

Sistema de inspección visual en tiempo real para detección de defectos en procesos industriales utilizando dispositivos móviles

Ismael Espinoza Arias¹, Luis Arturo Medina-Muñoz¹,
Samuel González-López², Felipe Morales-Solis¹

¹ Tecnológico Nacional de México/Tecnológico de Nogales, Sonora,
México

² Universidad de Sonora, Departamento de matemáticas, Hermosillo, Sonora,
México

{M24340931,Felipe.ms, Luis.mm}@nogales.tecnm.mx
samuelgonzalezlopez@gmail.com

Resumen. En la industria manufacturera, la detección oportuna de defectos es fundamental para garantizar la calidad del producto y reducir costos asociados al retrabajo y desperdicio de materiales. En este trabajo se presenta un sistema de inspección visual en tiempo real basado en técnicas de visión artificial y redes neuronales convolucionales, orientado a su futura implementación en dispositivos móviles. La propuesta permite capturar imágenes de productos industriales y clasificarlos automáticamente como productos aceptables o defectuosos mediante modelos de aprendizaje profundo. El sistema fue desarrollado considerando condiciones reales de operación, incluyendo variaciones de iluminación, posicionamiento y ruido visual presentes en entornos industriales. Como parte del proceso experimental, se aplicaron técnicas de aumento de datos y regularización para mejorar la capacidad de generalización del modelo y reducir efectos de sobreajuste. Los resultados preliminares obtenidos muestran un desempeño estable y tiempos de inferencia adecuados para aplicaciones de inspección visual en tiempo real. Este trabajo representa una extensión de investigaciones previas enfocadas en análisis de datos históricos, incorporando ahora capacidades de detección automática de defectos mediante visión artificial.

Palabras clave: Visión artificial, detección de defectos, redes neuronales convolucionales, inspección industrial, monitorización en tiempo real.

Real-time Visual Inspection System for Defect Detection in Industrial Processes Using Mobile Devices

Abstract. In the manufacturing industry, timely defect detection is fundamental to ensuring product quality and reducing costs associated

with rework and material waste. This paper presents a real-time visual inspection system based on machine vision techniques and convolutional neural networks, designed for future implementation on mobile devices. The system captures images of industrial products and automatically classifies them as acceptable or defective using deep learning models. It was developed under real-world operating conditions, including variations in lighting, positioning, and visual noise present in industrial environments. As part of the experimental process, data augmentation and regularization techniques were applied to improve the model's generalization capabilities and reduce overfitting. Preliminary results show stable performance and adequate inference times for real-time visual inspection applications. This work represents an extension of previous research focused on historical data analysis, now incorporating automatic defect detection capabilities using machine vision.

Keywords: Computer vision, defect detection, convolutional neural networks, industrial inspection, real-time monitoring.

1. Introducción

La adopción de tecnologías asociadas con la Industria 4.0 ha impulsado el desarrollo de sistemas inteligentes orientados a la automatización y optimización de procesos industriales. Dentro de este contexto, el control de calidad representa una de las áreas de mayor interés debido a su impacto directo en la eficiencia operativa, reducción de desperdicios y satisfacción del cliente.

Tradicionalmente, la inspección visual de productos manufacturados ha dependido de operadores humanos encargados de identificar defectos durante las diferentes etapas de producción. Sin embargo, este proceso suele ser lento, subjetivo y propenso a errores humanos, especialmente en líneas de producción continuas donde se requiere rapidez y precisión en la toma de decisiones.

En años recientes, el uso de técnicas de visión artificial y aprendizaje profundo ha demostrado resultados prometedores para la automatización de tareas de inspección visual. Particularmente, las redes neuronales convolucionales (CNN) han mostrado una alta capacidad para extraer patrones visuales y clasificar imágenes en distintos contextos industriales.

Por otro lado, la creciente disponibilidad de dispositivos móviles con capacidades computacionales avanzadas ha permitido considerar nuevas alternativas para el despliegue de sistemas de inteligencia artificial en tiempo real. Esto representa una oportunidad importante para implementar soluciones accesibles y escalables dentro de ambientes industriales sin requerir infraestructura especializada.

