

# Ciencias e Ingeniería

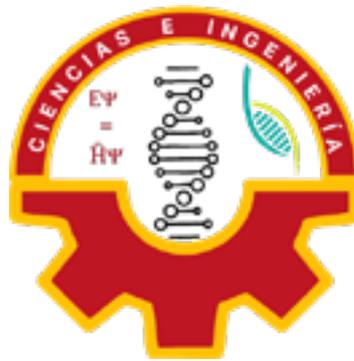
PARA CIUDADANOS

Revista de investigación científica



Lima - Perú

# Ciencias e Ingeniería



Volumen I-N°2 Agosto 2025

# Consejo Editorial

## Director

Dr. Francisco Javier Wong Cabanillas

## Editor, diseño y traducción

Bach. Carlos Alberto Vega Vidal

## Diagramador de texto y asistencia de diseño

Bach. Carlos Alberto Vega Vidal

## Comité Científico

Dra. Elena Rafaela Benavides Rivera  
Universidad Nacional Mayor de San Marcos.  
Lima-Perú

Dra. Ysabel Zevallos Parave  
Universidad Nacional de Educación Enrique Guzmán y Valle.  
Lima-Perú

Dr. Óscar Rafael Tinoco Gómez  
Universidad Nacional Mayor de San Marcos.  
Lima-Perú

# Evaluación del uso de machine learning para la calidad en la producción de acero: revisión sistemática

Sr. Lionel Tito Lázaro  
Universidad Tecnológica del Perú  
Correo electrónico: U22315786@utp.edu.pe

Srta. Marisol Yeni López Condori  
Universidad Tecnológica del Perú  
Correo electrónico: 1615013@utp.edu.pe

**Resumen:** El control de calidad en la producción de acero es esencial para industrias como la construcción y la manufactura, donde los defectos pueden afectar la seguridad y las funciones de producción. En este contexto, las técnicas tradicionales de inspección manual, aunque efectivas en algunos aspectos, tienen limitaciones como la privacidad del trabajador, lo que conlleva tiempos largos y altos costos. Por ello, la aplicación del machine learning ha crecido en los últimos años como herramienta para automatizar y optimizar este proceso. El machine learning como las redes neuronales convolucionales (CNN) y las redes generativas adversarias (GAN) han demostrado precisión (superior al 95%) en la detección de defectos en superficies de acero laminado y galvanizado. Estos modelos se proporcionan como imágenes de alta resolución, videos y sensores multiespectrales para el análisis de patrones y microestructuras. Además, implementarlo permite reducir los tiempos de inspección a milisegundos, aumentando la eficiencia y reduciendo los costos de producción. Sin embargo, existen limitaciones como la sensibilidad del modelo a las condiciones ambientales, la dependencia de bases de datos especializadas y los altos requerimientos computacionales. De igual forma, los dispositivos de captura de calidad en entornos industriales requieren de nuevas soluciones. En este contexto, se presenta una revisión sistemática para evaluar el impacto del machine learning en la producción de acero, destacando sus ventajas, limitaciones y perspectivas futuras. Los resultados confirman que la automatización con machine learning mejora la eficiencia operativa, el cual establece las bases para una producción de alta calidad en la industria del acero.

**Palabras claves:** Calidad del acero/ Industria manufacturera/ Machine learning/ Calidad.

**Abstract:** Quality control in steel production is essential for industries such as construction and manufacturing, where defects can affect safety and production functions. In this context, traditional manual inspection techniques, although effective in some aspects, have limitations such as worker privacy, which leads to long times and high costs. Therefore, the application of machine learning has grown in recent years as tools to automate and optimize this process. Machine learning such as convolutional neural networks (CNN) and generative adversarial networks (GAN) have demonstrated accuracy (over 95%) in detecting defects on rolled and galvanized steel surfaces. These models

are provided as high-resolution images, videos, and multispectral sensors for pattern and microstructure analysis. In addition, implementing it allows inspection times to be reduced to milliseconds, increasing efficiency and reducing production costs. However, there are limitations such as the sensitivity of the model to environmental conditions, dependence on specialized databases, and high computational requirements. Likewise, quality capture devices in industrial environments require new solutions. In this context, a systematic review is presented to assess the impact of machine learning on steel production, highlighting its advantages, limitations and future prospects. The results confirm that automation with machine learning improves operational efficiency, which lays the foundation for high-quality production in the steel industry.

**Keywords:** Steel quality/ Manufacturing industry/ Machine learning/ Quality.

**Résumé:** Le contrôle qualité dans la production d'acier est essentiel pour des secteurs tels que la construction et la fabrication, où les défauts peuvent affecter la sécurité et les fonctions de production. Dans ce contexte, les techniques d'inspection manuelle traditionnelles, bien qu'efficaces sous certains aspects, présentent des limites telles que la confidentialité des travailleurs, ce qui entraîne des délais longs et des coûts élevés. Pour cette raison, l'application de l'apprentissage automatique s'est développée ces dernières années en tant qu'outil permettant d'automatiser et d'optimiser ce processus. L'apprentissage automatique tel que les réseaux neuronaux convolutifs (CNN) et les réseaux contradictoires génératifs (GAN) ont démontré une précision (supérieure à 95 %) dans la détection des défauts sur les surfaces en acier laminé et galvanisé. Ces modèles sont fournis sous forme d'images haute résolution, de vidéos et de capteurs multispectraux pour l'analyse des motifs et de la microstructure. De plus, sa mise en œuvre permet de réduire les temps d'inspection à quelques millisecondes, augmentant ainsi l'efficacité et réduisant les coûts de production. Il existe cependant des limites telles que la sensibilité du modèle aux conditions environnementales, la dépendance à l'égard de bases de données spécialisées et les exigences informatiques élevées. De même, les dispositifs de capture de qualité dans les environnements industriels nécessitent de nouvelles solutions. Dans ce contexte, une revue systématique est présentée pour évaluer l'impact de l'apprentissage automatique dans la production d'acier, mettant en évidence ses avantages, ses limites et ses perspectives d'avenir. Les résultats confirment que l'automatisation associée à l'apprentissage automatique améliore l'efficacité opérationnelle, ce qui constitue la base d'une production de haute qualité dans l'industrie sidérurgique.

**Mots-clés:** Qualité de l'acier/ Industrie manufacturière/ Apprentissage automatique/ Qualité.

## 1. Introducción

La producción de acero es fundamental para industrias como la construcción y la manufactura. La calidad del acero es de suma importancia, y los progresos en el aprendizaje automático han facilitado una mejor precisión en la detección de defectos (MEF, 2023; MCTE, 2022). Investigaciones recientes indican que métodos como las redes neurona-

les convolucionales pueden lograr tasas de precisión del 91.14% en la identificación de fallas. Sin embargo, aún existen interrogantes sobre cómo se comparan estos enfoques con las inspecciones manuales en términos de eficiencia y costos (Schneider et al., 2024).

La necesidad de realizar una revisión sistemática surge debido a la dispersión de la información y la falta de acuerdo sobre las mejores estrategias para aplicar el machine learning en el control de calidad del acero (Akhyar et al., 2022; O'Donovan et al., 2024). Este análisis proporciona una visión actualizada para evaluar cómo estas tecnologías afectan a la industria.

El objetivo principal es comparar la precisión y la eficiencia del machine learning con respecto a los métodos manuales en la detección de defectos, examinando su efecto en los tiempos de inspección y los costos (Ahmed, 2023). Las preguntas clave incluyen: ¿Cuál es la precisión de estos sistemas frente a métodos tradicionales? y ¿Cómo impactan en la eficiencia operativa?

Esta revisión emplea la metodología PRISMA para garantizar una selección cuidadosa de estudios pertinentes (Haddaway et al., 2022). Se incluyeron investigaciones que examinan el machine learning en la inspección del acero, excluyendo aquellos artículos publicados antes de 2020. Este documento se encuentra ordenado por secciones. En la sección 2 se detalla la metodología realizada. La sección 3 se muestran los resultados obtenidos, los hallazgos relevantes sobre el machine learning y el impacto en la calidad del acero. En cuanto a la sección 4 contiene la discusión y finalmente, en la sección 5 se muestran las conclusiones obtenidas, brindándole relevancia a los beneficios del aprendizaje automático en la industria del acero.

## 2. Metodología de la investigación

Se realizó una revisión sistemática sin metaanálisis, utilizando la estrategia PICO para definir los componentes clave de la investigación. Una vez establecidos los elementos PICO, se formularon las preguntas de investigación científica. La pregunta general de investigación fue: RQ: ¿Cuál es el impacto que tiene la implementación de visión computacional y sistemas de machine learning en la eficiencia, precisión y rapidez de las inspecciones y el control de calidad en la producción del acero?. A partir de esta, se formularon preguntas más específicas: RQ1: ¿Cómo mejora la precisión de la inspección de defectos en acero con visión computacional frente a métodos manuales?, RQ2: ¿Cuál es la reducción en los tiempos de inspección gracias al machine learning en la producción de acero?, RQ3: ¿Qué modelos de machine learning son más eficientes para detectar defectos?, RQ4: ¿Cuáles son los métodos manuales de inspección actualmente utilizados y cómo se comparan con los automatizados?

Para formular estas preguntas de investigación específicas, se emplearon las siguientes palabras clave según el método PICO: P (calidad del acero, defectos superficiales, proceso de producción), I (machine learning, visión computacional, detección de defec-

tos), C (inspección manual, inspección visual, error humano), O (tiempo de inspección, precisión, eficiencia operativa).

