIÓN DE ARTÍCULOS POR NIVEL DE TRL</i>	63
TABLA 6. <i>LÍNEAS DE ACCIÓN</i>	71

Lista de Figuras

	Pág.
FIGURA 1. <i>CANTIDAD DE DOCUMENTOS POR AÑO</i>	35
FIGURA 2. <i>DOCUMENTOS POR TERRITORIO</i>	36
FIGURA 3. <i>AUTORES POR NÚMERO DE PUBLICACIONES</i>	37
FIGURA 4. <i>DOCUMENTOS POR ÁREA TEMÁTICA</i>	37
FIGURA 5. <i>REVISTAS POR NÚMERO DE PUBLICACIONES</i>	38
FIGURA 6. <i>REVISTAS POR NÚMERO DE CITACIONES</i>	39
FIGURA 7. <i>REDES DE COLABORACIÓN</i>	40
FIGURA 8. <i>ESTUDIO DE CO-OCURRENCIA DE PALABRAS CLAVE</i>	41
FIGURA 9. <i>DIAGRAMA METODOLOGÍA PRISMA</i>	42
FIGURA 10. <i>CANTIDAD DE PUBLICACIONES POR AÑO</i>	47
FIGURA 11. <i>DISTRIBUCIÓN DE ARTÍCULOS POR CATEGORÍA</i>	48
FIGURA 12. <i>DISTRIBUCIÓN DEL TIPO DE DATOS UTILIZADOS EN APLICACIONES DE LOGÍSTICA Y GESTIÓN DE INVENTARIOS</i>	51
FIGURA 13. <i>DISTRIBUCIÓN VERSIONES DEL MODELO YOLO</i>	55
FIGURA 14. <i>ORIGEN DEL DATASET</i>	59
FIGURA 15. <i>CLASIFICACIÓN DEL DATASET POR TAMAÑO</i>	60
FIGURA 16. <i>DISTRIBUCIÓN DE VACÍOS DE INVESTIGACIÓN</i>	61

Lista de Apéndices

Anexo A: Matriz de extracción de datos

Anexo B: Artículo síntesis de resultados

Los apéndices están adjuntos y puede visualizarlos en la base de datos de la biblioteca UIS

Resumen

Título: Revisión sistemática de literatura sobre la aplicación de la visión por computador en ingeniería industrial*

Autor: Oscar Daniel Meléndez García**

Palabras Clave: Visión por computador, Detección de objetos, Aprendizaje profundo, Automatización industrial, Revisión sistemática.

Descripción: La visión por computador es una tecnología basada en algoritmos de aprendizaje profundo que permite a los sistemas informáticos extraer información útil a partir de imágenes y videos, habilitando tareas como la detección de objetos, la estimación de movimiento y la inspección automatizada. Su integración con la ingeniería industrial ha crecido de forma acelerada en los últimos años, sin embargo, la literatura disponible sobre sus aplicaciones en este campo se encuentra dispersa y poco articulada, lo que dificulta identificar tendencias, limitaciones y oportunidades de desarrollo.

Este trabajo realizó una revisión sistemática de literatura siguiendo la metodología PRISMA, consultando Scopus y Web of Science para el período 2021–2025. De 1.388 registros iniciales se seleccionaron 124 artículos. Los resultados muestran que el control de calidad y manufactura concentra el 54% de las aplicaciones, con dominancia del modelo YOLO para detección de defectos, mientras que ergonomía y seguridad y salud en el trabajo representa el 25%, enfocado en análisis de movimiento corporal en tiempo real. Se encontró que el 48.4% de los artículos no reporta nivel de madurez tecnológica y solo 14 estudios validan en entornos reales de producción, evidenciando una brecha entre el rendimiento experimental y la viabilidad de implementación empresarial. Se identificaron otros vacíos relevantes como la ausencia de integración con gemelos digitales y la escasa atención a la privacidad de datos.

* Trabajo de Grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Estudios Industriales y Empresariales. Director: Iván David Ortiz Pineda. Ph. D. (c) Ciencias de la Computación.

Abstract

Title: Systematic literature review on the application of computer vision in industrial engineering *

Author: Oscar Daniel Meléndez García **

Key Words: Computer vision, Object detection, Deep learning, Industrial automation, Systematic review

Description: Computer vision is a technology based on deep learning algorithms that enables computer systems to extract useful information from images and videos, supporting tasks such as object detection and automated inspection. Its integration with industrial engineering has grown rapidly; however, the available literature on its applications remains scattered, making it difficult to identify clear trends, limitations, and development opportunities.

This work conducted a systematic literature review following the PRISMA methodology, consulting Scopus and Web of Science for the period 2021–2025. From 1,388 initial records, 124 articles were selected. Results show that quality control and manufacturing account for 54% of applications, with clear dominance of the YOLO model family, while ergonomics and occupational health and safety represent 25%, focused on real-time human motion analysis. It was found that 48.4% of articles do not report a technological maturity level and only 14 studies validate in active production environments, revealing a gap between experimental performance and real implementation feasibility. Relevant research gaps were also identified, including the absence of digital twin integration and limited attention to data privacy in worker monitoring applications.

* Degree Work

** Faculty of Physicomechanical Engineering. School of Industrial and Business Studies. Director: Iván David Ortiz Pineda. Ph. D. (c) Computer Science.

Introducción

La visión por computador (VC) es una rama de la inteligencia artificial que permite a las computadoras y sistemas obtener información significativa a partir de imágenes digitales, videos y otras entradas visuales para realizar acciones u ofrecer sugerencias en respuesta a dicha información (Agrawal et al., 2024).

En los últimos años se ha observado un incremento significativo en investigaciones sobre la aplicación de tecnologías de inteligencia artificial en entornos industriales, evidenciando el potencial de estas herramientas para optimizar procesos, mejorar la toma de decisiones y fortalecer la seguridad organizacional (Ochoa, 2024; Castro, 2025). A pesar de esto, la literatura sobre la visión por computador en la ingeniería industrial se encuentra dispersa, y se dificulta identificar problemáticas recurrentes, enfoques metodológicos predominantes y oportunidades de mejora. Frente a esta situación, resulta necesario realizar una revisión sistemática de literatura que permita sintetizar el conocimiento disponible, identificar tendencias metodológicas, reconocer vacíos de investigación y proponer líneas de desarrollo futuro.

Según este contexto, la tecnología tiene un potencial muy aprovechable en áreas como la ingeniería industrial, donde permite optimizar procesos productivos, mejorar el control de calidad, aumentar la eficiencia y seguridad en los sistemas de producción. Sin embargo, su integración en esta disciplina aún se encuentra en una etapa de consolidación, y su implementación representa una serie de desafíos técnicos, organizacionales y metodológicos.

En consecuencia, en este trabajo de grado se realizó una revisión sistemática de literatura sobre artículos científicos que abordan la implementación de VC para tareas propias de la ingeniería industrial, incluyendo investigaciones relacionadas con control de calidad, seguridad y

salud en el trabajo, logística y otras áreas afines. La revisión se centró en aplicaciones prácticas con modelos automatizados de procesamiento de imágenes en entornos industriales y empresariales. El propósito es condensar la información disponible y analizar el panorama actual de la VC en la ingeniería industrial, destacando tendencias relevantes, limitaciones actuales y posibles líneas de investigación futuras que faciliten su integración efectiva.

El documento se encuentra organizado de la siguiente manera, primero, se presenta el planteamiento del problema y los objetivos de la investigación; Segundo, se desarrolla el marco de referencia que va a sustentar teóricamente el estudio. Después de esto se describe la metodología y el protocolo de búsqueda empleado. Finalmente, se exponen los resultados del análisis y las conclusiones derivadas de la revisión.

1. Planteamiento del problema

visión por computadora es una rama de la inteligencia artificial que tiene como objeto dotar a los sistemas computacionales de la capacidad de interpretar y extraer información significativa a partir de imágenes y secuencias de video, emulando y en ciertos contextos superando las capacidades perceptuales del sistema visual humano (Szeliski, 2022). Esta disciplina abarca un espectro amplio de tareas de procesamiento visual, entre las que se destacan la clasificación de imágenes, la detección y localización de objetos, la segmentación semántica e instanciada, el reconocimiento de patrones, la estimación de pose, la reconstrucción tridimensional de escenas y el seguimiento de objetos en tiempo real; Un conjunto de capacidades que al ser integradas en sistemas de adquisición óptica y plataformas digitales, permiten un despliegue progresivo en dominios de alta exigencia técnica como la ingeniería industrial.

La ingeniería industrial es una disciplina que se encarga del mejoramiento de los sistemas que generan bienes y servicios. En ese mejoramiento continuo, la ingeniería industrial requiere de herramientas que permitan mejorar la optimización de los procesos. La visión por computador emerge como una alternativa para áreas como la ingeniería de calidad, permitiendo la automatización de control de calidad en una línea de producción; o en áreas como la salud y seguridad en el trabajo, permitiendo el monitoreo en tiempo real de posibles riesgos laborales de los empleados.

El interés del uso de visión por computador para apoyo a problemáticas de la ingeniería industrial ha aumentado en las últimas décadas. Esto se puede ver en el incremento sostenido de la producción científica de aplicaciones de modelos de visión artificial para tareas como inspección de calidad, monitoreo de inventarios, detección de riesgos laborales, entre otros (Ochoa, 2024; Castro, 2025). Sin embargo, este crecimiento no ha sido homogéneo, aspecto que se puede observar en la variabilidad de áreas, aplicaciones, tareas y metodologías empleadas en los estudios.

Esta dispersión en la literatura dificulta el conocimiento de los estándares, metodologías más empleadas, problemáticas abordadas o áreas que son más reportadas, ni cuáles vacíos siguen abiertos en la literatura. Por ende, es pertinente la realización de una revisión de literatura, que contemple los avances de la visión por computador, enfocando el estudio desde la perspectiva de las problemáticas de la ingeniería industrial.

En consecuencia, la presente investigación tiene como objetivo el realizar una síntesis de la literatura en materia de visión por computador aplicado a problemas derivados de la ingeniería industrial, teniendo como base la siguiente pregunta:

¿Cómo se caracteriza el desarrollo reciente de la visión por computador en la ingeniería industrial en términos de aplicaciones, metodologías empleadas y tendencias emergentes?

El alcance de este estudio se restringe al análisis de literatura científica indexada publicada entre 2021 y 2025 en las bases de datos Scopus y Web of Science. Se limitó el estudio a esta ventana de tiempo por el crecimiento de la necesidad de modelos de detección de objetos en tiempo real, como el YOLO, y los nuevos avances de arquitecturas basadas en representaciones latentes como el transformer, en esa ventana de tiempo.

2. Marco referencial

2.1. Marco de antecedentes

La visión por computador, rama de la inteligencia artificial, es cada vez más importante en la ingeniería industrial porque puede analizar, interpretar y transformar información visual para ayudar en la toma de decisiones. Al combinarse con técnicas de aprendizaje de máquina, se ha logrado enfrentar problemas complejos en diferentes sectores productivos, lo que ha mejorado la eficiencia, la calidad y la seguridad de los procesos industriales.

En el sector manufacturero y de producción, Castro Sánchez (2025) realiza un estudio exploratorio sobre el uso de técnicas de aprendizaje de máquina en el diseño de celdas de manufactura, en este estudio se destaca que los sistemas optimizados mediante métodos de programación lineal presentan limitaciones frente a los entornos productivos actuales. Y con la introducción de algoritmos de redes neuronales y la optimización por enjambre de partículas permitieron mejorar la disposición de máquinas y la asignación de tareas. Este estudio integró factores que van desde la capacidad de equipos, habilidades humanas, hasta variaciones en la

demanda, y demuestra cómo la inteligencia artificial amplía la capacidad analítica en la toma de decisiones industriales.

Para el campo de la seguridad y salud en el trabajo, Ochoa (2024) desarrolló un estado del arte sobre las tecnologías basadas en inteligencia artificial aplicadas a la gestión de la Seguridad y Salud en el Trabajo (SST). Esta investigación destaca la inteligencia artificial como una herramienta preventiva que es capaz de anticipar riesgos y reducir la ocurrencia de accidentes laborales, con tendencias y aplicaciones como el monitoreo en tiempo real, los sistemas predictivos de fallos y los equipos de protección personal inteligentes.

Por su parte, en el sector agroindustrial, López Jiménez, Ordóñez Santos, González Salcedo (2025) realizaron una revisión sistemática sobre el uso del aprendizaje de máquinas basado en reconocimiento de imágenes para la evaluación de la madurez del banano. Este trabajo identifica una mejor clasificación y distribución del fruto, utilizando técnicas como las máquinas de soporte vectorial, redes neuronales artificiales y árboles de decisión permiten clasificar niveles de madurez de forma precisa, para optimizar la cosecha.

En conjunto, estos antecedentes evidencian que la visión por computador contribuye significativamente a mejorar la calidad y eficiencia de los procesos productivos mediante el análisis automatizado de imágenes.

2.2. Marco teórico

2.2.1. Componentes clave en la visión por computador

La visión por computador se fundamenta en un conjunto de tecnologías provenientes de la inteligencia artificial que permiten a los sistemas informáticos adquirir, procesar, analizar e interpretar información visual (Agrawal et al., 2024). Entre los componentes más relevantes se

encuentran la inteligencia artificial, el aprendizaje de máquina, el aprendizaje profundo y las redes neuronales convolucionales, los cuales actúan de manera integrada para el reconocimiento y análisis de imágenes y videos.

2.2.1.1. Inteligencia artificial (IA). La inteligencia artificial es una rama de la informática que desarrolla sistemas capaces de simular comportamientos asociados a la inteligencia humana, como la toma de decisiones, la resolución de problemas y el aprendizaje autónomo. Según Anand et al. (2023), la IA combina programación informática compleja con modelos inspirados en los procesos cognitivos humanos para realizar una amplia gama de tareas que antes requerían de intervención humana directa. En este sentido, la IA constituye el marco general dentro del cual se desarrollan las tecnologías que hacen posible la visión por computador.

2.2.1.2. Internet de las cosas (IoT). El internet de las cosas es una red de dispositivos físicos, como vehículos, maquinaria y sensores que poseen la capacidad de transmitir datos automáticamente a través de redes de comunicación que no necesitan de intervención humana, permite la recolección de datos de proceso y habilita la toma de decisiones en tiempo real. Esta tecnología constituye uno de los pilares mas importantes de la industria 4.0. (Gomez et al., 2019)

2.2.1.3. Visión por computador (VC). La visión por computador es una subárea de la inteligencia artificial que busca dotar a los sistemas informáticos de la capacidad de comprender información visual compleja sobre su entorno (Agrawal et al., 2024). Esta disciplina combina técnicas de procesamiento digital de imágenes, aprendizaje automático y modelos matemáticos para extraer información significativa a partir de datos visuales como fotografías o videos. Su aplicación permite automatizar tareas de inspección, medición, reconocimiento y monitoreo en distintos contextos industriales.

2.2.1.4. Machine learning. El *machine learning* es una subdisciplina de la IA que se centra en el desarrollo de algoritmos que permiten a los sistemas aprender, mejorar y realizar predicciones a partir de los datos que se les proporcionan. En el ámbito industrial, esta tecnología facilita el análisis de grandes volúmenes de información generados por sensores, equipos o sistemas de producción, con el fin de detectar fallas, predecir mantenimientos, optimizar la asignación de recursos y mejorar la toma de decisiones estratégicas (Sánchez, s.f.).

2.2.1.5. Deep learning. El *deep learning* es una evolución del *machine learning* que emplea arquitecturas de redes neuronales profundas para procesar información en múltiples capas jerárquicas. Estas redes permiten aprender automáticamente representaciones complejas a partir de datos sin procesar, lo que resulta especialmente útil en tareas de reconocimiento visual, donde se requiere identificar patrones, formas y estructuras de alta complejidad.

2.2.1.6. Redes neuronales convolucionales (CNN). Las redes neuronales convolucionales son un tipo de arquitectura de deep learning diseñada específicamente para el procesamiento de datos visuales. De acuerdo con Wang et al. (2022), las CNN han demostrado un alto rendimiento en tareas de clasificación de imágenes y detección de objetos, gracias a su capacidad para extraer características relevantes de manera automática y eficiente. Su arquitectura permite realizar procesos de entrenamiento y predicción de extremo a extremo, eliminando la necesidad de una extracción manual de características, lo que las convierte en un pilar fundamental de la visión por computador moderna.

2.2.1.7. Modelos YOLO. YOLO (You only look once) corresponde a una familia de modelos de redes neuronales convolucionales que se diseñan para la detección de objetos en tiempo real. Estos modelos pasan la imagen por una red neuronal convolucional (CNN) y predicen directamente los cuadros delimitadores (bounding boxes) y las probabilidades de cada

clase, lo que se conoce como enfoque de pasada única. De esta manera el tiempo de inferencia se ve reducido, posicionando a YOLO como la arquitectura recurrente cuando se requiere tanto velocidad como precisión (Ali & Zhang, 2024).

2.2.1.8. Transfer learning. El *transfer learning* o aprendizaje por transferencia es una técnica del *machine learning* en la que un modelo previamente entrenado en un conjunto de datos de gran escala se reutiliza como punto de partida para resolver una tarea diferente pero relacionada. En lugar de entrenar un modelo desde cero, lo que requiere grandes cantidades de datos y recursos computacionales, el *transfer learning* aprovecha el conocimiento ya adquirido por el modelo base y lo ajusta para el nuevo problema con un conjunto de datos más pequeño (Singh & Desai, 2023). Esta técnica es ampliamente utilizada en visión por computador aplicada a entornos industriales, donde obtener grandes volúmenes de imágenes etiquetadas suele ser difícil y costoso.

2.2.1.9. Mecanismos de atención. Los mecanismos de atención son módulos que se integran dentro de las arquitecturas de *deep learning* para emular la capacidad humana de enfocarse selectivamente en las partes más relevantes de una imagen, ignorando el ruido de fondo. Su función es guiar a la red para que aprenda representaciones más precisas, asignando mayor peso a las regiones de interés durante el proceso de extracción de características. Entre los módulos más utilizados se encuentran SE (Squeeze-and-Excitation), CBAM (Convolutional Block Attention Module) y CA (Coordinate Attention), los cuales se insertan en diferentes etapas de la arquitectura para mejorar tanto la detección de objetos pequeños como la robustez ante condiciones de iluminación variable (Gao et al., 2025).

2.2.1.10. Métricas de evaluación de modelos. Para comparar el desempeño de los modelos de visión por computador se utilizan métricas estándar que permiten medir su precisión

y capacidad de detección. Las más empleadas en el contexto industrial son la precisión (*precision*), que indica qué proporción de las detecciones realizadas por el modelo son correctas; el *recall*, que mide qué proporción de los objetos reales fueron efectivamente detectados; el *F1-score*, que combina ambas métricas en un único valor balanceado; y el mAP (*mean Average Precision*), que evalúa el rendimiento global del modelo en múltiples clases de objetos y umbrales de detección. Adicionalmente, el IoU (*Intersection over Union*) es el criterio que determina si una detección se considera correcta al comparar el área de superposición entre la caja predicha y la caja real (Raisul Islam et al., 2024).

