

---

---

# TECNOLÓGICO DE ESTUDIOS SUPERIORES DE COACALCO

Unidad de Estudios de Posgrado e Investigación

**MAESTRÍA EN SISTEMAS AMBIENTALES**

## **T E S I S**

**Detección de residuos sólidos domésticos en  
tiempo real a través de YOLOv8 modelo de Deep  
Learning**

QUE PARA OBTENER EL GRADO DE:  
**MAESTRO EN SISTEMAS AMBIENTALES**

PRESENTA:  
**Iván Daniel Plasencia González**

DIRECTOR(A) DE TESIS:  
**Dra. Susana Lezama Álvarez**

Coacalco de Berriozábal, marzo 2024



GOBIERNO DEL  
ESTADO DE  
MÉXICO

Constancia de liberación del Comité  
Tutorial

FORMATO

FO-TESCO-121

Versión: 4

Pág.: 1 de 3



TESCo  
TECNOLÓGICO  
DE ESTUDIOS  
SUPERIORES  
DE COACALCO

CONSTANCIA DE LIBERACIÓN DEL COMITÉ TUTORIAL

Coacalco, Estado de México a  
27 de febrero de 2024

Ing. J. Beatriz Contreras Navarro  
Subdirección de Estudios Profesionales "C"  
**P R E S E N T E**

Por este conducto, le informamos que se después de haberse concluido el trabajo de Tesis o Tesina, **hemos avalado el impacto que tuvo el proyecto mediante la carta emitida por una unidad económica para el caso de los programas de posgrado profesionalizantes o publicado en una revista científica o presentado en congreso para los programas de posgrado en ciencias; así mismo, se ha realizado la sesión de derechos del proyecto y hemos emitido nuestras recomendaciones para la liberación del segundo idioma, mediante la constancia elaborada por la Subdirección de Estudios Profesionales.**

Por tal virtud, aprobamos que el estudiante **Iván Daniel Plasencia González** proceda a iniciar con el trámite de obtención del **grado o constancia correspondiente por haber cumplido con los requisitos mencionados y concluido sus asignaturas con un promedio mínimo de 80 en la Maestría en Sistemas Ambientales.**

**A T E N T A M E N T E**  
**"Ciencia, Técnica-Progreso"**

Comité Tutorial

| NOMBRE                               | FIRMA |
|--------------------------------------|-------|
| Dra. Susana Lezama Álvarez           |       |
| Dra. Raquel Eunice Hernández Ramírez |       |
| Dra. María Teresa Torres Mancera     |       |

**TODA COPIA EN PAPEL ES UN "DOCUMENTO NO CONTROLADO" A EXCEPCIÓN DEL ORIGINAL**

SECRETARÍA DE EDUCACIÓN  
SUBSECRETARÍA DE EDUCACIÓN MEDIA SUPERIOR Y NORMAL  
DIRECCIÓN GENERAL DE EDUCACIÓN SUPERIOR  
TECNOLÓGICO DE ESTUDIOS SUPERIORES DE COACALCO

AV. 16 DE SEPTIEMBRE NÚM. 54  
COACALCO DE BERRIOZÁBAL, MÉXICO  
TEL: (0155) 2159 4324, 2159 4325, 2159 4468  
www.tecnologicodecoacalco.edu.mx



GOBIERNO DEL  
ESTADO DE  
MÉXICO

Carta Autorización de impresión  
de Tesis o Tesina

FORMATO

FO-TESCo-123

Versión: 4

Pág.: 1 de 3



TESCo  
TECNOLÓGICO  
DE ESTUDIOS  
SUPERIORES  
DE COACALCO

Coacalco, Estado de México a  
27 de febrero de 2024.

## CARTA AUTORIZACIÓN DE IMPRESIÓN DE TESIS O TESINA

**C. Iván Daniel Plasencia González**  
Candidata a la Maestría en Sistemas Ambientales  
**PRESENTE.**

De acuerdo con los Lineamientos para la Operación de los Estudios de Posgrado vigentes en el Tecnológico Nacional de México y habiendo cumplido con todas las indicaciones que el Comité Tutorial le hizo al respecto de su Tesis o Tesina titulada:

**"Detección de residuos sólidos domésticos en tiempo real a través de YOLOv8 modelo de Deep Learning"**

Comunicó a usted que esta Subdirección concede su autorización para que proceda a la impresión de la misma.

