

# Tendencias Recientes en la Detección de Fallas en Sistemas Limpiaparabrisas Mediante Visión por Computadora

Manuel Roberto Ornelas Escárcega<sup>1</sup>, Ángel Israel Soto Marrufo<sup>2</sup>, Florencio Abraham Roldán Castellanos<sup>3</sup>

<sup>1,2,3</sup>Universidad Autónoma de Ciudad Juárez. Ave. Del Charro 402, C.P. 32310. Cd. Juárez, Chih., México.

**Resumen** — La evaluación de la calidad de limpieza en los sistemas limpiaparabrisas es un aspecto fundamental enfocado en garantizar la seguridad y visibilidad que tienen los pasajeros durante la conducción, especialmente en condiciones climáticas adversas como lluvia intensa, nieve o acumulación de partículas de diversa naturaleza sobre el parabrisas. Una limpieza deficiente puede comprometer la capacidad del conductor para reaccionar adecuadamente ante situaciones de riesgo. En este contexto, el uso de técnicas de visión por computadora se ha consolidado como una herramienta innovadora y confiable para asegurar la calidad de limpieza en las etapas de validación de producto. Estas técnicas permiten estandarizar la metodología de evaluación, reduciendo la subjetividad de las inspecciones visuales tradicionales y ofreciendo un proceso más preciso, repetible y objetivo. Se han identificado cuatro modos de falla principales en los sistemas limpiaparabrisas, cada uno con características específicas que pueden ser detectadas y analizadas mediante algoritmos de visión por computadora. La identificación temprana de estos tipos de fallas contribuye directamente a mejorar la confiabilidad y el desempeño del sistema. El presente artículo se centra en una revisión de literatura especializada que aborda las distintas técnicas aplicadas para la detección de cada uno de estos modos de falla, destacando sus ventajas, limitaciones y potencial de aplicación en la industria automotriz.

**Palabras Clave** — Sistema limpiaparabrisas, Inteligencia artificial, Visión por computadora, Redes neuronales convolucionales, Clasificación de imágenes

## Introducción

A lo largo de las últimas décadas, la industria automotriz ha experimentado un aumento en la complejidad de los sistemas que integran a los vehículos para aumentar la inteligencia, conectividad y comodidad. Estos sistemas que incluyen los sistemas de asistencia avanzada para el conductor ADAS por sus siglas en inglés Advanced Driver Assistance Systems, las unidades de control de motor (ECU por sus siglas en inglés Engine Control Units), los sistemas de entretenimiento entre otros, han incrementado la complejidad en los sistemas automotrices (Sonko et al., 2024). En este contexto, la evaluación de la calidad en sistemas automotrices se ha convertido en un desafío técnico cada vez más complejo que difícilmente puede garantizarse mediante métodos tradicionales basados en inspección humana. Por ello, surge la necesidad de metodologías automatizadas e inteligentes capaces de detectar fallas con alta precisión, consistencia y velocidad.

Entre las tecnologías emergentes, los sistemas de visión por computadora se han consolidado como una herramienta clave para la inspección automática y la detección de defectos en procesos de manufactura automotriz (Nava, 2021). Este enfoque permite realizar una evaluación de la calidad libre de variabilidad y fatigas asociadas a la evaluación humana. El procesamiento digital de imágenes involucra varias etapas entre las cuales destacan: el preprocesamiento, con el objetivo de realzar las características de interés de la imagen mediante filtros como el de media, gaussiano, Wiener o de mediana (Pustokhina et al., 2021), y la segmentación, que separa los objetos de interés del fondo utilizando métodos como la segmentación por umbral, por agrupamiento o detección de bordes (Cheng y Li, 2021). Estas técnicas constituyen la base sobre la cual se desarrollan sistemas de visión automatizados cada vez más robustos.

En los últimos años, el avance de la inteligencia artificial (IA) ha incrementado significativamente las capacidades de los sistemas de visión por computadora. La integración de algoritmos de machine learning, en especial las redes neuronales convolucionales (CNN por sus siglas en inglés Convolutional Neural Network), ha permitido que los modelos aprendan a reconocer patrones complejos y sutiles de manera autónoma, reduciendo la dependencia de reglas predefinidas y mejorando la capacidad de generalización. En el contexto de la calidad de la industria automotriz, la IA se ha convertido en una herramienta de suma utilidad para la detección temprana de defectos, y optimización de procesos de inspección (Matamoros et al., 2025).