2.2.1.11. Gemelos digitales (Digital twins). Los gemelos digitales emergen como una tecnología clave en la industria 4.0, corresponden a la versión virtual dinámica y sincronizada de un objeto, proceso o sistema. Esta representación se actualiza en tiempo real a partir de información que obtiene de sensores y sistemas de información, con el fin de monitorear, predecir y optimizar el comportamiento del sistema (Singh et al., 2021). Esta tecnología actúa como una plataforma que integra otras tecnologías clave de la industria 4.0 como el internet de las cosas, la inteligencia artificial, la analítica de datos y la visión por computador, mientras que sensores y cámaras captan la información, los modelos la interpretan, y el gemelo digital se encarga de consolidar todo virtualmente para el apoyo de la toma de decisiones.

2.2.2. Intersección con la ingeniería industrial

La ingeniería industrial es un campo multidisciplinario cuyos pilares fundamentales incluyen la optimización de los procesos, el aumento de la productividad, la garantía de la calidad, la seguridad de los trabajadores y la gestión eficiente de la cadena de suministro.

Integrar tecnologías emergentes que sean afines a cumplir con los objetivos de estos pilares resulta cada vez más necesario para mantener relevancia en un mercado competitivo.

La visión por computador se posiciona como una herramienta clave dentro de la ingeniería industrial, ya que permite capturar, procesar y analizar información visual en sistemas productivos donde tradicionalmente se dependía de la inspección humana (Sitnikov et al., 2021). Su integración con sensores industriales, sistemas de control y plataformas de datos abre la posibilidad de automatizar procesos que antes requerían criterio humano, reduciendo la variabilidad, los errores por fatiga y los tiempos de ciclo.

La intersección entre ambas disciplinas se da en áreas clave, como lo son el área de manufactura y control de calidad, la visión por computador permite verificar dimensiones, detectar defectos superficiales e inspeccionar ensamblajes de forma automatizada, reemplazando controles manuales que son lentos y sujetos a error (De Ketelaere et al., 2022). En la industria de los alimentos, cumple el rol de inspector al caracterizar el color, la forma y la textura de los productos, garantizando uniformidad y calidad en línea. Y en el área de seguridad y salud en el trabajo, a través de modelos de estimación de pose y detección de objetos, la visión por computador puede identificar comportamientos de riesgo y verificar el uso correcto de elementos de protección personal en fábricas y sitios de construcción (Addula & Tyagi, 2025).

2.2.3. Revisión sistemática de literatura y metodología PRISMA

Una revisión sistemática de literatura (RSL) es un tipo de investigación documental que busca identificar, seleccionar, evaluar y sintetizar toda la evidencia científica disponible sobre una pregunta de investigación específica, siguiendo un proceso explícito, riguroso y reproducible. A diferencia de una revisión narrativa, en la que el autor selecciona y comenta los estudios de manera subjetiva, la RSL define de antemano los criterios de inclusión y exclusión,

las fuentes de búsqueda y el protocolo de extracción de información, lo que reduce el sesgo y permite que otros investigadores repliquen el proceso (Raisul Islam et al., 2024).

PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) es una guía metodológica diseñada para mejorar la transparencia y la calidad en la presentación de revisiones sistemáticas. Proporciona a los autores orientación sobre cómo reportar de forma completa por qué se realizó la revisión, qué métodos se utilizaron y qué resultados se obtuvieron. El protocolo PRISMA estructura el proceso en cuatro fases consecutivas: identificación, cribado, evaluación de elegibilidad e inclusión de referencias científicas, garantizando la trazabilidad y el rigor metodológico de cada decisión tomada durante la revisión (Page et al., 2021).

2.2.4. Escala de madurez tecnológica (TRL)

La escala TRL (*Technology Readiness Level*) es un sistema de nueve niveles desarrollado originalmente por la NASA y adoptado posteriormente por organismos como la Comisión Europea para evaluar el grado de desarrollo y transferibilidad de una tecnología. Cada nivel describe el estado de avance de un sistema, desde la observación de principios básicos (TRL 1) hasta la demostración de un sistema operativo en entorno real (TRL 9). En el contexto de la visión por computador aplicada a la industria, esta escala permite distinguir entre sistemas que solo han sido probados en laboratorio y aquellos que han sido validados e integrados en procesos productivos reales (Mašlanka et al., 2025). En la tabla 1 se resumen los niveles más relevantes para este trabajo.

Tabla 1.

Niveles de madurez tecnológica

Nivel TRL	Descripción
------------------	--------------------

TRL 1 – 3	Investigación básica y prueba de concepto
TRL 4 – 5	Validación en laboratorio o entorno simulado
TRL 6 – 7	Prototipo demostrado en entorno relevante
TRL 8 – 9	Sistema completo validado y operativo en entorno real

La evaluación del nivel TRL de los estudios revisados es un indicador clave para determinar si las soluciones propuestas en la literatura están realmente cerca de poder implementarse en una empresa, o si todavía se encuentran en etapas experimentales.

3. Objetivos

3.1. Objetivo general

Analizar y caracterizar el estado actual de la investigación sobre la aplicación de la visión por computador en la ingeniería industrial mediante una revisión sistemática de la literatura.

3.2. Objetivos específicos

1. Examinar la estructura de la producción científica sobre visión por computador en la ingeniería industrial mediante un análisis bibliométrico, considerando indicadores como tendencias de publicación, autores, países, fuentes y redes de colaboración.
2. Caracterizar las principales aplicaciones y enfoques metodológicos de la visión por computador en las diferentes áreas de la ingeniería industrial, identificando las técnicas empleadas y los contextos de implementación reportados en la literatura.
3. Analizar los resultados obtenidos en los estudios revisados, evaluando sus aportes, ventajas, limitaciones y niveles de madurez tecnológica de las soluciones propuestas en entornos industriales.
4. Identificar tendencias emergentes, vacíos de investigación y oportunidades de desarrollo futuro en el área.
5. Sistematizar los hallazgos de la investigación en un documento académico estructurado con potencial de publicación.

3.3. Tabla de cumplimiento de objetivos

En la Tabla 2, se relaciona cada uno de los objetivos específicos con la sección del documento donde se puede evidenciar el cumplimiento.

Tabla 2.

Cumplimiento de los objetivos específicos del proyecto

Objetivo	Cumplimiento
Examinar la estructura de la producción científica sobre visión por computador en la ingeniería industrial mediante un análisis bibliométrico, considerando indicadores como tendencias de publicación, autores, países, fuentes y redes de colaboración.	Sección 5.2
Caracterizar las principales aplicaciones y enfoques metodológicos de la visión por computador en las diferentes áreas de la ingeniería industrial, identificando las técnicas empleadas y los contextos de implementación reportados en la literatura.	Sección 5.4.3 – 5.4.6
Analizar los resultados obtenidos en los estudios revisados, evaluando sus aportes, ventajas, limitaciones y niveles de madurez tecnológica de las soluciones propuestas en entornos industriales.	Sección 5.4.3 – 5.4.6
Identificar tendencias emergentes, vacíos de investigación y oportunidades de desarrollo futuro en el área.	Sección 5.5
Sistematizar los hallazgos de la investigación en un documento académico estructurado con potencial de publicación.	Sección 5.6 y Apéndice B

4. Metodología

La presente investigación se enmarca en un estudio de tipo documental, con enfoque predominantemente cualitativo y un componente cuantitativo asociado al análisis bibliométrico. El alcance del estudio es descriptivo y analítico, ya que busca caracterizar y examinar el estado actual de la investigación sobre la aplicación de la visión por computador en la ingeniería industrial.

Para ello, se adoptó el método de revisión sistemática de literatura, el cual permite identificar, seleccionar y analizar de manera estructurada y reproducible la evidencia científica disponible en bases de datos indexadas.

El proceso metodológico se desarrolló en cuatro fases principales, descritas a continuación.

4.1. Fase 1: Delimitación conceptual y formulación del protocolo

En esta fase se construyó el marco conceptual y metodológico que orienta la revisión. Se definió el problema de investigación, la pregunta orientadora y el alcance del estudio. Asimismo, se identificaron los términos clave y sinónimos relevantes para la construcción de la estrategia de búsqueda. Como resultado, se consolidó un protocolo de revisión sistemática que define los criterios de inclusión y exclusión, la estrategia de búsqueda y el esquema de registro del proceso, garantizando la trazabilidad y reproducibilidad.

Actividades principales:

- Se realizó una exploración preliminar de literatura para reconocer enfoques y conceptos centrales.
- Se definió la pregunta de investigación y los criterios de delimitación del estudio.

- Se construyó y validó la ecuación de búsqueda con operadores booleanos y términos clave.
- Se establecieron los criterios de inclusión y exclusión de los estudios.
- Se diseñó el esquema de registro y documentación del proceso de revisión.

4.2. Fase 2: Búsqueda sistemática y proceso de selección

Con base en el protocolo diseñado, se realizó la búsqueda estructurada en las bases de datos seleccionadas. Los registros recuperados fueron consolidados y depurados mediante la eliminación de duplicados. Se llevó a cabo un proceso de cribado en dos niveles, primero por título y resumen, y después por texto completo, aplicando los criterios de elegibilidad que se establecieron previamente. El proceso de selección fue documentado mediante un diagrama de flujo tipo PRISMA, que permite evidenciar de manera transparente las decisiones tomadas en cada etapa.

Actividades principales:

- Se ejecutó la búsqueda en cada base de datos definida.
- Se consolidaron los registros en la herramienta de gestión bibliográfica Rayyan.
- Se eliminaron duplicados y se registró el número de documentos depurados.
- Se realizó el cribado por título y resumen.
- Se evaluaron los textos completos según los criterios establecidos.
- Se elaboró el diagrama de flujo del proceso de selección.

4.3. Fase 3: Análisis bibliométrico y extracción de información

Previo al proceso de selección, se realizó un análisis bibliométrico sobre el conjunto inicial de registros recuperados, con el fin de examinar la evolución de la producción científica,

la distribución por países, autores, fuentes y áreas temáticas. Este análisis permitió caracterizar el panorama general del campo antes de profundizar en los artículos seleccionados.

De forma complementaria, una vez definida la muestra final de 124 artículos, se diseñó y aplicó una matriz de extracción de datos para sistematizar la información relevante de cada estudio. Esta matriz fue construida en torno a 12 variables de interés previamente definidas sin orden específico que otorgan el conocimiento requerido de la literatura seleccionada. La primera variable corresponde al año de publicación de cada estudio, una variable cuantitativa discreta que tiene el propósito de obtener información sobre las tendencias temporales presentes. Luego se encuentra la variable GAP, que sirve para identificar los vacíos reportados por los autores y el motivo de la realización de su estudio.

También se encuentran las variables área de aplicación y sector industrial, la primera identifica el dominio funcional de la ingeniería industrial en donde se aplica la visión por computador y la segunda describe la industria en donde la solución es empleada. La variable modelo, identifica el modelo de arquitectura de visión por computador utilizado en cada estudio, con el propósito de más adelante reconocer la existencia de tendencias de uso.

Por otro lado, el origen del dataset, que consiste en determinar si el dataset es público o propio del estudio, el tamaño, que identifica que tan grande es el dataset empleado y el tipo de datos utilizado, que diferencia si un estudio utiliza videos, imágenes o un esquema híbrido, son variables que permiten la caracterización de cada dataset utilizado, con el propósito de descubrir su relevancia en el estudio.

La variable de la metodología empleada, con el fin de identificar la estrategia técnica que utilizan los autores para emplear el modelo seleccionado. La variable de limitaciones declaradas recoge las restricciones y barreras que los autores reconocen luego de realizar el estudio, la

importancia de esta variable radica en la identificación de barreras estructurales que se comparten entre estudios. Por último las variables de madurez tecnológica y método de validación, en las que se representa el grado de desarrollo, la preparación de una solución para su aplicación industrial y la estrategia mediante las cuales se comprobó el funcionamiento del sistema propuesto.

Actividades principales:

- Se construyó la base de datos bibliométrica a partir de los registros iniciales.
- Se analizaron indicadores como frecuencia de publicaciones, autores, países y áreas temáticas.
- Se diseñó una matriz de extracción de datos con categorías alineadas a los objetivos.
- Se extrajo y clasificó la información clave de cada artículo de manera sistemática.

4.4. Fase 4: Síntesis y análisis de resultados

En esta fase se realizó un procedimiento de análisis cualitativo por categorías con el propósito de estructurar la información y generar conocimiento, tomando como unidad del análisis las variables de GAP, limitaciones declaradas y los modelos utilizados. Se realizó una síntesis analítica de la información extraída, identificando patrones, tendencias, niveles de madurez tecnológica, ventajas y limitaciones de las soluciones propuestas en los estudios revisados. Finalmente, se determinaron los vacíos de investigación y las oportunidades de desarrollo futuro en la integración de la visión por computador en la ingeniería industrial, generando conclusiones alineadas con los objetivos del estudio.

Actividades principales:

- Se compararon los resultados entre estudios con base en criterios comunes.

- Se identificaron las aplicaciones predominantes y los enfoques metodológicos recurrentes.
- Se analizaron las limitaciones y los niveles de madurez tecnológica reportados.
- Se formularon tendencias emergentes y líneas de investigación futura.
- Se redactó la síntesis narrativa de los hallazgos.

5. Desarrollo metodológico

5.1. Protocolo de búsqueda

La búsqueda de literatura se diseñó siguiendo los lineamientos de la metodología PRISMA, con el fin de garantizar transparencia, trazabilidad y reproducibilidad en el proceso de identificación y selección de estudios.

El protocolo se construyó a partir de tres ejes temáticos principales, cuya intersección delimita el alcance del estudio.

1. Tecnologías de visión por computador.

Este eje agrupa los términos asociados a las técnicas y herramientas que constituyen el objeto central de la revisión. Se consideró que un artículo pertenece a este eje cuando aborda el procesamiento de datos visuales mediante métodos computacionales, incluyendo tareas como lo pueden ser detección de objetos, segmentación de imágenes, reconocimiento de acciones o inspección visual automatizada. Se buscó que la visión por computador fuera el componente principal de la solución propuesta, no un elemento mencionado de forma marginal.

2. Dominio disciplinar de la ingeniería industrial.

Este eje delimita el campo de aplicación al que deben pertenecer los estudios. Comprende investigaciones asociadas con la ingeniería industrial, incluyendo áreas

como calidad, seguridad, productividad, logística y cadena de suministro. Su inclusión es necesaria para filtrar estudios que utilizan visión por computador en disciplinas ajenas como la medicina, la astronomía o las ciencias sociales.

3. Contexto industrial y productivo.

Este tercer eje complementa al anterior al exigir que los estudios estén desarrollados en entornos concretos de producción o gestión industrial. Corresponde a estudios enmarcados en manufactura, líneas de producción, almacenes, logística interna, mantenimiento o plantas industriales. Su propósito es excluir trabajos de carácter puramente teórico que no tienen aplicación directa en el contexto de la ingeniería industrial.

Esta estructura de tres ejes responde a la necesidad de recuperar artículos que no solo utilicen técnicas de visión por computador, sino que además estén contextualizados en problemáticas propias de la ingeniería industrial y en entornos productivos reales. Trabajar con un solo eje temático habría generado un volumen de resultados demasiado amplio y poco específico, mientras que la intersección de los tres permite acotar la búsqueda a los estudios verdaderamente relevantes para los objetivos de esta revisión.

5.1.1. Estrategia de búsqueda

Con base en los ejes temáticos definidos, se construyeron las siguientes ecuaciones de búsqueda utilizando operadores booleanos. Se diseñó una ecuación principal que combina los tres ejes simultáneamente, y dos ecuaciones complementarias orientadas a capturar estudios de áreas específicas (ergonomía y seguridad, y logística) que por su vocabulario particular podrían no ser recuperados por la ecuación principal.

Ecuación principal

((“computer vision” OR “machine vision” OR “industrial vision” OR “visual inspection” OR “video analytics” OR “object detection” OR “image segmentation” OR “pose estimation” OR “action recognition” OR “multi-object tracking”))

AND

(“industrial engineering” OR “operations management” OR “operations engineering” OR “quality engineering” OR “statistical process control” OR “human factors” OR “supply chain” OR logistics OR warehouse OR intralogistics OR “facility layout” OR “facilities engineering” OR productivity OR “work measurement” OR “time study” OR “work sampling” OR maintenance OR reliability)

AND

(manufacturing OR “production line” OR “shop floor” OR “material handling”))

Ecuaciones complementarias

((“computer vision” OR “pose estimation” OR “human action recognition” OR “image analysis”))

AND

(“ergonomics” OR “occupational safety” OR “industrial safety” OR “workplace monitoring” OR “human factors”))

((“computer vision” OR “machine vision” OR “image processing”))

AND

(“supply chain” OR “warehouse management” OR “inventory management” OR “last mile delivery”))

La búsqueda se realizó en las bases de datos Scopus (Elsevier) y Web of Science (Clarivate Analytics). Estas dos plataformas fueron seleccionadas por ser las bases de datos multidisciplinarias indexadas de mayor cobertura y reconocimiento en el ámbito de la ingeniería y las ciencias aplicadas, lo que garantiza que los estudios recuperados cumplen con estándares mínimos de calidad editorial. Se aplicó un rango temporal comprendido entre 2021 y 2025, con el objetivo de capturar la producción científica más reciente y relevante del campo, período en el

que la visión por computador ha experimentado su mayor crecimiento en aplicaciones industriales. Los resultados se restringieron a artículos científicos publicados en revistas académicas en idioma inglés, dado que este es el idioma predominante en la literatura científica indexada de las áreas de interés.

Como resultado inicial, la búsqueda en títulos, resúmenes y palabras clave arrojó los siguientes registros:

- Scopus (Elsevier): 918 registros
- Web of Science (Clarivate Analytics): 470 registros

Los registros fueron exportados y consolidados en la herramienta Rayyan, donde se identificaron y eliminaron 314 duplicados correspondientes a artículos indexados simultáneamente en ambas bases de datos, obteniendo un total de 1.074 documentos potenciales para el resto del proceso de selección.

5.1.3. Criterios de inclusión y exclusión

Los criterios de inclusión y exclusión se definieron antes de iniciar la búsqueda, con el fin de garantizar que las decisiones de selección fueran consistentes y no estuvieran influenciadas por los resultados encontrados.

Se incluyeron estudios que cumplieran con las siguientes condiciones:

- Sean artículos científicos publicados en revistas académicas revisadas por pares, lo que garantiza un mínimo de rigor metodológico y validación editorial.

- Presenten una aplicación explícita de visión por computador en un contexto industrial asociado a problemáticas de ingeniería industrial, asegurando la pertinencia temática directa con los objetivos de la revisión.
- Hayan sido publicados entre 2021 y 2025, con el fin de capturar el estado del arte más reciente del campo.
- Estén disponibles en idioma inglés, dado que es el idioma en que se publica la mayor parte de la producción científica indexada en las bases de datos consultadas.

Se excluyeron estudios que presentaran alguna de las siguientes condiciones:

- No se tuviera acceso al texto completo a través de los recursos digitales de la universidad, ya que la información metodológica completa es necesaria para la extracción de datos.
- Fueran duplicados de registros ya incluidos en el proceso.
- No presentaran información metodológica suficiente para extraer los campos clave de la matriz de extracción, lo que impediría un análisis sistemático consistente.
- Tuvieran como foco principal aplicaciones en dominios no industriales como diagnóstico médico, astronomía o aeronáutica, por estar fuera del alcance disciplinar de esta revisión.