**ATENTAMENTE**

**"Ciencia, Técnica-Progreso"**

**ING. J. BEATRIZ CONTRERAS NAVARRO**  
**SUBDIRECCIÓN DE ESTUDIOS PROFESIONALES "C"**

**TODA COPIA EN PAPEL ES UN "DOCUMENTO NO CONTROLADO" A EXCEPCIÓN DEL ORIGINAL**

SECRETARÍA DE EDUCACIÓN  
SUBSECRETARÍA DE EDUCACIÓN MEDIA SUPERIOR Y NORMAL  
DIRECCIÓN GENERAL DE EDUCACIÓN SUPERIOR  
TECNOLÓGICO DE ESTUDIOS SUPERIORES DE COACALCO

AV. 18 DE SEPTIEMBRE No. 54  
COACALCO DE BERRIOZÁBAL, MÉXICO  
TELS (0155) 2159-4324, 2159-4325, 2159-4468  
[www.tecnologicodecoacalco.edu.mx](http://www.tecnologicodecoacalco.edu.mx)

## Índice

|                                                                                                                                                    |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Resumen.....                                                                                                                                       | 3  |
| Abstract.....                                                                                                                                      | 4  |
| Lista de figuras.....                                                                                                                              | 5  |
| Listas de tablas .....                                                                                                                             | 7  |
| 1. Introducción .....                                                                                                                              | 9  |
| 2. Marco teórico.....                                                                                                                              | 12 |
| 2.1. La importancia de la química ambiental para la solución de problemas:<br>características químicas de los residuos sólidos urbanos. ....       | 12 |
| 2.2. Sociedad, Ambiente y Desarrollo: importancia de la clasificación de los residuos<br>sólidos urbanos.....                                      | 13 |
| 2.2.1. La etapa de reciclaje y reutilización de materiales es esencial para la<br>gestión del reciclaje y la reutilización de los materiales. .... | 14 |
| 2.2.2. La reducción de los Residuos en los vertederos. ....                                                                                        | 14 |
| 2.2.3. Proporcionar protección del medio ambiente y la salud humana.....                                                                           | 14 |
| 2.2.4. La eficacia en la gestión de los Residuos en la gestión de la residualidad.<br>15                                                           |    |
| 2.3. Ingeniería Verde: principios para el diseño. ....                                                                                             | 15 |
| 2.4. La Ingeniería Ambiental aplicada a los residuos sólidos.....                                                                                  | 18 |
| 2.5. Manejo y disposición de residuos sólidos urbanos. ....                                                                                        | 19 |
| 2.5.1. Clasificación de los RSU.....                                                                                                               | 20 |
| 2.5.2. Manejo de los residuos. ....                                                                                                                | 22 |
| 2.5.3. Manejo de los RSU y la Ingeniería Verde.....                                                                                                | 23 |
| 2.6. El reciclaje y la gestión de los residuos sólidos urbanos. ....                                                                               | 24 |

---

|        |                                                 |    |
|--------|-------------------------------------------------|----|
| 2.7.   | Inteligencia Artificial. ....                   | 27 |
| 2.7.1. | Principales Áreas y Aplicaciones de la IA. .... | 32 |
| 2.7.2. | Técnicas de la Inteligencia Artificial. ....    | 33 |
| 2.8.   | Visión Artificial.....                          | 37 |
| 2.8.1. | Etapas de la visión artificial.....             | 39 |
| 2.9.   | Modelo YOLO. ....                               | 43 |
| 2.9.1. | YOLO-v8 (2023). ....                            | 45 |
| 3.     | Estado del Arte. ....                           | 49 |
| 4.     | Justificación. ....                             | 56 |
| 5.     | Objetivos.....                                  | 60 |
| 5.1.   | Objetivo General .....                          | 60 |
| 7.2    | Objetivos Específicos.....                      | 60 |
| 6.     | Desarrollo experimental. ....                   | 62 |
| 7.     | Resultados.....                                 | 66 |
| 7.1.   | Análisis conjunto de datos. ....                | 66 |
| 7.2.   | Entrenamiento del modelo. ....                  | 72 |
| 8.     | Discusión de resultados.....                    | 80 |
| 9.     | Conclusiones y Perspectivas.....                | 86 |
| 10.    | Bibliografía y Referencias.....                 | 89 |

---

---

## Resumen

La preservación del medio ambiente se ha convertido en una necesidad para la sociedad, se constituye en un factor necesario para la subsistencia de las condiciones actuales del medio que nos rodea, por lo que se hace necesario que los profesionistas y profesionales y en general la sociedad vean la importancia de estudiar, identificar y poner acciones encaminadas en abatir y revertir los efectos de la acción humana. Como parte de la búsqueda se detectó la necesidad de hacer frente a la preocupante cantidad de residuos sólidos urbanos (RSU) que se generan día con día en la región, que a pesar de que existen ya muchas soluciones, no se ha logrado reducir los efectos que estos provocan como: deterioro del paisaje, fuentes nocivas para salud, impacto negativo en los diversos ecosistemas entre otros.

Uno de los problemas que se tienen es la mezcla de los RSU y dado que existen una diversidad y estos están compuestos de una variedad de materiales diferentes, se convierte en una dificultad y necesidad separar desde la fuente<sup>1</sup> dado que se generan una diversidad de RSU, lo anterior sucede por factores como: falta de tiempo para la clasificación, desconocimiento de los diversos materiales que componen, falta de cultura, etc. Ante lo expuesto se plantea como tema de tesis y basado en la economía circular de la reutilización de los desechos, la propuesta del uso de la inteligencia artificial, en específico la visión artificial, como medio para la clasificación de los RSU, mediante el desarrollo de un sistema de reconocimiento en tiempo real empleando el modelo You Only Look Once (YOLO) v8 con el fin de detectar y clasificar RSU mediante una cámara web por medio del entrenamiento de un modelo que utiliza una base de datos de residuos domésticos principalmente relacionados con: papel, plástico, vidrio, metal y residuos orgánicos.