La base de datos utilizada para realizar la búsqueda sistemática fue Scopus, donde se utilizó, las siguientes ecuaciones: ("computer vision" OR "machine vision" OR "artificial vision" OR "image analysis" AND "steel production" OR "metallurgical process" OR "steel manufacturing" OR "metal" AND "processing"), ("computer vision" OR "machine vision" OR "vision system" OR "image processing" AND "steel production" OR "steel manufacturing" OR "steel process" OR "steel industry").

Por otro lado, para esta metodología se propone la utilización de criterios de inclusión y exclusión, que sirvieron como filtros de selección de los documentos, los cuales se muestran en las siguientes tablas 1, 2:

**Tabla N°1:** Criterios de inclusión

Código	Criterio
CI1	Estudios sobre defectos físicos específicos en la producción de acero.
CI2	Evaluación de técnicas de visión computacional.
CI3	Publicaciones a partir del 2020.
CI4	Publicaciones en idiomas distintos del inglés.

**Fuente:** Elaboración propia

**Tabla N°2:** Criterios de exclusión

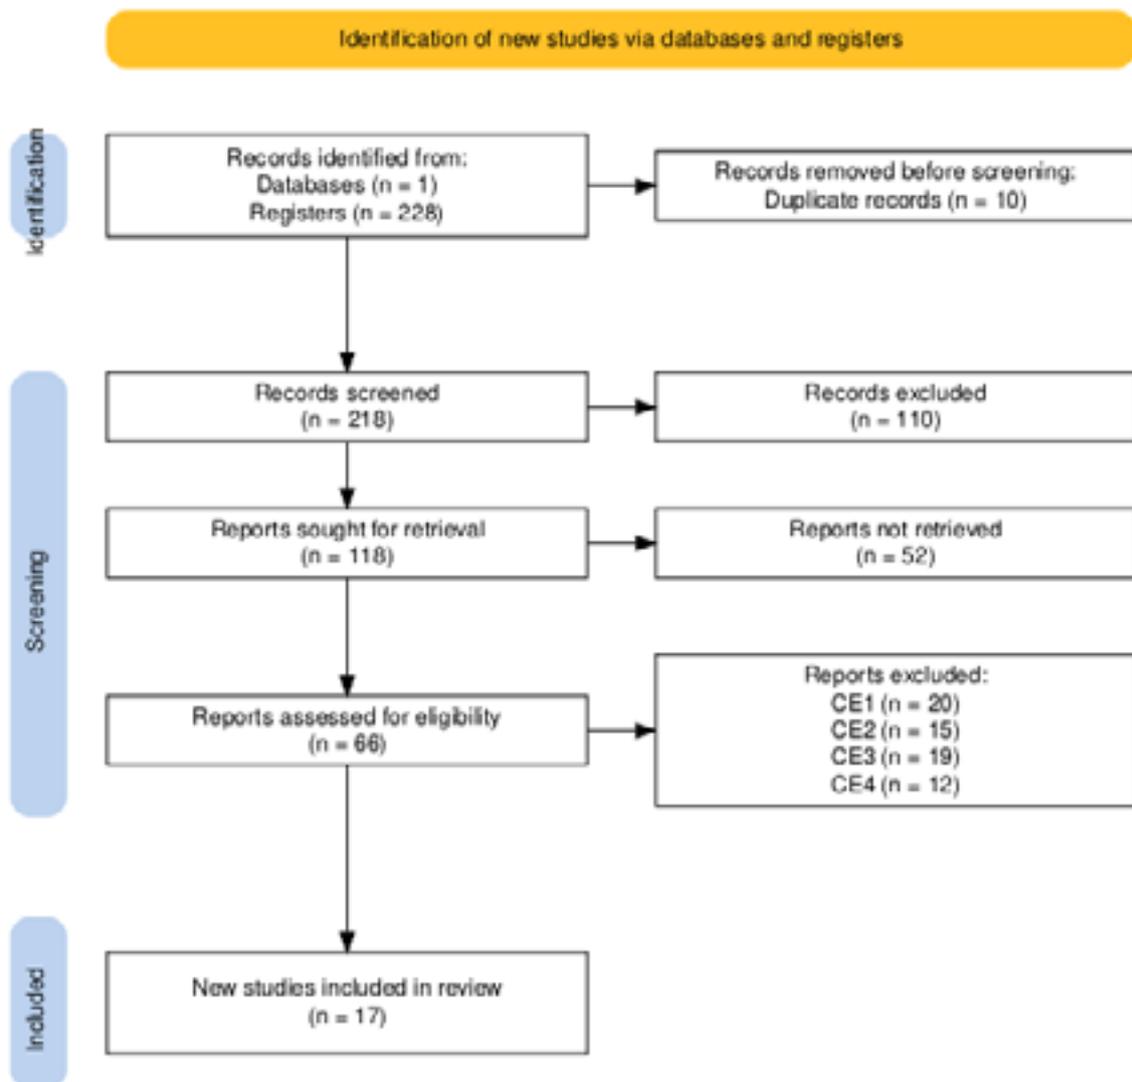
Código	Criterio
CE1	Estudios fuera de la industria del acero.
CE2	Foco exclusivo en técnicas manuales.
CE3	Teoría de visión computacional sin aplicaciones prácticas.
CE4	Defectos de superficie no detectables por visión computacional.

**Fuente:** Elaboración propia

Se eligió PRISMA para incluir todos los estudios relevantes en un área de investigación específica, minimizando así el proceso de selección (Haddaway et al., 2022). En total, se identificaron 228 artículos, de los cuales provienen de Scopus. Luego de eliminar 10 artículos duplicados, quedaron 218. Se excluyeron 110 tras la revisión del título y resumen, y 52 más porque no estaban disponibles a texto completo, obteniendo un total de 118. Finalmente, aplicando los criterios de inclusión y exclusión, se obtuvieron 17 artículos que cumplían con todos los requisitos para ser analizados, como se muestra

en el siguiente diagrama PRISMA, donde se destacan los aportes principales como se muestra en la tabla 3.

**Figura N°1:** Diagrama PRISMA de resultados



**Fuente:** Haddaway et al. (2022)

### 3. Resultados

En esta revisión de literatura, se ha encontrado que la implementación de machine learning y visión computacional, en el control de calidad en la producción de acero presenta ventajas significativas en comparación con los métodos tradicionales. Los resultados de estudios recientes, resumidos en la tabla 11, muestran que los modelos avanzados, como el DSTEELNet y EnsGAN-SDD, alcanzan precisiones de hasta un 97% y permiten una detección en tiempo real con tiempos de procesamiento tan bajos como 23 milisegundos por imagen (Ahmed, 2023; Akhyar et al., 2022), lo cual es nota-

blemente más rápido en comparación con los métodos manuales de inspección, que, debido a la subjetividad del operario, presentan variaciones en la precisión y un tiempo considerablemente mayor en cada evaluación.

A partir de los artículos revisados, se identifican dos factores principales que explican esta diferencia en rendimiento. El primero es la capacidad de los sistemas automatizados para analizar un mayor volumen de datos en menor tiempo, debido a la eficiencia de los algoritmos de machine learning que permiten identificar patrones y defectos sin intervención humana constante. Esto contrasta con la inspección manual, en la cual el operario debe analizar visualmente cada superficie de acero, siendo susceptible a errores y subjetividades, especialmente en defectos de menor tamaño o menos evidentes (Lin et al., 2023; Schneider et al., 2024).

El segundo factor es la escalabilidad y adaptabilidad de los sistemas de visión computacional, que pueden operar en tiempo real y adaptarse a diferentes entornos de producción mediante ajustes en los algoritmos y calibración de los dispositivos de captura. Sin embargo, como se observa en la tabla 15, la revisión sistemática ha revelado ciertas limitaciones en los sistemas automatizados; por ejemplo, los cambios de iluminación y las altas temperaturas en el entorno de producción pueden afectar la precisión de las cámaras y requieren calibraciones periódicas (Lin et al., 2023; O'Donovan et al., 2024).

Además, la disponibilidad y anotación de datos de alta calidad continúan siendo un desafío. La recolección de imágenes y su anotación, crucial para el entrenamiento de estos modelos, representa un proceso costoso y de alta demanda de tiempo, lo que limita

la implementación de estos sistemas en ciertos contextos de producción (Ahmed, 2023; Akhyar et al., 2022). A pesar de estas limitaciones, la precisión y rapidez que ofrecen las técnicas automatizadas en el control de calidad de acero sientan bases sólidas para futuras investigaciones y mejoras en la producción industrial (Lin et al., 2023; Schneider et al., 2024).

## **4. Análisis descriptivo de artículos**

### **4.1. Análisis bibliométrico**

La tabla 4 resume los datos bibliométricos principales de los estudios seleccionados, destacando el año, país, idioma, base de datos, tipo de publicación y métodos utilizados. La distribución temporal muestra un incremento, alcanzando su punto máximo en 2023 con un 31% de las publicaciones, reflejando el creciente interés en machine learning para inspección de acero. China lidera con un 38% de los estudios, seguida por el Reino Unido y Alemania (15% cada uno). Las publicaciones en inglés predominan (100%), y las bases más utilizadas son MDPI (31%), Springer e IEEE (15% cada una). La mayoría son artículos de revista (85%).