5.2. Análisis bibliométrico


Con el fin de comprender la extensión, la distribución geográfica y el perfil temático de la producción científica disponible, se realizó un análisis bibliométrico sobre el conjunto de registros recuperados en la búsqueda inicial, antes del proceso de selección. Este análisis

permitió identificar tendencias generales del campo e interpretar el contexto en el que se enmarca la literatura revisada.

La evolución temporal de las publicaciones se presenta en la Figura 1, que muestra la cantidad de documentos por año dentro del período analizado. La curva evidencia un crecimiento sostenido desde 2021 y un aumento especialmente marcado en 2025, año en el que la producción casi duplicó la cantidad de artículos disponibles respecto al inicio del período. Este comportamiento es característico de un campo en fase de expansión acelerada, e indica que el interés académico por la visión por computador aplicada a la ingeniería industrial no solo se mantiene, sino que sigue creciendo de forma activa.

Figura 1.

Cantidad de documentos por año




La distribución geográfica de los documentos se presenta en la Figura 2. Los resultados muestran una concentración alta de producción científica en el continente asiático, con China a la cabeza y seguida por Estados Unidos. Este liderazgo puede explicarse por dos factores complementarios, la existencia de políticas activas de inversión en el desarrollo de inteligencia


artificial en estos países, y la presencia de sectores manufactureros altamente automatizados que generan una demanda constante de soluciones basadas en visión por computador (Gao et al., 2025). Para el alcance de esta revisión, esta distribución también implica que una parte importante de los estudios analizados proviene de contextos industriales con alto nivel de automatización, lo cual es relevante al momento de interpretar los niveles de madurez tecnológica reportados.

Figura 2.

Documentos por territorio




La figura 3 corresponde a los 15 principales autores y la cantidad de publicaciones de cada uno, se puede observar una competencia muy estrecha, con una diferencia de solo 6 publicaciones entre el primer lugar y el último, los autores Wang Z., Li Y. y Zhang Y. encabezan la lista con 13 y 12 publicaciones respectivamente, consolidándose como los investigadores con la producción más constante en la aplicación de visión por computador en entornos industriales. La repetición de apellidos comunes en el ámbito sugiere una fuerte presencia de centros de investigación asiáticos, lo cual se alinea con el análisis territorial en el que actualmente lideran la implementación de modelos YOLO.

Figura 3.*Autores por número de publicaciones*

La procedencia temática de los documentos se presenta en la Figura 4, que revela un perfil claramente interdisciplinario. Las publicaciones se distribuyen principalmente entre ingeniería (30,4%) y ciencias de la computación (23,9%), dos disciplinas que en conjunto representan alrededor del 50% del material científico analizado. Esta distribución tiene sentido dado que la visión por computador es una tecnología que surge del desarrollo computacional, pero encuentra su mayor campo de aplicación en los problemas de ingeniería. Los porcentajes restantes se distribuyen entre áreas como ciencias de los materiales, física y ciencias agrícolas, lo que refleja la amplitud de sectores en los que esta tecnología ha encontrado aplicación. Esta distribución confirma que el desarrollo de la visión por computador en entornos industriales es un esfuerzo conjunto entre la innovación computacional y su aplicación práctica en los desafíos de la automatización (Gao et al., 2025).

Figura 4.

Documentos por área temática

Las concentraciones de conocimiento en las principales revistas se presentan en las figuras 5 y 6, estas revelan la revista **Sensors** como el eje central de este ecosistema, ya que lidera en la cantidad de artículos y en la cantidad de citas, que refleja el impacto total. Las revistas **IEEE Access** y el **International Journal of Advanced Manufacturing Technology (IJAMT)** completan el podio, lo que demuestra un balance entre revistas de tecnología general y revistas específicas de manufactura. También resulta importante resaltar el caso de la revista **International Journal of Production Research**, que aunque no está en los primeros puestos por cantidad de artículos, ocupa el tercer lugar en impacto con un total de 262 citas, lo que indica que las investigaciones publicadas allí suelen ser muy influyentes para la comunidad científica.

Revistas como **Robotics and Computer-Integrated Manufacturing** e **IEEE Transactions on Instrumentation and Measurement** muestran una correlación positiva entre la cantidad de publicaciones y las citas recibidas, estas fuentes garantizan una visibilidad técnica superior ante la comunidad académica especializada en automatización y control de calidad.

Figura 5.

Revistas por número de publicaciones

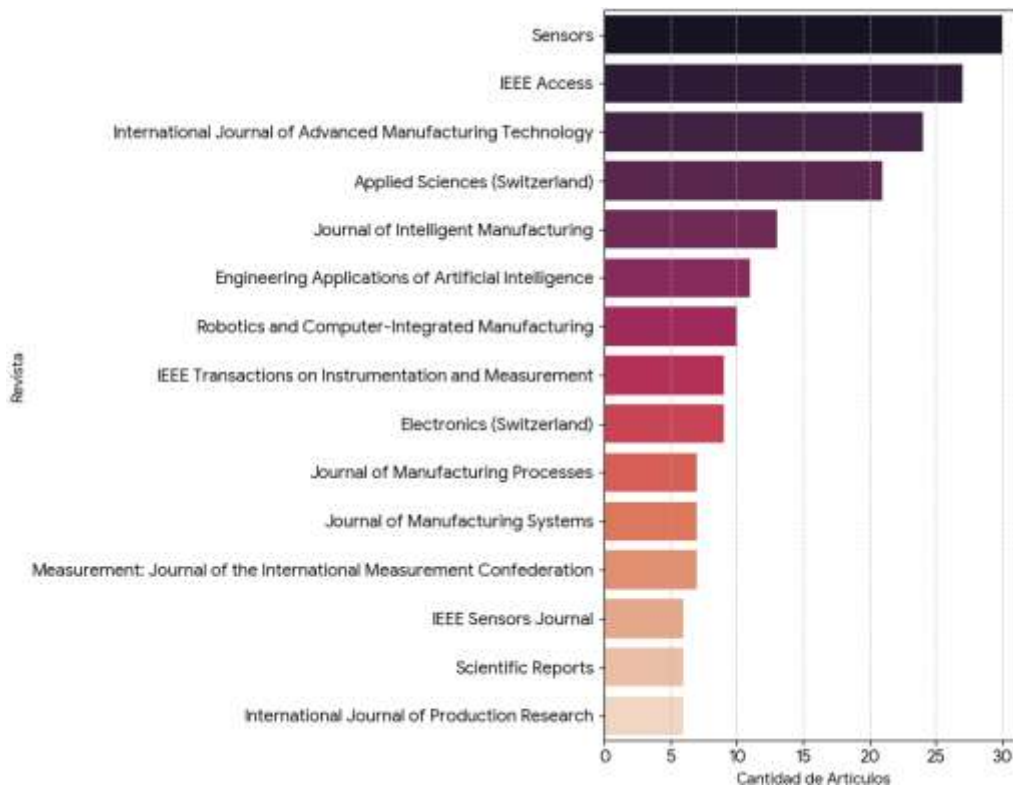



Figura 6.


Revistas por número de citaciones



La red de coautoría se presenta en la figura 7, el análisis muestra que el ecosistema de investigación es muy productivo, pero está dividido. La producción científica se concentra en grupos liderados por investigadores de origen asiático, como Zhang, Y., Wang, Z., y Li, Y., quienes anteriormente se identificaron como figuras clave. Se revela también comunidades cerradas con mucha colaboración interna, lo que indica que los grupos se especializan en áreas técnicas específicas. Sin embargo, falta una integración interdisciplinar a nivel general. Esta fragmentación es típica de un campo donde la innovación es descentralizada y se impulsa por la competencia técnica para mejorar modelos como YOLO.

Figura 7.

Redes de colaboración




En la figura 8 se presenta el estudio de co-ocurrencia de palabras clave, en este se observa una red de seis clusters temáticos, donde *Computer vision* actúa como hub central que articula tres núcleos consolidados, la detección de defectos por deep learning, el control de calidad e

inspeccion de procesos y la automatizacion bajo la industria 4.0, que se articulan entre si mediante nodos como *object detection*, *inspection* y *predictive maintenance*. junto a esta red se encuentran dos dominios emergentes, que a pesar de su baja densidad representan una gran relevancia para el estudio, son manufactura aditiva y la integraci3n del factor humano, este aislamiento estructural solo representa subexploracion. Tambien cabe mencionar que las zonas de baja conectividad delimitan con rigor bibliom3trico las fronteras activas del campo y proveen un sustento estructural para la identificaci3n de tendencias emergentes y vac3os estrat3gicos que se discuten en las secciones siguientes.

Figura 8.

Estudio de co-ocurrencia de palabras clave



En conjunto, los resultados del an3lisis bibliom3trico permiten trazar un panorama general del campo antes de entrar al an3lisis detallado de los art3culos seleccionados. La visi3n por computador aplicada a la ingenier3a industrial es un 3rea en crecimiento acelerado, con una

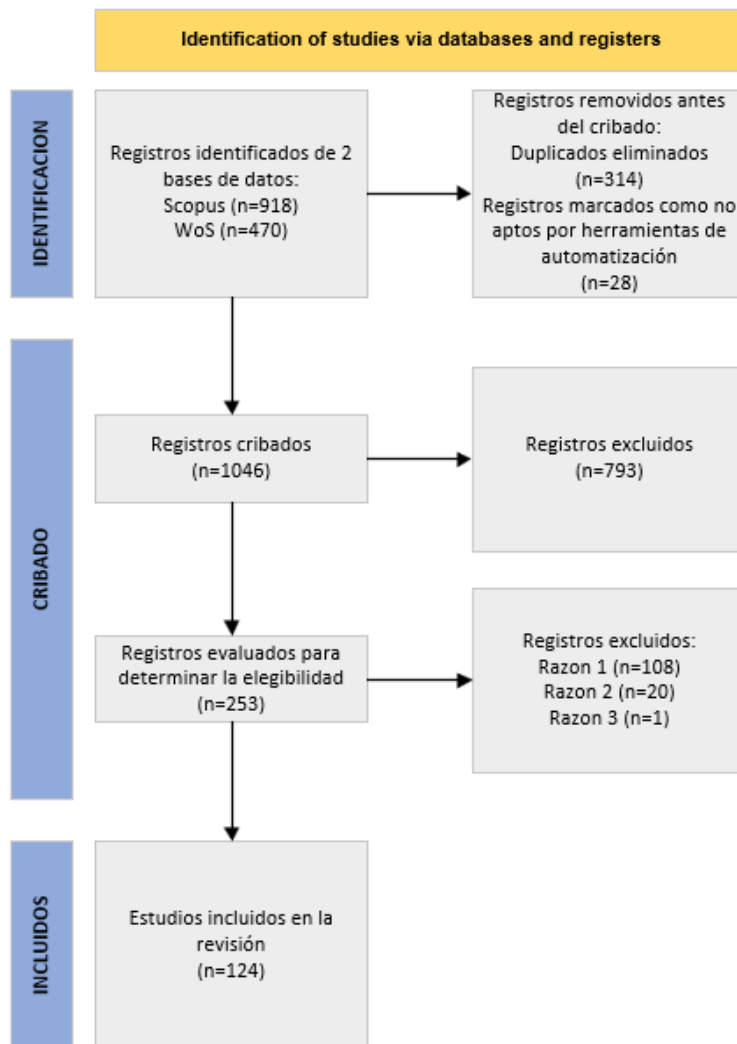
producción científica concentrada en países con sectores manufactureros avanzados y con un perfil interdisciplinario que combina el desarrollo algorítmico con la aplicación industrial. Este contexto es relevante para interpretar los resultados de la revisión, ya que buena parte de los estudios analizados provienen de entornos con niveles de automatización y recursos tecnológicos que no siempre son representativos de la realidad industrial de países en desarrollo.

5.3. Recolección y clasificación de artículos

El proceso de selección de los artículos incluidos en esta revisión siguió las cuatro fases establecidas por el protocolo PRISMA 2020: identificación, cribado, evaluación de elegibilidad e inclusión. La Figura 9 presenta el diagrama de flujo que resume las decisiones tomadas en cada etapa y los volúmenes de registros resultantes.

Figura 9.

Diagrama metodología PRISMA.



Nota: La presente revisión sistemática se ajustó a las recomendaciones del protocolo PRISMA 2020. La plataforma Rayyan se utilizó para la gestión de los artículos. Las bases de datos consultadas fueron Scopus y Web of Science, con fecha de búsqueda correspondiente al primer trimestre de 2026.

5.3.1. Fase de identificación

Esta fase tuvo como objetivo reunir todos los registros potencialmente relevantes disponibles en las bases de datos seleccionadas. Luego de ejecutar la estrategia de búsqueda en Scopus y Web of Science se obtuvieron 1.388 registros en total.

El primer paso fue la eliminación de duplicados, es decir, artículos indexados simultáneamente en ambas bases de datos. Este proceso fue asistido por la plataforma Rayyan,

que utiliza algoritmos de comparación de metadatos para identificar posibles coincidencias. Sin embargo, dado que estos algoritmos pueden generar tanto falsos positivos como falsos negativos, cada duplicado sugerido fue revisado manualmente antes de ser eliminado, verificando título, autores y DOI para confirmar que se trataba efectivamente del mismo registro. Este paso es importante porque eliminar por error un artículo único podría comprometer la exhaustividad de la revisión. Mediante este proceso se identificaron y eliminaron 314 duplicados, correspondientes al 22.6% del total inicial.

Adicionalmente, se eliminaron 28 registros marcados automáticamente por Rayyan por corresponder a revisiones de literatura o encuestas, tipos de documento que fueron excluidos desde el protocolo por no reportar aplicaciones originales de visión por computador. Tras esta fase quedaron 1.046 registros para continuar el proceso.

5.3.2. Fase de cribado

En esta fase se evaluaron los 1.046 registros restantes mediante la revisión de título y resumen, con el objetivo de descartar artículos irrelevantes sin necesidad de acceder al texto completo. Esta estrategia de dos niveles (primero título, luego resumen) permite optimizar el tiempo de revisión al reservar el análisis más detallado para los casos en que la información superficial no es suficiente para tomar una decisión.

En primer lugar, se descartaron los estudios cuyo título indicaba explícitamente que pertenecían a dominios fuera del alcance de la revisión, como diagnóstico médico, astronomía o aeronáutica. Cuando el título resultaba ambiguo o insuficiente para emitir un juicio sobre la relevancia del artículo, se procedió a revisar el resumen, que proporciona el contexto necesario para determinar si la aplicación reportada corresponde a un entorno industrial.

La tasa de descarte en esta fase fue del 75.8%, quedando 253 artículos candidatos. Este porcentaje responde a una estrategia de búsqueda amplia en la fase de identificación, diseñada para maximizar la sensibilidad y no dejar por fuera estudios relevantes. La especificidad se aplica precisamente en el cribado, lo que hace que una tasa de retención baja en esta etapa sea un indicador de que la ecuación de búsqueda funcionó correctamente y no de que los criterios sean demasiado restrictivos.

5.3.3. Fase de evaluación de elegibilidad

Esta fase requirió la recuperación y lectura del texto completo de los 253 artículos candidatos. De entrada, 20 registros fueron eliminados por no contar con acceso al documento completo a través de los recursos digitales de la universidad, y un registro adicional fue eliminado por aparecer como retractado en la base de datos, lo que invalida su contenido para efectos de una revisión sistemática.

Los 232 artículos restantes fueron evaluados con base en dos criterios de elegibilidad. El primero fue la relevancia temática directa, para esto el artículo debía abordar explícitamente la aplicación de técnicas de visión por computador en un contexto propio de la ingeniería industrial, no solo mencionarla como trabajo relacionado o como posibilidad futura. El segundo fue la calidad metodológica, en la cual el artículo debía describir con suficiente detalle el modelo utilizado, la metodología de entrenamiento, las métricas de evaluación y las condiciones de validación, información indispensable para completar los campos de la matriz de extracción de manera consistente.

Los artículos que cumplían uno de los criterios, pero no el otro, también fueron excluidos, dado que la utilidad de cada estudio para los objetivos de la revisión dependía del

cumplimiento de ambas condiciones simultáneamente. Un total de 108 artículos fueron eliminados en esta fase, dejando 124 registros para la inclusión final.

5.3.4. Fase de inclusión

La revisión quedó constituida por 124 artículos, lo que representa una tasa de inclusión del 8.9% respecto a los registros iniciales. Esta tasa es coherente con lo reportado en revisiones sistemáticas de campos similares, donde la combinación de una búsqueda amplia con criterios de selección rigurosos suele derivar en tasas de inclusión de entre el 5% y el 15% (Page et al., 2021).

Con el propósito de facilitar la extracción de información, los 124 artículos fueron sometido a un proceso sistemático de codificación en unos campos de interés previamente definidos: Año de publicación, resumen del aporte, metodología empleada, brecha de investigación identificada, limitaciones declaradas, área de aplicación, sector industrial, modelo de VC utilizado, método de validación, madurez tecnológica, tipo de datos utilizados, origen y tamaño del dataset. La matriz de extracción completa se encuentra disponible como Anexo A.

5.4. Análisis de resultados

El análisis de los 124 artículos incluidos en esta revisión se organizó según los campos definidos en la matriz de extracción, agrupados en ocho categorías que cubren aspectos bibliométricos, tecnológicos, industriales y de rigor experimental. El objetivo de este análisis es interpretar qué significan esos hallazgos para entender el estado real de la visión por computador en la ingeniería industrial.


5.4.1. Tendencia temporal

La distribución de los artículos seleccionados a lo largo del período 2021–2025 permite identificar la dinámica de crecimiento del campo dentro de la muestra analizada. Como se

observa en la Figura 10, la producción no ha sido uniforme, los artículos publicados en 2025 representan el 44.35% del total de la revisión, mientras que los de 2021 constituyen apenas una fracción del volumen final.

Figura 10.