---

<sup>1</sup> Se considera fuentes de RSU como los generadores de residuos como el resultado de la eliminación de materiales que se utilizan en las actividades humanas, estas fuentes pueden ser casas habitación, pero también pueden provenir de comercios

---

---

## Abstract

The preservation of the environment has become a necessity for society, it is a necessary factor for the subsistence of the current conditions of the environment that surrounds us, which is why it is necessary for professionals and in general society see the importance of studying, identifying and implementing actions aimed at reducing and reversing the effects of human action. As part of the search, the need to address the worrying amount of urban solid waste (MSW) that is generated every day in the region was detected, which despite the fact that there are many solutions, it has not been possible to reduce the effects. that these cause such as: deterioration of the landscape, sources harmful to health, negative impact on the various ecosystems among others.

One of the problems we have is the mixing of MSW and since there is a diversity and these are composed of a variety of different materials, it becomes difficult and necessary to separate from the source since a diversity of MSW is generated, The above happens due to factors such as: lack of time for classification, lack of knowledge of the various materials they make up, lack of culture, etc. Given the above, the proposal for the use of artificial intelligence, specifically artificial vision, as a means for classifying MSW, through the development of a real-time recognition system using the You Only Look Once (YOLO) v8 model in order to detect and classify MSW using a webcam by training a model that uses a database of household waste mainly related to: paper, plastic, glass, metal and organic waste.

## Lista de figuras

|                                                                                                                                    |    |
|------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1.- Desechos más comunes generados en los hogares (Secretaria de Medio Ambiente y Recursos Naturales (SEMARNAT), 2015)..... | 26 |
| Figura 2.- Aplicaciones de machine learning en la industria (SInergiaSys, 2024) .....                                              | 33 |
| Figura 3.- Esquema general del procesamiento de imágenes (Sucar & Gómez, 2024) 39                                                  |    |
| Figura 4.- Esquema general de visión por computadora (Sucar & Gómez, 2024) .....                                                   | 39 |
| Figura 5.- Fases de la Inteligencia Artificial (elaboración propia) .....                                                          | 62 |
| Figura 6.- Modelo de entrenamiento de inteligencia artificial de Tensorflow y proceso de pruebas (Polo, 2019).....                 | 63 |
| Figura 7.- Proceso de procesamiento de datos de la visión artificial (Sobrado Malpartida, 2003) .....                              | 63 |
| Figura 8.- Proceso de entrenamiento para el reconocimiento mediante la visión artificial (elaboración propia) .....                | 64 |
| Figura 9.- Método a seguir para el desarrollo del modelo de entrenamiento (elaboración propia) .....                               | 64 |
| Figura 10.- Ejemplos de imágenes que conforman el conjunto de datos (elaboración propia) .....                                     | 67 |
| Figura 11.- Programa de BBox-Label-Tool en rgáni con Syder(Python 3.11) (elaboración propia) .....                                 | 68 |
| Figura 12.- Uso de la herramienta Bbox-Label-Tool para Python (elaboración propia) 69                                              |    |
| Figura 13.- Resultado de la selección y clasificación de las imágenes por medio de Bbox-Label-Tool (elaboración propia) .....      | 69 |
| Figura 14.- Software utilizado para el entrenamiento del modelo (elaboración propia). 70                                           |    |
| Figura 15.- Archivo YAML para el modelo Yolo (elaboración propia .....                                                             | 71 |
| Figura 16.- Instrucciones del entrenamiento (elaboración propia) .....                                                             | 74 |
| Figura 17.- Ejemplo de IoU de los dos cuadros delimitadores (elaboración propia) .....                                             | 76 |
| Figura 18.- Intersección entre los dos cuadros delimitadores (elaboración propia) .....                                            | 77 |
| Figura 19.- Instrucción para ejecutar el modelo entrenado (elaboración propia) .....                                               | 80 |

---

|                                                                                                       |    |
|-------------------------------------------------------------------------------------------------------|----|
| Figura 20.- Detecciones en imágenes del conjunto prueba (elaboración propia).....                     | 81 |
| Figura 21.- Detecciones incorrectas (elaboración propia) .....                                        | 81 |
| Figura 22.- Detecciones de la clase metal (elaboración propia).....                                   | 82 |
| Figura 23.- Instrucciones para hacer las mediciones con el conjunto prueba (elaboración propia) ..... | 82 |