En trabajos previos, se han utilizado técnicas de minería de datos y procesamiento de lenguaje natural para el análisis de fallas y generación de recomendaciones de mantenimiento. No obstante, dichos enfoques operan de forma reactiva, es decir, después de que el defecto o la falla ya han ocurrido.

En este contexto, el presente trabajo propone un sistema de inspección visual en tiempo real basado en redes neuronales convolucionales, capaz de clasificar productos industriales como aceptables o defectuosos a partir de imágenes capturadas en condiciones reales de operación. Asimismo, se presenta el diseño preliminar de una aplicación móvil orientada a facilitar futuras implementaciones en entornos industriales.

2. Trabajos relacionados

El uso de técnicas de visión artificial y aprendizaje profundo en aplicaciones industriales ha incrementado considerablemente durante los últimos años, especialmente en tareas relacionadas con inspección visual y detección automática de defectos.

Las redes neuronales convolucionales (CNN) han demostrado un desempeño sobresaliente en problemas de clasificación de imágenes debido a su capacidad para extraer automáticamente características visuales relevantes. Modelos basados en CNN han sido ampliamente utilizados para detectar anomalías en superficies metálicas, componentes electrónicos, productos manufacturados y sistemas de ensamblaje industrial.

Diversos estudios han reportado resultados prometedores utilizando arquitecturas profundas para automatizar procesos de control de calidad, reduciendo la dependencia de inspección manual y mejorando la eficiencia operativa. Asimismo, arquitecturas ligeras como MobileNet han permitido implementar modelos de inteligencia artificial en dispositivos con recursos computacionales limitados, incluyendo dispositivos móviles y sistemas embebidos.

Por otra parte, técnicas de aumento de datos (data augmentation) y regularización han sido utilizadas para mejorar la capacidad de generalización de modelos entrenados con conjuntos de datos reducidos, mitigando problemas de sobreajuste durante el entrenamiento.

En el contexto de la Industria 4.0, la integración de sistemas inteligentes de inspección visual con plataformas de monitoreo y análisis de datos ha permitido mejorar la trazabilidad y supervisión de procesos industriales en tiempo real.

A diferencia de otros trabajos enfocados únicamente en clasificación de imágenes o análisis de datos históricos, la propuesta presentada en este trabajo busca integrar capacidades de inspección visual automática en tiempo real con una futura implementación orientada a dispositivos móviles.

3. Metodología

La metodología propuesta contempla el desarrollo de un sistema de inspección visual basado en redes neuronales convolucionales para la clasificación automática de productos industriales en condiciones aceptables y defectuosas.

El proceso general del sistema se divide en las siguientes etapas: adquisición de imágenes, preprocesamiento, entrenamiento del modelo, validación experimental y visualización de resultados.

3.1. Adquisición y organización del conjunto de datos

El conjunto de datos utilizado fue construido a partir de imágenes capturadas en condiciones reales de operación industrial. Las imágenes fueron clasificadas manualmente en dos categorías principales:

- **Good:** productos en condiciones aceptables.
- **Bad:** productos con defectos visibles.

El conjunto de datos fue dividido en subconjuntos independientes de entrenamiento y prueba con el objetivo de evitar contaminación de datos y garantizar una evaluación objetiva del modelo.

El conjunto de entrenamiento estuvo conformado por 664 imágenes correspondientes a productos en buenas condiciones y 582 imágenes correspondientes a productos defectuosos. Adicionalmente, se utilizó un conjunto independiente de prueba compuesto por 100 imágenes de cada categoría para validación experimental.

3.2. Preprocesamiento de imágenes

Antes del entrenamiento, todas las imágenes fueron redimensionadas a una resolución de 224×224 píxeles. Asimismo, los valores de intensidad de los píxeles fueron normalizados en el rango $[0,1]$ para facilitar el procesamiento por la red neuronal convolucional.