Entre los métodos destacan las redes neuronales convolucionales (CNN) y YOLOv8n mejorado, con precisiones superiores al 95% (Ahmed, 2023; Zhang, 2024). Estas tendencias subrayan la relevancia de machine learning en el control de calidad industrial, marcando avances tecnológicos significativos.

**Tabla N°4:** Métodos utilizados

<b>Autores</b>	<b>Año</b>	<b>País de origen</b>	<b>Idioma</b>	<b>Base de datos</b>	<b>Tipo</b>	<b>Métodos utilizados</b>
Ahmed, K. R.	2023	USA	English	MDPI	Journal Article	Redes neuronales convolucionales (CNN) fundamentadas en el aprendizaje profundo para la identificación de imperfecciones.
Lin, Y., Wang, P., et al.	2023	UK	English	Springer	Journal Article	Registro y combinación de imágenes para la medición de acero.
Akhyar, F., Furqon, E.N.	2022	Taiwan, Indonesia	English	MDPI	Journal Article	Redes generativas antagónicas (GANs)
Schneider, J., et al.	2024	Germany	English	HTM Journal	Journal Article	Inteligencia artificial para análisis microestructural en metalografía
O'Donovan, C., et al.	2024	UK	English	Springer	Journal Article	Análisis de imágenes para la supervisión de zinc fundido.
Luo, Q., et al.	2019	China	English	IEEE	Survey	Metodologías de detección visual de defectos
Fang, X., et al.	2020	China	English	MDPI	Survey	Métodos 2D/3D para detección de defectos superficiales
Guo, Z., et al.	2022	China	English	MDPI	Journal Article	YOLO mejorado para detección de defectos en superficies
Landgraf, J., et al.	2023	Germany	English	Materials Research Forum	Conference Paper	Segmentación semántica para detección de defectos

Zhouzhou Zheng et al.	2022	China	English	IOP	Journal Article	CASPPNet: Empleo de redes de pirámide espacial atrófica encadenada para optimizar la detección de imperfecciones en superficies de acero mediante la combinación de atención global y el perfeccionamiento de bordes.
Bin Xue, Zhisheng Wu	2021	China	English	Hindawi	Journal Article	Uso de visión artificial y extracción de características invariantes para la clasificación y segmentación de imperfecciones.
Kun Liu et al.	2019	China	English	IEEE	Journal Article	Algoritmo de descomposición de imágenes autoguiado para detección de defectos basado en características texturales y estructurales.
Zelin Zhang et al.	2024	China	English	Nature	Journal Article	Redes YOLOv8n optimizadas para identificar imperfecciones en componentes mecánicos recubiertos de óxido, incorporando enfoques de fusión multiescala.
Zhiqiang Hao et al.	2021	China	English	Wiley	Journal Article	Integración de información multidimensional y tecnologías de visión 3D para la inspección avanzada de imperfecciones en placas de acero.
Fabio Frustaci et al.	2022	Italy	English	MDPI	Journal Article	Aplicación de un sistema de visión robusto para la inspección automática en procesos de ensamblaje, integrando hardware y software para lograr alta velocidad y precisión.

Hiroimi Nishiura et al.	2022	Japan	English	Oxford	Journal Article	Sistema de aprendizaje automático para evaluar la calidad de microestructuras de acero, utilizando imágenes de microscopio y métodos de aumento de datos.
-------------------------	------	-------	---------	--------	-----------------	---

Fuente: Elaboración propia

## 4.2. Análisis comparativos

### 4.2.1. Definición de defectos físicos en el acero

La tabla 5 presenta una síntesis de los principales estudios sobre la definición de defectos físicos en el acero, subrayando su relevancia en aplicaciones industriales críticas. En primer lugar, los estudios enfocados en superficies de tiras de acero destacan defectos comunes como agujeros, rayaduras y grietas, señalando la importancia de la inspección visual automatizada para asegurar la calidad en sectores como el aeroespacial y automotriz (Ahmed, 2023; Guo et al., 2022; Landgraf et al., 2022; Xue et al., 2021; Liu et al., 2021; Hao et al., 2024).

Por otro lado, los estudios sobre acero galvanizado resaltan los defectos en el recubrimiento de zinc, tales como salpicaduras, que afectan la uniformidad y resistencia a la corrosión, destacando la necesidad de detección en tiempo real para mejorar la durabilidad del material (Schneider et al., 2023; Luo et al., 2019; Zheng et al., 2021).

Asimismo, se analizan defectos en el acero utilizado en los sectores aeroespacial, automotriz y de construcción, donde la calidad y precisión en la inspección son fundamentales para cumplir con altos estándares de seguridad (Lin et al., 2023; O'Donovan et al., 2024; Fang et al., 2018; Frustaci et al., 2022).

Además, la evaluación de microestructuras de acero y sus propiedades mecánicas se enfocan en aspectos como la resistencia a la corrosión y la distribución de carburos, elementos clave para la durabilidad del acero en aplicaciones industriales (Akhyar et al., 2023; Fang et al., 2018; Nishiura et al., 2022).

Finalmente, los estudios centrados en componentes mecánicos de acero sometidos a oxidación intensa destacan la inspección automatizada para asegurar la integridad en procesos de ensamblaje (Zhang et al., 2024; Hao et al., 2024; Frustaci et al., 2022).

**Tabla N°5:** Definición de defectos físicos en el acero

Definición de defectos físicos en el acero	N°	Autores
Las investigaciones se centran en las superficies de tiras de acero, examinando defectos comunes como agujeros, rasguños, grietas y pequeñas imperfecciones que son difíciles de identificar. Subrayan la relevancia de la precisión en la inspección visual automatizada para garantizar altos estándares de calidad y competitividad, especialmente en sectores críticos como la industria aeroespacial y automotriz.	6	Ahmed (2023); Guo et al. (2022); Landgraf et al. (2022); Xue et al. (2021); Liu et al. (2021); Hao et al. (2024)
Investigaciones sobre acero galvanizado, con énfasis en los procesos de inmersión en zinc y la influencia de defectos como salpicaduras que afectan la uniformidad del recubrimiento y la resistencia a la corrosión. Estas investigaciones resaltan la importancia de detectar defectos en tiempo real para optimizar la calidad del recubrimiento y la resistencia a la fatiga del material.	3	Schneider et al. (2023); Luo et al. (2019); Zheng et al. (2021)
Estudio del acero empleado en las industrias aeroespacial, automotriz y de construcción. Estos análisis destacan la relevancia de la calidad y la precisión en la inspección, utilizando tecnologías avanzadas para garantizar que el acero satisfaga los altos estándares exigidos en aplicaciones críticas.	4	Lin et al. (2023); O'Donovan et al. (2024); Fang et al. (2018); Frustaci et al. (2022)
Enfocados en la evaluación de microestructuras de acero y propiedades mecánicas específicas. Los estudios analizan cómo la inspección de calidad se realiza mediante análisis de microestructura, prestando especial atención a la resistencia a la corrosión, distribución de carburos y características físicas que aseguran la durabilidad del acero en aplicaciones industriales.	3	Akhyar et al. (2023); Fang et al. (2018); Nishiura et al. (2022)
Descripciones de estudios enfocados en componentes mecánicos de acero, sometidos a condiciones como la oxidación intensa y la precisión en ensamblaje. La inspección automatizada permite asegurar la calidad en procesos de ensamblaje industrial, evitando desplazamientos y asegurando la integridad de las piezas.	3	Zhang et al. (2024); Hao et al. (2024); Frustaci et al. (2022)

**Fuente:** Elaboración propia

#### 4.2.2. Modelos de visión computacional

La tabla 6 muestra los modelos avanzados de visión computacional aplicados a la detección de defectos en acero. DSTEELNet y CNN con pirámides espaciales atrous permiten una detección precisa en tiempo real en superficies de acero laminado (Ahmed, 2023; Schneider et al., 2023; Luo et al., 2019; Fang et al., 2018). EnsGAN-SDD y DetectoRS optimizan la resolución de imagen, mientras que MSFT-YOLO basado en transformer mejora la precisión en defectos complejos (Akhyar et al., 2023; Guo et al., 2022; Landgraf et al., 2022). CASPPNet, con segmentación y fusión de características,

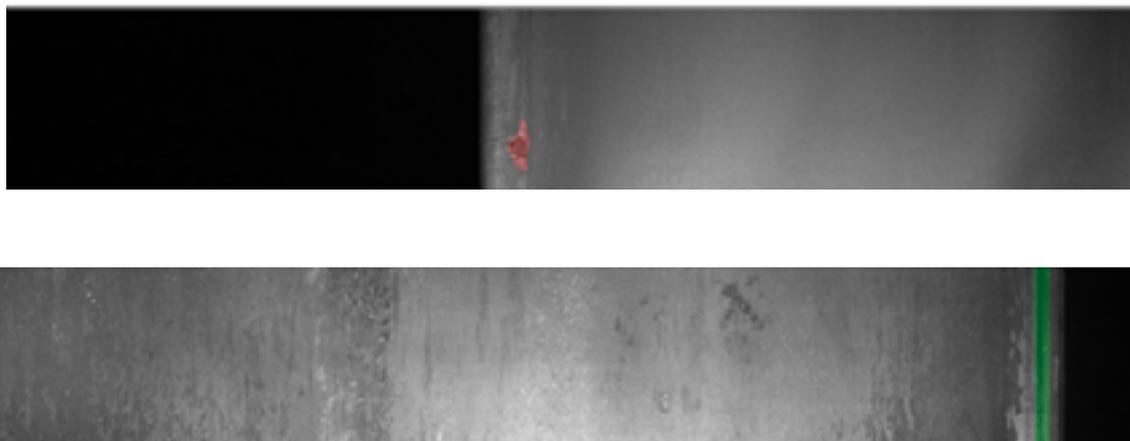
incrementa la precisión en ambientes ruidosos (Zheng et al., 2021; Xue et al., 2021; Hao et al., 2024).