En el caso de los sistemas limpiaparabrisas, la aplicación de visión por computadora en conjunto de inteligencia artificial, facilita la evaluación de la calidad de limpieza de manera objetiva y repetible. Los algoritmos de IA pueden identificar los tipos de fallas con la finalidad de estandarizar las evaluaciones, reducir la subjetividad e incrementar la satisfacción del cliente.

### *Fundamentos del sistema limpiaparabrisas y tipos de falla*

Los sistemas limpiaparabrisas constituyen un componente crítico en la seguridad de los vehículos al garantizar una visibilidad adecuada para el conductor en situaciones climáticas adversas como lluvia, nieve o suciedad. En México, su funcionamiento es

regulado por normativas internacionales como la SAE J903 (SAE, 1999) y por normativas estadounidenses como la FMVSS-104 de la *National Highway Traffic Safety Administration* (U.S.-NHTSA, 1996), que establecen criterios específicos sobre el área mínima de cobertura que un sistema limpiaparabrisas debe cubrir.

#### *Tipos de falla más comunes*

Para garantizar el buen desempeño de un sistema limpiaparabrisas, se somete a rigurosas pruebas de validación. Dentro de las pruebas más importantes se encuentra la durabilidad del sistema, que tiene como objetivo la verificación del funcionamiento del limpiaparabrisas a lo largo de su vida útil. Durante la evaluación de la calidad de limpieza, se encuentran cuatro modos de falla:

*Presencia de rayas.* Se manifiesta como líneas delgadas y continuas de agua que permanecen en el parabrisas después del ciclo de limpieza. Son causadas principalmente por presencia de grumos en la goma, si aparecen a pocos ciclos, o por desgaste irregular de la goma causado por acumulación de partículas.

*Presencia de brincoteos.* Se refiere a un movimiento intermitente irregular de la navaja durante el barrido de limpieza, generando líneas en un patrón de brincoteo a lo largo del área de limpieza. Se relaciona principalmente por un ángulo de contacto inapropiado.

*Presencia de bruma.* Se visualiza como una película difusa que se evapora mientras la navaja se desplaza por el parabrisas. En sus condiciones más severas, deja una marca permanente de agua en el vidrio en el centro de la navaja. Comúnmente se asocia con una fuerza alta del brazo, y un colapso del hule por un exceso de presión.

*Presencia de parches.* Se observan como zonas sin limpiar en donde quedan gotas irregulares grandes que no son limpiadas por la navaja. Se le asocia a un defecto en las curvaturas tanto de la navaja como del parabrisas, ya que son zonas de baja presión.

La detección de estos modos de falla de una manera crítica y oportuna permite la correcta validación del sistema para garantizar la seguridad del usuario a lo largo de la vida del vehículo. Por ello, su monitoreo y análisis ha sido objeto de interés en la literatura técnica, particularmente en el desarrollo de sistemas automáticos basados en visión por computadora e inteligencia artificial.

#### *Evaluación tradicional vs automatizada*

Tradicionalmente, la inspección de la calidad de limpieza de los sistemas limpiaparabrisas se ha realizado de forma visual y subjetiva por parte de los ingenieros durante las pruebas de durabilidad. Sin embargo, este método presenta una alta variabilidad y subjetividad y es difícil garantizar la repetibilidad de la evaluación.

La implementación de técnicas de visión por computadora e inteligencia artificial ha abierto una nueva posibilidad de desarrollar sistemas automáticos de inspección capaces de identificar los modos de falla mencionados de manera objetiva, repetible y precisa.

### **Metodología**

El presente estudio se basa en una revisión sistemática de literatura, orientada a identificar, analizar y clasificar los estudios más recientes enfocados en identificar al menos unos de los tipos de fallas de la calidad de los sistemas limpiaparabrisas mediante visión por computadora.

La búsqueda se realizó utilizando el buscador de Google Scholar durante los meses de agosto a octubre de 2025. Se utilizaron palabras clave en inglés y sus combinaciones, relacionadas con el tema central, entre las cuales destacan: windshield wiper system, vision-based inspection, image processing, strikes, haze, quality automotive industry. Para incluir más trabajos en la revisión, se optó por agregar trabajos del sector automotriz que incluyeran modelos de deep learning y visión por computadora. Para hacer una selección precisa de la información se utilizaron filtros, considerando las publicaciones entre 2015 y 2025 y con acceso completo al texto.

