

# Machine Learning para el control de calidad: aplicación de algoritmos de Object Detection para la industria automotriz.

Jesica Maia Numerosky, Lucas Rodriguez, Julián Arnesino y Matías Dinota

Cooperativa Eryx, CABA, Argentina {mnumerosky,lrodriguez}@eryx.co  
<https://www.eryx.co>

**Abstract.** Los algoritmos orientados a la detección de objetos (OD) basados en redes neuronales pueden ser aprovechados para disminuir la cantidad de autopartes defectuosas despachadas en una planta automotriz. Antes de su entrega, deben ser revisadas, proceso que, en general, se realiza manualmente. El objetivo del sistema diseñado es la automatización parcial de dicha inspección, corroborando mediante un sistema de *computer vision* (CV) la presencia o ausencia de accesorios. La instalación consta de equipamiento doméstico montado en una mesa de control (no se requirió *hardware* especializado); esto permite que sea fácilmente replicable utilizando cámaras web y una mini PC. Damos cuenta de los beneficios de la utilización de CV en estos contextos, las características del sistema, los desafíos enfrentados y sus soluciones.

**Keywords:** Computer Vision · Object Detection · Control de calidad · Automotriz.

## 1 Introducción

La visión artificial (CV) desempeña un papel significativo para los principales fabricantes de automóviles. A través de la implementación de este tipo de tecnologías en los procesos de producción pueden aprovechar nuevas herramientas que complementan el trabajo manual en las plantas industriales. Las mismas han abordado la adopción de tecnología desde distintos ángulos para mantener estándares de calidad y agilizar procesos de producción: robótica, realidad aumentada, sistemas informáticos para automatizar sus pedidos y demás [3].

Donde la inspección manual o de CV tradicional falla, el aprendizaje profundo (DL) puede proporcionar capacidades de inspección precisas para formas difíciles, piezas y modelos mixtos; y puede adaptarse y aprender a medida que cambian los productos, procesos y condiciones del ambiente [2]. Además, permite que los sistemas no solo localicen los defectos, sino también que los clasifiquen. Muchos fabricantes almacenan imágenes y datos de sus proyectos, y estos pueden ayudar a entrenar algoritmos de DL.

Actualmente la industria automotriz es la que más adopta sistemas de CV a nivel mundial y, según un informe [1], su adopción seguirá creciendo entre 2023 y 2030. En 2022 se utilizó mayormente para el segmento de QA e inspección.

## 2 Contexto del problema

La planta automotriz en la que desarrollamos este trabajo fabrica, entre otras autopartes, los techos interiores (*headliners* o techos) de 11 modelos de vehículos diferentes. Una vez fabricados, se les adicionan en su cara no visible una serie de accesorios. La cantidad y variedad de los mismos depende del tipo de vehículo.

Antes de ser despachado, el producto debe ser inspeccionado en sus dos caras: la visible es revisada para detectar defectos en la tela; la no visible, para chequear la presencia de los accesorios mencionados. La planta cuenta con una mesa de inspección sobre la cual se apoyan los techos de manera secuencial para revisar cada una de sus caras. Un mismo tipo de accesorio puede encontrarse en distintos tipos de techos y en cantidades variables. Los operarios deben asegurarse de que cada techo tenga los accesorios correspondientes para el modelo de vehículo que están inspeccionando. Para esto, ellos observan una tabla pegada en la pared que indica, para cada tipo de techo, la cantidad de cada accesorio que deberían encontrar. Este proceso es repetitivo y propenso a errores.

## 3 Descripción de la solución

Para aumentar la robustez, estandarización y auditabilidad del proceso; implementamos una solución que automatiza parcialmente la inspección de los techos. La misma consta de una instalación de seis cámaras ubicadas en la parte inferior de la mesa de inspección. De esta manera, al mismo tiempo que el inspector revisa la cara visible del techo, las cámaras captan desde abajo su cara no visible. Las mismas están conectadas a una computadora que también se encuentra en la mesa, donde corre nuestro sistema de inspección (fig. 1b).



(a) Pantalla que ve el operario y lo guía en la inspección.



(b) Subsistema de reconocimiento.

### 3.1 Implementación

El sistema implementado consta de dos subsistemas que corren en computadoras distintas y se comunican a través de una red local vía API. El primero de ellos guía al operario en el proceso de inspección, mientras que el segundo se encarga de reconocer los accesorios presentes en los techos y enviarle esa información al primero para que se tomen acciones de acuerdo al resultado obtenido. El motivo por el cual se decidió este diseño tiene que ver con la disposición espacial: la computadora del sistema de reconocimiento se encuentra en la mesa que gira 360 grados, lo cual dificulta la conexión directa a un monitor y a una red cableada.