Modelos como DCNN y YOLOv8n son utilizados para inspección de microestructuras y detección en componentes oxidados, con aceleración hardware-software (O'Donovan et al., 2024; Liu et al., 2021; Zhang et al., 2024; Nishiura et al., 2022). Finalmente, algoritmos de extracción de características de textura mejoran la identificación en superficies homogéneas de acero (Frustaci et al., 2022; Lin et al., 2023).

**Tabla N°6:** Modelos de visión computacional

Modelos de visión computacional	N°	Autores
Incluye modelos como DSTEELNet y redes convolucionales (CNN) con módulos de pirámide espacial atrous, utilizados para detectar defectos en tiras y superficies planas de acero en tiempo real. Estos modelos mejoran la precisión en la detección de defectos, especialmente en laminados en caliente y frío, al combinar diferentes técnicas de visión.	5	Ahmed (2023); Schneider et al. (2023); Luo et al. (2019); Fang et al. (2018)
Incluye modelos como EnsGAN-SDD que emplea redes generativas antagónicas (GAN) para mejorar la resolución de imagen y DetectoRS para alta resolución. También se destaca MSFT-YOLO basado en transformer, optimizado para manejar defectos complejos en entornos industriales, logrando una precisión mejorada en comparación con versiones anteriores.	3	Akhyar et al. (2023); Guo et al. (2022); Landgraf et al. (2022)
Se enfoca en la segmentación con redes como CASPPNet y la fusión de características multidimensionales para mejorar la precisión en la detección de defectos en acero, especialmente en condiciones industriales con alto ruido de fondo.	3	Zheng et al. (2021); Xue et al. (2021); Hao et al. (2024)
Utiliza modelos específicos como DCNN para el análisis de microestructuras en imágenes metalográficas y YOLOv8n mejorado para detectar defectos en componentes oxidados. Además, emplea sistemas de visión robustos con aceleración hardware-software y técnicas de aprendizaje automático para la inspección de microestructuras de acero.	4	O'Donovan et al. (2024); Liu et al. (2021); Zhang et al. (2024); Nishiura et al. (2022)
Incluye algoritmos avanzados de extracción de características de textura y procesamiento de imagen, diseñados específicamente para superficies de acero homogéneas, mejorando la precisión en la identificación de defectos visibles y detallados.	2	Frustaci et al. (2022); Lin et al. (2023)

Fuente: Elaboración propia

**Figura N°2:** Imagen y DETECTORS para alta resolución

**Fuente:** Akhyar, (2023).

Nota: Tiene la condición de defecto de superficie y tiene la condición de defecto.

#### **4.2.3. Datos de entrada**

La tabla 7 detalla los datos de entrada utilizados para la inspección de defectos en acero, esenciales para optimizar la calidad en distintas fases de producción. Imágenes de alta resolución capturadas en tiempo real, o mejoradas con superresolución, son fundamentales para detectar defectos como rayones y grietas en productos laminados en caliente y frío, lo que contribuye a la precisión en la inspección (Ahmed, 2023; Lin et al., 2023; Akhyar et al., 2023; Luo et al., 2019; Zheng et al., 2021).

Para superficies galvanizadas, las imágenes capturadas permiten analizar variaciones en el recubrimiento y texturas, útiles para detectar salpicaduras de zinc y realizar un análisis detallado de patrones superficiales (Schneider et al., 2023; Fang et al., 2018; Xue et al., 2021; Liu et al., 2021). Cámaras de alta velocidad y sensores 3D son empleados en la inspección de tiras laminadas en caliente, proporcionando una captura de imágenes en tiempo real que sostiene la eficiencia en la producción (Guo et al., 2022; Zhang et al., 2024).

Las imágenes multiespectrales y de fusión (térmica y visible) se utilizan para destacar defectos pequeños en condiciones complejas, permitiendo un análisis avanzado de la superficie (Landgraf et al., 2022; Hao et al., 2024). Finalmente, imágenes 2D, 3D, y micrografías permiten la alineación y evaluación de microestructuras, útiles para el análisis de estructuras internas tras tratamientos térmicos (O'Donovan et al., 2024; Frustaci et al., 2022; Nishiura et al., 2022).

**Tabla N°7:** Datos de entrada

Datos de entrada	N°	Autores
Se emplean imágenes de alta resolución de superficies de acero laminado, ya sea capturadas en tiempo real o mejoradas mediante superresolución. Estas imágenes facilitan la detección de defectos como rayones, grietas y deformaciones en productos laminados en caliente y frío, optimizando así el proceso de inspección de calidad.	5	Ahmed (2023); Lin et al. (2023); Akhyar et al. (2023); Luo et al. (2019); Zheng et al. (2021)
Se utilizan imágenes tomadas de superficies galvanizadas y texturas de acero plano para identificar variaciones en el recubrimiento y analizar patrones superficiales. Este tipo de información es particularmente valiosa para detectar salpicaduras de zinc y llevar a cabo un análisis exhaustivo de las texturas.	5	Schneider et al. (2023); Fang et al. (2018); Xue et al. (2021); Liu et al. (2021)
Cámaras de alta velocidad y sensores 3D registran imágenes en tiempo real, siendo perfectos para inspeccionar defectos en tiras de acero laminado en caliente. La rápida captura de imágenes ayuda a mantener la eficiencia en la línea de producción mientras se identifican defectos durante el proceso.	2	Guo et al. (2022); Zhang et al. (2024)
Se utilizan imágenes multiespectrales y técnicas de fusión (térmica y visible) para identificar defectos en tiempo real. Estas imágenes son especialmente efectivas para destacar defectos pequeños y facilitan un análisis detallado de la superficie de acero en condiciones complejas.	2	Landgraf et al. (2022); Hao et al. (2024)
Se utilizan imágenes 2D y 3D, así como micrografías y análisis microscópicos, para la alineación, medición geométrica y evaluación de microestructuras. Son especialmente valiosas en el análisis detallado de las estructuras internas y características de los productos de acero tras su tratamiento térmico.	3	O'Donovan et al. (2024); Frustaci et al. (2022); Nishiura et al. (2022)

Fuente: Elaboración propia

#### 4.3.4. Variable que utilizan los modelos

La tabla 8 describe las variables principales utilizadas por los modelos de detección de defectos en acero, simplificando el enfoque técnico. Muchos modelos emplean análisis de textura de superficie y patrones usando transformada de Fourier y redes neuronales (CNN) para detectar rayones, grietas y variabilidad en superficies planas de acero (Ahmed, 2023; Lin et al., 2023; Luo et al., 2019; Fang et al., 2018).

Otros modelos aplican segmentación basada en dimensiones multifractales, enfocándose en un análisis detallado de las texturas para identificar variaciones en la superficie (Akhyar et al., 2023; Fang et al., 2018). También se utilizan características de microestructura, como distribución de carburos, para evaluar la calidad del acero (O'Donovan et al., 2024; Nishiura et al., 2022).

Para productos galvanizados, se asegura la uniformidad del recubrimiento de zinc mediante técnicas de sustracción de fondo, detectando salpicaduras y otros defectos (Schneider et al., 2023). Además, la transformada de Gabor y características morfológicas ayudan a identificar microgrietas y agujeros en superficies laminadas (Guo et al., 2022; Landgraf et al., 2022).

Algunos modelos combinan datos de textura, geometría y brillo para evaluar defectos de forma tridimensional (Hao et al., 2024; Frustaci et al., 2022). Finalmente, se emplea información semántica y propiedades de color para analizar defectos complejos, como aquellos en superficies oxidadas (Zheng et al., 2021; Xue et al., 2021; Zhang et al., 2024).

**Tabla N°8:** Variable principal utilizan los modelos

Variable principal utilizan los modelos	N°	Autores
Los modelos utilizan el análisis de la textura de la superficie, patrones de textura y espectros de energía. Emplean técnicas como la transformada de Fourier y redes neuronales convolucionales (CNN) para identificar defectos como rayones, grietas y variaciones en superficies planas de acero.	5	Ahmed (2023); Lin et al. (2023); Luo et al. (2019); Fang et al. (2018)
Modelos que utilizan segmentación de textura basada en dimensiones multifractales para detectar variaciones en la superficie del acero, centrándose en un análisis profundo y segmentación de texturas.	2	Akhyar et al. (2023); Fang et al. (2018)
Se emplean características de microestructura obtenidas a través de análisis metalográfico y la distribución de carburos para evaluar la calidad del acero y clasificar sus propiedades.	2	O'Donovan et al. (2024); Nishiura et al. (2022)
Se enfoca en la uniformidad del recubrimiento de zinc, utilizando técnicas de sustracción de fondo para identificar defectos de salpicaduras y garantizar la calidad en productos galvanizados.	1	Schneider et al. (2023)
Modelos que utilizan la transformada de Gabor y características morfológicas para identificar microgrietas y agujeros en superficies laminadas, aumentando la precisión en entornos industriales.	2	Guo et al. (2022); Landgraf et al. (2022)
Los modelos combinan información multidimensional, como textura, geometría y brillo, junto con datos tridimensionales, para llevar a cabo la segmentación geométrica y evaluar defectos.	2	Hao et al. (2024); Frustaci et al. (2022)
Modelos que emplean información semántica enriquecida, momentos invariantes y características de color para examinar defectos complejos, especialmente en componentes oxidados o en condiciones de difícil inspección.	3	Zheng et al. (2021); Xue et al. (2021); Zhang et al. (2024)

Fuente: Elaboración propia

#### 4.3.5. Tamaño de muestra

La Tabla 9 sintetiza el tamaño de muestra utilizado en diversos estudios para analizar defectos en acero. En algunos casos, se emplearon grandes conjuntos de datos como NEU y Severstal, con aproximadamente 12,000 imágenes de defectos en tiras de acero, además de un dataset expandido mediante redes generativas adversariales y análisis de microestructuras basado en 2 millones de imágenes de microscopía óptica (Ahmed, 2023; Akhyar et al., 2023; O'Donovan et al., 2024).