Los trabajos se clasifican en dos grupos principales: 1) métodos clásicos de procesamiento digital de imágenes utilizando técnicas matemáticas para la extracción de características, y 2) métodos modernos enfocados en técnicas de procesamiento digital de imágenes para el preprocesamiento, junto con técnicas modernas de inteligencia artificial para la segmentación de los objetos de interés.

Dentro de cada grupo se evaluaron los siguientes criterios: enfoque técnico empleado, tipo de defecto detectado, precisión, recall y F1 score, ventajas y limitaciones y aplicabilidad en entornos industriales automotrices.

### **Resultados**

#### *Métodos de inspección clásicos por visión por computadora*

Los primeros enfoques que utilizaron equipos de cómputo se basan en algoritmos clásicos para el procesamiento de imágenes. Dichos algoritmos se basan en transformaciones de color, ajuste de brillo y contraste, técnicas de detección de bordes, y análisis de defectos como rayas y presencia de gotas.

Un ejemplo destacado es el trabajo de Ishizuka y Onogushi (2017), quienes detectaron y clasificaron gotas de lluvia de diferentes formas mediante procesamiento digital de imágenes clásico. El método propuesto combina el análisis de bordes y análisis texturas para detectar la presencia de gotas. Para la detección de bordes, se calcula la proporción de píxeles detectados como bordes y el número total de píxeles de la imagen, siendo un alto valor un índice de presencia de gotas de lluvia. Para el análisis de texturas, se analizan los patrones de brillo y contraste para distinguir entre superficies secas o cubiertas de gotas.

Asimismo, el trabajo realizado por Shinde y Dharmadhikari (2017), quienes buscan reducir la intervención humana en la activación del sistema limpiaparabrisas. Para el preprocesamiento de las imágenes, se convierten a escala de grises seguido de una etapa de filtrado y realce de bordes mediante los filtros de Sobel y Canny. Posteriormente se utilizó un umbral adaptativo que permite distinguir regiones secas y mojadas del parabrisas. Finalmente, se aplica un algoritmo de visión por computadora que analiza la cantidad de píxeles que corresponden a gotas de agua. Con esta información, se regula la velocidad del parabrisas al determinar el porcentaje de área ocupada por gotas para estimar el grado de oclusión del parabrisas.

De igual forma, en el trabajo realizado por Dash (2020), tiene como objetivo medir con precisión la dinámica del impacto y la evaporación de gotas de líquido sobre superficies sólidas. Para la metodología, se libera una gota de individual y se captura la secuencia temporal de impacto, expansión y evaporación. Para el preprocesamiento de las imágenes, primero se convierte a escala de grises y para el filtrado y detección de bordes se utilizó el filtro Canny para la identificación del cambio de estado de líquido a gaseoso para la identificación de bruma. Posteriormente, se utilizó el umbral de Otsu con dos tipos de umbrales, fuerte y débil, para calcular el máximo gradiente de la intensidad de los píxeles. Después de esto, se detectó la evaporación al comparar el tamaño de la gota en el transcurso de un par de segundos.

#### *Métodos de inspección modernos basados en aprendizaje profundo*

El uso de redes neuronales convolucionales (CNN) ha revolucionado la detección de defectos visuales en la industria automotriz. A diferencia de los métodos tradicionales descritos en la sección anterior, los modelos basados en aprendizaje profundo tienen la peculiaridad de poder aprender directamente de los datos y extraer las características complejas sin intervención, lo cual mejora significativamente su precisión y generalización.

Un ejemplo destacado es el trabajo de Sari y Ulas (2022), cuyo trabajo se enfocó en la detección automática de defectos como rayones y burbujas en superficies de envases de vidrio. Para la etapa de preprocesamiento, utilizaron técnicas de conversión a espacio de color HSV y CIE-Lab/Luv. En el espacio HSV, el canal V se separa para segregar los defectos por reflejo o brillo. Del espacio CIE-Lab/Luv se beneficia de que es un espacio perceptualmente uniforme para distinguir variaciones de color. Posteriormente se aplica una ecualización de histograma adaptativa al canal V del espacio HSV antes de introducir las imágenes a un modelo YOLO-v3 para la detección y clasificación de defectos. Para realizar una comparación, se emplea un modelo Faster R-CNN para comparar el desempeño. De los resultados obtenidos, el modelo YOLO-v3 con las imágenes sin procesar tiene una precisión del 94.5%, un recall del 94.66% y un F1 score de 94.6%. Dentro de las diferentes combinaciones realizadas, la que obtuvo mejor desempeño fue la de uso de CIE-Lab/Luv y la ecualización del histograma adaptativo con una precisión del 97.1%, un recall del 97.27% y un F1 del 97.35%. En todos los ejercicios, el modelo YOLO-v3 obtuvo un resultado superior.