## Listas de tablas

|                                                                                                             |    |
|-------------------------------------------------------------------------------------------------------------|----|
| Tabla 1.- Clasificación de los residuos (Carrasco Romero & Morocho Vera, 2015).....                         | 20 |
| Tabla 2.- Problemática asociada a la generación de residuos (Junta de Andalucía, 2013)<br>.....             | 26 |
| Tabla 3.- Clasificación de la IA por su aprendizaje (aprendizaje automático) (Rodríguez<br>D. , 2023) ..... | 28 |
| Tabla 4.- Clasificación de las IA por su aprendizaje (aprendizaje profundo) (Rodríguez D.<br>, 2023) .....  | 30 |
| Tabla 5.- Variantes del modelo YOLOv8 y sus aplicaciones (ultralytics, 2023).....                           | 47 |
| Tabla 6.- Parámetros de entrenamiento (elaboración propia) .....                                            | 73 |
| Tabla 7.- Matriz de aprendizaje multiclase (elaboración propia) .....                                       | 74 |
| Tabla 8.- Métricas obtenidas (elaboración propia) .....                                                     | 78 |
| Tabla 9.- Resultados del conjunto prueba (elaboración propia .....                                          | 83 |

# **CAPÍTULO 1**

# **INTRODUCCIÓN**

## 1. Introducción

A nivel mundial se generan alrededor de 1.3 mil millones de toneladas de basura diaria (semarnat.gob.mx, 2023), en América Latina y el Caribe ronda en 540 mil toneladas al día (unep.org, 2017), en México se estima en más de 103 mil toneladas diarias de basura doméstica (Cruz Aburto, 2018); el Estado de México se generan 16,187 toneladas de residuos sólidos urbanos (Huerta, 2022), el municipio de Coacalco de Berriozábal genera 300 toneladas (Venegas, 2022), en promedio se estima que una persona produce diariamente 854 gramos de residuos en el hogar (Carranza, 2020). Es alarmante el aumento de la generación de este tipo de residuos domésticos ya que ha incrementado año tras año. En el Estado de México se ha comportado de la siguiente manera según datos de los reportados por los municipios al INEGI en 2010 se produjo una recolección de 8.2 toneladas de desechos diarios, para el 2012 aumento a 12 toneladas, para el 2014 solo aumento una tonelada y para el 2016 disminuyó a la misma cantidad del 2014 y para los años 2018 y 2020 se mantuvo en los mismos indicadores. Es preocupante no solo las cantidades de residuos que se producen, sino que, por falta de normatividad y civismo, estos desechos se mezclan y se convierten en importantes focos de contaminación, ya que combinados se generan sustancias químicas altamente nocivas para el ecosistema.

El presente trabajo pretende dar una propuesta de solución tomando en cuenta las clasificaciones aceptadas de los RSU, principios de ingeniería verde y de la economía circular que de acceso a formular el reaprovechamiento de los RSU por medio de visión y la inteligencia artificial que permita ayudar a la separación principalmente en los hogares y con ello se facilite la actividad de clasificar y almacenar desde la fuente de generación de los desechos. Existen varias propuestas que ayudan a esta actividad, sin embargo, la propuesta que se hace pretende clasificar mediante el uso de la inteligencia y visión artificial 5 tipos de basura más común en el hogar.

La investigación inicia determinando la problemática que existe alrededor de la clasificación de los RSU y la existencia de las diferentes propuestas para su clasificación y separación. Si bien es cierto que ya existen diferentes métodos que permiten la clasificación de los RSU, muchos de ellos no exploran el uso de las nuevas tecnologías como la inteligencia y visión artificial como motor de clasificación, por lo que este trabajo representa una propuesta basada en YOLOv8.

Posteriormente a la determinación de la problemática de la clasificación de los RSU, se hará uso de técnicas de procesamiento digital de imágenes, además de la implementación de algoritmos de Inteligencia Artificial que permitirán identificar los diversos tipos de residuos y poder así determinar su tipo y clasificación.

Para determinar lo anterior descrito a lo largo del trabajo surgirán diversos cuestionamientos como saber si ¿Una computadora es capaz de poder identificar los diferentes tipos de residuos?, la respuesta tendrá lugar dentro del campo de la aplicación de la visión artificial, para lo cual tendremos que determinar que es la visión artificial, se abordaran los sistemas automáticos de reconocimiento que se desarrollaran por medio de 5 fases.

Al finalizar la tesis se presentarán los resultados del desarrollo de 5 fases que consisten en la adquisición de las imágenes, procesamiento digital de las imágenes para mejorar el área de reconocimiento, la segmentación de ese objeto, extracción de las características de lo segmentado y finalmente se utiliza la inteligencia artificial para el reconocimiento de los residuos.