Otros estudios capturan imágenes en tiempo real durante procesos de laminado y galvanizado, utilizando cámaras CCD y anotación de datos, aunque sin especificar un

número exacto de muestras (Lin et al., 2023; Schneider et al., 2023; Luo et al., 2019; Fang et al., 2018).

En condiciones controladas de laboratorio, se analizaron entre 1,200 y 2,500 muestras, considerando variables como temperatura, estrés mecánico y condiciones de producción normales para acero laminado en frío y galvanizado (Guo et al., 2022; Landgraf et al., 2022; Zheng et al., 2021; Xue et al., 2021).

Finalmente, en condiciones de alta producción industrial, se evaluaron entre 1,500 y 2,200 muestras bajo simulaciones de vibración y desgaste, tanto en línea de producción como en laboratorio, asegurando precisión en entornos industriales (Liu et al., 2021; Zhang et al., 2024; Hao et al., 2024; Frustaci et al., 2022; Nishiura et al., 2022).

**Tabla N°9:** Tamaño de muestra

Tamaño de muestra	N°	Autores
Se emplearon grandes conjuntos de datos como NEU y Severstal, con aproximadamente 12,000 imágenes de defectos en tiras de acero. También se usó un dataset expandido mediante redes generativas adversariales, partiendo de 5,000 imágenes, y un análisis de microestructuras basado en 2 millones de imágenes de microscopía óptica.	3	Ahmed (2023); Akhyar et al. (2023); O'Donovan et al. (2024)
Los estudios capturan imágenes en tiempo real durante procesos de laminado y galvanizado, utilizando sistemas de cámaras CCD y anotación de datos, aunque no se especifica un número exacto de muestras.	5	Lin et al. (2023); Schneider et al. (2023); Luo et al. (2019); Fang et al. (2018)
Los estudios analizaron entre 1,200 y 2,500 muestras en condiciones controladas de laboratorio, incluyendo variaciones de temperatura, estrés mecánico, y condiciones de producción normales en acero laminado en frío y galvanizado.	4	Guo et al. (2022); Landgraf et al. (2022); Zheng et al. (2021); Xue et al. (2021)
Incluyen entre 1,500 y 2,200 muestras evaluadas en condiciones de alta producción industrial, simulando condiciones de vibración y desgaste. Las evaluaciones se realizaron tanto en línea de producción como en ambientes de laboratorio para asegurar precisión en entornos industriales.	5	Liu et al. (2021); Zhang et al. (2024); Hao et al. (2024); Frustaci et al. (2022); Nishiura et al. (2022)

**Fuente:** Elaboración propia

#### 4.3.6. Métodos de evaluación actuales para mejorar la calidad en la producción del acero

Los métodos de evaluación actuales para mejorar la calidad en la producción de acero están detallados en las Tablas 10, 11, 12 y 13, combinando técnicas manuales, automatizadas y machine learning. La Tabla 10 describe cómo la inspección visual bajo condiciones específicas (luz polarizada, alta temperatura) detecta defectos en aceros laminados y planos (Ahmed, 2023; Schneider et al., 2023). Herramientas como rayos X y ultrasonidos complementan la inspección visual para detectar grietas y defectos profundos (Akhyar et al., 2023; Luo et al., 2019). También se utilizan pruebas químicas y espectrometría para evaluar microestructuras y bordes en acero (Lin et al., 2023; Zheng et al., 2021).

La tabla 10 destaca sistemas automatizados en laminado en caliente y frío para inspección en tiempo real, asegurando calidad en tiras y láminas (Lin et al., 2023; Luo et al., 2019). En galvanización, los sistemas detectan defectos en recubrimientos de zinc (Schneider et al., 2023). Además, cámaras de escaneo optimizan la inspección continua en producción y corte final (Guo et al., 2022; Landgraf et al., 2022). Según la tabla 11, machine learning reduce los tiempos de evaluación a menos de un segundo, logrando eficiencias superiores al 99% frente a métodos manuales de hasta 50 minutos (Lin et al., 2023; Fang et al., 2018). Otros modelos procesan datos en 0.7 a 1.5 segundos, incluso en condiciones industriales complejas (O'Donovan et al., 2024; Schneider et al., 2023).

En la tabla 12 se detalla la inspección de productos bajo condiciones específicas. El acero estructural se evalúa en escenarios de alta temperatura y presión (Ahmed, 2023; Luo et al., 2019). El acero laminado y las chapas galvanizadas son inspeccionados para detectar desgaste y corrosión (Lin et al., 2023; Akhyar et al., 2023). También se analizan microestructuras en ambientes húmedos para oxidación y estrés mecánico (O'Donovan et al., 2024; Fang et al., 2018).

Las tablas 10, 11, 12 y 13 muestran cómo los métodos manuales, automatizados y machine learning contribuyen a mejorar la calidad en la producción de acero.

**Tabla N°10:** Métodos o técnicas manuales

Métodos o técnicas manuales	N°	Autores
Se lleva a cabo una inspección visual bajo condiciones específicas de iluminación y ambiente, como alta temperatura, oscuridad o luz polarizada.	4	Ahmed (2023); Schneider et al. (2023); Xue et al. (2021); Hao et al. (2024)
La inspección visual se apoya en herramientas como rayos X, ultrasonido y microscopía en frío para facilitar la identificación de grietas, defectos profundos y problemas en zonas oxidadas.	4	Akhyar et al. (2023); Luo et al. (2019); Landgraf et al. (2022); Liu et al. (2021)
Se emplean pruebas de laboratorio y análisis químico junto con la inspección visual para evaluar.	4	Lin et al. (2023); O'Donovan et al. (2024); Fang et al. (2018); Guo et al. (2022)
Se utilizan técnicas especializadas como luz polarizada, espectrometría y microscopía óptica para analizar bordes, grietas pequeñas y defectos irregulares en aceros planos y en las microestructuras de acero.	4	Zheng et al. (2021); Zhang et al. (2024); Frustaci et al. (2022); Nishiura et al. (2022)

Fuente: Elaboración propia

**Tabla N°11:** Fase de producción se usan métodos automatizados

Fase de producción se usan métodos automatizados	N°	Autores
Los métodos automatizados se utilizan principalmente en el laminado en caliente y frío para supervisar y garantizar la calidad de productos planos de acero, como tiras y láminas. Esta etapa facilita la detección de defectos en tiempo real y aumenta la eficiencia de la producción.	4	Lin et al. (2023); Luo et al. (2019); Zheng et al. (2021); Zhang et al. (2024)
Los sistemas de inspección automatizada se aplican durante la galvanización para identificar en tiempo real defectos en el recubrimiento de zinc, garantizando la uniformidad y calidad del recubrimiento en productos de acero galvanizado.	2	Schneider et al. (2023); Xue et al. (2021)
En la producción continua de tiras de acero en caliente, se implementan cámaras de escaneo y otros sistemas automatizados para llevar a cabo inspecciones en tiempo real. Esto facilita la detección de defectos de superficie y contribuye a mejorar la eficiencia de la línea de producción.	3	Akhyar et al. (2023); Guo et al. (2022); Liu et al. (2021)

Tras la fase de enfriamiento y tratamiento térmico, se aplican técnicas de inspección automatizadas para analizar las microestructuras, garantizando el control de calidad antes del almacenamiento o el ensamblaje final.	3	O'Donovan et al. (2024); Hao et al. (2024); Nishiura et al. (2022)
La inspección automatizada se efectúa durante el procesamiento final, corte y empaque de láminas de acero para garantizar que las superficies estén libres de defectos antes de su envío. También abarca el posicionamiento en líneas de ensamblaje en algunas aplicaciones industriales.	3	Fang et al. (2018); Landgraf et al. (2022); Frustaci et al. (2022)

