



## **SISTEMA DE INSPECCIÓN AUTOMATIZADO SUPERVISADO EN BOCA DE ENVASE PEAD**

### **SUPERVISED AUTOMATED INSPECTION SYSTEM IN HDPE CONTAINER TOP**

Claudia Mayerli Cifuentes Molina<sup>1</sup>, Cristian David López Vargas<sup>2</sup> y José John Fredy  
González Veloza<sup>3</sup>

#### **RESUMEN**

El consumo de una gran variedad de productos que ofrece el mercado a nivel nacional tiene en común los controles de calidad que se realizan previos y durante sus procesos de manufactura para ser comercializados posteriormente; estos controles han evolucionado a través del tiempo de acuerdo a los requisitos creados por los entes reguladores para mejorar la calidad del producto final. Por eso, con el desarrollo de este proyecto se busca que con la ayuda de un submodelo de aprendizaje supervisado de Machine Learning con imágenes, se reduzcan los defectos que presentan los envases, específicamente en la prueba de hermeticidad que puede fallar hasta un 50% dependiendo la inestabilidad del proceso.

A partir de los sistemas automáticos (machine learning) implementados en diferentes industrias como farmacéutica y alimentos, se ensaya utilizar un modelo de Deep learning para la identificación de la ovalidad de la boca de un envase fabricado en PEAD (polietileno de alta densidad), a partir de 1512 imágenes tomadas con una cámara de celular de 48 MP y unas variables controladas durante el proceso.

El modelo de clasificación entrenado logra un AUC de 99% en los datos de validación para la identificación del defecto de ovalidad en la boca del envase.

**Palabras clave:** Aprendizaje automático, aprendizaje profundo, envase PEAD, hermeticidad.

---

<sup>1</sup> Fundación Universitaria Los Libertadores, Bogotá-Colombia, Contacto: [cmCIFuentesm@libertadores.edu.co](mailto:cmCIFuentesm@libertadores.edu.co)

<sup>2</sup> Universidad de Ciencias Aplicadas y Ambientales - UDCA, Bogotá-Colombia, Contacto: [cristianlopez.9201@gmail.com](mailto:cristianlopez.9201@gmail.com)

<sup>3</sup> Fundación Universitaria Los Libertadores, Bogotá-Colombia, Contacto: [jjgonzalezv02@libertadores.edu.co](mailto:jjgonzalezv02@libertadores.edu.co)



## **ABSTRACT**

The consumption of a wide variety of products offered by the market at the national level has in common the quality controls that are carried out prior to and during their manufacturing processes to be subsequently marketed; These controls have evolved over time in accordance with the requirements created by regulatory entities to improve the quality of the final product. For this reason, with the development of this project, it is sought that with the help of a submodel of supervised learning of Machine Learning with images, the defects that the containers present are reduced, specifically in the hermeticity test that can fail up to 50% depending the instability of the process.

From the automatic systems (machine learning) implemented in different industries such as pharmaceuticals and food, a Deep learning model is tested to identify the ovality of the mouth of a container made of HDPE (high density polyethylene), through from 1512 images taken with a 48 MP cell phone camera and controlled variables during the process.

The trained classification model achieves an AUC of 99% in the validation data for the identification of the defect of ovality in the mouth of the container.

**Keywords:** Machine learning, Deep learning, HDPE packaging, hermeticity.

## **INTRODUCCIÓN**

El presente trabajo de investigación propone detectar en un envase PEAD de tres litros (ver figura 1), las bocas ovaladas de un lote de producción, que normalmente es utilizado para el almacenamiento de suavizante. Al encontrarse este defecto en la boca se genera incumplimiento en la prueba de hermeticidad, puesto que se detecta fuga, causando re procesos o devolución en su defecto si este envase llega así al cliente y este detecta derrames de su producto envasado, debido a que en el arranque de producción puede fallar hasta un 50% de defecto en la boca y durante el proceso estable se evidencia en un 0.8% por variaciones del proceso en la máquina. Esta falla, que afecta la calidad del envase, trae adicionalmente consecuencias monetarias para la compañía y con el cliente final que puede llegar a dar por terminado el contrato.