# **CAPÍTULO 2**

# **MARCO TEÓRICO**

## 2. Marco teórico

### **2.1. La importancia de la química ambiental para la solución de problemas: características químicas de los residuos sólidos urbanos.**

La Química Ambiental estudia los procesos químicos que tienen lugar en el medio ambiente global, o en alguna de sus partes: el suelo, los ríos y lagos, los océanos, la atmósfera, así como el impacto de las actividades humanas sobre nuestro entorno y la problemática que ello ocasiona. Se ocupa también, por tanto, del impacto ambiental de vertidos antropogénicos sea cual fuere su naturaleza, de su estudio, disminución y/o eliminación, reducción de su carga dañina, por lo que supervisa directamente cualquier proceso de naturaleza industrial que pudiera poner en peligro la conservación del medio ambiente, especialmente si se ven personas involucradas en ello, aplicación de la química al estudio de los problemas y la conservación del medio ambiente (Mota Ávila , 2011).

La química ambiental aplicada a este trabajo nos permite conocer las características químicas de los residuos sólidos urbanos que a su vez serán factores claves para algunos procesos de recuperación y tratamiento final. Si bien este trabajo no se centra en las características químicas de los RSU, es importante tener presente la importancia de la recuperación de estos residuos desde la perspectiva de los procesos de recuperación energética. Otras características como la eventual presencia de productos tóxicos, metales pesados, contenido de elementos inertes, etc., son información muy útil para diseñar soluciones adecuadas en los procesos de recuperación y para establecer las adecuadas precauciones higiénicas y sanitarias. Como consecuencia de la enorme variabilidad que experimenta la composición de los residuos sólidos urbanos, la composición química resultante de su conjunto también es muy variable. Es necesario conocer la composición de un residuo concreto para determinar sus características de recuperación energética y la potencialidad de producir fertilizantes u otro tipo de uso con la adecuada relación carbono/nitrógeno. También es conveniente

conocer la presencia y concentración de residuos tóxicos y peligrosos para evaluar el riesgo que su manejo, tratamiento, reprocesado y reutilización, puedan aportar a la salud humana y al medio ambiente. Las propiedades calorimétricas de los residuos urbanos son los parámetros sobre los que se diseñan las instalaciones de incineración y de recuperación energética. Su valoración, fruto de la propia variabilidad de la composición, viene marcada por el poder calorífico de cada producto. En términos generales, puede indicarse que el poder calorífico de la totalidad de los residuos sólidos urbanos está entre 1.500 y 2.200 kcal/kg (ambientum.com, 2022).

De lo anterior descrito radica la importancia que tiene el conocimiento de la química de los RSU ya que permite reconocer que tipo de clasificación se puede plantear de forma tal que se pueda aprovechar al máximo la tarea categorizar los residuos para su posterior uso.

### **2.2. Sociedad, Ambiente y Desarrollo: importancia de la clasificación de los residuos sólidos urbanos.**

La gestión de residuos sólidos urbanos (RSU) es un desafío global que implica a la sociedad, el entorno y el desarrollo sostenible. En un entorno cada vez más poblado y urbanizado, la cantidad de residuos generados ha alcanzado niveles críticos, lo que conlleva a que la clasificación de los residuos sea una tarea fundamental para abordar este problema de manera efectiva.

La clasificación de los residuos sólidos urbanos (RSU) es un procedimiento fundamental que implica la separación de los residuos en diversas categorías, según su estructura y características. Esta práctica es esencial debido a diversas cuestiones fundamentales que afectan a la sociedad, el ambiente y el desarrollo sostenible (GISA, 2023).

### **2.2.1. La etapa de reciclaje y reutilización de materiales es esencial para la gestión del reciclaje y la reutilización de los materiales.**

Una de las razones fundamentales para la clasificación de los RSU es la capacidad de reciclar y reutilizar materiales que aún pueden ser utilizados. Al separar los residuos orgánicos, inorgánicos y peligrosos, se logra una simplificación en el proceso de reciclaje. Los residuos orgánicos, tales como los restos de comida, papel y cartón, pueden convertirse en composta o biogás. Los residuos inorgánicos, como plásticos, metales y vidrio, pueden reciclarse para elaborar nuevos productos. La eficacia de la clasificación asegura la recuperación de recursos valiosos y disminuye la dependencia de la extracción de materias primas, lo cual resulta fundamental para la preservación de los recursos naturales (Raza Carrillo & Acosta, 2022).

### **2.2.2. La reducción de los Residuos en los vertederos.**

La clasificación de residuos reduce la cantidad de residuos que se transportan a vertederos y rellenos sanitarios. Al separar los residuos en sus categorías apropiadas, se reduce la carga de residuos en estos sitios, lo que prolonga su existencia y previene la contaminación del suelo y el agua subterránea. Asimismo, la reducción de residuos en vertederos es fundamental para minimizar la liberación de gases de efecto invernadero, como el metano, que contribuyen al cambio climático (Secretaría de Medio Ambiente y Recursos Naturales, 2008).

### **2.2.3. Proporcionar protección del medio ambiente y la salud humana.**

La adecuación apropiada de los RSU es fundamental para preservar la salud humana y el medio ambiente. Los residuos peligrosos, tales como baterías, productos químicos y medicamentos, deben manejarse y eliminarse de manera segura para evitar

riesgos para la salud y la contaminación ambiente. La clasificación precisa de estos residuos asegura su tratamiento adecuado y reduce el riesgo de liberación de sustancias dañinas en el aire, el agua y el suelo.

