

Separador industrial PET mediante técnicas de visión computacional

Irving Misael Caballero Aquino, Axel Adrián Casarrubias Calvillo,
Rubén Daniel Vera León

Universidad Politécnica del Valle de México,
México

{irving.caballero.aquino, axel.casarrubias.calvillo,
ruben.vera.leon}@upvm.edu.mx

Resumen. En el ámbito del sector industrial existen amplias aplicaciones a la recolección y clasificación de plásticos, así como el PET, aunque, la principal razón por la que este suele ser recolectado es para reciclarlo. El PET usualmente se segmenta en dos categorías: PET cristalino y PET de color, dicha segmentación por lo regular consiste en una técnica en donde un grupo de personas están al pendiente del lugar donde se junta el PET y lo va separando por categoría (cristal y de color) para así llevar a cabo el proceso de reciclaje. Nosotros logramos desarrollar una alternativa para la clasificación de PET con ayuda de inteligencia artificial logrando detectar los tipos o bien la clase a la cual corresponde. Se pretende implementar ésta técnica de clasificado conectando una cámara que será la extensión del clasificador para la aplicación de inteligencia artificial y con ello, poder identificar a alta velocidad el tipo de PET y definir a que clase pertenece, reduciendo tiempo y esfuerzo en el proceso de clasificación de PET y satisfaciendo las necesidades de reciclaje, cuidado del medio ambiente, reducción de basura en las calles, así como el cuidado del calentamiento global, las cuales son problemáticas actuales que necesitan de soluciones.[1]. Ya que la revolución e innovación de la tecnología cada vez es más eficiente, este proyecto es competente para participar y aplicarlo en el sector de INDUSTRIA 4.0 [2, 3]. La norma ISO 14001 [4] en algunos países es exigente ante todas las industrias cuando se trata de ecología y medio ambiente, por lo que nos dimos la tarea de implementar procesos más rápidos y eficientes ya que es una de las operaciones o procesos más comunes. Es por esto que nuestro clasificador de PET es una de las mejores herramientas gracias a la implementación de inteligencia artificial [5].

Palabras clave: PET, innovación, industria 4.0, medio ambiente, ISO, calentamiento global, reciclar

Pet Industrial Separator Using Computer Vision Techniques

Abstract. In the field of the industrial sector there are extensive applications of collecting and classifying plastics, as well as PET, albeit the mean reason is for recycling. PET is usually segmented in two categories: crystalline and colored pet this consists of a technique where a group of people are on the slope of the

place where the pet meets and separates it by class (glass) and (colored) in order to carry out the process of recycling. We managed to develop an alternative for PET classification with the help of artificial intelligence managing to detect the types or the class with which they are corresponding to. It is intended to use this classifier connected to a camera which is an extension of the classifier for the artificial intelligence application, as well as identify at high speed the type of PET and also define which class the PET belongs to, in order to reduce time end effort on the PET classifying process, satisfying some necessities like recycling, taking care of the environment, and excess rubbish on the streets and also with the care of global warming which are nowadays problems that need answers. Since the revolution and innovation of technology is becoming more efficient this project is competent to participate and apply in the sector of INDUSTRIA 4.0 ISO 14001 standard in some countries is demanding in all industries when it comes to ecology and environment, consequently, we were tasked with implementing faster and more efficient processes as it is one of the most common operation or processes, worldwide. That's why our PET classifier is one of the best tools thanks to the implementation of artificial intelligence.

Keywords: PET, innovation, industry 4.0, environment, ISO, global warming, recycle.

1. Introducción

Hoy en día la aplicación y resecación de plásticos y PET es muy común ya que tiene una gran variedad de potencial a desempeñar. El plástico se ha hecho tan omnipresente que resulta difícil creer que apenas llevamos produciéndolo a escala industrial desde hace solo unas décadas.

Su historia es más reciente de lo que se podría pensar. Los primeros plásticos totalmente sintéticos empezaron a fabricarse a comienzos del siglo XX: la baquelita, ideada en 1907, fue el primero de ellos, pero no fue hasta después de la II Guerra Mundial cuando arrancó la fabricación y utilización masiva de todo tipo de materiales de ese tipo [6].