Para decidir el algoritmo de OD a utilizar buscamos un balance entre precisión y velocidad en el reconocimiento de los objetos. Las fuentes consultadas comparan distintos algoritmos SOTA con YOLOv3 y YOLOv4 [5] [6], y estas últimas con YOLOv8 [4]; y reportan que este algoritmo es la mejor opción para realizar en tiempo real, comprometiéndose en poca medida la precisión. Utilizamos la versión *nano* del modelo preentrenado para hacer *transfer learning*: tomamos 700 fotos de los techos con diferentes configuraciones e hicimos *fine-tuning* del modelo en una GPU remota durante 167 épocas (una hora y media). Aumentamos los datos realizando pequeñas rotaciones de las imágenes para dar cuenta de pequeños movimientos en la mesa que pueden hacer que los accesorios se vean torcidos. Logramos un mAP50-95 de 0.949 a lo largo de todas las clases.

Diseñamos el sistema haciendo foco en la robustez y la modularidad. Algunos ejemplos de esto son los siguientes:

- Se permite configurar la cantidad de cámaras. Además de eso, el sistema continúa funcionando cuando alguna se desconecta o vuelve a conectar.
- Tanto el sistema como los *tests* permiten tomar videos como *input*, *mockeando* las seis cámaras. De esta forma pudimos testear el sistema a medida que lo desarrollamos con videos de la planta, sin necesidad de ir a la misma para obtener datos reales.
- El módulo reconocedor es fácilmente reemplazable, lo cual hace que el sistema sea replicable en una variedad de entornos. Puede emplearse cualquiera de los algoritmos que existen, o incluso uno propio.
- El subsistema de reconocimiento provee una API REST con variedad de *end-points* para distintas necesidades que pueda tener el otro subsistema: dada una detección en una imagen, guardar un resultado serializado; *streamear* las imágenes con sus detecciones para que una pantalla las muestre, etc.

## 4 Resultados

El sistema se encuentra desplegado en la planta y funcionando desde abril de 2023. Luego de un periodo de *ramp-up*, donde comenzaron inspeccionando 80 techos diarios, esta cantidad fue creciendo hasta alcanzar una media de 579 inspecciones diarias y un máximo de 973. Contamos con resultados correspondientes a 69 días de uso. En ese período se realizaron 33988 inspecciones, con una duración que tiene una mediana de 71 segundos. Nuestro sistema indica que, de

los techos que ingresan a inspección, el 0,25% tiene algún componente faltante o mal colocado. Cuando eso ocurre, el operario inspecciona el techo manualmente y, en caso de que el techo sea efectivamente defectuoso, lo envía a reparación (si es posible arreglarlo) para adicionar accesorios faltantes o lo descarta. Como no está registrado lo que vio el inspector en ese momento, no podemos saber si se trataba de un falso negativo o no. Tampoco podemos saber con exactitud el porcentaje de falsos positivos. No obstante, remarcamos que las autoridades del área de control de calidad se encuentran satisfechas con el funcionamiento del producto, dado que no les reportaron casos de techos defectuosos despachados.

## 5 Trabajo a futuro

Si bien este sistema es un producto que ya se encuentra terminado, lo vemos como un proyecto en constante desarrollo. En ese sentido, estamos adaptándolo para que soporte un módulo de clasificación. El objetivo inmediato es utilizarlo en el control de calidad de otras piezas (se nos solicitó implementarlo para la clasificación de las telas de los asientos, apoyabrazos e interiores de las puertas) y, a largo plazo, emplearlo incluso en otros rubros diferentes del automotriz.

Además de eso, el desarrollo actual puede “alimentar” un módulo (actualmente en desarrollo) que brinde estadísticas en tiempo real en una pantalla. Esto podría brindarle a los tomadores de decisiones información concreta para detectar puntos de falla y “afinar el lápiz” para mejorar sus procesos de producción.

Por último, tuvimos que hacer un *trade-off* entre la carga de CPU y los FPS que mostramos. El algoritmo YOLO permite inferir unos 12,5 FPS en una CPU convencional, pero por el uso de 6 cámaras en simultáneo decidimos limitar la calidad de la *stream* a 2 FPS para no sobrecargarla. Queda pendiente la exploración de técnicas de *pruning* del modelo para abordar esta cuestión.

## Bibliografía

1. Machine Vision Market Growth & Analysis Report, 2030, <https://www.grandviewresearch.com/industry-analysis/machine-vision-market>, consultado el 2023/05/05.
2. Mahony, N.O., Campbell, S., Carvalho, A., Harapanahalli, S., Velasco-Hernandez, G., Krpalkova, L., Riordan, D., Walsh, J.: Deep Learning vs. Traditional Computer Vision. (2020).
3. Digitizing the Human Side of Manufacturing – Retrocausal, <https://retrocausal.ai/digitizing-the-human-side-of-manufacturing/>, consultado el 2023/05/05.
4. Jocher, G., Chaurasia, A., Qiu, J.: YOLO by Ultralytics. (2023).
5. Tan, L., Huangfu, T., Wu, L., Chen, W.: Comparison of RetinaNet, SSD, and YOLO v3 for real-time pill identification. BMC Med Inform Decis Mak. 21, 324 (2021). <https://doi.org/10.1186/s12911-021-01691-8>.
6. Kim, J., Sung, J.-Y., Park, S.: Comparison of Faster-RCNN, YOLO, and SSD for Real-Time Vehicle Type Recognition. In: 2020 IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia). pp. 1–4 (2020). <https://doi.org/10.1109/ICCE-Asia49877.2020.9277040>.