### **2.2.4. La eficacia en la gestión de los Residuos en la gestión de la residualidad.**

La clasificación de RSU también mejora la eficiencia en la gestión de residuos sólidos urbanos. Facilita la recolección selectiva y el procesamiento posterior, lo que ahorra tiempo y recursos. Además, fomenta la planificación de sistemas de gestión de residuos más efectivos y sostenibles, lo que conduce a un uso más eficiente de energía y recursos naturales (Organización Panamericana de la Salud, 2000).

La clasificación de los residuos sólidos urbanos es una práctica esencial que contribuye significativamente a la gestión sostenible de los RSU. Promueve el reciclaje, reduce la contaminación, protege la salud y el ambiente, y optimiza la gestión de residuos. Es un componente crucial en la construcción de un futuro más limpio y sostenible para las generaciones presentes y futuras, es aquí donde la cultura y herramientas que nos ayuden a prevenir la mezcla de estos residuos se vuelve más importante y vital ya que es la acción necesaria que permitirá hacer la diferencia y prevención de los resultados de la acumulación y mezcla de los residuos.

### **2.3. Ingeniería Verde: principios para el diseño.**

La Ingeniería Verde es una disciplina de la ingeniería que se enfoca en la creación de procedimientos y productos que sean ambientalmente sostenibles (Gómez Cívicos, 2008). Se fundamenta en los siguientes doce principios:

- Prevención de la contaminación. Es preferible prevenir la contaminación que tratar o limpiar el residuo ya producido.
- La eficacia de los recursos. Es imperativo emplear la menor cantidad posible de materiales y energía para la producción de bienes y servicios.
- Ciclo de vida. Se debe tener en cuenta el impacto ambiental de un producto o proceso durante todo su ciclo de vida, desde la extracción de materias primas hasta la disposición final de los residuos.
- Diseño amigable con el medio ambiente. Los productos y procesos deben elaborarse de manera que sean lo más respetuosos con el medio ambiente.
- Evaluación del ciclo de vida. Es imperativo llevar a cabo una evaluación del impacto ambiental de un producto o proceso, con el fin de identificar oportunidades de mejora.
- Diseño destinado a la reutilización. Los artículos deben ser concebidos con el fin de efectuar la reutilización o reparación eficiente de los mismos.
- Diseño destinado al reciclaje. Los productos deben concebirse de manera que los materiales que los conforman puedan reciclarse con facilidad.
- Diseño para la disminución de la toxicidad. Los productos deben concebirse de manera que utilicen materiales y procesos lo menos peligrosos posible.
- Diseño de energía sostenible. Los artículos y procedimientos deben ser concebidos con el fin de utilizar energías renovables o que sean eficientes en el aprovechamiento de la energía.
- Diseño para la salud humana. Los productos y procesos deben concebirse de manera que no representen riesgos para la salud humana.
- Diseño para la equidad social. Los artículos y procedimientos deben ser concebidos con el fin de garantizar disponibilidad para todos los grupos sociales.
- Educación ambiental. Se debe educar a la población sobre los principios de la Ingeniería Verde para promover el desarrollo sostenible.

Estos principios pueden aplicarse a la gestión de residuos sólidos urbanos de diversas maneras, además brindan soporte a este trabajo ya que la concepción está encaminada a que antes de resolver los problemas que han causado los RSU se prevenga desde la fuente. Por ejemplo, el principio de prevención de la contaminación puede aplicarse mediante la reducción de la generación de residuos, el uso de materiales reciclados o la reutilización de productos. El principio de eficiencia de los recursos puede aplicarse mediante la reducción del consumo de energía en la recolección y tratamiento de residuos, o mediante la selección de tecnologías más eficientes. El principio de ciclo de vida del producto puede aplicarse al momento en el que se planifica el uso de los residuos destinando su uso o recuperación después de cumplir con su función mediante la evaluación del impacto ambiental de los diferentes sistemas de gestión de residuos.

En el contexto de la gestión de residuos sólidos urbanos, algunos de los beneficios de la aplicación de principios de Ingeniería Verde incluyen:

- Reducción de la contaminación ambiental. La reducción de la generación de residuos, el uso de materiales reciclados y la reutilización de productos contribuyen a reducir la contaminación del aire, el agua y el suelo.
- Ahorro de recursos naturales. La reducción del consumo de energía y la utilización de materiales reciclados contribuyen a ahorrar recursos naturales, como los combustibles fósiles y los minerales.
- Mejora de la salud pública. La reducción de la generación de residuos y la mejora de las condiciones sanitarias en los vertederos contribuyen a mejorar la salud pública.

A continuación, se presentan algunos ejemplos concretos de cómo se pueden aplicar principios de Ingeniería Verde en la gestión de residuos sólidos urbanos:

- Uso de contenedores de basura separados para residuos orgánicos, reciclables y no reciclables. Esto facilita la separación de residuos y aumenta la tasa de reciclaje.