**Figura 1.** Envase PEAD de tres litros color azul.

De esta manera, se evidencia la oportunidad de mejora con la implementación de un modelo inteligente Deep learning, para la detección sencilla de la ovalidad que se puede presentar las bocas en los envases, puesto que la detección de fallas es uno de estos dominios que está experimentando un gran éxito en la visión artificial (Pathak et al., 2018).

El consumo de cualquiera de los productos que ofrece el mercado a nivel mundial dentro de un sin fin de variedades en alimentos, medicamentos, accesorios personales, para el hogar, mascotas y demás, cuentan con algo en común durante sus procesos de manufactura; son los controles de calidad e inspección a las que deben ser sometidos para cumplir con los estándares que exigen los organismos reguladores de acuerdo al sector, para que estos sean liberados y comercializados. Estos controles han evolucionado a través del tiempo y también con el aumento de los requisitos creados por los entes reguladores, puesto que, al ser un proceso de revisión realizado netamente por personas encargadas para este fin, ocasionando el progreso en la comprensión de los mecanismos cerebrales que requiere la construcción de modelos computacionales que no solo emulan la anatomía y la fisiología del cerebro, sino



que, en última instancia, igualan su rendimiento en tareas visuales (Pinto et al., 2008; Wei, 2019).

Para disminuir la probabilidad al error humano y garantizar la calidad de los productos, se propone en este trabajo el uso de redes neuronales convolucionales (CNN), conocidas como ConvNets, uno de los algoritmos más utilizados de Deep learning, que plantea una estrategia para aprender representaciones de características más adecuadas en la tarea de detección de objetos y con buena capacidad de generalización (Ouyang et al., 2017).

Los resultados que se obtienen en el desarrollo de este proyecto, pueden brindar alcance a los demás equipos que fabrican otros envases en la misma industria de plástico y así dispersar la información a otras empresas que puedan presentar este tipo de inconsistencias.

## **REFERENTES TEÓRICOS**

### **Aprendizaje de máquina (ML)**

El aprendizaje de máquina es creado como un sub campo de la inteligencia artificial (IA) para resolver problemas más complejos, debido a que el ML aprende de la experiencia y mejora su rendimiento a medida que aprende (Bini, 2018), es un sistema de aprendizaje automático que le permite a la máquina construir predicciones a partir de reglas (Srivastava, 2021); Estos sistemas automáticos de inspección visual son implementados en los procesos de manufactura para brindar un alto nivel de precisión en la verificación de los productos pese a que los consumidores son igualmente muy exigentes y poco pacientes con la calidad de estos (Zhao, 2019).

### **Deep learning.**

Las “redes neuronales profundas” son versiones más complejas de estos modelos que hacen uso de niveles jerárquicos para segregar y gestionar el resultado final. Estas redes han dado lugar a una nueva forma de IA, conocida como "aprendizaje profundo" (Helm et al., 2020) y el propósito principal de la detección de objetos es identificar y ubicar uno o más objetivos efectivos a partir de imágenes fijas o datos de video (Cao et al., 2020; Dai et al., 2016), en este caso, son imágenes fijas que se tomaron de un envase PEAD recién soplado.



### **Polietileno de alta densidad.**

El PEAD (polietileno de alta densidad) es un homopolímero sintético inerte, empleado en moldeo por inyección y soplado con una distribución de peso molecular amplia (Guerrero et al., 2003), es ampliamente utilizado en producción de envases para uso doméstico e industrial. En Colombia la mayoría de empresas se rigen respecto a la *NTC 5511* (Instituto Colombiano de normas técnicas y certificación. INCOTEC, 2007), donde se define los criterios de aceptación de un envase plástico, así mismo, detalla la prueba de hermeticidad que debe realizarse para cumplir la inexistencia de fuga del producto.

Se han realizado estudios que son de gran interés e innovación teórica, como el método para la detección y clasificación en tiempo real de defectos de superficies plásticas utilizando aprendizaje profundo que es You Only Look Once (YOLO), mostrado un rendimiento excelente en la detección de objetos (Bin Roslan et al., 2022), o la clasificación de latas dentro del proceso de fabricación de envases de aluminio para bebidas, acertando exitosamente en un 88% de las latas que tienen o no barniz interno (Soto, 2021), ambos con un enfoque en la satisfacción del cliente, prevención de errores, reducción de costos, participación de todos los integrantes de la empresa y generación de competitividad (Arenas, 2014).