Cantidad de publicaciones por año



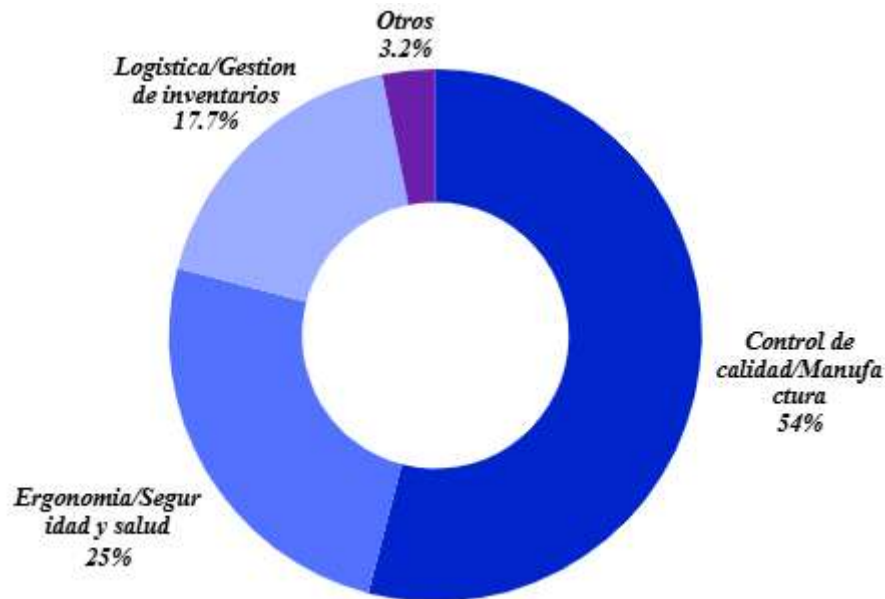
Este crecimiento acelerado no es un dato menor. Un incremento superior al 300% en cuatro años indica que la visión por computador en entornos industriales pasó de ser un tema exploratorio a un área de investigación consolidada. Esto tiene implicaciones directas para interpretar los resultados de esta revisión, buena parte del conocimiento disponible es reciente, lo que significa que muchos de los enfoques metodológicos y modelos identificados aún están en proceso de maduración y validación. El peso tan alto del año 2025 en la muestra sugiere que cualquier revisión realizada en años anteriores ya estaría desactualizada, lo que refuerza la pertinencia y la oportunidad de este trabajo.

5.4.2. Areas de aplicación

Con el fin de organizar los 124 artículos de manera coherente con las disciplinas propias de la ingeniería industrial, se definieron cuatro categorías de área de aplicación, presentadas en la Figura 11.

Figura 11.

Distribución de artículos por categoría



5.4.2.1 Control de calidad, inspección y manufactura general. Esta categoría concentra más de la mitad de los artículos de la revisión y es claramente el área más consolidada de la visión por computador en la ingeniería industrial. la inspección visual es una de las tareas más costosas, repetitivas y propensas al error humano en cualquier proceso productivo, y la visión por computador ofrece una solución directa a ese problema. Dentro de esta categoría, la aplicación más frecuente es la detección de defectos superficiales en productos manufacturados, que abarca desde grietas en acero laminado (Wu et al., 2026) hasta imperfecciones en juntas de silicona (Liang & Chen, 2025), tabletas farmacéuticas (Vijayakumar et al., 2024) y telas (Cui et al., 2025).

Una segunda aplicación relevante es la metrología sin contacto, donde sistemas de visión reemplazan instrumentos de medición manual como calibradores o máquinas de medición por coordenadas, verificando dimensiones críticas de piezas durante la producción sin interrumpir el flujo de trabajo (Rajagounder, 2025). Otros usos menos frecuentes incluyen la inspección de ensamblajes, el monitoreo en tiempo real de procesos como soldadura y manufactura aditiva, y la clasificación de productos agrícolas.

Lo que distingue a esta categoría no es solo su volumen sino su nivel de madurez comparativo. Es el área donde se encuentran los benchmarks públicos más consolidados como NEU-DET, MVTEC y Severstal, y donde hay mayor cantidad de estudios con validación en entornos reales de producción.

5.4.2.2 Ergonomía y seguridad y salud en el trabajo. Esta categoría representa el segundo bloque más importante de la revisión y se diferencia estructuralmente de la anterior: mientras que en control de calidad el sistema observa objetos o superficies, aquí el sistema observa personas. Esto tiene implicaciones técnicas importantes, ya que el análisis debe realizarse en tiempo real sobre sujetos en movimiento, lo que hace que el video sea el tipo de dato predominante en esta categoría en lugar de imágenes estáticas (Mares-Castro et al., 2025).

Las aplicaciones se dividen en dos grandes grupos. Por un lado, las aplicaciones de ergonomía, que se centran en la evaluación postural y el análisis de movimiento para estimar el riesgo biomecánico al que están expuestos los trabajadores durante tareas manuales como levantamiento de cargas o ensamblaje repetitivo.

Por otro lado, las aplicaciones de seguridad y salud en el trabajo, orientadas a la detección del uso correcto de elementos de protección personal, la identificación de comportamientos de riesgo y el monitoreo de zonas restringidas en planta. Un ejemplo

representativo es el trabajo de Alenjareghi et al. (2025), que implementa un sistema de análisis de riesgos en tiempo real para la colaboración segura entre humanos y robots en tareas de desensamblaje, combinando estimación de pose con lógica de análisis de peligros.

Una tendencia clara en esta categoría es la transición de modelos 2D a modelos 3D. Los sistemas iniciales estimaban ángulos en un solo plano, lo que limitaba su precisión al no capturar el movimiento completo del cuerpo. Los estudios más recientes utilizan cámaras de profundidad o múltiples cámaras para reconstruir la postura en tres dimensiones, mejorando significativamente la fiabilidad de las evaluaciones ergonómicas (Chen et al., 2024).

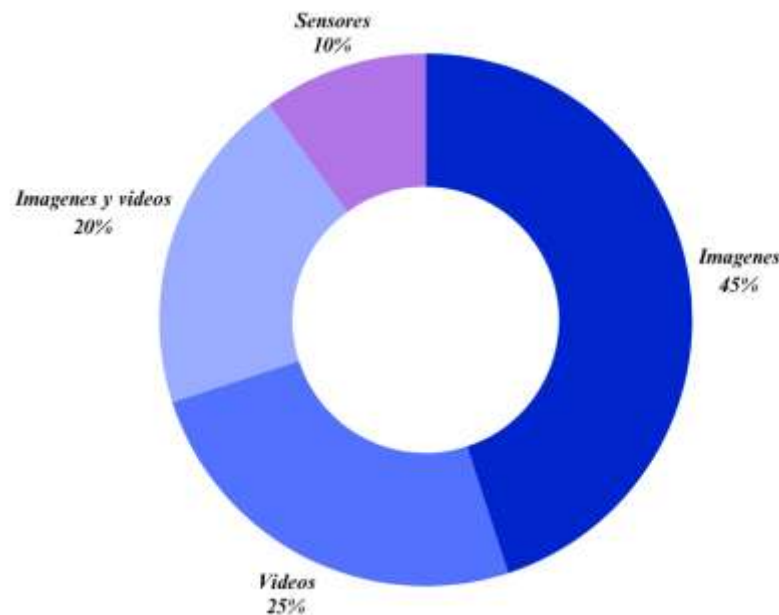
5.4.2.3 Logística, gestión de inventarios y cadena de suministro. Esta categoría expone aplicaciones interesantes, aunque es la menos madura de las tres principales. Aquí la visión por computador se emplea principalmente para automatizar el conteo de inventario, mejorar la trazabilidad de productos dentro de almacenes y reemplazar procesos manuales de supervisión con sistemas de cámaras fijas o robots autónomos. Un caso representativo es el de Cheng et al. (2025), que implementa un sistema de monitoreo en tiempo real de un almacén mediante cámaras de techo integradas con un gemelo digital, logrando seguimiento de activos y análisis de escenas de forma continua.

Sin embargo, es llamativo que solo dos artículos de esta categoría reportan implementación en niveles TRL 8–9, es decir, sistemas operativos en entornos reales de operación. Esto sugiere que a pesar del interés académico, la adopción industrial de la visión por computador en logística aún está en etapas tempranas, posiblemente por la complejidad de integrar estos sistemas con los ERP y WMS existentes en las empresas.

Como se observa en la Figura 12, esta categoría también presenta la mayor variedad en el tipo de datos utilizados, algunos estudios trabajan exclusivamente con imágenes, otros con video, y otros con enfoques híbridos que combinan ambos dependiendo de la tarea específica.

Figura 12.

Distribución del tipo de datos utilizados en aplicaciones de logística y gestión de inventarios



5.4.2.4 Categoría otros. Esta categoría agrupa un conjunto pequeño de artículos con aplicaciones que no encajan de forma clara en las anteriores, como monitoreo de acceso a zonas restringidas y análisis del comportamiento de clientes en tiendas retail. Dado su bajo volumen y la heterogeneidad de los temas, estos estudios se incluyeron en la revisión, pero no se analizaron como una categoría independiente.

5.4.3. Sectores industriales de aplicación

A diferencia del área de aplicación, que describe qué tarea realiza el sistema de visión, el sector industrial describe en qué industria opera. Este análisis permite evaluar la amplitud de adopción de la tecnología e identificar nichos donde apenas empieza a explorarse su potencial. La Tabla 3 resume los principales sectores identificados y sus aplicaciones representativas.

Tabla 3.

Sector industrial y sus aplicaciones

Sector industrial	Aplicaciones representativas
Manufactura general	Inspección de piezas, manufactura aditiva, control de proceso, ensamblaje automatizado
Industria automotriz	Inspección de componentes, ergonomía en línea de producción, ensamblaje, detección de EPP
Retail	Gestión automática de almacenes, monitoreo y surtido de estantes, inventarios, seguimiento de comportamiento de clientes
Construcción	Monitoreo de seguridad en obra, detección de EPP, evaluación ergonómica de trabajadores
Siderurgia	Detección de defectos en acero laminado, inspección de soldaduras y rodamientos
Industria alimentaria	Inspección de calidad en productos cárnicos y lácteos, detección de defectos en líneas de producción
Agricultura	Clasificación de frutos cosechados, detección de enfermedades en cultivos, estimación de madurez y rendimiento en cosecha
Industria textil	Detección de defectos en productos y materias primas como telas o yute
Farmacéutica	Inspección de tabletas en blísteres, detección de partículas en viales liofilizados
Otros sectores	Minería, tabaco, logística portuaria.

La manufactura general y la industria automotriz concentran la mayor cantidad de estudios, lo que es consistente con el dominio del control de calidad dentro de las áreas de aplicación. Ambos sectores cuentan con procesos de inspección bien definidos, líneas de producción estructuradas y una presión competitiva alta por reducir el desperdicio y los defectos, lo que los convierte en terreno apto para la adopción de sistemas de visión automatizados.

Sectores como la siderurgia y la industria alimentaria también tienen una presencia significativa, impulsados por la necesidad de inspeccionar grandes volúmenes de producto a alta velocidad en condiciones que hacen inviable la inspección humana continua, ya sea por temperatura, velocidad de la línea o volumen de producción. Por su parte, sectores como la farmacéutica y la industria textil presentan casos de aplicación más específicos, pero igualmente relevantes, donde la visión por computador permite alcanzar niveles de precisión y consistencia que no son posibles con métodos manuales.

Un hallazgo llamativo es la presencia de la construcción como sector relevante, principalmente a través de aplicaciones de seguridad y salud en el trabajo. Esto refleja el creciente interés por trasladar la tecnología desde entornos de manufactura controlados hacia entornos dinámicos y no estructurados, donde las condiciones cambian constantemente y el riesgo para los trabajadores es más difícil de gestionar.

5.4.4. Modelos y metodologías empleadas

5.4.4.1 Familias de modelos. El análisis del modelo empleado en cada estudio revela una concentración tecnológica muy marcada. Como se observa en la Tabla 2, la familia YOLO domina con el 46% de los estudios, seguida por ResNet con el 16.9% y los enfoques tradicionales de procesamiento de imágenes con el 11.3%.

Tabla 4.

Distribución de familias de modelos.

Familia de modelos	Versiones representativas	%
YOLO	v3, v4, v5, v7, v8, v10, v11 V8 como versión principal, aplicable en la mayoría de las áreas	46%
ResNet	ResNet-101, ResNet-50, ResNet-34, ResNet-18 Se utiliza principalmente como backbone para transfer learning	16.9%
Estimadores de pose	OpenPose, HRNet, MediaPipe Hands, Detectron2, VideoPose3D Se emplea en ergonomía y seguridad y salud en el trabajo	10.5%
Enfoques tradicionales	Canny, Otsu, SIFT, HOG Se utilizan en entornos con restricciones computacionales severas	11.3%
VGG	VGG-16 y VGG-19 Predominantes en estudios anteriores a 2023	8.9%


La predominancia de YOLO no es una coincidencia. Esta familia de modelos fue diseñada desde sus primeras versiones para la detección de objetos en tiempo real, lo que la hace especialmente adecuada para entornos industriales donde la velocidad de procesamiento es tan importante como la precisión. Estas características de diseño presentan una sinergia especial con el control de calidad debido a que resuelve un problema real. El sistema debe indicar dónde se encuentra el defecto y a qué tipo corresponde, la arquitectura de YOLO resuelve ambas tareas simultáneamente, generando coordenadas de cajas delimitadoras y probabilidades de clase con

alta eficiencia computacional. Esta capacidad es especialmente valiosa para detectar grietas, rayones, deformaciones, manchas o componentes ausentes en productos manufacturados.(Yang et al., 2025)

Una línea de producción plantea un conjunto de restricciones técnicas muy específicas y el sistema debe procesar imágenes a la velocidad de la línea, debe tomar una decisión de aceptación o rechazo en un tiempo de ciclo compatible con el ritmo del proceso y debe operar de forma continua durante turnos de producción de 8 a 12 horas sin degradación de rendimiento. Estas restricciones no implican directamente que la precisión máxima sea el objetivo prioritario, importa más la velocidad de inferencia consistente y la estabilidad del rendimiento a lo largo del proceso. YOLOv8, la versión más utilizada (ver Figura 13), ofrece un equilibrio entre rendimiento y facilidad de implementación que lo convierte en el punto de partida natural para la mayoría de las aplicaciones de inspección visual. Además, su arquitectura modular facilita las personalizaciones que se discuten más adelante.

Figura 13.

Distribución versiones del modelo YOLO



En las aplicaciones de logística, la tarea predominante es el conteo y seguimiento de objetos, que es un problema de múltiple seguimiento de objetos (MOT) que involucra la asociación temporal de detecciones entre fotogramas, la gestión de oclusiones y la identidad persistente de cada objeto a lo largo del tiempo. El componente crítico de estas aplicaciones es el algoritmo de asociación temporal, como DeepSORT o ByteTrack, que combina las detecciones de YOLO con descriptores de apariencia y predicciones de movimiento para mantener la identidad de cada objeto. La elección de YOLO como detector es habitual, pero el diferenciador tecnológico real está en el algoritmo de seguimiento, razón por la cual la literatura de logística muestra una mayor diversidad metodológica que la de control de calidad.

ResNet, por su parte, se utiliza principalmente como modelo base para *transfer learning*: en lugar de entrenar un modelo desde cero, los investigadores aprovechan los pesos preentrenados de ResNet en grandes conjuntos de datos como ImageNet y los ajustan para la tarea específica de inspección industrial. Esta estrategia es especialmente valiosa en contextos donde los datos son escasos, como en la detección de defectos en productos poco comunes o en sectores con baja disponibilidad de imágenes etiquetadas (Singh & Desai, 2023).

La presencia significativa de enfoques tradicionales como Canny, Otsu y SIFT, con un 11.3%, no debe interpretarse como un rezago tecnológico. En muchos casos estos métodos son deliberadamente preferidos sobre el *deep learning* cuando el entorno de aplicación tiene restricciones computacionales severas, cuando el conjunto de datos disponible es demasiado pequeño para entrenar una red neuronal, o cuando la tarea es suficientemente simple como para no justificar la complejidad de un modelo profundo. Un ejemplo de esto es el sistema de inspección de engranajes de Ari et al. (2025), que utiliza procesamiento HSV y umbralización de

Otsu para clasificar defectos en una línea de producción en masa, logrando resultados satisfactorios con hardware de bajo costo.

5.4.4.2 Metodologías de diseño. Más allá del modelo base utilizado, los estudios revisados emplean diversas estrategias de diseño que determinan cómo se construye y adapta el sistema. La más recurrente es la incorporación de mecanismos de atención dentro de la arquitectura del modelo. Como se explicó en el marco teórico, estos módulos permiten que la red se enfoque en las regiones relevantes de la imagen ignorando el ruido de fondo, lo que mejora la detección de defectos pequeños o de bajo contraste.

Los módulos más frecuentes en la revisión son SE, CBAM, CA y GAM, que se insertan en diferentes etapas de la arquitectura, algunos en el extractor de características para mejorar la representación interna de la imagen, y otros entre el extractor y el predictor para filtrar la información antes de la detección final. Estudios como el de Wu et al. (2026) y Wang et al. (2024) ilustran bien este patrón, incorporando módulos de atención dentro de versiones modificadas de YOLO para mejorar la detección de defectos en acero y piezas de manufactura aditiva respectivamente.

La segunda metodología relevante es la estimación de pose corporal y el análisis cinemático, exclusiva de las aplicaciones de ergonomía y seguridad y salud en el trabajo. Estos sistemas extraen esqueletos humanos a partir de video, calculan ángulos articulares y los comparan con umbrales de riesgo biomecánico establecidos por normas como REBA o NIOSH. La evolución más notable en esta área es la transición de estimaciones 2D a modelos 3D, que requieren o bien cámaras de profundidad, o bien la combinación de múltiples ángulos de cámara para reconstruir la postura completa del trabajador (Chen et al., 2024).

Una tercera metodología que merece mención es el aumento de datos mediante redes generativas, utilizada en estudios donde la clase de defecto de interés es muy poco frecuente en la producción real y el conjunto de datos original está desequilibrado. Li et al. (2024) emplean StyleGAN2 para generar imágenes sintéticas de defectos en caramelos, permitiendo entrenar un modelo con datos suficientes sin necesidad de recolectar cientos de muestras defectuosas reales.

5.4.5. Generalidades del dataset

La caracterización del dataset es uno de los indicadores más reveladores del estado real del campo, porque permite entender no solo con qué datos se entrenaron los modelos sino qué tan replicables y generalizables son los resultados obtenidos.

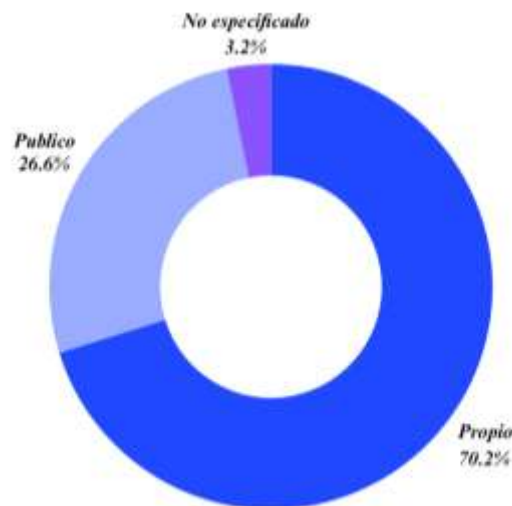
Como se observa en la Figura 14, el 70% de los artículos utilizó un dataset propio, construido específicamente para el estudio. Este porcentaje es alto y tiene una explicación directa, la detección de defectos industriales es una tarea altamente específica del contexto, y los defectos de una línea de producción de juntas de silicona poco tienen en común con los de una línea de tabletas farmacéuticas o los de una fábrica de telas.

El uso de un único conjunto de datos propio es problemático, desde un punto de vista de replicabilidad de los modelos, porque puede dar origen a dos problemáticas, primero, el sesgo de distribución o de dominio, que implica que los modelos son útiles únicamente en configuraciones controladas similares a los datos usados en entrenamiento, pero un cambio en estas condiciones (iluminación, ángulo de la cámara, color de fondo, ruido del entorno, entre otros) puede afectar el desempeño en etapa de uso; segundo, el sesgo en datasets pequeños, ya que un conjunto de datos entrenado con pocas muestras tiene poca capacidad de generalización, lo que puede sesgar métricas como mAP o la precisión.