Uno de los estudios más avanzados es el de Chen et al. (2024) quienes emplearon una versión modificada del YOLOv5 y una estrategia de red ligera para la detección de grietas, burbujas y rayaduras en entornos de inspección automotriz. Para la extracción de características, se integró MobileNetV3 en el *backbone* del algoritmo y para eficientar la extracción de características se empleó el módulo Ghost, lo que permitió mejorar el desempeño a un costo computacional bajo. Durante la etapa del entrenamiento, utilizaron técnicas de aumento de datos como transformaciones espaciales de rotación, cambios de escala y recortes, con la finalidad de incrementar la cantidad de datos disponibles. Como resultado, obtuvieron un incremento del 3.9% en la precisión y un incremento en la tasa de recuperación de defectos del 7.6% con respecto al modelo YOLOv5 original.

De forma similar, Ding y Yang (2024), emplearon un algoritmo basado en YOLOv5 para la detección de microdefectos en vidrios de dispositivos móviles tales como polvo, puntos y microrayones en vidrios planos de pantallas de teléfonos móviles. Para la metodología se diseñó una plataforma que utiliza una iluminación por reflexión total que permite resaltar los defectos diminutos. Para el procesamiento de imágenes, se optimiza el ángulo y la intensidad de la iluminación para maximizar el contraste de defectos. Para aumentar la cantidad de datos disponibles, se aplican transformaciones geométricas, mezcla de imágenes y fusión sintética de defectos para diversificar el conjunto de entrenamiento. Como resultados, se obtuvo un incremento en la precisión del 2.62% con respecto al algoritmo YOLOv5 original.

A pesar del que objetivo del trabajo de Zhang (2025) es la activación del sistema limpiaparabrisas de manera automática, combinó técnicas de visión por computadora, como modificaciones en el espacio HSV y transformaciones como zooming y desplazamiento, junto con modelo de detección de objetos basado en la arquitectura YOLOv8 para la detección de gotas de lluvia de manera continua y en tiempo real para determinar la intensidad de la lluvia. El modelo fue entrenado en tres escenarios: día, noche y todo tiempo. Dentro de los resultados obtenidos, para el modelo de día, se logró una precisión del 90% y un recall del 83%, para el modelo de noche, se consiguió una precisión del 89% y un recall del 80%. Finalmente para el modelo de todo tiempo, se consiguió una precisión del 89% y un recall del 82%.

El trabajo realizado por Ke (2025) tiene como objetivo la detección de defectos en superficies metálicas y propone un modelo híbrido basado en redes neuronales convolucionales. En su enfoque, la etapa de localización de defectos se realiza con una arquitectura U-Net con el backbone ResNet34 junto con un clasificador EfficientNet-B4 para integrar la detección y la clasificación. Las imágenes son sometidas a un preprocesamiento con iluminación estroboscópica seguido de composiciones pseudo-RGB para resaltar los defectos superficiales. Dentro de los resultados, alcanzaron una precisión en clasificación del 98.2% y una precisión en localización de defectos del 96.5%.

Otro trabajo reciente realizado por Cumbajin (2024) desarrolló un sistema de detección de defectos en piezas cerámicas utilizando visión por computadora y CNN. La propuesta incluyó un método preciso para la obtención de imágenes con una cámara industrial controlando la iluminación. El preprocesamiento de las imágenes incluyó técnicas como conversión a escala de grises, umbralización, recorte y normalización. Se utilizaron técnicas de aumento de datos con la finalidad de evitar el sobreajuste. El sistema fue evaluado en tres arquitecturas: AlexNet, VGG y ResNet. De las tres redes, ResNET fue la que obtuvo los mejores resultados con una precisión del 98.00% y un F1-Score del 97.29%.

Uno de los trabajos recientes en inspección automatizada de calidad es el de Khempalure et al. (2024), quienes desarrollaron un sistema basado en redes neuronales profundas para la detección y clasificación de defectos en productos manufacturados. El sistema contempla dos modalidades; la primera es una clasificación binaria tipo defecto / no defecto; y una clasificación multiclase que especifica el tipo de defecto mediante el algoritmo YOLOv8. Para la clasificación binaria, se alcanzó una exactitud en las pruebas del 97.49%. Para la clasificación multiclase, el modelo YOLOv8 obtuvo una precisión del 98.7%.