En la era actual de rápidos avances tecnológicos también se encuentra la investigación de clasificación plástica con imágenes hiperespectrales NIR y aprendizaje profundo, donde la inteligencia artificial (IA) ha pasado de ser una mera teoría a una aplicación tangible en una escala sin precedentes (Helm et al., 2020), donde se logra resultados de rendimiento notables con una puntuación f1 general y una precisión de 0,79 para todos los plásticos, 0,9 para plásticos de colores y 0,67 para plásticos negros (Sbrana et al., 2023).

### **METODOLOGÍA**

Para el desarrollo de este proyecto se solicita el permiso al gerente general para tomar las fotografías durante el proceso de manufactura del lote de producción número 1230369598 el pasado 03 de marzo de 2023, a continuación, se discrimina cada paso.



**Figura 2.** Envase PEAD de tres litros color azul.

### **Muestreo.**

Se realiza un muestreo de cerca de 4 horas para la toma de 1512 imágenes, entre 5 y 6 por minuto. Estas imágenes fueron tomadas con un celular marca VIVO Y33 que cuenta con una cámara trasera principal de 48 MP viene con una variedad de funciones de procesamiento.

Las imágenes fueron tomadas a una altura de 15 cm arriba de la boca y un ángulo de 90°, se crea un soporte en el equipo (ver figura 2), se configura la cámara a un tamaño de fotografía 1:1, se activa las líneas de encuadre (para fijar el centro de la boca) y se realiza la toma de la fotografía con un disparo manual cada 12 segundos y ayuda de un dispositivo bluetooth. Esto permite que la ubicación y condiciones de luz sean iguales para todas las imágenes.

### **Sopladora**

La máquina de soplado número 10 de marca TONGDA MACHINERY Co está identificada con un número de modelo IT6000 y cuenta con los datos de rendimiento (ver tabla 1).



**Tabla 1.** Datos de rendimiento de máquina de soplado.

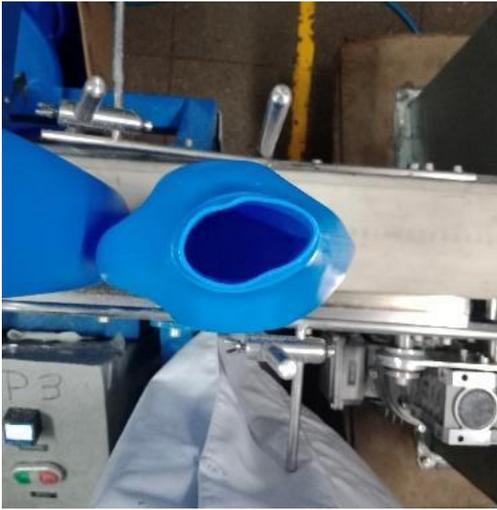
|  |              |  |
|--|--------------|--|
| Peso neto (sin extrusora, cabezal de extrusión y WBK)            | kg           | aprox. 5.100                                   |
| Aire requerido   | NI/min.      | 2.000  |
| Refrigeración necesaria para el depósito hidráulico              | kJ/h         | aprox. 39.800                                  |
| Refrigeración de la zona de alimentación de la extrusora + molde | kJ/kg/h      | HMPE 720 + 150<br>PE 590 + 110<br>PVC 420 + 70 |
| Potencia del motor bomba hidráulica                              | kW           | 18,5   |
| Corriente de carga total del sistema completo                    | A            | 112  |
| Carrera del sistema de cierre                                    | mm           | 350  |
| Ciclos en vacío  | s            | 2,1  |
| Número máximo de ciclos por estación                             | 1/min.       | 10   |
| Fuerza de cierre del molde                                       | kN           | 100  |
| Presión de operación del agua de refrigeración                   | bar<br>(psi) | 4 (58)   |
| Presión de operación del sistema neumático                       | bar<br>(psi) | 8 - 10 (116 - 145)                             |
| Presión neumática de entrada recomendada                         | bar<br>(psi) | MÁX. 12 (174)                                  |