Fuente: Elaboración propia

**Tabla N°12:** Tiempo de evaluación automatizada

Tiempo de evaluación automatizada	N°	Autores
El tiempo promedio de procesamiento con Machine learning es de 0.035 y 0.005 segundos, en contraste con los 25 a 30 minutos que se requieren manualmente. Esto representa una reducción de más del 99%.	2	Lin et al. (2023); Fang et al. (2018)
El machine learning reduce el tiempo de procesamiento a un rango de 0.1 a 0.195 segundos, en comparación con los 30 a 45 minutos que se requieren manualmente, logrando así una reducción de más del 99%.	3	Ahmed (2023); Akhyar et al. (2023); Fang et al. (2018)
Los promedios de tiempo utilizando Machine learning están entre 0.68 y 1.2 segundos, en contraste con los 10 a 20 segundos que demandan los métodos manuales, lo que produce reducciones notables.	3	Luo et al. (2019); Zheng et al. (2021); Liu et al. (2021)
El promedio de tiempo con machine learning varía entre 1.1 y 2 segundos, mientras que los métodos manuales toman entre 20 y 30 segundos, lo que resulta en eficiencias destacadas en el proceso de inspección.	5	Guo et al. (2022); Landgraf et al. (2022); Hao et al. (2024); Frustaci et al. (2022); Nishiura et al. (2022)
Los tiempos de procesamiento con machine learning oscilan entre 0.7 y 1.5 segundos, en contraste con los 12 a 50 minutos necesarios para los métodos manuales, lo que resulta en una mejora de eficiencia superior al 98%.	4	O'Donovan et al. (2024); Schneider et al. (2023); Xue et al. (2021); Zhang et al. (2024)

Fuente: Elaboración propia

**Tabla N°13:** Productos pueden ser inspeccionados manualmente

Productos pueden ser inspeccionados manualmente	N°	Autores
Evaluación de muestras de acero estructural bajo diversas condiciones: 50 muestras en luz natural y vibración. 45 muestras en alta presión y temperatura. 55 muestras en baja presión y humedad. 60 muestras en alta temperatura.	4	Ahmed (2023); Schneider et al. (2023); Luo et al. (2019); Zhang et al. (2024)
Análisis de muestras de acero laminado en frío en condiciones variadas: 40 muestras a alta temperatura. 50 muestras bajo presión para detectar microfisuras. 55 muestras evaluadas en bordes bajo vibración	3	Lin et al. (2023); Zheng et al. (2021); Frustaci et al. (2022)
Inspección de chapas galvanizadas en condiciones controladas: 60 muestras de chapas en baja temperatura para detectar corrosión. 45 muestras de tiras en frío para desgaste y corrosión.	2	Akhyar et al. (2023); Liu et al. (2021)
Evaluación de acero inoxidable en entornos específicos: 35 muestras en ambientes húmedos. 40 muestras en alta vibración para estrés mecánico. 30 muestras en ambientes húmedos para oxidación. 35 muestras en alta vibración para adherencia.	4	O'Donovan et al. (2024); Fang et al. (2018); Guo et al. (2022); Xue et al. (2021)
Análisis en acero de herramienta y acero plano: 30 muestras de herramienta en humedad para desgaste y cortes. 40 muestras en calor para grietas. 50 muestras de acero plano en baja luz para porosidad. 40 muestras de herramienta en baja temperatura para fisuras.	4	Fang et al. (2018); Landgraf et al. (2022); Hao et al. (2024); Nishiura et al. (2022)

Fuente: Elaboración propia

#### 4.3.7. Niveles de eficiencia de los modelos de machine learning y sus limitaciones

En el caso de los modelos de machine learning aplicados a la inspección de acero, una de las métricas más relevantes para medir su eficiencia es la precisión. Según la tabla 14, destacan los trabajos de Luo et al. (2019) y Hao et al. (2024), que alcanzan una precisión del 99% en texturas complejas y técnicas de aprendizaje profundo, seguidos de Ahmed (2023), Lin et al. (2023) y Schneider et al. (2023) con valores entre 95% y 98% en defectos como grietas y abolladuras. Por otro lado, modelos como los de O'Donovan

et al. (2024) y Frustaci et al. (2022) muestran una precisión del 92% al 95% en microestructuras y ensamblajes industriales.

Sin embargo; pese a estos resultados prometedores, aún existen limitaciones identificadas en la tabla 15. Por ejemplo, los sistemas enfrentan dificultades para detectar defectos pequeños o con texturas similares al fondo, lo que se atribuye a problemas de resolución (Ahmed, 2023; Akhyar et al., 2023). Además, factores como la sensibilidad a condiciones de iluminación y ruido visual afectan la estabilidad de los modelos en entornos industriales complejos (Lin et al., 2023; Zhang et al., 2024). Otra limitación es la dependencia de bases de datos poco diversas, lo que dificulta la generalización de los modelos en diferentes escenarios (Fang et al., 2018; Nishiura et al., 2022). Finalmente, en entornos con alto volumen de datos, equilibrar precisión y velocidad sigue siendo un desafío significativo (O'Donovan et al., 2024; Luo et al., 2019).

Estos resultados reflejan la necesidad de seguir optimizando los modelos de machine learning para superar las barreras actuales y mejorar su desempeño en aplicaciones reales.

**Tabla N°14:** Precisión del machine learning

Precisión del machine learning	N°	Autores
Alta precisión en modelos de detección de defectos en superficies de acero: 95% de precisión en redes neuronales profundas. 97% en superficies lisas. 98% en detección de grietas y abolladuras. 94% en detección de texturas. 97% en bordes y patrones repetitivos. 95% en detección de abolladuras.	6	Ahmed (2023); Lin et al. (2023); Akhyar et al. (2023); Schneider et al. (2023); Fang et al. (2018)
Modelos con alta precisión en bordes y defectos microscópicos: 96% con alta sensibilidad en bordes. 94.5% en defectos microscópicos. Superior al 95% usando segmentación avanzada.	3	O'Donovan et al. (2024); Guo et al. (2022); Zheng et al. (2021)
Precisión en condiciones específicas y texturas complejas: 99% en técnicas avanzadas de aprendizaje profundo. 96% en condiciones de ruido y baja iluminación. 93% en partes mecánicas corroídas. 97% utilizando fusión de información multidimensional.	4	Luo et al. (2019); Xue et al. (2021); Zhang et al. (2024); Hao et al. (2024)
Precisión en inspección de ensamblajes y microestructuras: 92% en láminas laminadas. 95% en líneas de ensamblaje complejas. 92.5% en estimación de calidad de microestructuras.	3	Landgraf et al. (2022); Frustaci et al. (2022); Nishiura et al. (2022)

Fuente: Elaboración propia

**Tabla N°15: Limitaciones**

Limitaciones	N°	Autores
Los sistemas tienen dificultades para identificar defectos pequeños o de baja intensidad debido a su resolución limitada y a la dificultad para diferenciarlos de texturas que son similares al fondo.	3	Ahmed (2023); Akhyar et al. (2023); Liu et al. (2021)
Existe una alta sensibilidad a las condiciones de iluminación, el contraste y las variaciones de luz, lo que impacta la precisión, especialmente en superficies reflectantes o texturas complejas.	3	Lin et al. (2023); Landgraf et al. (2022); Hao et al. (2024)
El sistema presenta sensibilidad a interferencias como polvo, vibraciones y ruido visual, lo que afecta su estabilidad y robustez en entornos industriales complejos.	3	Schneider et al. (2023); Zheng et al. (2021); Zhang et al. (2024)
La dependencia de bases de datos con escasa diversidad complica la generalización de los modelos y genera variabilidad en los resultados, dependiendo de la preparación y anotación de las imágenes.	2	Fang et al. (2018); Nishiura et al. (2022)
Existen limitaciones en la segmentación y clasificación de defectos irregulares o poco comunes, así como dificultades para gestionar ruido en las imágenes y datos desbalanceados.	2	Luo et al. (2019); Xue et al. (2021)
Hay dificultades para equilibrar la precisión y la velocidad en la detección de defectos en tiempo real, especialmente en líneas de producción con un alto volumen de datos.	2	O'Donovan et al. (2024); Fang et al. (2018)
Las limitaciones de hardware dificultan la implementación de sistemas de visión que demandan un alto consumo computacional, lo que impacta la eficiencia en la inspección automatizada.	1	Frustaci et al. (2022)

Fuente: Elaboración propia

#### 4.3.8. Mejora la evaluación de la calidad del acero utilizando machine learning

La aplicación de machine learning en la producción de acero ha optimizado significativamente los procesos de inspección y control de calidad. Según la tabla 16, los sistemas automatizados permiten reducir costos entre un 15% y un 53%, disminuyendo retrabajos, desperdicio de materiales y errores humanos (Ahmed, 2023; Lin et al., 2023; Luo et al., 2019; Hao et al., 2024). Además, se elimina la necesidad de inspecciones manuales redundantes y se optimizan tareas repetitivas, incrementando la eficiencia del proceso (Zheng et al., 2021; Xue et al., 2021).

Las ventajas de estas metodologías se detallan en la tabla 17, donde se observa un incremento del 10% en la producción y una reducción del 15% en defectos gracias al

control en tiempo real y la detección de problemas sin detener la línea de producción (Ahmed, 2023; Fang et al., 2018; Landgraf et al., 2022). La inspección automatizada también mejora la productividad al evitar interrupciones y permite identificar defectos en superficies oxidadas sin necesidad de procesos de limpieza previos (Zhang et al., 2024; Hao et al., 2024).

En cuanto a los resultados específicos, la tabla 18 destaca modelos como DSTEELNet y YOLOv5, que alcanzan precisiones superiores al 95%, con tiempos de inspección en milisegundos por imagen, optimizando el control de calidad en tiempo real (Ahmed, 2023; Schneider et al., 2023; Luo et al., 2019). Además, algoritmos avanzados de segmentación multifractal logran una precisión del 92% en superficies homogéneas y heterogéneas (Akhyar et al., 2023; Fang et al., 2018). La integración de machine learning también ha reducido falsos positivos en un 15% y mejorado la confiabilidad de los sistemas en líneas de producción (Fang et al., 2018; Zhang et al., 2024).