Los datasets públicos disponibles, aunque útiles como *benchmarks*, generalmente no cubren la variabilidad de condiciones, materiales y tipos de defecto que se encuentran en aplicaciones industriales reales. Sin embargo, construir un dataset propio implica un costo significativo en tiempo, etiquetado manual y acceso a muestras defectuosas, lo que se convierte a su vez en una barrera para la replicación de los resultados en otros contextos.

Figura 14.

Origen del dataset.



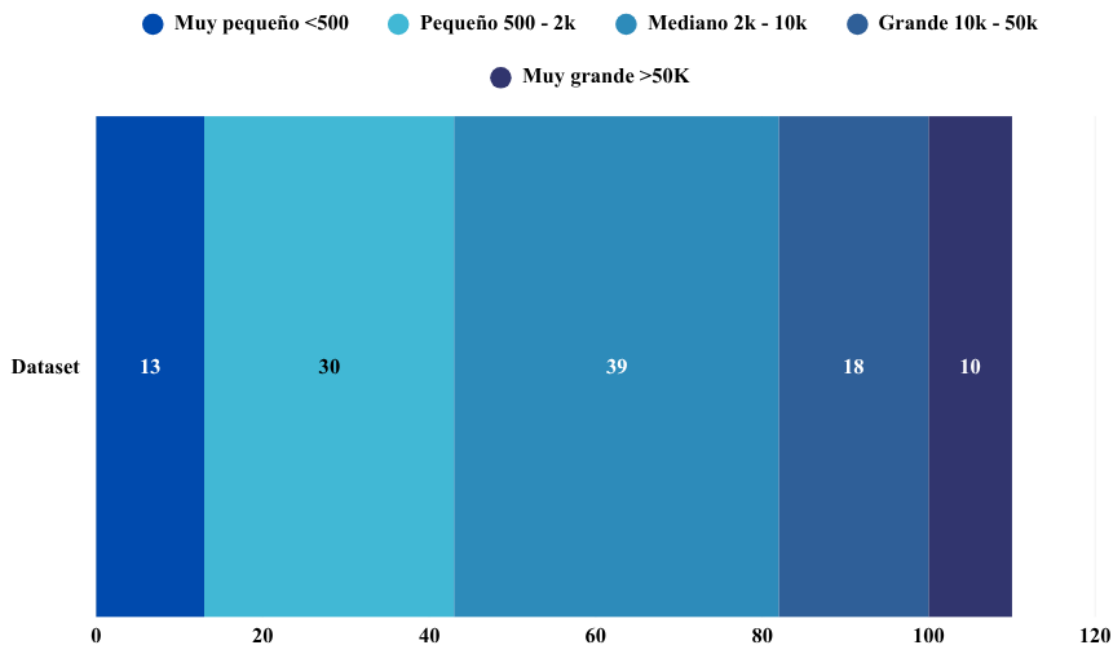
Los datasets públicos se concentran principalmente en el área de control de calidad y manufactura, donde existen *benchmarks* consolidados como NEU-DET para defectos en acero, MVTec para anomalías industriales generales, JPEGWELD para soldaduras y Severstal para superficies de acero. Estos *benchmarks* han permitido comparaciones sistemáticas entre modelos en esa área, algo que no existe de forma equivalente en ergonomía o logística.

En cuanto al tamaño del dataset, la Figura 15 muestra que la distribución es amplia. Esto tiene implicaciones directas sobre la capacidad de generalización de los modelos. Un dataset pequeño, es suficiente para demostrar el concepto en condiciones controladas, pero suele ser insuficiente para garantizar que el sistema funcione de forma robusta frente a la variabilidad real

de una línea de producción, donde las condiciones de iluminación, el estado de los equipos y la diversidad de los productos cambian continuamente.

Figura 15.

Clasificación del dataset por tamaño.



El tipo de dato dominante en la revisión es la imagen estática, utilizada en la mayoría de las aplicaciones de control de calidad. El video como tipo de dato exclusivo aparece en 32 artículos y está concentrado casi en su totalidad en el área de ergonomía y seguridad y salud en el trabajo, donde el riesgo radica en el movimiento y una imagen estática no captura la información necesaria para evaluar una postura dinámica o detectar un comportamiento inseguro en desarrollo.

5.4.6 Vacíos de investigación identificados

El campo GAP de la matriz de extracción registra las brechas del conocimiento que cada autor identifica como motivación para su estudio. Analizar estos vacíos de forma agregada permite construir un mapa de los problemas recurrentes que la comunidad científica reconoce

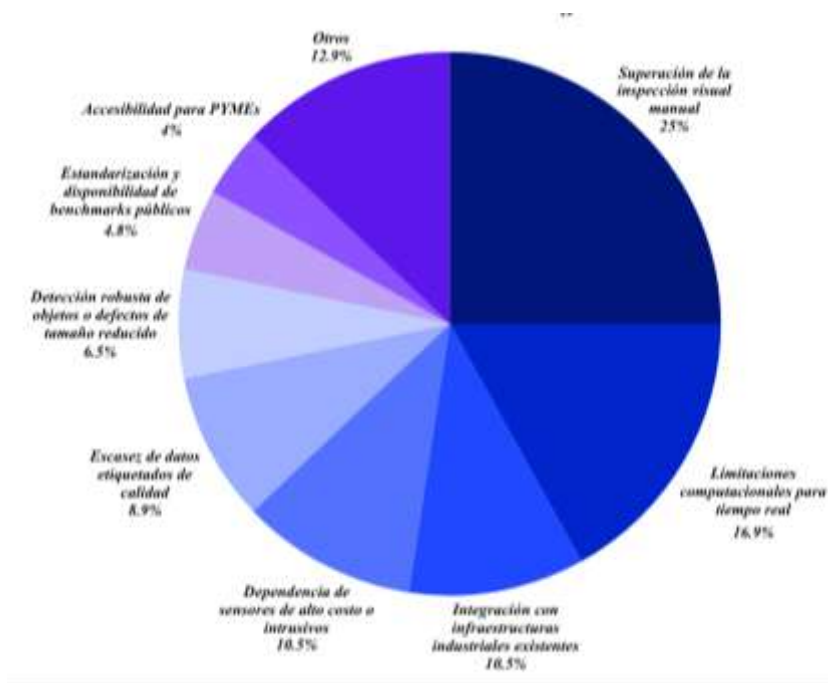
como prioritarios, y que en muchos casos siguen siendo las mismas limitaciones que se repiten de un estudio al siguiente.

Como se observa en la Figura 16, el vacío más recurrente, presente en aproximadamente el 25% de los estudios, es la necesidad de superar la inspección visual manual como estándar de referencia en la industria. Esta limitación ha dado origen a trabajos como el de Xu et al., (2025), en el que los autores reportan lograr una precisión del 97.9% en la detección de defectos de soldadura automatizada, mostrando sus ventajas respecto a la inspección tradicional.

Sin embargo, que este siga siendo el punto de partida de tantos estudios después de años de investigación en visión por computador indica que la adopción real de estas tecnologías en la industria es mucho más lenta que su desarrollo académico, y que una proporción importante de las empresas sigue dependiendo de inspectores humanos para tareas en las que la tecnología ya ofrece soluciones probadas en entornos de laboratorio (Mao et al., 2022).

Figura 16.

Distribución de vacíos de investigación



El segundo vacío más frecuente es la brecha entre la precisión demostrada experimentalmente y las restricciones reales de implementación en entornos industriales a escala. Varios estudios logran métricas de detección muy altas en sus datasets de prueba, pero al mismo tiempo reconocen que sus modelos requieren hardware costoso, tiempos de inferencia que no se ajustan a los ciclos de producción, o condiciones de iluminación controladas que no se pueden garantizar en planta (Huang et al., 2024). Este vacío es especialmente relevante porque sugiere que el problema no es únicamente técnico sino también económico y operativo, diseñar un sistema que funcione bien en laboratorio es distinto a diseñar uno que pueda implementarse de forma sostenible en una empresa real.

En el área de ergonomía y seguridad y salud en el trabajo, el vacío más reportado es la dependencia de sensores costosos como los sistemas de captura de movimiento (MoCap) y los dispositivos portables, que resultan inviables para uso continuo en entornos de trabajo reales. La visión por computador surge precisamente como alternativa no intrusiva a estos sistemas, pero los estudios revisados muestran que aún hay desafíos importantes en precisión y robustez que deben resolverse antes de que esta sustitución sea completa.

5.4.7 Método de validación y madurez tecnológica

Estas dos dimensiones se analizan de forma conjunta porque son complementarias, el método de validación describe el entorno en que se evaluó el sistema, mientras que la madurez tecnológica describe qué tan cerca está ese sistema de poder operarse de forma continua en una empresa real. Juntas, permiten responder la pregunta más importante desde la perspectiva de la ingeniería industrial: ¿qué tan implementables son realmente los sistemas propuestos en la literatura?

En cuanto al método de validación, el 50.8% de los artículos reporta haber realizado pruebas en entornos reales, incluyendo plantas industriales, almacenes, obras de construcción, campos agrícolas y minas. A primera vista este porcentaje podría interpretarse como una señal positiva de aplicabilidad. Sin embargo, al analizar en detalle las condiciones de esa validación, la imagen cambia. Muchos de los estudios que declaran validación en entorno real lo hacen en condiciones específicas y controladas dentro de ese entorno, un conjunto fijo de muestras capturadas con equipos de alta calidad, condiciones de iluminación estables, y tasas de producción que no representan la presión de una operación continua.

Solo 10 estudios de los 124 reportan de forma explícita que la validación se realizó en una línea de producción activa bajo condiciones reales de operación, con tasas de producción representativas y sin interrupciones del proceso. Un ejemplo de este nivel de validación es el trabajo de Frustaci et al. (2022), que implementó un sistema de inspección de convertidores catalíticos directamente en la celda de calidad de una línea de ensamblaje automotriz, operando en ciclos de producción reales.

En cuanto a la madurez tecnológica, un hallazgo relevante de la revisión es que el 48.4% de los artículos no reporta explícitamente ningún nivel de madurez tecnológica. Esta omisión sistemática no es un descuido menor: refleja una tendencia del campo académico a priorizar la demostración de precisión técnica (métricas como mAP o F1-score) por encima de la caracterización del estado real de desarrollo del sistema. En otras palabras, la comunidad científica se enfoca en demostrar que el modelo funciona bien, pero no en responder si ese modelo está listo para salir del laboratorio.

De los estudios que sí declaran su nivel de madurez, en la tabla 5 se presenta la distribución correspondiente.

Tabla 5.

Distribución de artículos por nivel de TRL.

Nivel TRL	Cantidad de estudios
TRL 1–3 (concepto y prueba en laboratorio)	18
TRL 4–6 (prototipo validado en entorno relevante)	34
TRL 7–9 (sistema validado y operativo en entorno real)	14
No reportado	58

Solo 14 estudios alcanzan niveles TRL 7–9, es decir, sistemas que han sido demostrados o están operando en condiciones reales de producción. Ejemplos de este nivel incluyen el sistema de inspección en línea de rodillos cónicos de Singh & Desai (2025), que opera en la línea de producción de una PYME automotriz, y el sistema de detección de defectos en filtros de cigarrillos de Huang et al. (2024), validado directamente en la línea de producción de una fábrica tabacalera con 20.000 imágenes propias y acelerado por hardware FPGA para cumplir con los tiempos de ciclo reales.

Esta concentración en niveles bajos y medios de madurez tiene implicaciones importantes para un ingeniero industrial que considere adoptar estas tecnologías. La mayoría de los sistemas reportados en la literatura no están listos para implementarse directamente, requieren adaptación al contexto específico de la empresa, construcción de un dataset propio, ajuste del hardware de captura, integración con los sistemas de control existentes y validación bajo las condiciones reales de operación. Este proceso puede ser costoso y técnicamente exigente, especialmente para empresas pequeñas o medianas que no cuentan con equipos de ingeniería especializados en visión por computador.

5.4.8 Limitaciones declaradas

El análisis de las limitaciones que los propios autores reconocen en sus estudios es quizás el campo más honesto de la matriz de extracción, porque revela no solo las barreras técnicas del campo sino también la distancia real entre lo que se logra en un entorno de investigación y lo que se necesita para una implementación industrial sostenible. Las cuatro limitaciones más frecuentes identificadas en la revisión son las siguientes.

5.4.8.1 Dataset de tamaño insuficiente y desbalance de clases. Esta es la limitación más recurrente y está presente en estudios de todas las áreas. Un dataset pequeño expone al modelo al riesgo de sobreajuste, el sistema aprende a reconocer los ejemplos del entrenamiento, pero no generaliza bien frente a datos nuevos, lo que en un entorno industrial se traduce en un sistema que funciona bien durante las pruebas pero falla en producción cuando aparecen variaciones que no estaban en el conjunto de entrenamiento.

El desbalance de clases agrava este problema, en la mayoría de las líneas de producción los productos defectuosos son una minoría, lo que hace que el modelo tenga muy pocos ejemplos de la clase que más importa detectar (Li et al., 2024). Algunos estudios abordan esto con técnicas de aumento de datos o generación sintética de imágenes, pero estas soluciones tienen límites cuando la variabilidad real del proceso es muy alta.

5.4.8.2 Sensibilidad a condiciones de iluminación. Esta limitación aparece en estudios de todas las áreas y representa una de las brechas más concretas entre el entorno de laboratorio y el entorno industrial real. Los modelos se entrenan bajo condiciones de iluminación controladas y su rendimiento cae de forma significativa cuando se enfrenta a sombras proyectadas por maquinaria, cambios de turno que alteran la luz natural, reflejos en superficies metálicas o variaciones en la temperatura de color de las lámparas industriales. Estudios como el de Çelik et

al. (2024) y Maślanka et al. (2025) mencionan explícitamente que esta sensibilidad fue uno de los principales obstáculos durante las pruebas en planta y que requirió ajustes al sistema de iluminación como parte de la implementación.

5.4.8.3 Oclusión de objetos y puntos clave. La oclusión es un problema especialmente frecuente en aplicaciones de estimación de pose corporal y detección de EPP, donde partes del cuerpo o del equipo de protección quedan parcialmente ocultas por herramientas, maquinaria u otros trabajadores. También aparece en aplicaciones de seguimiento de objetos en almacenes o líneas de ensamblaje con múltiples elementos superpuestos. Cuando el modelo no puede ver la región de interés completa, su capacidad de clasificación o estimación se degrada de forma considerable, lo que en una aplicación de seguridad podría generar falsas alarmas o, peor aún, no detectar un riesgo real.

5.4.8.4 Altos costos computacionales. Esta limitación conecta directamente con el análisis de madurez tecnológica. Varios estudios logran métricas de detección elevadas utilizando modelos de alta complejidad que requieren GPUs de alto rendimiento para operar en tiempo real. En un entorno de laboratorio esto no representa un problema, pero en una implementación industrial el costo del hardware necesario para ejecutar el modelo puede hacer inviable la solución desde el punto de vista económico, especialmente en PYMEs.

Estudios como el de Lim et al. (2024) identifican explícitamente que el rendimiento del modelo cae de forma significativa al ejecutarse en hardware de bajo costo, y proponen arquitecturas más ligeras como alternativa. La aceleración por FPGA, utilizada por Huang et al. (2024), es otra respuesta a este problema pero implica un nivel de especialización técnica que no está al alcance de todas las organizaciones.

5.5 Identificación de tendencias y vacíos

Los hallazgos de esta revisión no solo permiten describir el estado actual de la visión por computador en la ingeniería industrial, sino también identificar hacia dónde se dirige el campo y qué problemas estructurales siguen sin resolverse. Esta sección articula esas tendencias y vacíos dentro del marco de la Industria 4.0, entendida como el conjunto de tecnologías y principios que buscan integrar los sistemas físicos de producción con plataformas digitales inteligentes para crear fábricas más autónomas, conectadas y eficientes.

5.5.1. *La visión por computador como habilitador de la Industria 4.0*

Uno de los hallazgos transversales de esta revisión es que la visión por computador no opera de forma aislada en los estudios más avanzados, aparece integrada con otros componentes del ecosistema de la Industria 4.0. Sistemas como el de Gao et al. (2025) combinan detección visual con IoT y computación en la nube para construir plataformas de inspección distribuidas, mientras que Maślanka et al. (2025) integran cámaras inteligentes con PLCs mediante protocolos industriales estándar como EtherNet/IP, cerrando el ciclo entre la detección visual y la respuesta automatizada del proceso. Esta tendencia de integración es relevante porque indica que el valor real de la visión por computador en la industria no está solo en el modelo de detección, sino en su capacidad de conectarse con los sistemas de control, los datos de proceso y las plataformas de gestión existentes en la planta.

Sin embargo, esta integración también expone uno de los vacíos más importantes identificados en la revisión, la desconexión entre la visión por computador y la tecnología de gemelos digitales (*digital twins*). El gemelo digital es uno de los pilares conceptuales de la Industria 4.0, ya que permite crear una réplica virtual y dinámica de un sistema físico que se actualiza en tiempo real con datos del proceso.

La visión por computador es un insumo natural para alimentar ese gemelo digital con información visual del estado de los productos, los equipos y los trabajadores. Sin embargo, prácticamente ninguno de los 124 artículos revisados aborda esta integración de forma explícita. El trabajo de Cheng et al. (2025), que implementa monitoreo de almacén con cámaras de techo conectadas a una representación digital del espacio, es uno de los pocos que se acerca a este concepto, aunque sin desarrollarlo de forma completa. El trabajo de Truong et al. (2025) también menciona la posibilidad de integrar su sistema de monitoreo de soldadura con un gemelo digital, pero lo presenta como trabajo futuro. Esta desconexión entre dos tecnologías que deberían complementarse de forma natural representa una oportunidad de investigación clara y subutilizada.

5.5.2. La tendencia de micro-innovación sobre YOLO

Una de las tendencias metodológicas más claras de la revisión es el patrón de personalización incremental del modelo YOLO. Aproximadamente la mitad de los estudios que usan YOLO no lo implementan tal como está disponible, sino que identifican un módulo específico de la arquitectura que limita el rendimiento en su contexto particular y lo reemplazan con un mecanismo de atención u otro componente más adecuado. Wu et al. (2026) reemplazan el módulo de fusión de características por uno multiescala para mejorar la detección de defectos pequeños en acero. Wang et al. (2024) incorporan atención por coordenadas para mejorar la sensibilidad espacial en manufactura aditiva. Vijayakumar et al. (2024) integran BiFPN para mejorar la fusión de características en la detección de tabletas farmacéuticas.

Este patrón de micro-innovaciones tiene valor porque produce mejoras concretas y medibles en contextos específicos. Sin embargo, también plantea una pregunta sobre la acumulación real de conocimiento en el campo, cada estudio crea su propia variante de YOLO,

optimizada para un material, un tipo de defecto y unas condiciones de iluminación particulares, pero esa solución raramente se generaliza a otros contextos. El resultado es una difusión de modelos altamente especializados que son difíciles de comparar entre sí y que no necesariamente avanzan hacia soluciones más robustas y transferibles. Esto conecta directamente con el vacío de madurez tecnológica identificado en la sección 5.4.7, muchos estudios producen sistemas muy precisos en condiciones controladas, pero esa precisión no se traduce automáticamente en implementabilidad industrial.