- Implementación de programas de compostaje doméstico y comunitario. Esto reduce la cantidad de residuos que se envían a los vertederos.
- Recolección de residuos de alimentos orgánicos para su conversión en biogás. El biogás puede utilizarse como combustible para generar electricidad o calor.
- Implementación de sistemas de recogida puerta a puerta para residuos reciclables. Esto facilita la recogida de residuos reciclables y aumenta la tasa de reciclaje.
- Uso de tecnologías de tratamiento de residuos que sean más eficientes en el uso de energía y que generen menos residuos peligrosos.

La aplicación de principios de Ingeniería Verde en la gestión de residuos sólidos urbanos puede contribuir a mejorar la sostenibilidad ambiental y económica de este sector y es un motivo por el cual se orienta el desarrollo del presente trabajo de tesis.

### **2.4. La Ingeniería Ambiental aplicada a los residuos sólidos.**

La Ingeniería Ambiental cumple un papel fundamental en la gestión y tratamiento de residuos sólidos, abordando los desafíos ambientales y promoviendo la sostenibilidad. Los residuos sólidos, que contienen una amplia gama de materiales desechados por actividades humanas, representan un desafío ambiental significativo que requiere una gestión eficiente y sostenible (Kumar, Smith, Fowler, Velis, & Kumar, 2017).

La clasificación y reciclaje de residuos sólidos es una de las áreas fundamentales en la Ingeniería Ambiental. La segregación efectiva de residuos en categorías como orgánicos, inorgánicos, reciclables y peligrosos es esencial para optimizar los procesos de reciclaje y minimizar el impacto ambiental (Gupta, Yadav, & Kumar, 2015). La implementación de tecnologías avanzadas, como la visión artificial y la automatización en la clasificación de residuos, ha demostrado ser eficaz en mejorar la eficiencia y precisión de estos procesos (Rodríguez & López, 2019).

La administración y la disposición adecuada de residuos sólidos son también esenciales. Técnicas como el compostaje, la incineración y el relleno sanitario son habitualmente utilizadas. El proceso de compostaje es efectivo para la eliminación de residuos orgánicos, transformándolos en productos esenciales como fertilizantes. La investigación arroja, aunque controversial debido a sus emisiones, puede disminuir significativamente el volumen de residuos y generar energía. Los rellenos sanitarios siguen siendo una opción habitual, aunque presentan dificultades relacionadas con la emisión de gases de efecto invernadero y la contaminación del suelo y agua subterránea (Tchobanoglous, Theissen, & Eliassen, 1982).

La Ingeniería Ambiental se enfoca en tácticas de prevención y minimización de residuos. Las estrategias a seguir incluyen la creación de productos más sostenibles, la promoción del consumo responsable y el fomento de la economía circular. La economía circular, que se fundamenta en el principio de "cerrar el ciclo" de los artículos, es una respuesta al modelo lineal de "utilizar y desechar" y fomenta la reutilización y reciclaje de materiales (Manrique López-Henares, 2021).

En última instancia, la participación y formación de la comunidad constituyen un elemento esencial en la gestión de residuos sólidos. Los hechos de concienciación y compromiso de individuos y comunidades pueden tener un impacto significativo en la generación y segregación de residuos. Los programas educativos y programas de sensibilización son fundamentales para fomentar hábitos sostenibles y responsables en la gestión de residuos (Rodríguez García R. , Gómez Curquejo, Zarauza Cabrerizo, & Benítez Rodríguez, 2013).

### **2.5. Manejo y disposición de residuos sólidos urbanos.**

Los residuos sólidos urbanos (RSU) son aquellos que se generan en las actividades domésticas, comerciales, industriales, de servicios y de la construcción, y que se recolectan, transportan y almacenan de manera distintiva. En México, la

producción de residuos residuales se estima en 120 millones de toneladas por año, lo que representa un promedio de 1.4 kilogramos por persona al día (Secretaría de Medio Ambiente y Recursos Naturales, 2020).

El control de los residuos residuales es un problema complejo que tiene consecuencias ambientales, económicas y sociales. En México, el manejo de los residuos está regulado por la Ley General para la Prevención y Gestión Integral de los Residuos (LGPGIR), la cual establece los principios y las disposiciones para la gestión integral de los residuos.

### 2.5.1. Clasificación de los RSU.

En la tabla 1 se describe la clasificación de los RSU de acuerdo con tres categorías: según su composición, según el tipo de manejo, según la fuente de origen.