De igual manera, el trabajo de Profilli et al. (2024) se enfocó en la inspección de calidad en este caso en sondas de ultrasonido. El aporte destacable es en la metodología en la cual emplearon una cámara monocroma y una iluminación cuidadosamente calibrada con montaje automatizado para obtener imágenes de diferentes ángulos. Posteriormente se evaluaron tres arquitecturas de redes neuronales: MMSD-Net, ResNet y EfficientNet para la detección y clasificación de defectos. La mejor configuración correspondió a EfficientNet alcanzando una detección con exactitud del 98.63% y una precisión de clasificación del 81.90%.

Uno de los trabajos más recientes en la inspección automática de defectos en manufactura de semiconductores es el de Dey et al. (2022) quienes aplicaron máscaras de CNN en imágenes obtenidas por microscopía electrónica de barrido para detectar defectos diminutos (menos de 32 nm). La metodología consiste en generar máscaras para cada defecto detectado lo cual permite cuantificar con precisión la extensión del defecto y su cantidad. Utilizaron el modelo Detectron2 con algunas modificaciones en los backbones como ResNet50 y ResNet101. El sistema demostró una alta efectividad tanto cualitativa como cuantitativa. Mejoró la capacidad de segmentación de instancias de defecto respecto a modelos anteriores generando máscaras precisas y permitiendo el conteo y medición de defectos a nivel de pixel.

Otro trabajo novedoso en la inspección automatizada de superficies metálicas es el de Chou Wang y Mao (2025) quienes propusieron un sistema basado en deep learning para la detección automática de defectos superficiales y en orificios de láminas metálicas. Para superar la limitante de escasez de datos, se empleó una estrategia con ConSinGAN, una red generativa que permite sintetizar nuevas imágenes para enriquecer la base de datos. Se utilizaron diferentes versiones del YOLO (v3, v4, v7 y v9) evaluando su desempeño y capacidad de generar datos. La mejor configuración fue con YOLOv9 + ConSinGAN con una precisión del 91.3%. En comparación, los modelos sin la generación de datos sintéticos obtuvieron valores significativamente menores. Por ejemplo, YOLOv7 sin ConSinGAN obtuvo un F1-Score del 73.9% mientras que con la generación de datos se incrementó a 87.9%.

De igual manera el trabajo de Liu et al. (2024) desarrollaron un método para la detección de microrayaduras en superficies metálicas basado en una arquitectura U-Net denominada MSDD-UNet. Su arquitectura incorpora un módulo de downsampling basado en el Espacio de Profundidad junto con un módulo ligero de atención por canal y un bloque de auto-atención optimizado aplicado en las conexiones “skip” del codificador-decodificador, con el fin de preservar detalles finos y resaltar defectos pequeños. En sus experimentos, el modelo completo logró una precisión del 87.40% , un recall del 90.46% y un F1-score del 88.90%.

De los trabajos más recientes, destaca el estudio de Li et al. (2025) quienes desarrollaron un modelo ligero denominado DY-YOLO para la detección de defectos en vidrios de pantallas de teléfonos móviles. Su propuesta se centra en mejorar la dinámica entre el backbone y módulos optimizados de atención para fortalecer la extracción de características pequeñas con bajo contraste. En las evaluaciones experimentales, el modelo DY-YOLO obtuvo una precisión del 99.3% superando al modelo base YOLOv8 por 1%.

### ***Discusión***

La Tabla 1, muestra una síntesis comparativa entre los artículos seleccionados mostrando su enfoque técnico, aplicación principal, ventajas y limitaciones.

Los enfoques basados en aprendizaje profundo y visión por computadora han demostrado una alta efectividad en la detección de defectos visuales —como rayas, bruma y gotas de lluvia— alcanzando precisiones superiores al 90% en la mayoría de los estudios revisados (Chen et al., 2024; Ding y Yang, 2024; Zhang et al., 2025). Además, estas técnicas ofrecen ventajas claves como automatización del proceso de inspección, eliminando la variabilidad humana; adaptabilidad a diferentes tipos de falla y condiciones del parabrisas mediante el entrenamiento supervisado; integración con sistemas embebidos para inspecciones adaptadas a líneas de producción.

Los estudios cuyo objeto de estudio no son los parabrisas, como las superficies metálicas y cerámicas tuvieron métricas similares (Ke 2025, Cumbajin et al. 2024, Khempalure et al. 2024, Profilli et al. 2024, Dey et al. 2024, Chou et al. 2025, Liu et al. 2024). Estas novedosas técnicas incluyen acercamientos novedosos para la detección de los defectos, como el aumento de datos mediante redes generativas como ConSinGAN y metodologías de obtención de las imágenes precisas para alimentar los modelos de IA.