### **Clasificación e identificación de imágenes.**

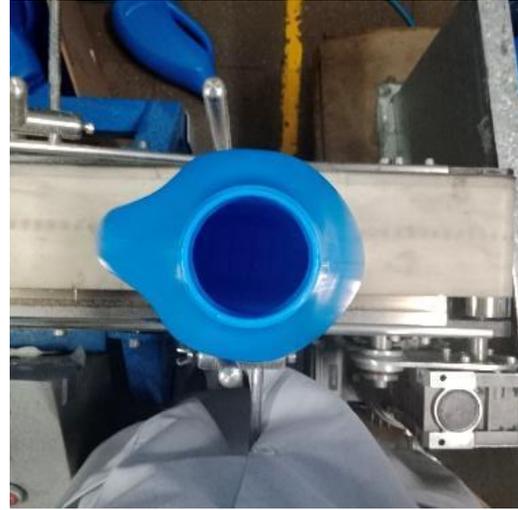
De las 1512 imágenes se toma una a una, se revisa y clasifica en dos carpetas con defecto (ver figura 3a) y sin defecto (ver figura 3b).

### **División del conjunto de datos.**

Se realizó una partición de las imágenes recolectadas en tres grupos: el primero, corresponde al 70% de los datos para el entrenamiento del modelo, el segundo, al 20% que corresponde a la validación del modelo y el último grupo con un 10% que corresponde a la prueba final del modelo.



**Figura 3a.** Con defecto



**Figura 3b.** Sin defecto

### **Descripción del modelo.**

Se escogió un modelo de referencia para la clasificación de imágenes publicado por Nicolás Renotte, quien crea un cuaderno en Jupyter que muestra un clasificador de imágenes con Python y Tensorflow para detectar si una persona se encuentra triste o feliz. Nicolás Renotte comparte con el público más de 164 repositorios que se encuentran disponibles en la red <https://github.com/nicknochnack/ImageClassification.git>, además de compartir una serie de información en su página oficial que permitió el desarrollo de este modelo para la clasificación binaria de este envase cuando se encuentra o no con defecto en la boca.

Inicialmente, el modelo se alimenta de las imágenes originales con un tamaño de entrada de 256x256x3 que corresponde a las imágenes con y sin defecto, donde el modelo redimensiona cada una de estas de 0 a 1 y se realiza la división del conjunto de datos, donde hay un total de 47 lotes cada uno con 32 imágenes, con esta información, se construye un modelo secuencial de Deep learning utilizando una red neuronal convolucional (CNN) de tres capas y dos tipos de función de activación, 'relu' y 'sigmoide', un optimizador “Adam” y finalmente se incluye un callback de cinco épocas o fases por cada lote con el fin de detener el modelo cuando el AUC sobre los datos de validación se estabilice esto último con el fin de evitar el overfitting del modelo sobre los datos de entrenamiento (Soto, 2021).