Las tablas 16, 17 y 18 evidencian como la implementación de machine learning ha transformado los procesos de inspección en la industria del acero, logrando una mayor eficiencia, reducción de costos y una calidad superior en los productos finales.

**Tabla N°16:** Alcance del método automatizado

Alcance del método automatizado	N°	Autores
La automatización en la inspección de acero permite una reducción de costes entre un 45% y un 53%, logrando mayor eficiencia en el proceso y reduciendo la necesidad de intervención manual en tareas repetitivas.	4	Ahmed (2023); Lin et al. (2023); Luo et al. (2019); Fang et al. (2018)
La automatización permite reducir costos en un 20% a 30%, optimizando el uso de personal y reduciendo los rechazos por falsos positivos en inspecciones.	3	Fang et al. (2018); Guo et al. (2022); Landgraf et al. (2022)
La automatización en inspecciones reduce entre un 18% y un 35% los costos asociados a retrabajos y desperdicio de materiales defectuosos, disminuyendo los errores humanos en el proceso.	4	Zheng et al. (2021); Xue et al. (2021); Liu et al. (2021); Zhang et al. (2024)
La implementación de sistemas automatizados ha reducido los costos en un rango del 15% al 40%, optimizando la clasificación, selección de materiales y eliminando inspecciones redundantes.	3	Hao et al. (2024); Frustaci et al. (2022); Nishiura et al. (2022)

Fuente: Elaboración propia

**Tabla N°17:** Ventajas de la propuesta

Ventajas de la propuesta	N°	Autores
Las metodologías automatizadas permiten un control en tiempo real, mejorando la tasa de producción y reduciendo el desperdicio al disminuir los productos defectuosos y optimizar el flujo de producción, con un incremento estimado del 10% en la producción y una reducción del 15% en defectos.	5	Ahmed (2023); Lin et al. (2023); Akhyar et al. (2023); Schneider et al. (2023); Luo et al. (2019)
La visión computacional y la automatización de inspección permiten mantener un flujo continuo en la línea de producción, eliminando la necesidad de interrupciones para la inspección, lo que se traduce en mayor productividad y una mejora en la eficiencia del proceso.	5	Fang et al. (2018); Fang et al. (2018); Guo et al. (2022); Zheng et al. (2021); Xue et al. (2021)
La inspección automatizada en tiempo real reduce los errores humanos y permite detectar defectos sin detener la línea de producción, con beneficios adicionales en la remanufactura al evitar la necesidad de limpieza previa para identificar defectos en superficies oxidadas.	5	Landgraf et al. (2022); Liu et al. (2021); Zhang et al. (2024); Hao et al. (2024); Frustaci et al. (2022)
Las mejoras en la microscopía automatizada permiten un análisis consistente y fluido de microestructuras, optimizando el flujo de producción y reduciendo defectos en productos complejos.	2	O'Donovan et al. (2024); Nishiura et al. (2022)

Fuente: Elaboración propia

**Tabla N°18:** Resultados de los estudios

Resultados de los estudios	N°	Autores
Modelos como DSTEELNet y YOLOv5 han alcanzado precisiones superiores al 95%, logrando tiempos de inspección en el rango de milisegundos por imagen. Esto ha optimizado el control de calidad en tiempo real, permitiendo una detección rápida y precisa de defectos en superficies de acero laminado y galvanizado.	5	Ahmed (2023); Lin et al. (2023); O'Donovan et al. (2024); Schneider et al. (2023); Luo et al. (2019)
Mediante redes convolucionales profundas y algoritmos avanzados de segmentación multifractal, los sistemas han mejorado significativamente en la resolución de imágenes y la segmentación de texturas complejas, logrando precisiones de hasta el 92% en superficies homogéneas y heterogéneas de acero.	4	Akhyar et al. (2023); Fang et al. (2018); Landgraf et al. (2022); Zheng et al. (2021)
La integración de machine learning en el procesamiento masivo de datos ha reducido falsos positivos en un 15% y optimizado el flujo de inspección, logrando tiempos de procesamiento de hasta 1 segundo por imagen y mejorando la confiabilidad en la identificación de defectos.	5	Fang et al. (2018); Guo et al. (2022); Xue et al. (2021); Zhang et al. (2024); Hao et al. (2024)
La automatización de la inspección mediante machine learning ha reducido significativamente los costos y ha mejorado la eficiencia de los procesos, alcanzando una precisión del 92.5% y superando la calidad de las inspecciones manuales en aceros especiales y otros productos metálicos.	3	Liu et al. (2021); Frustaci et al. (2022); Nishiura et al. (2022)

Fuente: Elaboración propia

## 5. Discusión

En esta revisión sistemática, se ha encontrado que la aplicación de machine learning en la inspección de acero ha mejorado significativamente la eficiencia y precisión de los procesos de control de calidad. Según Ahmed (2023) y Schneider et al. (2023), los modelos de machine learning alcanzan precisiones superiores al 95%, mientras que el tiempo promedio de procesamiento es de tan solo 0.035 a 1.5 segundos por imagen, en comparación con los tiempos manuales que pueden extenderse hasta 50 minutos (Lin et al., 2023; Fang et al., 2018). Esta diferencia se explica por dos razones principales. La primera es la capacidad de los sistemas automatizados para procesar grandes volúmenes de datos en tiempo real, lo que elimina la dependencia del trabajo manual y los retrasos asociados. La segunda es la integración de técnicas avanzadas de segmentación y aprendizaje profundo, como las reportadas por Luo et al. (2019) y Hao et al. (2024), que optimizan la detección de defectos incluso en superficies complejas.

Sin embargo, aunque la automatización ha demostrado ser eficaz, se identificaron limitaciones importantes. Por ejemplo, los sistemas son sensibles a condiciones de iluminación, ruido visual y la resolución de las imágenes de entrada, lo que puede afectar su desempeño en entornos industriales desafiantes (Zheng et al., 2021; Zhang et al., 2024). Además, la dependencia de bases de datos limitadas en diversidad dificulta la generalización de los modelos a diferentes escenarios de producción (Fang et al., 2018; Nishiura et al., 2022). Finalmente, la implementación de estos sistemas requiere hardware de alto consumo computacional, lo que puede ser una barrera para empresas con recursos limitados (Frustaci et al., 2022). A pesar de estas limitaciones, los resultados de esta revisión subrayan que la automatización basada en machine learning ha sentado bases sólidas para una producción más eficiente y sostenible en la industria del acero.

## **6. Conclusiones**

En este estudio se realizó una revisión exhaustiva de la literatura científica para analizar el impacto de machine learning en la inspección y control de calidad en la producción de acero. Los hallazgos destacan que la aplicación de métodos automatizados ha reducido significativamente los tiempos de inspección y ha mejorado la precisión, logrando eficiencias superiores al 95% en la detección de defectos.

La automatización permite no solo identificar defectos con mayor rapidez, sino también optimizar la producción al reducir los costos asociados al desperdicio y a los retrabajos. Además, su implementación minimiza los errores humanos, favoreciendo la sostenibilidad de los procesos industriales. No obstante, se identifican limitaciones relacionadas con la resolución de los sistemas, las condiciones del entorno y la dependencia de bases de datos específicas.

Aunque existen desafíos por superar, los avances en machine learning ofrecen un gran potencial para transformar la inspección de acero, marcando un camino hacia una producción más eficiente, rentable y de alta calidad. Es fundamental continuar investigando en la diversificación de bases de datos y en el desarrollo de tecnologías más accesibles para maximizar el impacto de estas herramientas en la industria.

## **7. Agradecimientos**

Agradecemos a la Universidad Tecnológica del Perú (UTP) por su apoyo y por brindarnos las herramientas necesarias para desarrollar esta revisión sistemática.

De manera especial, reconocemos al docente Jorge Luis Roca Becerra por su valiosa guía y motivación, que fueron fundamentales para completar este trabajo con éxito.