El tereftalato de polietileno (PET) es un polímero plástico que se obtiene mediante un proceso de polimerización de ácido tereftálico y mono etilenglicol. Es un polímero lineal, con un alto grado de cristalinidad y termoplástico en su comportamiento, lo cual lo hace apto para ser transformado mediante procesos de extrusión, inyección, inyección-soplado y termoformado. Sus principales características son:

- Es totalmente reciclable.
- Cristalinidad y transparencia, aunque admite cargas de colorantes.
- Buen comportamiento frente a esfuerzos permanentes.
- Alta resistencia al desgaste.
- Muy buen coeficiente de deslizamiento.
- Buena resistencia química.
- Excelente barrera a CO₂, aceptable barrera a O₂ y humedad.
- Compatible con otros materiales barrera que mejoran en su conjunto la calidad de barrera de los envases y por lo tanto permiten su uso en mercados específicos.

- Aprobado para su uso en productos que deban estar en contacto con productos alimentarios.

Las propiedades físicas del PET y su capacidad para cumplir diversas especificaciones técnicas han sido las razones por las que el material haya alcanzado un desarrollo relevante en la producción de fibras textiles y en la producción de una gran diversidad de envases, especialmente en la producción de botellas, bandejas, flejes y láminas [7].

El reciclaje es una de las alternativas utilizadas en la reducción del volumen de los residuos sólidos. Se trata de un proceso que consiste básicamente en volver a utilizar materiales que fueron desechados y que aún son aptos para elaborar otros productos o volver a fabricar los mismos.

El PET es uno de los subproductos que más se recupera debido a que tiene un alto precio de venta, aproximadamente \$6.80 por kg, el cual depende del mercado internacional, además de que se ha establecido un amplio canal de captación para su retorno a la industria.

El PET puede reciclarse múltiples veces, pero para uso alimentario solo se permite un primer nivel, pasado éste se utiliza para una amplia variedad de productos finales como: fibra, fibra de relleno textil, correas, y botellas y envases para usos no alimentarios como detergentes y productos fitosanitarios [1].

El PET se obtiene a partir de materiales de embalaje, como envases de comida y botellas de refrescos o de agua mineral. Para alcanzar un alto grado de calidad e higiene, los procesadores necesitan una corriente de pelets prácticamente pura. Esto se logra retirando productos de colores no deseados, aluminio, otros metales y muchas más sustancias extrañas [8].

2. Trabajos relacionados

Hoy en día, existen máquinas que se encargan de clasificar no solo PET, sino que también otros productos, aunque por lo regular, estas máquinas son enfocadas para ver si los productos cumplen con un color estándar o un aspecto en específico y estas máquinas suelen ser robustas debido al gran trabajo, así como con cierto costo elevado a cubrir para empresas pequeñas.

Las clasificadoras ópticas de la serie Sortex son prueba de ello pues realizan las funciones descritas, son equipadas con los desarrollos tecnológicos más innovadores, esta serie detecta impurezas, partículas extrañas y colores no deseados, y los descarta de forma eficaz [8, 9].

De acuerdo con el avance tecnológico y la necesidad de implementar nuevos métodos para ser competentes en la INDUSTRIA 4.0, se ha impulsado a que se utilice Deep Learning para obtener una mayor identificación y exactitud en nuestros procesos, esto queda evidenciado en [11], donde se propone la integración de aprendizaje profundo o Deep Learning en los procesos de reciclaje desarrollando un prototipo de sistema automatizado que integra visión artificial para la selección de empaques de plástico, vidrio y lata para la selección de material reciclable, debido al posible incremento de residuos para los próximos años en Colombia, lo que sugiere que la falta de un sistema eficiente de reciclaje propicia al desecho de elementos potencialmente