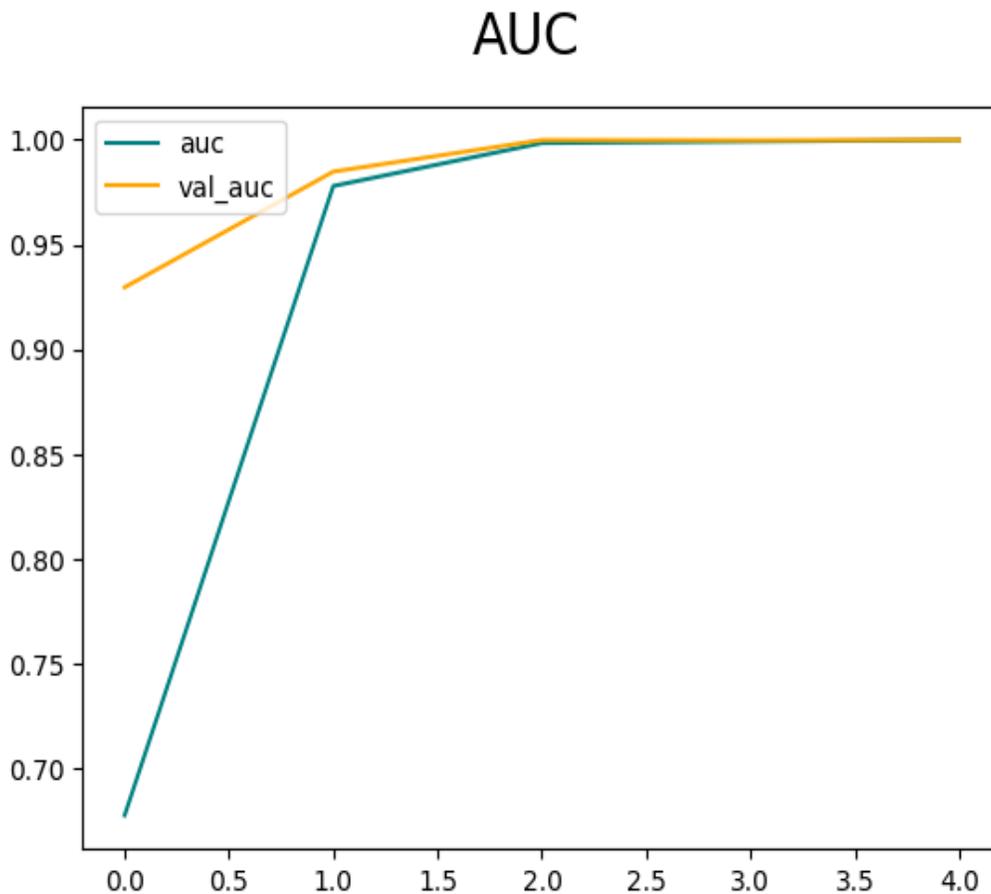


## RESULTADOS

### Entrenamiento del modelo

El entrenamiento del modelo desarrollado se puede evidenciar con la evolución del área bajo la curva (AUC) (ver figura 4), métrica utilizada para verificar el rendimiento de este modelo de clasificación binaria.

El tiempo de ejecución de las cinco fases de entrenamiento del modelo para las 1512 imágenes fue de 28 minutos con un procesador Intel(R) Core(TM) i7-4790 CPU @ 3.60GHz, 3601 Mhz, 4 procesadores principales, 8 procesadores lógicos y una memoria física instalada (RAM)8,00 GB.



**Figura 4.** Resultado de AUC vs la validación de AUC.



### Desempeño del modelo

Para la revisión del modelo propuesto, se genera una matriz de confusión (ver figura 5) y valorar el desempeño de este, observando que la tasa de falsos negativos es de 1, es decir, el modelo identifica un 94% de las bocas cuando se encuentran con defecto y el 100% de las bocas que no tienen defecto.

|                        | Esperado Sin defecto | Esperado Con defecto |
|------------------------|----------------------|----------------------|
| Predicción Sin defecto | 111                  | 0                    |
| Predicción Con Defecto | 1                    | 16                   |

**Figura 5.** Matriz de confusión en datos de testeo.

La precisión y sensibilidad conseguida en datos de prueba es del 100% para el modelo entrenado, con un tiempo de inferencia de 105 ms por imagen.

### CONCLUSIONES

Este proyecto describe el desarrollo de un modelo de aprendizaje profundo para la clasificación binaria de un envase de PEAD, cuya boca puede encontrarse o no defectuosa en una línea de producción de una empresa que fabrica envases plásticos. A partir del modelo desarrollado se consiguió una evolución del área bajo la curva (AUC) de 0.9992, es decir, presenta un muy buen rendimiento como un clasificador binario y una precisión general del 100%, identificando de manera correcta si la boca del envase tiene o no defectos. Adicionalmente, de acuerdo a la matriz de confusión para los datos de testeo demuestra de forma explícita que los falsos negativos obtenidos son de 1, por lo que el modelo desarrollado es confiable. Las implementaciones generales de este tipo de modelos en la industria generan un control bastante efectivo de los defectos, sin embargo, no es ampliamente utilizado debido



a la falta de conocimiento del uso de visión artificial en tiempo real, lo cual sería una ventaja para el proceso.