5.5.3. El vacío de privacidad en aplicaciones de monitoreo de trabajadores

Un vacío que resulta llamativo por su ausencia más que por su presencia es el de la privacidad de datos. Solo dos artículos de los 124 revisados abordan explícitamente este tema: De Coninck et al. (2026), que propone un sistema de anonimización contextual para aplicaciones de ergonomía basada en visión, y un segundo estudio que menciona el marco GDPR como referencia. Esto es preocupante considerando que el 25% de los artículos de la revisión involucra sistemas que capturan video continuo de trabajadores en su entorno laboral, analizando su postura, sus movimientos y sus comportamientos en tiempo real.

En el contexto de la Industria 4.0, donde la recopilación masiva de datos de proceso es una práctica estándar, la extensión de esa lógica de datos hacia las personas que operan en la planta genera tensiones éticas y legales que la investigación académica no está abordando con la seriedad que merece. Regulaciones como el GDPR en Europa o la creciente normativa sobre el uso de inteligencia artificial en entornos laborales hacen que este no sea un tema opcional para una implementación real. Cualquier empresa que quiera adoptar un sistema de monitoreo visual de trabajadores necesita resolver estas preguntas antes de desplegar la tecnología, y la literatura científica ofrece muy poca orientación al respecto.

Una línea de trabajo prometedora en este sentido es el desarrollo de sistemas de visión que procesen los datos de forma anonimizada desde la captura, es decir, que el algoritmo opere directamente sobre representaciones distorsionadas o esquematizadas del cuerpo humano, como esqueletos articulares o siluetas binarizadas, en lugar de sobre el video original del trabajador. De esta manera el sistema puede realizar la evaluación ergonómica o detectar el comportamiento de riesgo sin que en ningún momento se almacene o transmita una imagen identificable de la persona.

5.5.4. La brecha de adopción en PYMEs y economías emergentes

Otro vacío transversal que emerge del análisis es la escasa atención que la investigación presta a las condiciones de implementación en pequeñas y medianas empresas. La mayoría de los estudios revisados se desarrollan en entornos con recursos tecnológicos y financieros significativos, laboratorios universitarios bien equipados, plantas de empresas grandes del sector automotriz o siderúrgico, o instalaciones de investigación aplicada en países con sectores manufactureros altamente automatizados. Como se identificó en el análisis bibliométrico, China y Estados Unidos concentran la mayor parte de la producción científica, lo que implica que los contextos industriales representados en la literatura no son necesariamente extrapolables a empresas medianas en economías en desarrollo.

Singh & Desai (2023) son uno de los pocos equipos que mencionan explícitamente las PYMEs como contexto de aplicación, señalando que la necesidad de grandes recursos computacionales y extensos datasets de entrenamiento es precisamente lo que dificulta el despliegue de soluciones de visión por computador en ese tipo de empresas. Este es un vacío relevante desde la perspectiva de la ingeniería industrial aplicada, si la tecnología solo es

accesible para grandes empresas con capacidad de inversión, su impacto en la transformación productiva de la industria en general será limitado.

Una dirección de investigación concreta para cerrar esta brecha es el desarrollo de modelos ligeros y de bajo costo computacional, diseñados desde el inicio para operar en hardware accesible como microcontroladores industriales o cámaras inteligentes de gama media, sin necesidad de GPUs dedicadas. Arquitecturas como TinyML o modelos basados en redes neuronales cuantizadas apuntan en esa dirección, y algunos estudios como el de Fernandes et al. (2025), que implementa un sensor de visión TinyML para estimar el nivel de ocupación de contenedores en un almacén, demuestran que es posible obtener resultados útiles con recursos computacionales mínimos.

5.5.5. Líneas de acción sugeridas

En la tabla 6 se encuentran las líneas de acción propuestas a futuro, respecto a los vacíos y tendencias identificadas.

Tabla 6.

Líneas de acción

Tendencia identificada	Posibles líneas futuras
La visión por computador como habilitador de la Industria 4.0	<ul style="list-style-type: none"> • Diseñar una arquitectura de un sistema que conecte un modelo de detección de defectos a un gemelo digital para análisis de errores en una línea de producción en tiempo real. • Diseñar sistemas que conecten la detección de objetos de visión por computador con gestión de inventarios en tiempo real, realizando la conexión con el ERP.

	<ul style="list-style-type: none"> • Diseñar sistemas que conecten el seguimiento de trayectorias de los modelos visión por computador con el monitoreo de salud y seguridad en el trabajo.
Micro-innovación sobre YOLO	<ul style="list-style-type: none"> • Construir un benchmark industrial, con imágenes de diferentes fuentes, para poder evaluar las micro innovaciones del YOLO y poder comparar en las mismas métricas su replicabilidad en diferentes configuraciones.
Privacidad en aplicaciones de monitoreo de trabajadores	<ul style="list-style-type: none"> • Métodos de procesamiento de imágenes y videos, sobre hardware sin almacenamiento de la captura. • Modelos de visión por computador basados en capturas anónimas o codificadas, que no permitan identificar al sujeto.
La brecha de adopción en PYMEs	<ul style="list-style-type: none"> • Modelos basados en arquitecturas sencillas (TinyML o redes convolucionales ligeras) que puedan ser ejecutadas en hardware no especializado. • Una metodología que permita estandarizar el proceso de ajuste de modelos open-source pre entrenados, que podrían ser utilizadas en algunos contextos específicos de empresas pequeñas. • Diseño de rutas de adopción por etapas, que sean factibles con la estructura de una empresa tipo Pymeas.

5.5.6. Síntesis

En resumen, los vacíos y tendencias identificados en esta revisión llevan a una conclusión clara: el campo de la visión por computador en la ingeniería industrial ha avanzado de forma técnica y rápida, pero aún enfrenta desafíos estructurales. La integración con el ecosistema

digital de la Industria 4.0, la privacidad de los trabajadores, la adaptación a entornos con recursos limitados y la creación de soluciones realmente implementables son áreas donde la investigación futura tiene mucho por hacer. Superar estas brechas es solo un reto tecnológico y organizacional, que la academia y la industria deben abordar.

6. Conclusiones

Esta revisión sistemática analizó 124 artículos científicos publicados entre 2021 y 2025 sobre la aplicación de la visión por computador en la ingeniería industrial, siguiendo la metodología PRISMA. Los resultados permiten extraer las siguientes conclusiones, alineadas con los objetivos del trabajo.

En áreas como la manufactura y el control de calidad, se pudo observar que la literatura ha alcanzado un nivel de madurez significativo, lo que se puede evidenciar en el establecimiento de métricas y de conjuntos de datos públicos utilizados para tareas de detección automatizada de defectos. Esto se puede atribuir a que la inspección manual de productos es una necesidad compartida por las diferentes industrias. Este estado de la literatura implica que, a futuro, la investigación en esta área se debería concentrar en la transferencia de esa tecnología a entornos industriales reales.

Así mismo, en áreas como la seguridad y salud en el trabajo, se puede ver una implementación de los modelos para otras tareas específicas como el monitoreo de uso de elementos de protección personal y la identificación de posturas riesgosas desde un punto de vista ergonómico. Estas implementaciones requieren un nivel de madurez mayor, al pasar de detecciones puntuales a monitoreo continuo.

Por otra parte, en áreas como la logística, el área con menos representación en la muestra de artículos analizados, se puede ver un estado incipiente de soluciones basados en visión por computador. Eso se puede atribuir a la complejidad estructural de los problemas relacionados a esta área, ya que aplicar visión a monitoreo de inventarios, almacenes o despachos, requieren una planeación y un análisis más profundo de la cadena de suministro a la que se este aplicando. Por lo tanto, a futuro se podrían enfocar en la implementación de soluciones en esta área, pero considerando la integración a los sistemas existentes.

Cabe resaltar que un elemento metodológico sobresaliente de este estudio fue la implementación predominante de modelos YOLO para las tareas de visión por computador. El uso de este modelo, diseñado para la localización de objetos, implica una necesidad de pasar de modelos tradicionales, donde la tarea se enfocaba en clasificar un objeto (si tiene falla o no), a tareas de mayor complejidad donde se debe identificar una característica puntual de ese objeto (en donde está la falla y de que naturaleza es). Además, su adaptabilidad a diferentes objetos permite ser usado tanto en áreas de calidad para analizar productos, como en logística para trayectorias, o en seguridad y salud en el trabajo para caracterizar personas.

Otro elemento para considerar es el bajo nivel de madurez tecnológica reportado en los estudios, considerando la omisión de esta información por parte de los autores. De los estudios en la muestra que reportaban ese nivel, se pudo observar que muy pocos artículos alcanzan un nivel de aplicación industrial en sus investigaciones. Esta limitante es coherente a la dificultad de alcanzar un modelo usable en entornos reales, considerando que muchas limitaciones reportadas son la falta de generalización de los modelos a condiciones del entorno. Este factor indica una necesidad por mejorar los procesos de transferencia tecnológica, para poder pasar de prototipos de laboratorio a soluciones que puedan ser utilizados en entornos reales.

Finalmente, se identificaron vacíos de investigación estructurales que el campo no ha abordado con suficiente profundidad, la desconexión con la tecnología de gemelos digitales a pesar de ser ambos pilares de la Industria 4.0, la escasa atención a la privacidad de los trabajadores en sistemas de monitoreo visual, y la falta de soluciones diseñadas para contextos con recursos limitados como las PYMEs. Estos vacíos representan las oportunidades de desarrollo más claras para la investigación futura en el área.

7. Recomendaciones

Con base en los hallazgos de esta revisión, se presentan recomendaciones para dos grupos principales: los investigadores que trabajan en visión por computador aplicada a la ingeniería industrial y las universidades que forman ingenieros industriales.

A los investigadores se les recomienda informar claramente el nivel TRL alcanzado en cada estudio. Omitir este dato, como ocurrió en el 48.4% de los artículos revisados, dificulta que la comunidad científica conozca el verdadero estado de implementación del campo y complica la comparación entre soluciones. También se sugiere enfocar más esfuerzos en validar las soluciones en condiciones industriales reales, con tasas de producción y variabilidad propias del entorno. Los resultados de laboratorio son útiles como punto de partida, pero no bastan para demostrar la viabilidad de una solución.

También se recomienda investigar métodos de entrenamiento que reduzcan la necesidad de grandes conjuntos de datos etiquetados, como el aprendizaje con pocos ejemplos o la detección de anomalías no supervisada. Esto haría las soluciones más accesibles en contextos con pocos recursos de datos. Además, es importante avanzar en la integración de la visión por

computador con gemelos digitales y plataformas IIoT, para cerrar la brecha entre tecnologías complementarias en la Industria 4.0.

En el monitoreo de trabajadores, se aconseja priorizar sistemas que usen representaciones anonimizadas del cuerpo humano, como esqueletos articulares, en vez de video identificable. Esto ayuda a cumplir con las normas de privacidad y facilita la adopción en entornos laborales reales.

A las universidades que forman ingenieros industriales se les recomienda incluir en sus programas contenidos prácticos sobre visión por computador y aprendizaje automático aplicado a procesos industriales. No se trata de enseñar a desarrollar modelos, sino de formar en criterios de selección, evaluación de madurez y gestión de implementación, que son habilidades clave para liderar estos proyectos en empresas. Además, es importante fortalecer la formación en gestión de datos industriales, ya que crear y mantener datasets de calidad es una de las principales barreras para implementar estas tecnologías, y los ingenieros industriales están bien preparados para asumir este reto.

Por último, se sugiere impulsar proyectos de investigación aplicada en colaboración con PYMEs locales, ya que en estos casos la brecha de adopción es mayor y el apoyo técnico de la universidad puede generar un impacto significativo.

Referencias bibliográficas

- Addula, S. R., & Tyagi, A. K. (2025). Future of Computer Vision and Industrial Robotics in Smart Manufacturing. En A. K. Tyagi, S. Tiwari, S. K. Arumugam, & A. K. Sharma (Eds.), *Artificial Intelligence-Enabled Digital Twin for Smart Manufacturing* (pp. 505-539). Wiley.
<https://doi.org/10.1002/9781394303601.ch22>
- Agrawal, P., Bose, R., Gupta, G. K., Kaur, G., Paliwal, S., & Raut, A. (2024). Advancements in Computer Vision: A Comprehensive Review. *Int. Conf. Innov. Challenges Emerg. Technol., ICICET*. 2024 International Conference on Innovations and Challenges in Emerging Technologies, ICICET 2024. <https://doi.org/10.1109/ICICET59348.2024.10616321>
- Ahmed, I., Alkahtani, M., Khalid, Q. S., & Alqahtani, F. M. (2024). Improved Commodity Supply Chain Performance Through AI and Computer Vision Techniques. *IEEE Access*, *12*, 24116-24132. <https://doi.org/10.1109/ACCESS.2024.3361756>
- Alenjareghi, M. J., Keivanpour, S., Chinniah, Y. A., & Jocelyn, S. (2025). Computer vision-enabled real-time job hazard analysis for safe human–robot collaboration in disassembly tasks. *Journal of Intelligent Manufacturing*, *36*(8), 5563-5591. <https://doi.org/10.1007/s10845-024-02519-8>
- Alexopoulos, K., Catti, P., Kanellopoulos, G., Nikolakis, N., Blatsiotis, A., Christodoulopoulos, K., Kaimenopoulos, A., & Ziata, E. (2023). Deep Learning for Estimating the Fill-Level of Industrial Waste Containers of Metal Scrap: A Case Study of a Copper Tube Plant. *Applied Sciences*, *13*(4), 2575. <https://doi.org/10.3390/app13042575>
- Ali, S. H., & Aygun, H. (2022). Air-Drawing. *Int. Informatics Softw. Eng. Conf., IISEC*. 3rd International Informatics and Software Engineering Conference, IISEC 2022.
<https://doi.org/10.1109/IISEC56263.2022.9998215>

- Ali, M. L., & Zhang, Z. (2024). The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. *Computers, 13*(12), 336.
<https://doi.org/10.3390/computers13120336>
- Anand, S., Raja, R. G., & Sheela, T. (2023). An overview of AI platforms, frameworks, libraries, and processes. En P. Raj, U. Köse, U. Sakthivel, S. Nagarajan, & V. S. Asirvadam (Eds.), *Explainable Artificial Intelligence (XAI): Concepts, enabling tools, technologies and applications* (pp. 93-113). Institution of Engineering and Technology.
- Ari, P. D., Akkoyun, F., & Ercetin, A. (2025). A Machine Vision System for Gear Defect Detection. *Processes, 13*(6), 1727. <https://doi.org/10.3390/pr13061727>
- Arunima, P. L., Gopinath, P. P., Geetha Lekshmi, P. R., & Esakkimuthu, M. (2024). Digital assessment of post-harvest Nendran banana for faster grading: CNN-based ripeness classification model. *Postharvest Biology and Technology, 214*, 112972.
<https://doi.org/10.1016/j.postharvbio.2024.112972>
- Benharkat, N. E. H., Bentaalla Kaced, S., Chakhrit, A., & Chergui, A. (2026). Automatic real-time ergonomic posture assessment using digital models: A case study of manual handling tasks. *The International Journal of Advanced Manufacturing Technology, 142*(1-2), 963-980.
<https://doi.org/10.1007/s00170-025-17232-w>
- Bimrose, M. V., Hu, T., McGregor, D. J., Wang, J., Tawfick, S., Shao, C., Liu, Z., & King, W. P. (2024). Automatic detection of hidden defects and qualification of additively manufactured parts using X-ray computed tomography and computer vision. *Manufacturing Letters, 41*, 1216-1224.
<https://doi.org/10.1016/j.mfglet.2024.09.147>

- Çelik, M. T., Arslankaya, S., & Yildiz, A. (2024). Real-time detection of plastic part surface defects using deep learning- based object detection model. *Measurement*, *235*, 114975.
<https://doi.org/10.1016/j.measurement.2024.114975>
- Chen, H., Liu, P., Zhou, G., Lu, M.-L., & Yu, D. (2025). Computer vision and tactile glove: A multimodal model in lifting task risk assessment. *Applied Ergonomics*, *127*, 104513.
<https://doi.org/10.1016/j.apergo.2025.104513>
- Chen, H.-C., Lin, S.-H., Liau, B.-Y., Yang, P., Chen, K.-H., & Wang, Y.-C. (2025). Sensor-integrated Machine Vision System for Enhanced Defect Detection in Industrial Applications. *Sensors and Materials*, *37*(12), 5439. <https://doi.org/10.18494/SAM5700>
- Chen, S., Dong, F., & Demachi, K. (2023). Hybrid visual information analysis for on-site occupational hazards identification: A case study on stairway safety. *Safety Science*, *159*, 106043. <https://doi.org/10.1016/j.ssci.2022.106043>
- Chen, W., Gu, D., & Ke, J. (2024). Real-time ergonomic risk assessment in construction using a co-learning-powered 3D human pose estimation model. *Computer-Aided Civil and Infrastructure Engineering*, *39*(9), 1337-1353. <https://doi.org/10.1111/mice.13139>
- Chen, X., Yu, Y., & Li, Z. (2025). A vision-based approach to assessing worker ergonomics in low-light construction environments. *Advanced Engineering Informatics*, *66*, 103463.
<https://doi.org/10.1016/j.aei.2025.103463>
- Cheng, J., Verhulst, C., De Clercq, P., Van De Velde, S., Sagaert, S., Mertens, M., Birem, M., Deshmukh, M., Broekx, N., Rademakers, E., Bey-Temsamani, A., & Blanquart, J.-E. (2025). Real-Time Warehouse Monitoring with Ceiling Cameras and Digital Twin for Asset Tracking and Scene Analysis. *Logistics*, *9*(4), 153. <https://doi.org/10.3390/logistics9040153>

- Cruciata, L., Contino, S., Ciccarelli, M., Pirrone, R., Mostarda, L., Papetti, A., & Piangerelli, M. (2025). Lightweight Vision Transformer for Frame-Level Ergonomic Posture Classification in Industrial Workflows. *Sensors*, 25(15), 4750. <https://doi.org/10.3390/s25154750>
- Cui, H., Seyam, A., & Shamey, R. (2025). Textile and colour defect detection using deep learning methods. *Coloration Technology*, cote.70044. <https://doi.org/10.1111/cote.70044>
- David, J., Garzinová, R., Barčák, T., Slácala, J., & Shmeleva, N. (2019). Digitization of embossed numbers on continuous steel casting billets. *METAL - Int. Conf. Metall. Mater., Conf. Proc.*, 1892-1897.
- De Coninck, S., Gamba, E., Van Doninck, B., Bey-Temsamani, A., Cardoen, T., Leroux, S., & Simoens, P. (2026). Securing workers and workspaces: Contextual privacy for vision-based ergonomics. *Computer Vision and Image Understanding*, 265, 104675. <https://doi.org/10.1016/j.cviu.2026.104675>
- De Ketelaere, B., Wouters, N., Kalfas, I., Van Belleghem, R., & Saeys, W. (2022). A fresh look at computer vision for industrial quality control. *Quality Engineering*, 34(1), 152-158. <https://doi.org/10.1080/08982112.2021.2001828>
- De Simone, G., Saggese, A., Foggia, P., & Vento, M. (2026). Deep learning based empty shelf detection based on autonomous mobile robot. *Computer Vision and Image Understanding*, 265, 104697. <https://doi.org/10.1016/j.cviu.2026.104697>
- DeKeyrel, K. (2025). Improve visual inspections with AI and edge computing. *Control Engineering*, 72(1), 28-29.
- Deng, H., Ou, Z., & Deng, Y. (2021). Multi-Angle Fusion-Based Safety Status Analysis of Construction Workers. *International Journal of Environmental Research and Public Health*, 18(22), 11815. <https://doi.org/10.3390/ijerph182211815>