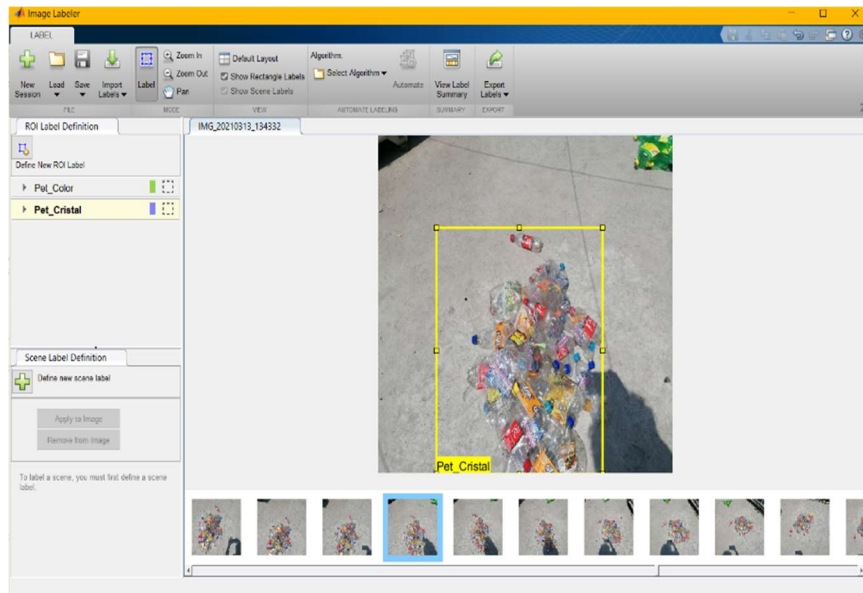


Fig. 1. Sesión de etiquetado en Matlab.

provechosos en beneficio de la industria y el medio ambiente. Ya que, con el proceso desarrollado manualmente, no se optimizan los recursos como tiempo y cantidad de materiales clasificados, por lo cual el porcentaje de residuos reciclados es bajo en este país.

Producto de esta práctica improvisada en los vertederos, se presentan consecuencias como daños ambientales, problemas de salubridad a la población, así como desaprovechamiento de recursos y materias primas. Esto indica que, debido al tradicional proceso de reciclaje, se está perdiendo materia prima, que eventualmente, puede reintegrarse al ciclo de vida útil, esto por la falta de implementación de un sistema de control que facilite el proceso de clasificación [11].

Una vez planteada la problemática y diseñado tanto el entrenamiento como la implementación del hardware [11], concluye que en el aplicativo se necesita diseñar una interfaz que permita a usuarios que no cuenten con el hardware probar la capacidad de clasificación de la red neuronal convolucional, con la finalidad de despertar la curiosidad por el aprendizaje profundo y sus aplicaciones.

El diseño de un hardware a escala expuso resultados positivos, lo que indica que este prototipo se puede adaptar a procesos de clasificación de residuos para contribuir con el cuidado del medio ambiente en Colombia implementando Deep Learning [11].

En [12] se muestra información importante con aspectos relacionados al desarrollo del proyecto, pues [12] emplea técnicas de Deep Learning y You Only Look Once V2 (YOLO V2) mediante MATLAB [13], si bien la solución no se relaciona en cuanto al eje temático abordado, este es un trabajo importante, ya que con estas técnicas se desarrolla el proyecto, lo cual nos permite tener una referencia de resultados favorables [12].

Tabla 1. Imágenes ocupadas para entrenar Clasificador de PET.

Clases	Número de Imágenes
PET Cristal	1000
PET Color	1000



Fig. 2. Arquitectura ResNet-18 con YOLO V2.

3. Materiales y métodos propuestos

Las redes neuronales convolucionales (CNN o ConvNets) son herramientas esenciales para el aprendizaje profundo y son especialmente útiles para tareas de clasificación de imágenes, detección de objetos y reconocimiento. Las CNN se implementan como una serie de capas interconectadas [18].

Para poder realizar la clasificación, se implementó un detector You Only Look Once (YOLO) v2 [10]. Como red neuronal base, se empleó ResNet-18 [14], la cual es una red neuronal convolucional que tiene 18 capas de profundidad, puede cargar una versión preentrenada de la red entrenada en más de un millón de imágenes desde la base de datos ImageNet [15]. La red preentrenada puede clasificar imágenes en 1000

Entrenar a YOLO V2 object detector

```
opts=trainingOptions('adam','MiniBatchSize',32,...  
    'InitialLearnRate',0.0001,...  
    'MaxEpochs',20,'LearnRateSchedule','piecewise',...  
    'LearnRateDropPeriod',75,...  
    'Shuffle','every-epoch',...  
    'L2Regularization',0.0001,'Verbose',true,'VerboseFrequency',50,...  
    'DispatchInBackground',true,...  
    'ExecutionEnvironment','auto')
```

Fig. 3 Configuración de entrenamiento.




Fig. 4. Función de pérdida con 20 épocas.

categorías de objetos. Para el entrenamiento, se proponen los siguientes requisitos detallados a continuación.

3.1. Categorías

El proyecto CALSIFICADOR DE PET empleó una base de datos de 2000 imágenes en 2 ROI labels: PET CRISTAL Y PET COLOR en la sesión de etiquetado de Matlab (Fig.1), aunque, previamente, la carpeta principal de la base de datos se dividió en dos en relación a su categoría (PET cristal y PET color), cada una de estas carpetas con 1000 imágenes.