## 8. Literatura citada

- AHMED, K. R. (2023). DSTEELNET: A REAL-TIME PARALLEL DILATED CNN WITH ATROUS SPATIAL PYRAMID POOLING FOR DETECTING AND CLASSIFYING DEFECTS IN SURFACE STEEL STRIPS. *SENSORS*, 23(1), 544. [HTTPS://DOI.ORG/10.3390/S23010544](https://doi.org/10.3390/s23010544)
- AKHYAR, F., FURQON, E. N., & LIN, C. (2022). ENHANCING PRECISION WITH AN ENSEMBLE GENERATIVE ADVERSARIAL NETWORK FOR STEEL SURFACE DEFECT DETECTORS (ENS-GAN-SDD). *SENSORS*, 22(11), 4257. [HTTPS://DOI.ORG/10.3390/S22114257](https://doi.org/10.3390/s22114257)
- FANG, X., LUO, Q., ZHOU, B., LI, C., & TIAN, L. (2020A). RESEARCH PROGRESS OF AUTOMATED VISUAL SURFACE DEFECT DETECTION FOR INDUSTRIAL METAL PLANAR MATERIALS. *SENSORS*, 20(18), 5136. [HTTPS://DOI.ORG/10.3390/S20185136](https://doi.org/10.3390/s20185136)
- FANG, X., LUO, Q., ZHOU, B., LI, C., & TIAN, L. (2020B). RESEARCH PROGRESS OF AUTOMATED VISUAL SURFACE DEFECT DETECTION FOR INDUSTRIAL METAL PLANAR MATERIALS. *SENSORS*, 20(18), 5136. [HTTPS://DOI.ORG/10.3390/S20185136](https://doi.org/10.3390/s20185136)
- 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](https://doi.org/10.3390/s22082839)
- GUO, Z., WANG, C., YANG, G., HUANG, Z., & LI, G. (2022). MSFT-YOLO: IMPROVED YOLOv5 BASED ON TRANSFORMER FOR DETECTING DEFECTS OF STEEL SURFACE. *SENSORS*, 22(9), 3467. [HTTPS://DOI.ORG/10.3390/S22093467](https://doi.org/10.3390/s22093467)
- HAO, Z., WANG, Z., BAI, D., & ZHOU, S. (2021). TOWARDS THE STEEL PLATE DEFECT DETECTION: MULTI-DIMENSIONAL FEATURE INFORMATION EXTRACTION AND FUSION. *CONCURRENCY AND COMPUTATION PRACTICE AND EXPERIENCE*, 33(21). [HTTPS://DOI.ORG/10.1002/CPE.6384](https://doi.org/10.1002/cpe.6384)
- LANDGRAF, J. (2023). COMPUTER VISION FOR INDUSTRIAL DEFECT DETECTION. *MATERIALS RESEARCH PROCEEDINGS*, 25, 371-378. [HTTPS://DOI.ORG/10.21741/9781644902417-46](https://doi.org/10.21741/9781644902417-46)
- LIN, Y., WANG, P., WANG, Z., ALI, S., & MIHAYLOVA, L. (2023). TOWARDS AUTOMATED REMOTE SIZING AND HOT STEEL MANUFACTURING WITH IMAGE REGISTRATION AND FUSION. *JOURNAL OF INTELLIGENT MANUFACTURING*. [HTTPS://DOI.ORG/10.1007/S10845-023-02251-9](https://doi.org/10.1007/s10845-023-02251-9)
- LIU, K., LUO, N., LI, A., TIAN, Y., SAJID, H., & CHEN, H. (2019). A NEW SELF-REFERENCE IMAGE DECOMPOSITION ALGORITHM FOR STRIP STEEL SURFACE DEFECT DETECTION. *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, 69(7), 4732-4741. [HTTPS://DOI.ORG/10.1109/TIM.2019.2952706](https://doi.org/10.1109/TIM.2019.2952706)
- LUO, Q., FANG, X., LIU, L., YANG, C., & SUN, Y. (2020A). AUTOMATED VISUAL DEFECT DETECTION FOR FLAT STEEL SURFACE: A SURVEY. *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, 69(3), 626-644. [HTTPS://DOI.ORG/10.1109/TIM.2019.2963555](https://doi.org/10.1109/TIM.2019.2963555)

- LUO, Q., FANG, X., LIU, L., YANG, C., & SUN, Y. (2020B). AUTOMATED VISUAL DEFECT DETECTION FOR FLAT STEEL SURFACE: A SURVEY. *IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT*, 69(3), 626-644. [HTTPS://DOI.ORG/10.1109/TIM.2019.2963555](https://doi.org/10.1109/TIM.2019.2963555)
- MINISTERIO DE TRABAJO Y PROMOCIÓN DEL EMPLEO (2021). ANUARIO ESTADÍSTICO SECTORIAL 2020. [HTTPS://CDN.WWW.GOB.PE/UPLOADS/DOCUMENT/FILE/2038301/ANUARIO\\_2020.PDF](https://cdn.www.gob.pe/uploads/document/file/2038301/ANUARIO_2020.PDF)
- MINISTERIO DE TRABAJO Y PROMOCIÓN DEL EMPLEO (2022). ANUARIO ESTADÍSTICO SECTORIAL 2021. [HTTPS://WWW.GOB.PE/INSTITUCION/MTPE/INFORMES-PUBLICACIONES/3247012-ANUARIO-ESTADISTICO-SECTORIAL-2021](https://www.gob.pe/institucion/mtpe/informes-publicaciones/3247012-anuario-estadistico-sectorial-2021)
- NISHIURA, H., MIYAMOTO, A., ITO, A., HARADA, M., SUZUKI, S., FUJII, K., MORIFUJI, H., & TAKATSUKA, H. (2022). MACHINE-LEARNING-BASED QUALITY-LEVEL-ESTIMATION SYSTEM FOR INSPECTING STEEL MICROSTRUCTURES. *MICROSCOPY*, 71(4), 214-221. [HTTPS://DOI.ORG/10.1093/JMICRO/DFAC019](https://doi.org/10.1093/jmicro/dfac019)
- O'DONOVAN, C., GIANNETTI, C., & PLEYDELL-PEARCE, C. (2024). REAL-TIME MONITORING OF MOLTEN ZINC SPLATTER USING MACHINE LEARNING-BASED COMPUTER VISION. *JOURNAL OF INTELLIGENT MANUFACTURING*. [HTTPS://DOI.ORG/10.1007/S10845-024-02418-Y](https://doi.org/10.1007/s10845-024-02418-y)
- SCHNEIDER, J., ROSTAMI, R., CORCORAN, M., & KOPALA, G. (2024). INTEGRATION OF ARTIFICIAL INTELLIGENCE INTO METALLOGRAPHY: AREA-WIDE ANALYSIS OF MICROSTRUCTURAL COMPONENTS OF A JOMINY SAMPLE. *HTM JOURNAL OF HEAT TREATMENT AND MATERIALS*, 79(1), 3-14. [HTTPS://DOI.ORG/10.1515/HTM-2023-0032](https://doi.org/10.1515/htm-2023-0032)
- XUE, B., & WU, Z. (2021). KEY TECHNOLOGIES OF STEEL PLATE SURFACE DEFECT DETECTION SYSTEM BASED ON ARTIFICIAL INTELLIGENCE MACHINE VISION. *WIRELESS COMMUNICATIONS AND MOBILE COMPUTING*, 2021(1). [HTTPS://DOI.ORG/10.1155/2021/5553470](https://doi.org/10.1155/2021/5553470)
- ZHANG, Z., WANG, X., WANG, L., & XIA, X. (2024). SURFACE DEFECT DETECTION METHOD FOR DISCARDED MECHANICAL PARTS UNDER HEAVY RUST COVERAGE. *SCIENTIFIC REPORTS*, 14(1). [HTTPS://DOI.ORG/10.1038/S41598-024-58620-8](https://doi.org/10.1038/s41598-024-58620-8)
- ZHENG, Z., HU, Y., ZHANG, Y., YANG, H., QIAO, Y., QU, Z., & HUANG, Y. (2022A). CASPPNET: A CHAINED ATROUS SPATIAL PYRAMID POOLING NETWORK FOR STEEL DEFECT DETECTION. *MEASUREMENT SCIENCE AND TECHNOLOGY*, 33(8), 085403. [HTTPS://DOI.ORG/10.1088/1361-6501/AC68D2](https://doi.org/10.1088/1361-6501/ac68d2)
- ZHENG, Z., HU, Y., ZHANG, Y., YANG, H., QIAO, Y., QU, Z., & HUANG, Y. (2022B). CASPPNET: A CHAINED ATROUS SPATIAL PYRAMID POOLING NETWORK FOR STEEL DEFECT DETECTION. *MEASUREMENT SCIENCE AND TECHNOLOGY*, 33(8), 085403. [HTTPS://DOI.ORG/10.1088/1361-6501/AC68D2](https://doi.org/10.1088/1361-6501/ac68d2)

# ÍNDICE DE IMÁGENES



## De izquierda a derecha

1. <https://www.agroperu.pe/peru-inicio-la-campana-2025-2026-de-arandanos-con-resultados-muy-positivos/>
2. <https://agraria.pe/noticias/minagri-y-regiones-impulsaran-el-mercado-interno-de-fibra-de-21635>
3. [https://stock.adobe.com/pe/images/eyeshadow-palette-and-brushes/213607157?prev\\_url=detail](https://stock.adobe.com/pe/images/eyeshadow-palette-and-brushes/213607157?prev_url=detail)
4. [https://stock.adobe.com/pe/images/warehouse-metal-blank-electroplating-plant-for-the-metal/194755542?prev\\_url=detail](https://stock.adobe.com/pe/images/warehouse-metal-blank-electroplating-plant-for-the-metal/194755542?prev_url=detail)
5. [https://stock.adobe.com/pe/images/a-toy-truck-carrying-fresh-feijoa-yellow-background-delivery-concept-for-large-sized-items-and-fresh-tropical-fruits-from-the-new-harvest/464837972?prev\\_url=detail](https://stock.adobe.com/pe/images/a-toy-truck-carrying-fresh-feijoa-yellow-background-delivery-concept-for-large-sized-items-and-fresh-tropical-fruits-from-the-new-harvest/464837972?prev_url=detail) y [https://stock.adobe.com/pe/images/e-commerce-outline-icon/575813205?prev\\_url=de](https://stock.adobe.com/pe/images/e-commerce-outline-icon/575813205?prev_url=de)

# Ciencias e Ingeniería



<https://ctscafe.pe/index.php/cienciaingenieria>  
Volumen I- N° 2 Agosto 2025

Contáctenos en nuestro correo electrónico  
**[cienciaseingenierias@ctscafe.pe](mailto:cienciaseingenierias@ctscafe.pe)**

Página Web:  
**<https://ctscafe.pe/index.php/cienciaingenieria>**