- Di Rienzo, F., Miglionico, G. C., Ducange, P., Marcelloni, F., Salti, N., & Vallati, C. (2025). Improving Accuracy in Industrial Safety Monitoring: Combine UWB Localization and AI-Based Image Analysis. *Journal of Sensor and Actuator Networks*, 14(6), 118.
<https://doi.org/10.3390/jsan14060118>
- Ding, C., Wang, D., Feng, Z., Li, W., & Cui, D. (2021). Integration of vibration and optical techniques for watermelon firmness assessment. *Computers and Electronics in Agriculture*, 187, 106307. <https://doi.org/10.1016/j.compag.2021.106307>
- Dong, P., Wang, Y., Yu, Q., Feng, W., & Zong, G. (2024). AMC-YOLO: Improved YOLOv8-based defect detection for cigarette packs. *IET Image Processing*, 18(14), 4873-4886.
<https://doi.org/10.1049/ipr2.13272>
- Driouache, Y., Milpied, J., & Motamedi, A. (2024). Vision-based method to identify materials transported by dump trucks. *Engineering Applications of Artificial Intelligence*, 135, 108768.
<https://doi.org/10.1016/j.engappai.2024.108768>
- Dubis, D., Chochół, A., Betlej, I., Boruszewski, P., & Borysiuk, P. (2024). Vision Inspection Method for the Quality Assessment of Paint Coatings on Glassware. *Materials*, 17(18), 4566.
<https://doi.org/10.3390/ma17184566>
- Ellinger, A., Woerner, C., & Scherer, R. (2022). Automatic Segmentation of Bulk Material Heaps Using Color, Texture, and Topography from Aerial Data and Deep Learning-Based Computer Vision. *Remote Sensing*, 15(1), 211. <https://doi.org/10.3390/rs15010211>
- Esfandiari Fard, S., Ghosh, T., & Sazonov, E. (2025). Multi-Task NoisyViT for Enhanced Fruit and Vegetable Freshness Detection and Type Classification. *Sensors*, 25(19), 5955.
<https://doi.org/10.3390/s25195955>

Evaluación del uso de Machine Learning para la Calidad en la Producción de Acero: Revisión

Sistemática | Ciencias e Ingeniería. (s. f.). Recuperado 6 de noviembre de 2025, de

<https://ctscafe.pe/index.php/cienciaingenieria/article/view/422>

Fan, C., Mei, Q., & Li, X. (2024). 3D pose estimation dataset and deep learning-based ergonomic risk assessment in construction. *Automation in Construction, 164*, 105452.

<https://doi.org/10.1016/j.autcon.2024.105452>

Fernandes, R. D. A., Bragança, H., Cavalcante, W., Gomes, R. C. S., Nellessen, P. H., Camelo, L., & Torné, I. (2025). Bin Occupancy Estimation in Warehouses With a TinyML Vision Sensor. *IEEE Sensors Letters, 9*(8), 1-4. <https://doi.org/10.1109/LSENS.2025.3592171>

Firdiantika, I. M., Lee, S., Bhattacharyya, C., Jang, Y., & Kim, S. (2024). EGCY-Net: An ELAN and GhostConv-Based YOLO Network for Stacked Packages in Logistic Systems. *Applied Sciences, 14*(7), 2763. <https://doi.org/10.3390/app14072763>

Forero-Corba, W., & Negre Bennasar, F. (2023). Técnicas y aplicaciones del Machine Learning e Inteligencia Artificial en educación: Una revisión sistemática. *RIED-Revista Iberoamericana de Educación a Distancia, 27*(1), 209-253. <https://doi.org/10.5944/ried.27.1.37491>

Frustaci, F., Spagnolo, F., Perri, S., Cocorullo, G., & Corsonello, P. (2022). Robust and High-Performance Machine Vision System for Automatic Quality Inspection in Assembly Processes. *Sensors, 22*(8), 2839. <https://doi.org/10.3390/s22082839>

Fu, H., Wang, Y., Shu, X., Chen, X., & Lin, K. (2022). A Machine Vision-Based Method for Detecting Surface Hollow Defect of Hot-State Shaft in Cross Wedge Rolling. *Metals, 12*(11), 1938. <https://doi.org/10.3390/met12111938>

- Gao, P., Liu, F., Sun, X., Wang, F., & Li, J. (2021). Rapid non-contact visual measurement method for key dimensions of revolving workpieces. *International Journal of Metrology and Quality Engineering*, 12, 10. <https://doi.org/10.1051/ijmqe/2021008>
- Gao, T., Zhang, X., Xia, Z., & Zhang, H. (2025). Optimization of Industrial Quality Inspection Systems in Computer Vision: Integration of Deep Learning and IoT Technologies. *Journal of Organizational and End User Computing*, 37(1), 1-33. <https://doi.org/10.4018/JOEUC.395859>
- Gao, Y., Zhang, Z., Zhu, X., & Ding, S. (2025). Research Progress on the Integration of Robot Vision, Computer Vision and Machine Learning: Technological Evolution, Challenges and Industrial Applications. *International Journal of Current Research in Science, Engineering & Technology*, 8(1), 257-262. <https://doi.org/10.30967/IJCRSET/Yujie-Gao/174>
- Gomez, C., Chessa, S., Fleury, A., Roussos, G., & Preuveneers, D. (2019). Internet of Things for enabling smart environments: A technology-centric perspective. *Journal of Ambient Intelligence and Smart Environments*, 11(1), 23-43. <https://doi.org/10.3233/AIS-180509>
- Guo, Y., Zeng, Y., Gao, F., Qiu, Y., Zhou, X., Zhong, L., & Zhan, C. (2022). Improved YOLOV4-CSP Algorithm for Detection of Bamboo Surface Sliver Defects With Extreme Aspect Ratio. *IEEE Access*, 10, 29810-29820. <https://doi.org/10.1109/ACCESS.2022.3152552>
- Hakala, J., & Häkkinen, J. (2022). A Method for Measuring Contact Points in Human–Object Interaction Utilizing Infrared Cameras. *Frontiers in Robotics and AI*, 8, 800131. <https://doi.org/10.3389/frobt.2021.800131>
- Han, S., Zhang, Z., Liu, J., Han, X., Wang, T., & Che, H. (2026). Detection Method of Safety Wear Based on Multi-Anchor Box Detection and Multimodal Fusion Hierarchical Sample Matching Mechanism. *IEEE Access*, 14, 2374-2390. <https://doi.org/10.1109/ACCESS.2025.3648771>

- He, S., Wang, Y., & Liu, H. (2022). Image Information Recognition and Classification of Warehoused Goods in Intelligent Logistics Based on Machine Vision Technology. *Traitement Du Signal*, 39(4), 1275-1282. <https://doi.org/10.18280/ts.390420>
- Herve, Q., Ipek, N., Verwaeren, J., & De Beer, T. (2024). Automated particle inspection of continuously freeze-dried products using computer vision. *International Journal of Pharmaceutics*, 664, 124629. <https://doi.org/10.1016/j.ijpharm.2024.124629>
- Ho Chi Minh City University of Technology, VNU-HCM, Vietnam, Do, H.-T., & Pham, V.-C. (2021). Deep Learning Based Goods Management in Supermarkets. *Journal of Advances in Information Technology*, 12(2), 164-168. <https://doi.org/10.12720/jait.12.2.164-168>
- Honggang, H., Lawal, O. M., Tan, Y., & Cheng, K. (2025). An anchor-based YOLO fruit detector developed on YOLOv5. *PLOS One*, 20(9), e0331012. <https://doi.org/10.1371/journal.pone.0331012>
- Hsu, G.-S. J., Wu, J. S., Huang, Y.-K. D., Chiu, C.-C., & Kang, J.-H. (2025). Automatic Detect Incorrect Lifting Posture with the Pose Estimation Model. *Life*, 15(3), 358. <https://doi.org/10.3390/life15030358>
- Hu, S., Lu, Z., Xu, X., Deng, R., Du, X., & Duan, Q. (2025). LAECIPS: Large Vision Model Assisted Adaptive Edge-Cloud Collaboration for IoT-based Embodied Intelligence System (arXiv:2404.10498). arXiv. <https://doi.org/10.48550/arXiv.2404.10498>
- Huang, L., Shen, Q., Jiang, C., & Yang, Y. (2024). Deep Neural Network-Based Cigarette Filter Defect Detection System with FPGA Acceleration for Online Recognition. *Sensors*, 24(20), 6752. <https://doi.org/10.3390/s24206752>

IIEE Transactions on Occupational Ergonomics and Human Factors. (2017). *IIEE Transactions on Occupational Ergonomics and Human Factors*, 5(3-4), ebi-ebi.

<https://doi.org/10.1080/24725838.2017.1411103>

Imam, M., Baïna, K., Tabii, Y., Ressami, E. M., Adlaoui, Y., Boufousse, S., Benzakour, I., & Abdelwahed, E. H. (2025). Integrating real-time pose estimation and PPE detection with cutting-edge deep learning for enhanced safety and rescue operations in the mining industry.

Neurocomputing, 618, 129080. <https://doi.org/10.1016/j.neucom.2024.129080>

International Journal of Computer Integrated Manufacturing. (2003). *International Journal of Computer Integrated Manufacturing*, 16(3), 229-229.

<https://doi.org/10.1080/0951192031000075962>

Işıkdağ, Ü., Çemrek, H. A., Sönmez, S., Aydın, Y., Bekdaş, G., & Geem, Z. W. (2025). A Real-Time Advisory Tool for Supporting the Use of Helmets in Construction Sites. *Information*, 16(10),

824. <https://doi.org/10.3390/info16100824>

Jamali, P. V., Nambi, E., M, L., Saravanan, S., & V, C. (2025). Rice-YOLO: An Automated Insect Monitoring in Rice Storage Warehouses with the Deep Learning Model. *ACS Agricultural Science & Technology*, 5(2), 206-221. <https://doi.org/10.1021/acsagscitech.4c00633>

Ji, J., Pannakkong, W., & Buddhakulsomsiri, J. (2023). A Computer Vision-Based System for Metal Sheet Pick Counting. *Computers, Materials & Continua*, 75(2), 3643-3656.

<https://doi.org/10.32604/cmc.2023.037507>

Jia, L., Yuan, X., Chen, Z., Wang, T., Gao, L., Gu, G., Wang, X., & Wang, Y. (2025). TSE-YOLO: A Model for Tomato Ripeness Segmentation. *Agriculture*, 16(1), 8.

<https://doi.org/10.3390/agriculture16010008>

- Kiliç, K., Kiliç, K., Doğru, İ. A., & Özcan, U. (2024). Using Deep Learning Techniques for Anomaly Detection of Wood Surface. *Drvna Industrija*, 75(3), 275-286.
<https://doi.org/10.5552/drvind.2024.0114>
- Kim, H., Jung, W.-K., Park, Y.-C., Lee, J.-W., & Ahn, S.-H. (2022). Broken stitch detection method for sewing operation using CNN feature map and image-processing techniques. *Expert Systems with Applications*, 188, 116014. <https://doi.org/10.1016/j.eswa.2021.116014>
- Kingsly, S. R., & Archana, T. (2024). Understanding AI and Machine Learning Concepts. En R. Masengu, C. Tsikada, & J. Garwi (Eds.), *AI and Machine Learning Applications in Supply Chains and Marketing* (pp. 371-391). IGI Global. <https://doi.org/10.4018/979-8-3693-6760-5.ch0015>
- Kumar, A., & Agrawal, S. (2024). A quality-based sustainable supply chain architecture for perishable products using image processing in the era of industry 4.0. *Journal of Cleaner Production*, 450, 141910. <https://doi.org/10.1016/j.jclepro.2024.141910>
- Kusnadi, A., Tobing, F. A. T., Winantyo, R., Haryanto, S., Nathania, L., & Tanveer, M. (s. f.). *Beef Freshness Classification Using CNN with DCT and GLCM Feature Extraction*.
- Lee, C., Kim, Y., & Kim, H. (2024). Computer-Vision-Based Product Quality Inspection and Novel Counting System. *Applied System Innovation*, 7(6), 127. <https://doi.org/10.3390/asi7060127>
- Lee, Y., Yun, J., Lee, S., & Lee, C. (2024). Image Data-Centric Visual Feature Selection on Roll-to-Roll Slot-Die Coating Systems for Edge Wave Coating Defect Detection. *Polymers*, 16(8), 1156. <https://doi.org/10.3390/polym16081156>
- Lema, D. G., Usamentiaga, R., & García, D. F. (2023). Low-cost system for real-time verification of personal protective equipment in industrial facilities using edge computing devices. *Journal of Real-Time Image Processing*, 20(6), 111. <https://doi.org/10.1007/s11554-023-01368-7>

- Li, H., Yue, X., Wang, Z., Wang, W., Tomiyama, H., & Meng, L. (2021). A survey of Convolutional Neural Networks—From software to hardware and the applications in measurement. *Measurement: Sensors*, *18*, 100080. <https://doi.org/10.1016/j.measen.2021.100080>
- Li, X., Xue, S., Li, Z., Fang, X., Zhu, T., & Ni, C. (2024). A Candy Defect Detection Method Based on StyleGAN2 and Improved YOLOv7 for Imbalanced Data. *Foods*, *13*(20), 3343. <https://doi.org/10.3390/foods13203343>
- Liang, L., & Chen, J. (2025). VST-YOLOv8: A Trustworthy and Secure Defect Detection Framework for Industrial Gaskets. *Electronics*, *14*(19), 3760. <https://doi.org/10.3390/electronics14193760>
- Liao, Q., Gardner, B., Barlow, R., McMillan, K., Moore, S., Fitzgerald, A., Arzhaeva, Y., Botwright, N., Wang, D., & Nelis, J. L. (2025). Improving traceability and quality control in the red-meat industry through computer vision-driven physical meat feature tracking. *Food Chemistry*, *480*, 143830. <https://doi.org/10.1016/j.foodchem.2025.143830>
- Lim, S., Ham, U.-H., & Han, S.-M. (2024). Implementation of Integrated Development Environment for Machine Vision-Based IEC 61131-3. *Computers*, *13*(7), 172. <https://doi.org/10.3390/computers13070172>
- Lin, H., Cai, D., Xu, Z., Wu, J., Sun, L., & Jia, H. (2024). Fabric4show: Real-time vision system for fabric defect detection and post-processing. *Visual Intelligence*, *2*(1), 13. <https://doi.org/10.1007/s44267-024-00047-w>
- Liu, B., Gao, F., & Li, Y. (2023). Cost-Sensitive YOLOv5 for Detecting Surface Defects of Industrial Products. *Sensors*, *23*(5), 2610. <https://doi.org/10.3390/s23052610>
- Liu, C., Lin, W., Feng, Y., Guo, Z., & Xie, Z. (2023). ATC-YOLOv5: Fruit Appearance Quality Classification Algorithm Based on the Improved YOLOv5 Model for Passion Fruits. *Mathematics*, *11*(16), 3615. <https://doi.org/10.3390/math11163615>

- Lončarević, Z., Reberšek, S., Šela, S., Skvarč, J., Ude, A., & Gams, A. (2024). Adaptive Visual Quality Inspection Based on Defect Prediction From Production Parameters. *IEEE Access*, *12*, 93899-93910. <https://doi.org/10.1109/ACCESS.2024.3424664>
- Lu, G., Qian, W., Xiong, X., Lu, D., & Fu, S. (2025). YOLOv7-Driven Visual Inspection System for Edge Banding Defects in Panel Furniture. *Drvna Industrija*, *76*(4), 407-418. <https://doi.org/10.5552/drvind.2025.0262>
- Lu, J., Chen, W., Lan, Y., Qiu, X., Huang, J., & Luo, H. (2024). Design of citrus peel defect and fruit morphology detection method based on machine vision. *Computers and Electronics in Agriculture*, *219*, 108721. <https://doi.org/10.1016/j.compag.2024.108721>
- Luarn, P., & Su, W.-C. (2025). Color recognition-based computer vision technology refines traditional manufacturing factory processes. *Measurement Science and Technology*, *36*(4), 046007. <https://doi.org/10.1088/1361-6501/adc1fa>
- Luo, X., Sun, Q., Yang, T., He, K., & Tang, X. (2023). Nondestructive determination of common indicators of beef for freshness assessment using airflow-three dimensional (3D) machine vision technique and machine learning. *Journal of Food Engineering*, *340*, 111305. <https://doi.org/10.1016/j.jfoodeng.2022.111305>
- Mao, C., & Ma, W. (2022). An Automatic Detection and Online Quality Inspection Method for Workpiece Surface Cracks based on Machine Vision. *International Journal of Circuits, Systems and Signal Processing*, *16*, 141-150. <https://doi.org/10.46300/9106.2022.16.18>
- Mao, M., Lee, A., & Hong, M. (2024). Efficient Fabric Classification and Object Detection Using YOLOv10. *Electronics*, *13*(19), 3840. <https://doi.org/10.3390/electronics13193840>
- Mares-Castro, A., Calzada-Ledesma, V., Becerra-Rodríguez, M. B., Santiago-Montero, R., & Estrada-Monje, A. (2025). Intelligent Motion Classification via Computer Vision for Smart

Manufacturing and Ergonomic Risk Prevention in SMEs. *Applied Sciences*, 15(20), 10914.

<https://doi.org/10.3390/app152010914>

Martínez Gila, D. M., Bonillo Martínez, D., Satorres Martínez, S., Cano Marchal, P., & Gámez

García, J. (2024). Non-invasive detection of pesticide residues in freshly harvested olives using hyperspectral imaging technology. *Smart Agricultural Technology*, 9, 100644.

<https://doi.org/10.1016/j.atech.2024.100644>

Maślanka, M., Jancarczyk, D., & Rysinski, J. (2025). Integration of Machine Vision and PLC-Based Control for Scalable Quality Inspection in Industry 4.0. *Sensors*, 25(20), 6383.

<https://doi.org/10.3390/s25206383>

Medina, A., Bradley, R., Xu, W., Ponce, P., Anthony, B., & Molina, A. (2024). Learning

manufacturing computer vision systems using tiny YOLOv4. *Frontiers in Robotics and AI*, 11.

<https://doi.org/10.3389/frobt.2024.1331249>

Mehta, D., & Klarmann, N. (2023). Autoencoder-Based Visual Anomaly Localization for

Manufacturing Quality Control. *Machine Learning and Knowledge Extraction*, 6(1), 1-17.

<https://doi.org/10.3390/make6010001>

Mirbod, M., Ghatari, A. R., Saati, S., & Shoar, M. (2022). Industrial parts change recognition model

using machine vision, image processing in the framework of industrial information integration.