Para evitar la pérdida de información al momento de etiquetar mediante el preprocesamiento de imágenes, se estableció un rango de dimensiones en todas las imágenes de 224 x 224 a 780 x 780, todas las imágenes se ajustaron al tamaño máximo establecido con la finalidad de acelerar el tiempo de entrenamiento, ya que, previamente se realizaron otros entrenamientos con imágenes sin reestablecer su tamaño, lo cual generó un tiempo prolongado de entrenamiento, pese a tener pocas categorías, además, el restablecimiento del tamaño, ayudó a igualar el tamaño de las fotografías, pues había fotografías horizontales y verticales en las carpetas. A pesar de que se restableció el formato de las imágenes, la resolución de las imágenes no fue afectada.

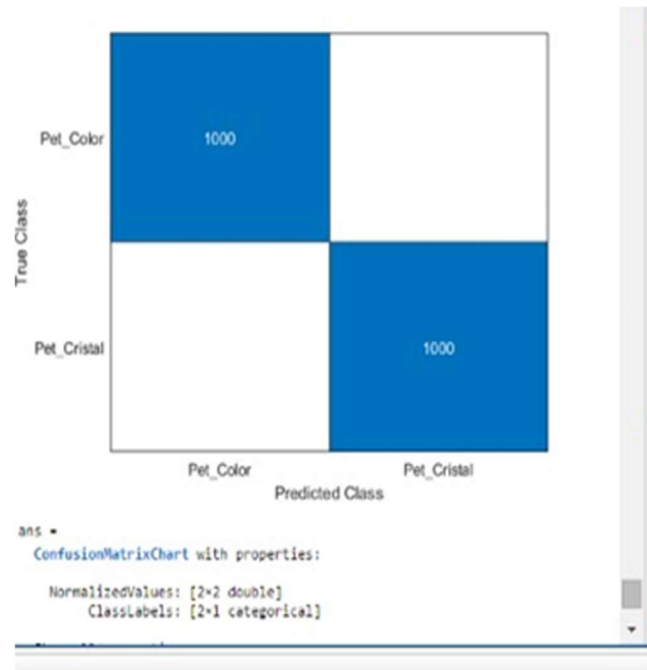


Fig. 5. Matriz de Confusión del entrenamiento petring.

Tabla 2. Comparación de entrenamiento.

Categoría	Imágenes Totales	Imágenes entrenadas
PET Cristal	1000	1000
PET Color	1000	1000

3.2. Dataset

Como se mencionó en el punto anterior, se utilizó una base de datos con un total de 2000 imágenes (Tabla 1). Los Dataset fueron recopilados por los participantes de este proyecto a partir de fotografías tomadas por ellos mismos, no obstante, hubo una Dataset previa en donde se recopilaron 5000 imágenes, sin embargo, se seleccionaron solo 2000 imágenes debido a sus características, además de ser un número razonable pues no era lo suficientemente grande para retrasar el entrenamiento de la red.

Por otro lado, se eligieron las 2000 imágenes para evitar confusiones, pues ciertas imágenes de la primera Dataset, tenían dos tipos de PETS combinados en una sola foto, lo cual generaba un conflicto al generar la matriz de confusión al estar almacenadas en una carpeta aparte.

Es importante aclarar que algunas imágenes empleadas en las pruebas son en su mayoría imágenes diferentes de la Dataset empleada, ya sea de la versión de 5000 imágenes o descargadas de Internet.



Fig. 6. Detección 1 PET CRISTAL.



Fig. 7. Detección 2 PET CRISTAL.



Fig. 8. Detección 3 PET CRISTAL.

3.3. Arquitectura

Para implementar el detector YOLO v2 en ResNet18 se estableció en inputLayer un tamaño mínimo de [224 224 3], posteriormente se generó una capa ReorgLayerSource en el nodo de Res3a_relu con la finalidad de obtener los datos procesados de las imágenes a través de las capas convolucionales y ReLu para poder realizar una detección ROI mediante los GroundTruth, posteriormente se genera una ReorgConcatenationLayer para finalmente ingresarlo al detector YOLO.

Reorg Layer sirve para combinar características de nivel medio y características de alto nivel y precisión de clasificación de getter a través de diferentes formas, como la combinación máxima y la suma. En YOLO v2, el autor usa una Reorg Layer para remodelar el tensor de salida a fin de que dos salidas de tensor puedan concatenarse juntas [17].