### **RECOMENDACIONES.**

Para futuros modelos a desarrollar se recomienda el uso de un GPU (procesador gráfico de imágenes), que acelera el procesamiento de las imágenes puesto que la complejidad y cantidad que se necesitan para el entrenamiento de un modelo en Deep learning son bastantes. También, testear el modelo con una mayor cantidad de imágenes para verificar que no esté sobre ajustado.

### **REFERENCIAS BIBLIOGRÁFICAS**

- Arenas, A. V. P. (2014). *DISEÑO DE UN SISTEMA DE CONTROL DE CALIDAD PARA EL PROCESO PRODUCTIVO DE LA EMPRESA RYCAR S.A.*
- Bin Roslan, M. I., Ibrahim, Z., & Aziz, Z. A. (2022). Real-Time Plastic Surface Defect Detection Using Deep Learning. *2022 IEEE 12th Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, 111–116. <https://doi.org/10.1109/ISCAIE54458.2022.9794475>
- Bini, S. A. (2018). Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care? *Journal of Arthroplasty*, 33(8), 2358–2361. <https://doi.org/10.1016/j.arth.2018.02.067>
- Cao, D., Chen, Z., & Gao, L. (2020). An improved object detection algorithm based on multi-scaled and deformable convolutional neural networks. *Human-Centric Computing and Information Sciences*, 10(1). <https://doi.org/10.1186/s13673-020-00219-9>
- Dai, J., Li, Y., He, K., & Sun, J. (2016). *R-FCN: Object Detection via Region-based Fully Convolutional Networks*. <http://arxiv.org/abs/1605.06409>
- Guerrero, C., Lozano, T., González, V., & Arroyo, E. (2003). Morfología y propiedades de politereftalato de etilen-glicol y polietileno de alta densidad. *CIENCIA UANL / VOL N°2*.
- Helm, J. M., Swiergosz, A. M., Haerberle, H. S., Karnuta, J. M., Schaffer, J. L., Krebs, V. E., Spitzer, A. I., & Ramkumar, P. N. (2020). Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions. In *Current Reviews in Musculoskeletal*



*Medicine* (Vol. 13, Issue 1, pp. 69–76). Springer. <https://doi.org/10.1007/s12178-020-09600-8>

Instituto Colombiano de normas técnicas y certificación. INCOTEC. (2007). *NTC 5511. ENVASES PLASTICOS. USO GENERAL.*

Ouyang, W., Zeng, X., Wang, X., Qiu, S., Luo, P., Tian, Y., Li, H., Yang, S., Wang, Z., Li, H., Wang, K., Yan, J., Loy, C. C., & Tang, X. (2017). DeepID-Net: Object Detection with Deformable Part Based Convolutional Neural Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(7), 1320–1334. <https://doi.org/10.1109/TPAMI.2016.2587642>

Pathak, A. R., Pandey, M., & Rautaray, S. (2018). Application of Deep Learning for Object Detection. *Procedia Computer Science*, 132, 1706–1717. <https://doi.org/10.1016/j.procs.2018.05.144>

Pinto, N., Cox, D. D., & DiCarlo, J. J. (2008). Why is real-world visual object recognition hard? *PLoS Computational Biology*, 4(1), 0151–0156. <https://doi.org/10.1371/journal.pcbi.0040027>

Sbrana, A., de Almeida, A. G., de Oliveira, A. M., Neto, H. S., Rimes, J. P. C., & Belli, M. C. (2023). Plastic Classification With NIR Hyperspectral Images and Deep Learning. *IEEE Sensors Letters*, 7(1), 1–4. <https://doi.org/10.1109/LSSENS.2023.3234401>

Soto, J. (2021). *CLASIFICADOR DE LATAS SIN BARNIZ INTERNO DENTRO DEL PROCESO DE FABRICACIÓN DE ENVASES DE ALUMINIO PARA BEBIDAS.*

Srivastava, S. , D. A. V. , A. C. (2021). *Análisis comparativo de algoritmos de detección de imágenes de aprendizaje profundo.*

Wei, W. , C. T. , X. W. , Y. L. , Y. H. y J. L. (2019). *Reconocimiento de objetos de imagen.*

Zhao, Z. Q. , Z. P. , X. S. T. , & W. X. (2019). *Detección de objetos con aprendizaje profundo una revisión.*