Journal of Industrial Information Integration, 26, 100277.

<https://doi.org/10.1016/j.jii.2021.100277>

Muñoz, J., Sanchez, A., & Kemper, G. (2024). End-to-end solution for automatic beverage stock

detection in supermarkets based on image processing and convolutional neural networks.

International Journal of Cognitive Computing in Engineering, 5, 453-474.

<https://doi.org/10.1016/j.ijcce.2024.09.001>

Nguyen Thi Phuong, T., Cho, G. S., & Chatterjee, I. (2025). Automating container damage detection with the YOLO-NAS deep learning model. *Science Progress*, *108*(1), 00368504251314084.

<https://doi.org/10.1177/00368504251314084>

Ochoa, L. M. G. (s. f.). *Tecnologías basadas en Inteligencia Artificial aplicadas a la gestión de la Seguridad y Salud*.

Oliveira, M. M., Cerqueira, B. V., Barbon, S., & Barbin, D. F. (2021). Classification of fermented cocoa beans (cut test) using computer vision. *Journal of Food Composition and Analysis*, *97*,

103771. <https://doi.org/10.1016/j.jfca.2020.103771>

Papoutsakis, K., Bakalos, N., Zacharia, A., Fragkoulis, K., Kapetadimitri, G., & Pateraki, M. (2026).

A vision-based framework and dataset for human behavior understanding in industrial assembly lines. *Computer Vision and Image Understanding*, *263*, 104592.

<https://doi.org/10.1016/j.cviu.2025.104592>

Park, M., Tran, D. Q., Bak, J., Kulinan, A. S., & Park, S. (2023). Real-time monitoring unsafe behaviors of portable multi-position ladder worker using deep learning based on vision data.

Journal of Safety Research, *87*, 465-480. <https://doi.org/10.1016/j.jsr.2023.08.018>

Pati, N., Sharma, A., Gourisaria, M. K., Jena, J. J., Jha, A. V., Appasani, B., & Bizon, N. (2026). A real-time industrial safety automation using YOLO architectures leveraging diverse chromatic domains.

Scientific Reports, *16*(1), 7253. <https://doi.org/10.1038/s41598-026-37869-1>

PRISMA statement. (s. f.). PRISMA Statement. Recuperado 6 de noviembre de 2025, de

<https://www.prisma-statement.org>

Raisul Islam, M., Zakir Hossain Zamil, M., Eshmam Rayed, M., Mohsin Kabir, M., Mridha, M. F.,

Nishimura, S., & Shin, J. (2024). Deep Learning and Computer Vision Techniques for Enhanced

Quality Control in Manufacturing Processes. *IEEE Access*, 12, 121449-121479.

<https://doi.org/10.1109/ACCESS.2024.3453664>

Rajagounder, R. (2025). A machine vision system for inspecting mechanical parts. *Machine Graphics and Vision*, 34(1), 75-86. <https://doi.org/10.22630/MGV.2025.34.1.4>

Rappe, N. A., Kirda, A. W., Yassin, H., Bartoszek, M., & Caesarendra, W. (2025). Application of YOLOv8 in fusion welding defect detection on carbon steel for potential remote visual inspection. *Advances in Science and Technology Research Journal*, 19(12), 436-453.

<https://doi.org/10.12913/22998624/210216>

Ray, A., & Kolekar, M. H. (2022). Image segmentation and classification using deep learning. En D. Ghai, S. L. Tripathi, S. Saxena, M. Chanda, & M. Alazab (Eds.), *Machine Learning Algorithms for Signal and Image Processing* (pp. 19-36). Wiley. <https://doi.org/10.1002/9781119861850.ch2>

Rodrigues, P. B., Xiao, Y., Fukumura, Y. E., Awada, M., Aryal, A., Becerik-Gerber, B., Lucas, G., & Roll, S. C. (2022). Ergonomic assessment of office worker postures using 3D automated joint angle assessment. *Advanced Engineering Informatics*, 52, 101596.

<https://doi.org/10.1016/j.aei.2022.101596>

Sabri, K., & Gaceb, M. (2025). Smart casting: Vision-driven defect detection for high-precision manufacturing. *The International Journal of Advanced Manufacturing Technology*, 140(3-4),

1871-1894. <https://doi.org/10.1007/s00170-025-16390-1>

Sánchez, M. S. C. (s. f.). *Estudio exploratorio sobre técnicas de machine learning aplicadas al diseño de celdas de*.

Santi, R., Suwarningsih, W., & Sasongko Sastrosubroto, A. (2025). Automated Detection of Helmet Wearing with YOLOv8 and Real-Time Monitoring for Factory Safety. *Interdisciplinary Journal of Information, Knowledge, and Management*, 20, 014. <https://doi.org/10.28945/5499>

- Sarkar, N. (2023). *AI-Based Smart Delivery System Using Image Processing and Computer Vision*.
<https://doi.org/10.15157/IJITIS.2023.6.4.1255-1263>
- Shahin, M., Hosseinzadeh, A., & Chen, F. F. (2025). AI-Enabled Sustainable Manufacturing: Intelligent Package Integrity Monitoring for Waste Reduction in Supply Chains. *Electronics*, *14*(14), 2824. <https://doi.org/10.3390/electronics14142824>
- Shen, H., Wei, B., & Ma, Y. (2024). Unsupervised anomaly detection for manufacturing product images by significant feature space distance measurement. *Mechanical Systems and Signal Processing*, *212*, 111328. <https://doi.org/10.1016/j.ymsp.2024.111328>
- Shetye, S., Shetty, S., Shinde, S., Madhu, C., & Mathur, A. (2023). Computer Vision for Industrial Safety and Productivity. *Int. Conf. Commun. Syst., Comput. IT Appl., CSCITA - Proc.*, 117-120. <https://doi.org/10.1109/CSCITA55725.2023.10104764>
- Shi, C., Zhu, D., Shen, J., Zheng, Y., & Zhou, C. (2023). GBSG-YOLOv8n: A Model for Enhanced Personal Protective Equipment Detection in Industrial Environments. *Electronics*, *12*(22), 4628. <https://doi.org/10.3390/electronics12224628>
- Shili, M., Sohaib, O., & Hammedi, S. (2024). You Only Look Once Version 5 and Deep Simple Online and Real-Time Tracking Algorithms for Real-Time Customer Behavior Tracking and Retail Optimization. *Algorithms*, *17*(11), 525. <https://doi.org/10.3390/a17110525>
- Silva, C. A. D. S., & Paladini, E. P. (2025). Smart Machine Vision System to Improve Decision-Making on the Assembly Line. *Machines*, *13*(2), 98. <https://doi.org/10.3390/machines13020098>
- Singh, M., Fuenmayor, E., Hinchy, E., Qiao, Y., Murray, N., & Devine, D. (2021). Digital Twin: Origin to Future. *Applied System Innovation*, *4*(2), 36. <https://doi.org/10.3390/asi4020036>

- Singh, S. A., & Desai, K. A. (2023). Automated surface defect detection framework using machine vision and convolutional neural networks. *Journal of Intelligent Manufacturing*, 34(4), 1995-2011. <https://doi.org/10.1007/s10845-021-01878-w>
- Singh, S. A., & Desai, K. A. (2025). Integrated vision-based in-line surface defect detection system for realizing zero-defect manufacturing of tapered rollers. *CIRP Journal of Manufacturing Science and Technology*, 63, 475-489. <https://doi.org/10.1016/j.cirpj.2025.10.009>
- Singh, S. A., Kumar, A. S., & Desai, K. A. (2023). Vision-based system for automated image dataset labelling and dimension measurements on shop floor. *Measurement*, 216, 112980. <https://doi.org/10.1016/j.measurement.2023.112980>
- Sitnikov, P., Gubinskiy, A., Ivaschenko, A., & Nikiforova, T. (2021). Computer vision application for mechanical engineering production manual operations control. *AIP Conf. Proc.*, 2402. <https://doi.org/10.1063/5.0071973>
- Sun, F., Guan, Z., Lyu, Z., & Liu, S. (2025). High-Precision Stored-Grain Insect Pest Detection Method Based on PDA-YOLO. *Insects*, 16(6), 610. <https://doi.org/10.3390/insects16060610>
- Sundaram, S., & Zeid, A. (2023). Artificial Intelligence-Based Smart Quality Inspection for Manufacturing. *Micromachines*, 14(3), 570. <https://doi.org/10.3390/mi14030570>
- Szeliski, R. (s. f.). *Computer Vision: Algorithms and Applications, 2nd Edition*.
- Szkudlarek, J., Owczarek, G., Jachowicz, M., & Zagrodny, B. (2022). Procedure for Determining Dimensional Allowances for PPE Using 3D Scanning Methods. *International Journal of Environmental Research and Public Health*, 19(4), 2397. <https://doi.org/10.3390/ijerph19042397>
- Tan, P. X., Hoang, D.-C., Nguyen, A.-N., Kamioka, E., Duong, T. H. A., Huynh, T.-M., Nguyen, D.-M., Ngo, D.-H., Cao, M.-D., Nguyen, T.-U., Nguyen, V.-T., Tran, D.-T., Duong, V.-H., Mai, A.-T., Pham, D.-L., Phan, K.-T., & Do, M.-Q. (2025). Depth-Guided Monocular Object Pose

Estimation for Warehouse Automation. *IEEE Access*, 13, 110166-110184.

<https://doi.org/10.1109/ACCESS.2025.3582924>

Tao, J., Chen, Q., Xu, J., Zhao, H., & Song, S. (2022). Utilization of Both Machine Vision and Robotics Technologies in Assisting Quality Inspection and Testing. *Mathematical Problems in Engineering*, 2022, 1-9. <https://doi.org/10.1155/2022/7547801>

Trujillo-Lopez, L. A., Raymundo-Guevara, R. A., & Morales-Arevalo, J. C. (2025). User-Centered Design of a Computer Vision System for Monitoring PPE Compliance in Manufacturing. *Computers*, 14(8), 312. <https://doi.org/10.3390/computers14080312>

Truong, V. D., Wang, Y., Won, C., & Yoon, J. (2025). A Deep Learning-Based Machine Vision System for Online Monitoring and Quality Evaluation During Multi-Layer Multi-Pass Welding. *Sensors*, 25(16), 4997. <https://doi.org/10.3390/s25164997>

Tu, W., Fang, J., Fangyu, Jiao, & Ci, Y. (2021). Bibliometric research in the field of artificial intelligence. *Journal of Physics: Conference Series*, 1883(1), 012165. <https://doi.org/10.1088/1742-6596/1883/1/012165>

Vadivel, S. M., Madhumitha, R., Nair, Y., Aniruddha, P. M., Mithun, S. P., & Sarathy, Y. (2025). Weave defect detection in jute manufacturing value chain using artificial intelligence and computer vision. *International Journal of System Assurance Engineering and Management*. <https://doi.org/10.1007/s13198-025-02797-2>

Vijayakumar, A., Vairavasundaram, S., Koilraj, J. A. S., Rajappa, M., Kotecha, K., & Kulkarni, A. (2024). Real-time visual intelligence for defect detection in pharmaceutical packaging. *Scientific Reports*, 14(1), 18811. <https://doi.org/10.1038/s41598-024-69701-z>

- Villegas-Ch, W., Navarro, A. M., & Sanchez-Viteri, S. (2024). Optimization of inventory management through computer vision and machine learning technologies. *Intelligent Systems with Applications*, 24, 200438. <https://doi.org/10.1016/j.iswa.2024.200438>
- Wan, T., Liang, Z., Fan, F., Qiu, J., Liu, C., & Wang, X. (2026). A machine vision-coupled colorimetric electrospun nanofiber film for on-site TVB-N prediction and freshness grading of pork. *Food Control*, 183, 111953. <https://doi.org/10.1016/j.foodcont.2025.111953>
- Wang, H., Wang, Y., Ni, P., Lan, G., Liu, D., He, G., Lou, W., & Feng, E. (2025). Defect measurement method of circular saw blade based on machine vision. *The International Journal of Advanced Manufacturing Technology*, 137(3-4), 2091-2107. <https://doi.org/10.1007/s00170-025-15226-2>
- Wang, H., Xie, Z., Lu, L., Li, L., & Xu, X. (2021). A computer-vision method to estimate joint angles and L5/S1 moments during lifting tasks through a single camera. *Journal of Biomechanics*, 129, 110860. <https://doi.org/10.1016/j.jbiomech.2021.110860>
- Wang, J., Zeng, X., Duan, S., Zhou, Q., & Peng, H. (2022). Image Target Recognition Based on Improved Convolutional Neural Network. *Mathematical Problems in Engineering*, 2022(1), 2213295. <https://doi.org/10.1155/2022/2213295>
- Wang, W., Wang, P., Zhang, H., Chen, X., Wang, G., Lu, Y., Chen, M., Liu, H., & Li, J. (2023). A Real-Time Defect Detection Strategy for Additive Manufacturing Processes Based on Deep Learning and Machine Vision Technologies. *Micromachines*, 15(1), 28. <https://doi.org/10.3390/mi15010028>
- Wang, Z., Wang, W., Chen, J., Zhang, X., & Miao, Z. (2023). Posture Risk Assessment and Workload Estimation for Material Handling by Computer Vision. *International Journal of Intelligent Systems*, 2023(1), 2085251. <https://doi.org/10.1155/2023/2085251>

Wiggerthale, J., & Reich, C. (2025). Operationalizing the R4VR-Framework: Safe Human-in-the-Loop Machine Learning for Image Recognition. *Processes*, *13*(12), 4086.

<https://doi.org/10.3390/pr13124086>

Wu, H.-Q., Yan, H., Zhang, H., Xu, S.-W., Gao, F.-Y., & Chen, Z.-W. (2026). Optimized Industrial Surface Defect Detection Based on Improved YOLOv11. *Structural Durability & Health Monitoring*, *20*(1), 1-10. <https://doi.org/10.32604/sdhm.2025.070589>

Xu, S., Cui, W., Zhou, X., Zhong, Q., Wei, Y., & Wang, Y. (2025). Machine vision-based surface defect detection method for welds. *Diagnostyka*, *26*(1), 1-12.

<https://doi.org/10.29354/diag/195841>

Xuan Tan, P., Hoang, D.-C., Kamioka, E., Nguyen, A.-N., Tran, D.-T., Duong, V.-H., Mai, A.-T., Pham, D.-L., Phan, K.-T., Dinh, X.-T., Trang, T. T. T., Pham, X.-D., Nguyen, N.-L., Nguyen, T.-U., Trinh, V.-A., Tran, K.-D., & Bui, S.-A. (2025). Visibility Aware In-Hand Object Pose Tracking in Videos With Transformers. *IEEE Access*, *13*, 35733-35749.

<https://doi.org/10.1109/ACCESS.2025.3545049>

Yang, Q., Liu, L., Zhou, J., Rogers, M., & Jin, Z. (2024). Predicting the growth trajectory and yield of greenhouse strawberries based on knowledge-guided computer vision. *Computers and Electronics in Agriculture*, *220*, 108911. <https://doi.org/10.1016/j.compag.2024.108911>

Yang, X., Ruan, C., Yu, F., Yang, R., Guo, B., Yang, J., Gao, F., & He, L. (2025). TEB-YOLO: A Lightweight YOLOv5-Based Model for Bamboo Strip Defect Detection. *Forests*, *16*(8), 1219.

<https://doi.org/10.3390/f16081219>

Yang, W., Chen, M., Wu, H., Lin, Z., Kong, D., Xie, S., & Takamasu, K. (2023). Deep learning-based weak micro-defect detection on an optical lens surface with micro vision. *Optics Express*, *31*(4), 5593. <https://doi.org/10.1364/OE.482389>

- Yang, X., Ruan, C., Yu, F., Yang, R., Guo, B., Yang, J., Gao, F., & He, L. (2025). TEB-YOLO: A Lightweight YOLOv5-Based Model for Bamboo Strip Defect Detection. *Forests*, *16*(8), 1219. <https://doi.org/10.3390/f16081219>
- Yu, Z., Wang, D., & Wu, H. (2025). Defect Detection Method for Large-Curvature and Highly Reflective Surfaces Based on Polarization Imaging and Improved YOLOv11. *Photonics*, *12*(4), 368. <https://doi.org/10.3390/photonics12040368>
- Yuan, H. Z., Ghazali, K. H., Lubis, A., Sunardi, S., Yanto, B., & Khan, S. U. (2025). Implementing Image Processing for Quality Inspection of Car Air Conditioning Vents. *The 8th Mechanical Engineering, Science and Technology International Conference*, 46. <https://doi.org/10.3390/engproc2025084046>
- Zhang, J., Wang, X., Xia, J., Xing, S., & Zhang, X. (2022). Flexible sensing enabled intelligent manipulator system (FSIMS) for avocados (*Persea Americana* Mill) ripeness grading. *Journal of Cleaner Production*, *363*, 132599. <https://doi.org/10.1016/j.jclepro.2022.132599>
- Zhang, S., Zheng, X., Xu, F., Wang, S., Zhang, Q., & Cao, Y. (2024). Optimization Management of Storage Location in Stereoscopic Warehouse by Integrating Genetic Algorithm and Particle Swarm Optimization Algorithm. *Journal of Applied Mathematics*, *2024*(1), 2790066. <https://doi.org/10.1155/2024/2790066>
- Zhang, Z., Kong, J., Liu, H., Shao, H., Guan, C., Li, H., & Xu, X. (2026). 3D human pose estimation-based action recognition method for complex industrial scenarios. *Displays*, *92*, 103298. <https://doi.org/10.1016/j.displa.2025.103298>
- Zhao, D., Kong, F., Lv, N., Xu, Z., & Du, F. (2024). A Common Knowledge-Driven Generic Vision Inspection Framework for Adaptation to Multiple Scenarios, Tasks, and Objects. *Sensors*, *24*(13), 4120. <https://doi.org/10.3390/s24134120>

Zheng, H., Chen, X., Cheng, H., Du, Y., & Jiang, Z. (2024). MD-YOLO: Surface Defect Detector for Industrial Complex Environments. *Optics and Lasers in Engineering*, 178, 108170.

<https://doi.org/10.1016/j.optlaseng.2024.108170>

Zhou, L., Zhang, L., & Konz, N. (2023). Computer Vision Techniques in Manufacturing. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 53(1), 105-117.

<https://doi.org/10.1109/TSMC.2022.3166397>

Zhou, X., Wang, W., & Hu, Y. (2025). 3D ergonomics parameter measurement using video-based deep learning. *Measurement*, 256, 118034. <https://doi.org/10.1016/j.measurement.2025.118034>

Zhu, Q., Zhang, Y., Luan, J., & Hu, L. (2022). A Machine Vision Development Framework for Product Appearance Quality Inspection. *Applied Sciences*, 12(22), 11565.

<https://doi.org/10.3390/app122211565>

Zhu, Z., Mu, F., Radwin, R., & Li, Y. (2025). Towards video-based injury risk assessment: Predicting lifting loads from body pose trajectories. *Machine Vision and Applications*, 36(6), 136.

<https://doi.org/10.1007/s00138-025-01758-w>

(S. f.). Recuperado 14 de abril de 2026, de

<file:///C:/Users/Asus/OneDrive/Documentos/Articulos%20tesis/>