Con el objetivo de mejorar la capacidad de generalización del modelo y reducir efectos de sobreajuste, se aplicaron técnicas de aumento de datos (data augmentation), incluyendo:

- Rotaciones aleatorias.
- Variaciones de brillo.
- Desplazamientos horizontales y verticales.
- Zoom aleatorio.
- Reflejo horizontal.

3.3. Arquitectura del modelo

El modelo desarrollado corresponde a una red neuronal convolucional (CNN) compuesta por múltiples capas convolucionales y de agrupamiento (pooling), seguidas por capas densas para la clasificación final.

La arquitectura implementada incluye:

- Tres capas convolucionales con funciones de activación ReLU.
- Capas MaxPooling para reducción espacial.
- Una capa Flatten para vectorización de características.
- Una capa densa de 128 neuronas.
- Una capa Dropout para reducir sobreajuste.
- Una capa de salida Softmax para clasificación binaria.

El entrenamiento del modelo fue realizado utilizando el optimizador Adam y la función de pérdida categorical crossentropy.

Tabla 1. Arquitectura de la red neuronal convolucional utilizada.

Capa	Configuración
Conv2D	32 filtros, kernel 3x3
MaxPooling	2x2
Conv2D	64 filtros, kernel 3x3
MaxPooling	2x2
Conv2D	128 filtros, kernel 3x3
MaxPooling	2x2
Dense	128 neuronas
Dropout	0.5
Salida	2 clases (Softmax)

3.4. Entrenamiento y validación

Durante las primeras pruebas experimentales se identificaron comportamientos de sobreajuste, observándose una diferencia considerable entre el desempeño del entrenamiento y validación.

Para reducir este problema se implementó una estrategia de Early Stopping, permitiendo detener automáticamente el entrenamiento cuando el desempeño sobre el conjunto de validación dejaba de mejorar.

Finalmente, el desempeño del modelo fue evaluado mediante métricas de clasificación y análisis visual de resultados.

3.5. Diseño preliminar de aplicación móvil

Como complemento del sistema de inspección visual, se desarrolló un prototipo de interfaz móvil utilizando la plataforma Figma. Este diseño tiene como objetivo explorar futuras implementaciones del modelo en dispositivos móviles orientados a aplicaciones de monitoreo industrial en tiempo real.

4. Resultados

El modelo fue evaluado utilizando un conjunto independiente de validación compuesto por imágenes de productos en condiciones aceptables y defectuosas.

Durante las primeras etapas experimentales se identificaron efectos de sobreajuste, observándose una diferencia considerable entre el desempeño de entrenamiento y validación. Para mitigar este comportamiento, se implementaron técnicas de aumento de datos (data augmentation) y Early Stopping.

Los resultados preliminares obtenidos muestran un comportamiento estable del modelo bajo condiciones industriales reales, evidenciando el potencial de las redes neuronales convolucionales para aplicaciones de inspección visual automatizada.

El modelo alcanzó una exactitud (accuracy) de validación cercana al 73 % durante las pruebas experimentales preliminares.




Fig. 1. Pipeline general del sistema de inspección visual propuesto.

La Figura 2 muestra el flujo general del sistema propuesto, desde la adquisición de imágenes hasta la clasificación automática mediante redes neuronales convolucionales.

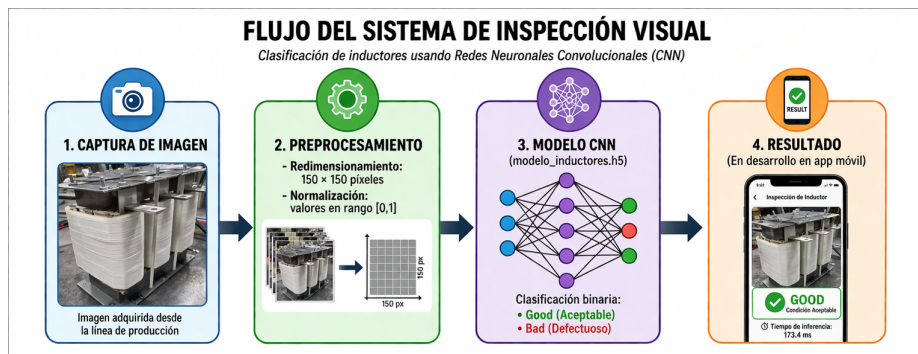


Fig. 2. Pipeline general del sistema de inspección visual propuesto.