A pesar de presentar numerosas bondades, los sistemas basados en aprendizaje profundo, presentan diversos desafíos que limitan la adopción masiva de estos sistemas en la industria automotriz. La limitante principal es la dependencia de grandes volúmenes de datos etiquetados, ya que es fundamental que el modelo sea alimentado con una cantidad grande de datos, requiriendo del orden de miles de imágenes etiquetadas, para el ajuste fino de los parámetros del modelo. Dentro de la literatura analizada, no se encuentran datasets públicos con tanta cantidad de datos, y además se emplean técnicas de aumento de datos para la creación de datos sintéticos.

Otra limitante es que el rendimiento de los modelos es óptimo siempre y cuando se empleen en condiciones similares a las del entrenamiento. Cambios en la iluminación, ángulo de cámara y otras variaciones, podrían afectar significativamente la precisión del sistema. Otro problema que se tiene con el empleo de redes neuronales convolucionales es que el procesamiento se

hace como si fuera una “caja negra”, en la cual, es complicado el diagnóstico de errores y compensaciones o ajustes sobre las decisiones tomadas.

A pesar de encontrar en la literatura métodos para la identificación de los cuatro modos de falla descritos, no se encontró ningún método que los incluyera a todos, demostrando que existe un vacío en el conocimiento sobre un sistema que permita la detección de estos defectos en un parabrisas.

La revisión de literatura permitió identificar varias oportunidades en la investigación y aplicación industrial tales como:

- Desarrollo de datasets públicos con imágenes etiquetadas con los diferentes modos de falla capturados en distintas condiciones ambientales y de iluminación.
- Mejora en la interpretabilidad de modelos mediante técnicas de visualización de activaciones o mapas de calor que permitan explicar el área de parabrisas en donde se detectó el defecto.
- Establecimiento de estándares de evaluación visual automatizada en colaboración con los fabricantes de equipo original OEMs.

Estas oportunidades representan áreas estratégicas para la investigación aplicada el desarrollo de estándares industriales en la evaluación automatizada de sistemas limpiaparabrisas.

### Conclusiones

La inspección de la calidad de limpieza de los sistemas limpiaparabrisas es un aspecto esencial para garantizar la seguridad, particularmente en condiciones ambientales adversas. A lo largo de esta revisión, se han identificado diferentes métodos para la clasificación de los modos de falla como rayas, parches, brincoteos y bruma, así como las estrategias clásicas por procesamiento digital de imágenes y modernas como el aprendizaje profundo para su detección.

Los métodos tradicionales presentan limitaciones en cuanto a precisión y recall especialmente en entornos automotrices industriales. Por el contrario, los métodos modernos basados en visión por computadora y aprendizaje profundo, han demostrado un alto potencial para superar estas limitaciones, permitiendo un aumento de la precisión y adaptabilidad a diferentes condiciones de luz.

Método / Autor	Enfoque técnico	Aplicación principal	Ventajas identificadas	Limitaciones
<b>Ishizuka &amp; Onoguchi (2017)</b>	Análisis de bordes + análisis de textura	Detección de gotas de lluvia con distintas formas	Bajo costo computacional, robusto en iluminación variable	No detecta fallas específicas del sistema limpiaparabrisas (rayas, parches, etc.)
<b>Shinde &amp; Dharmadhikari (2017)</b>	Escala de grises, Sobel/Canny, umbral adaptativo	Control automático de limpiaparabrisas por cantidad de gotas	Algoritmo simple, procesamiento en tiempo real	Sensible a ruido, iluminación y reflejos; no identifica fallas mecánicas
<b>Dash et al. (2020)</b>	Segmentación, Canny, umbral de Otsu	Detección de evaporación y dinámica de gotas	Muy preciso para transiciones líquido-gas	No aplica directamente a fallas de limpieza; requiere cámara de alta velocidad
<b>Sari &amp; Ulas (2022)</b>	CSC (HSV, CIE-Lab), AHE + YOLOv3	Defectos en vidrio (rayas, burbujas)	F1 > 97%; mejora significativa con conversión de color	Requiere gran cantidad de datos; no diseñado para parabrisas curvos
<b>Chen et al. (2024)</b>	YOLOv5 modificado + MobileNetV3 + Ghost	Grietas, burbujas y rayaduras	Ligero y eficiente; +3.9% precisión, +7.6% recall	Complejidad de implementación; dependiente de dataset
<b>Ding &amp; Yang (2024)</b>	YOLOv5 + iluminación por reflexión total + aumento de datos	Microdefectos (polvo, puntos, microrayones)	Excelente contraste para defectos diminutos; +2.62% precisión	Requiere iluminación especializada y calibración