3.4. Entrenamiento

Se realizaron distintos entrenamientos con ciertas variantes en las bases de datos, la base de datos de 2000 imágenes funcionó, las anteriores pruebas tuvieron una



Fig. 9. Detección PET COLOR.



Fig. 10. Detección 2 PET COLOR.



Fig. 11. Detección 3 PET COLOR.

Tabla 3. Comparación de precisión de TESTS.

Categoría	Precisión del TEST
PET Cristal 1	.919
PET Cristal 2	.912
PET Cristal 3	.902
PET Colores 1	.886
PET Colores 2	.900
PET Colores 3	.867

configuración similar a la (Fig.3), pero con cambios en las épocas entre entrenamientos, siendo que partimos con la base de 5000 imágenes y 5 épocas, el primer entrenamiento generó un Mini-batch Loss de .7, una cantidad que podía ser mejorada, se optó por reducir la base de datos, es así que llegamos a la Dataset con su número de imágenes anteriormente mencionada que generó un entrenamiento rápido y efectivo.

Una vez tomada la decisión de usar una Dataset de 2000 imágenes, se realizaron ciertos entrenamientos, siendo 20 épocas y un MiniBatch Size de 32 suficientes para generar una Mini-batch Loss de .2.

Al momento de realizar los entrenamientos, se ocupó una Laptop Hp Pavilion Gaming con Tarjeta gráfica GeForce GTX 1660 Ti with Max-Q Design, durante 20 épocas, obteniendo la función de pérdida expuesta en (Fig.4), donde podemos ver una respuesta satisfactoria con esas épocas al irse reduciendo.

Con este entrenamiento se obtiene la matriz de confusión (Fig.5), se puede apreciar que no hay ninguna imagen que no se haya entrenado, lo cual es favorable, pues indica que no hubo pérdidas y que la red pudo aprovechar cada imagen para satisfacer los resultados del Object Detector. Una vez comparada la matriz de confusión con la cantidad total de imágenes con las que se entrenaron, se obtuvo lo indicado en la Tabla 2.

4. Resultados

Los modelos desarrollados fueron evaluados en el conjunto de prueba que consta de 6 imágenes tomadas de bases de datos descartadas anteriormente y algunas sacadas de la Dataset empleada.

Estas imágenes que se busca detectar con el entrenamiento indicado, mostraron, al ser introducidas en el código para pruebas, que PET es el que se encuentra en la imagen, ya sea de color o de cristal, es por lo que se usaron 6 imágenes en total, 3 para cada categoría para poner a prueba el entrenamiento.

Con relación a los resultados en las 3 primeras imágenes introducidas, se muestra que en todos los casos la detección marca que son PET cristal, puede haber ciertos errores, especialmente en la Fig.7 pues, se evitó que se pongan 2 Bounding Boxes al mismo tiempo con la condición de que se marque la opción que tiene más probabilidades al ser mayor de .7 y solo marca PET cristal, al ser el que es más visible en la imagen. En las Fig. [9, 10, 11] se aprecian las pruebas con imágenes que contengan en su mayoría PET de Color, por lo que, los resultados se inclinan y detectan PET COLOR.

Mediante Deep Learning se generó la clasificación, así mismo se entrenó con diferentes bases de datos, ya que contamos con una base de datos de 5,000 imágenes diferentes capturadas por nosotros mismos, luego de hacer los primeros entrenamientos, se mostraba un exceso de salidas al tener 3 carpetas, en la que una contenía imágenes donde se localizaban tanto PET cristal como PET de color en una misma imagen, lo cual no nos permitía generar una matriz de confusión, pues era difícil de interpretar al tener imágenes en que no pertenecían en su totalidad a un solo tipo de PET, por lo que la Matriz de Confusión quedaba desordenada y parecía que no había hecho un entrenamiento adecuado, obstaculizando al conocimiento de los resultados, optándose por una base de datos más pequeña enfocándonos en imágenes puramente de un solo tipo.

Una vez realizado el entrenamiento y las pruebas, en estas hubo una precisión óptima (Tabla 3), dicha conclusión la inferimos al ver el número que se encuentra en las etiquetas, pues indica el número de certeza que tiene el detector de que sea PET cristal o PET de color, aunque se puede observar en la detección 2 de PET cristal que solo

marca un área en un solo tipo e ignora el hecho de que se encuentra PET de color, lo cual se debe a las configuraciones realizadas en el entrenamiento.