La Figura 3 presenta ejemplos representativos de imágenes pertenecientes a las categorías utilizadas durante el entrenamiento y validación del modelo.

Las curvas de entrenamiento y validación obtenidas durante el proceso experimental se muestran en las Figuras 4 y 5.

La Figura 6 presenta la matriz de confusión obtenida durante las pruebas experimentales preliminares.

La matriz de confusión permitió observar un mejor desempeño en la identificación de productos en buenas condiciones, mientras que algunos productos




Fig. 3. Ejemplos de imágenes correspondientes a productos en buenas y malas condiciones.




Fig. 4. Curva de accuracy durante el entrenamiento y validación del modelo.

defectuosos presentaron mayor dificultad de clasificación debido a similitudes visuales y variaciones presentes en el entorno industrial.

Los resultados muestran una evolución estable del entrenamiento, reduciendo considerablemente los efectos de sobreajuste observados durante las pruebas iniciales.

Asimismo, el sistema presentó tiempos de inferencia del orden de milisegundos por imagen, lo cual sugiere su viabilidad para aplicaciones de inspección visual en tiempo real.

Como complemento del sistema propuesto, la Figura 7 y Figura 8 presentan el diseño preliminar de una interfaz móvil desarrollada en Figma para futuras implementaciones orientadas a monitoreo industrial.




Fig. 5. Curva de pérdida (loss) durante el entrenamiento y validación del modelo.

5. Discusión

Los resultados obtenidos demuestran el potencial de las redes neuronales convolucionales para aplicaciones de inspección visual automatizada en entornos industriales. A pesar de las limitaciones inherentes al tamaño y variabilidad del conjunto de datos, el modelo logró identificar patrones relevantes asociados a productos defectuosos y no defectuosos bajo condiciones reales de operación.

Durante las primeras etapas experimentales se observaron comportamientos de sobreajuste, reflejados en una diferencia considerable entre el desempeño de entrenamiento y validación. Este comportamiento es común en modelos de aprendizaje profundo entrenados con conjuntos de datos relativamente reducidos.

Para reducir este efecto, se incorporaron técnicas de aumento de datos y estrategias de regularización, incluyendo Early Stopping y Dropout, logrando una evolución más estable durante el entrenamiento y una mejor capacidad de generalización. Asimismo, las pruebas experimentales permitieron observar la influencia de factores como iluminación, ángulos de captura y complejidad visual del entorno industrial sobre el desempeño del modelo. Esto evidencia la importancia de contar con conjuntos de datos más amplios y variados para futuras etapas de entrenamiento.

Por otra parte, el diseño preliminar de la aplicación móvil representa una aproximación inicial hacia la implementación de sistemas inteligentes de inspección visual accesibles y portátiles.

La posibilidad de ejecutar modelos de inteligencia artificial en dispositivos móviles abre nuevas oportunidades para aplicaciones de monitoreo industrial en tiempo real.




Fig. 6. Matriz de confusión obtenida durante la validación experimental del modelo.

Aunque los resultados actuales corresponden a una etapa preliminar del proyecto, el sistema desarrollado proporciona una base sólida para futuras investigaciones orientadas a mejorar la precisión, robustez y escalabilidad del modelo mediante arquitecturas más avanzadas y conjuntos de datos de mayor tamaño.