<b>Cumbajin et al. (2024)</b>	CNN con preprocesamiento + inspección en tiempo real	Defectos en piezas cerámicas (superficies industriales)	ResNet: Precisión 98.00%, F1 = 97.29%	Sensible a variaciones de textura/esmalte; dataset privado
<b>Li et al. (2025)</b>	DY-YOLOv8 Kernel largo separable	Defectos en pantallas de smartphone	mAP@0.5 = 99.3%; mAP@0.5:0.95 = 70.9% en un benchmark	Puede que los valores de precisión/recall/F1 no estén disponibles; costo de entrenamiento / dataset riguroso
<b>Liu et al. (2024)</b>	YOLOv5 + SPPFKCSPC	Defectos superficies metálicas	Uso en dos datasets. NEU-DET precisión del 88.3%, 7.2% superior. Con PV-Multi-Defect 97.5%, aumento del 1.5%	Evaluación sobre datos públicos y no ambiente industrial. No se prueban variaciones de condiciones.
<b>Ke (2025)</b>	YOLOv8 + atención espacial. Modelo híbrido	Defectos microscópicos en líneas de producción en superficies metálicas	Excelente balance velocidad/precisión; precisión en la clasificación del 98.2% y en localización del 96.5%	Menor desempeño en condiciones de baja iluminación. Propenso a fallas en superficies reflectantes.
<b>Khemplapure et al. (2024)</b>	YOLOv8 modificado	Sin especificar el tipo de producto manufacturado	Alta precisión del 98.7% en clasificación, reducción de personal humano	Requiere dataset etiquetado. Necesita calidad de imágenes
<b>Profili et al. (2024)</b>	CNN en específico MMSD-Net, ResNet y EfficientNet	Defectos en probetas de ultrasonido	EfficientNet el mejor modelo con precisión del 98.63%. Defectos de entre 0.2mm hasta 10mm	Morfología de la superficie, tipo de iluminación, deflejos afectan la calidad de la imagen.
<b>Chou et al. (2025)</b>	YOLOv3, v4, v7 y v9 + ConSinGAN	Chapas metálicas	YOLOv9 + ConSinGAN precisión del 91.3%. Uso en HW con sistema SCADA	Depende del dataset aumentado
<b>Dey et al. (2022)</b>	Máscara de CNN ligera + Detectron2	Defectos en semiconductores.	Precisión promedio del 93.6%. Cuantifica el área del defecto en píxeles.	Requiere imágenes de SEM de calidad etiquetadas
<b>Zhang et al. (2025)</b>	YOLOv8 + modificaciones HSV	Detección continua de lluvia (control automático)	Funcionamiento día/noche; precisión ~90%	Bajo rendimiento en condiciones extremas; no detecta fallas mecánicas

**Tabla 1:** Síntesis comparativa de los trabajos seleccionados.

Sin embargo, estos métodos no se encuentran exentos de desafíos. La necesidad de tener grandes volúmenes de datos etiquetados y la generalización a nuevas condiciones representan un barrera muy importante para la implementación industrial de estos sistemas a gran escala.

Por último, se destacan varias líneas de investigación prometedoras como el desarrollo de datasets públicos y la implementación de sistemas embebidos inteligentes. La implementación de estos avances tecnológicos permitirá no solo mejorar la eficiencia y precisión de la inspección de limpieza en los sistemas limpiaparabrisas, sino también facilitar su integración en entornos de producción automatizados.

En conjunto, la aplicación de inteligencia artificial y visión por computadora representa un paso importante hacia la automatización del control de calidad automatizado, con impacto directo en la seguridad, confiabilidad y satisfacción del cliente.