5. Conclusiones y trabajo futuro

En este proyecto, se implementaron técnicas Deep Learning [13] y You Only look Once (YOLO) con MATLAB. para la detección y clasificación del PET este clasificador es un proyecto totalmente competente que, una vez desarrollado en un ambiente tangible que no solo se quede en detección de objetos, puede ser empleado principalmente para la industria 4.0 [16].

El proyecto, como ya se mencionó, puede ser aplicado en cualquier sector dedicado al reciclaje y está dirigido principalmente para reducir el trabajo al momento de separar el PET en lugares donde se emplea la mano de obra y como una alternativa a reducir gastos en empresas medianas que emplean técnicas como sensores o máquinas clasificadoras industriales. Si bien los resultados son buenos, aún queda mucho trabajo para implementarlo de manera física en tiempo real, donde no solo sea detectar por medio de fotos, si no por medio de video en tiempo real, además de vincular más funcionalidades a esta técnica como la creación de bases de datos donde se registren las cantidades de cada tipo de PET que pasen frente a la cámara.

Asimismo, es importante llevar a cabo más entrenamientos a fin de que aumente la eficacia de la técnica hasta un nivel con errores mínimos o bien, modificar el código de pruebas para que puedan aparecer más de un Vounding Box, con lo cual se determinarían tanto PET de Colores como PET cristal en una sola imagen. Es importante, poder generar otras alternativas a distintos problemas que puedan ser aplicados en la industria 4.0 mediante la implementación de Deep Learning.

Referencias

1. La falacia de la industria en la lucha contra la contaminación plástica: Estado de Reciclaje en México, <https://cdn2.hubspot.net/hubfs/2617486/Greenpeace/templates/pages/alianza/estado-del-reciclaje-reporte-completo.pdf> (2019)
2. AS news (2020) <https://www.asnews.mx/>
3. Molina, I.: México se encamina a ser líder de la industria 4.0 en América Latina. <https://mexicoindustry.com/noticia/mexico-se-encamina-a-ser-lider-de-la-industria-40-en-america-latina>
4. ISO 14001 Gestión medioambiental. <https://www.normas-iso.com/iso-14001/> (2021)
5. Certificación ISO 14001. <http://www.fao.org/3/ad818s/ad818s08.htm> (2021)
6. Direct industry.: <https://www.directindustry.es/fabricante-industrial/clasificador-botellas-188024.html> (2021)
7. Acoplásticos. <https://www.acoplásticos.org/index.php/mnu-pre/opm-bus-pref/36-opc-fag-pre4> (2021)
8. La clasificación de los plásticos. <https://gestoresderesiduos.org/noticias/la-clasificacion-de-los-plasticos> (2020)
9. Búler: <https://sortex.com.ar/clasificacion-de-plasticos/clasificacion-de-pet/> (2021)
10. MathWorks object detection using YOLO v2 deep learning. https://la.mathworks.com/help/deeplearning/ug/objectdetection-using-yolo-v2.html?s_tid=blogs_rc. 6 (2020)

11. Prototipo de sistema automatizado con visión artificial para la selección de empaques de plástico, vidrio y lata en el proceso de reciclaje. <http://repositorio.ucundinamarca.edu.co/bitstream/handle/20.500.12558/2497/Trabajo%20de%20grado.pdf?sequence=3&isAllowed=y>
12. Gómez, M. A., Hernández, A., I., Santiago, K. A., Varela, A.: Alternativa para la detección Covid-19 mediante rayos X en México ocupando técnicas de Deep Learning y YOLO V2. (2020)
13. MathWorks Object detection using deep learning. <https://la.mathworks.com/help/vision/ug/getting-started-with-object-detection-using-deep-learning.html> (2020)
14. Resnet 18. <https://la.mathworks.com/help/deeplearning/ref/resnet18.html>
15. ImageNet. <http://www.image-net.org> (2021)
16. Gobierno de México. <https://www.gob.mx/se/articulos/el-desarrollo-de-la-industria-4-0-en-mexico?idiom=es> (2021)
17. Mao, L.: YOLO v2 reorg layer explained. <https://leimao.github.io/blog/Reorg-Layer-Explained/> (2021)
18. Redes neuronales convolucionales. <https://la.mathworks.com/discovery/convolutional-neural-network-matlab.html>. (2020)