6. Conclusiones

En este trabajo se presentó el desarrollo de un sistema de inspección visual basado en redes neuronales convolucionales para la clasificación automática de productos industriales en condiciones aceptables y defectuosas. Los resultados experimentales obtenidos demostraron la viabilidad del uso de técnicas de visión artificial y aprendizaje profundo para aplicaciones de monitoreo e inspección industrial bajo condiciones reales de operación. Asimismo, el modelo mostró un desempeño estable y tiempos de inferencia adecuados para aplicaciones en tiempo real.

Durante el desarrollo del proyecto se identificaron desafíos importantes relacionados con el sobreajuste, variabilidad visual y tamaño limitado del conjunto de datos. No obstante, la incorporación de técnicas de regularización y aumento




Fig. 7. Flujo principal de la aplicación móvil.

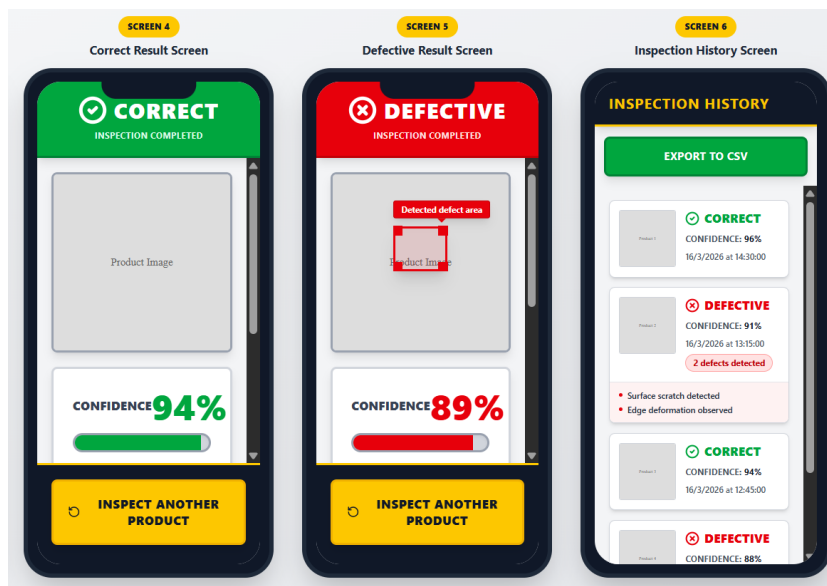


Fig. 8. Pantallas de resultados y registro histórico.

de datos permitió mejorar la capacidad de generalización del sistema y estabilizar el proceso de entrenamiento.

Adicionalmente, se desarrolló un prototipo preliminar de interfaz móvil orientado a futuras implementaciones de inspección visual inteligente en dispositivos portátiles, alineándose con tendencias actuales asociadas con Industria 4.0 y sistemas inteligentes de manufactura.

Como trabajo futuro, se contempla la ampliación del conjunto de datos, la incorporación de arquitecturas basadas en transfer learning, como MobileNetV2, y la implementación completa del sistema en plataformas móviles para aplicaciones industriales en tiempo real.

Finalmente, este trabajo establece una base experimental para futuras investigaciones relacionadas con sistemas inteligentes de inspección visual y detección automática de defectos en entornos industriales.

Referencias

1. LeCun, Y., Bengio, Y., Hinton, G.: Deep learning. *Nature*, 521(7553), 436–444 (2015)
2. Krizhevsky, A., Sutskever, I., Hinton, G.: ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90 (2017)
3. He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778 (2016)
4. Howard, A. et al.: MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861* (2017)
5. Tan, M., Le, Q.: EfficientNet: Rethinking model scaling for convolutional neural networks. *Proceedings of the International Conference on Machine Learning (ICML)* (2019)
6. Shorten, C., Khoshgoftaar, T.: A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 1–48 (2019)
7. Abadi, M. et al.: TensorFlow: Large-scale machine learning on heterogeneous systems. *Software available from tensorflow.org* (2015)
8. Lu, Y.: Industry 4.0: A survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, 6, 1–10 (2017)
9. Szeliski, R.: *Computer Vision: Algorithms and Applications*. Springer (2022)