## Referencias

- Chen, Z., Huang, S., Lv, H., Luo, Z., and Liu, J. (2024). *Defect detection in automotive glass based on modified YOLOv5 with multi-scale feature fusion and dual lightweight strategy*. *The Visual Computer*, 40:8099–8112.
- Cheng, Y., and Li, B. (2021). Image segmentation technology and its application in digital image processing. *2021 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC)*, 1174–1177. IEEE, Dalian, China.
- Chou, P.-H., Wang, C.-C., & Mao, W.-L. (2025, October 3). *YOLO-Based defect detection for metal sheets*. arXiv.
- Cumbajin, E., Rodrigues, N., Costa, P., Miragaia, R., Frazão, L., Costa, N., Fernández-Caballero, A., Carneiro, J., Buruberri, L. H., & Pereira, A. (2024). *A real-time automated defect detection system for ceramic pieces manufacturing process based on computer vision with deep learning*. *Sensors*, 24(1), 232.
- Dash, A., Bange, P. G., Patil, N. D., and Bhardwaj, R. (2020). *An image processing method to measure droplet impact and evaporation on a solid surface*. *Measurement Science and Technology*, 31(10):105301.
- Dey, B., Dehaerne, E., Khalil, K., Halder, S., Leray, P., & Bayoumi, M. A. (2022). *Deep Learning based Defect classification and detection in SEM images: A Mask R-CNN approach*. arXiv.
- Ding, P., and Yang, L. (2024). *Glass defect detection with improved data augmentation under total reflection lighting*. *Applied Sciences (Switzerland)*, 14(3):1024.
- Ke, H. L. (2025). *Using Convolutional Neural Networks for Material Surface Quality Inspection and Classification*. *International Journal of Computational Intelligence Systems*, 18, Article 224.
- Khemlapure, V., Patil, A., Chavan, N., & Mali, N. (2024). *Product defect detection using deep learning*. *International Journal of Intelligent Systems and Applications*, 16(4), 39–54.
- Li, J., Long, H., Liu, M., Huang, Y., & Bao, N. (2025). *Smartphone screen surface defect detection using dynamic large separable kernel attention and multi-scale feature bi-directional path aggregation network*. *Scientific Reports*, 15(1), 40620.
- Liu, Y., Qin, Y., Lin, Z., Xia, H., & Wang, C. (2024). *Detection of Scratch Defects on Metal Surfaces Based on MSDD-UNet*. *Electronics*, 13(16), 3241.
- Matamoros, O. M., Nava, J. G. T., Escobar, J. J. M., and Chavez, B. A. C. (2025). Artificial intelligence for quality defects in the automotive industry: A systemic review. *Sensors*, 25(5):1288. Accedido: 11 de octubre de 2025.
- Nava, A. V. (2021). *Vision system for quality inspection of automotive parts based on nondefective samples* [Tesis de maestría, Tecnológico de Monterrey]. Dirigida por el Dr. Irving Armando Cruz Albarrán y co-dirigida por el Dr. Luis Alberto Morales Hernández.
- Profili, A., Magherini, R., Servi, M., Spezia, F., Gemmiti, D., & Volpe, Y. (2024). *Machine vision system for automatic defect detection of ultrasound probes*. *The International Journal of Advanced Manufacturing Technology*, 135, 3421–3435.
- Pustokhina, I. V., Pustokhin, D. A., & Popov, A. I. (2021). *Application of different filtering techniques in digital image processing*. *Journal of Physics: Conference Series*, 2062(1), 012007. IOP Publishing. <https://doi.org/10.1088/1742-6596/2062/1/012007>.
- Shinde, R. G., and Dharmadhikari, V. B. (2017). *Development of computer vision-based windshield wiper control system for automobiles*. *International Research Journal of Engineering and Technology (IRJET)*, 4(7):1573–1578.

Sari, F., and Ulas, A. B. (2022). *Deep learning application in detecting glass defects with color space conversion and adaptive histogram equalization. Traitement du Signal*, 39(2):731–736.

Society of Automotive Engineers. (1999). SAE J903: Passenger car windshield wiper systems. Warrendale, PA: SAE International. Accedido: 8 de noviembre de 2025.

Sonko, S., Daudu, C. D., Osasona, F., Monebi, A. M., Etukudoh, E. A., and Atadoga, A. (2024). The evolution of embedded systems in automotive industry: A global review. *World Journal of Advanced Research and Reviews*, 21(2):96–104.

U.S.NHTSA,1996 U.S. National Highway Traffic Safety Administration. (1996). *TP-104-08: Laboratory Test Procedure for FMVSS No. 104 — Windshield Wiping and Washing Systems*. U.S. Department of Transportation, National Highway Traffic Safety Administration, Washington, DC.

Zhang, G., Wang, G., Chen, J., Jiang, W., Hao, X., and Deng, T. (2025). *An automatic control system based on machine vision and deep learning for car windscreen cleaning. Scientific Reports*, 15:4857.