*Tabla 1.- Clasificación de los residuos (Carrasco Romero & Morocho Vera, 2015)*

| <b>Según su composición</b>    |                                                                                                                                                             |
|--------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Desechos orgánicos             | Comprende a los restos de comida, vegetales, frutas, papel, cartón, plástico, textiles cuero, goma, desechos de jardín, entre otros elementos.              |
| Desechos inorgánicos           | Son residuos vidrios, metales ferrosos y no ferrosos, cenizas entre otros elementos.                                                                        |
| <b>Según el tipo de manejo</b> |                                                                                                                                                             |
| Desechos peligrosos            | Son aquellos desechos que están compuestos con sustancias que por sí mismo o al reaccionar con otros, pueden originar daños a la salud pública y ambiental. |
| Desechos no peligrosos         | Los desechos que no pertenecen a la categoría de los desechos peligrosos                                                                                    |

|                                      |                                                                                                                                                                                                                                                                                                                     |
|--------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Desechos inertes                     | Son los desechos que no presentan ningún tipo de efectos ambientales estimables al interactuar con el medio ambiente.                                                                                                                                                                                               |
| <b>Según su fuente de generación</b> |                                                                                                                                                                                                                                                                                                                     |
| Domésticos                           | Residen de los desechos sólidos orgánicos e inorgánicos generados por la limpieza de las viviendas. Los desechos lo conforman elementos u objetos como restos de comida, papel, cartón, vidrios, plásticos entre otros materiales que son utilizados en la vida diaria.                                             |
| Comerciales,                         | Los desechos comerciales son los generados en lugares comerciales y financieros como albergues, mercados, comedores y almacenes. Los materiales que predominan son los plásticos, vidrio, restos de comida, cartón, entre otros elementos utilizados en el área mercantil.                                          |
| Institucionales                      | Son los desechos producidos por entidades estatales, hospitales, centros de educación, correccionales, lugares administrativos. En los cuales no se consideran los desechos sanitarios de los hospitales y los creados por la construcción de las correccionales                                                    |
| Construcción y demolición            | Se originan por la demolición, remodelación y construcción de viviendas, edificaciones y otras estructuras. Estos desechos están conformados por varillas, restos de hormigón, madera, vidrios.                                                                                                                     |
| Servicios Municipales                | Los desechos por servicios municipales son los que provienen de la limpieza de las infraestructuras municipales y del abastecimiento de otras actividades municipales, entre ellos también el barrido de vías, callejones, jardines, playas, entre otros lugares recreativos, animales muertos, carros abandonados. |

|                                                   |       |                                                                                                                                       |
|---------------------------------------------------|-------|---------------------------------------------------------------------------------------------------------------------------------------|
| Desechos de plantas de tratamiento; incineradoras | de de | Son desechos sólidos y semisólidos que se forman mediante el proceso de tratamiento del agua, agua residual e industrial, entre otras |
| Industriales                                      |       | Desechos derivados de procesos de fabricación, reparación de equipos, centrales térmicas, plantas químicas entre otro.                |
| Agrícolas                                         |       | Son desechos que se originan debido a la crianza de animales, cultivos y cosechas de huertas.                                         |

### 2.5.2. Manejo de los residuos.

El control de los RSU puede dividirse en las siguientes etapas:

- Generación: La etapa en la que se producen los residuos de origen.
- Separación: La fase en la que se separan los residuos en diversas fracciones, según su origen o composición.
- Recopilación. Se trata de la etapa en la que se recogen los residuos de los lugares en los que se generan.
- Transporte: Se trata de la etapa en la que los residuos se trasladan desde los lugares de generación hasta los lugares de tratamiento o disposición final.
- Tratamiento: Se trata de la etapa en la que los residuos compactan para reducir su volumen o peligrosidad.
- Disposición final: La etapa en la que se depositan los residuos de manera definitiva.

Los RSU se gestionan principalmente en México a través de los siguientes sistemas:

- Rellenos sanitarios: Son instalaciones diseñadas para el acopio y la disposición final de los residuos sólidos.

- Incineración: Es un proceso térmico que se utiliza para reducir el volumen de los residuos.
- Compostaje: Es un proceso biológico que se utiliza para convertir los residuos orgánicos en compost, un material que puede utilizarse como fertilizante.
- Disposición final de los RSU en México

En México, la disposición final de los RSU se realiza principalmente en rellenos sanitarios. En 2022, se estima que el 80% de los RSU generados en México se depositaron en rellenos sanitarios (Secretaría de Medio Ambiente y Recursos Naturales, 2017).

Los rellenos sanitarios son una solución relativamente económica para la disposición final de los residuos, pero tienen impactos ambientales negativos, como la generación de gases de efecto invernadero, la contaminación del agua y del suelo, y la atracción de fauna nociva (Cárdenas-Valbuena, 2022).

### **2.5.3. Manejo de los RSU y la Ingeniería Verde.**

La Ingeniería Verde es una rama de la ingeniería que se centra en el desarrollo de procesos y productos que sean ambientalmente sostenibles. Los principios de la Ingeniería Verde pueden aplicarse al manejo de los RSU para mejorar su sostenibilidad ambiental y económica.

Algunos ejemplos de cómo se pueden aplicar los principios de la Ingeniería Verde al manejo de los RSU incluyen:

- Reducción de la generación de residuos: Esto se puede lograr mediante la promoción del consumo responsable, el diseño de productos más duraderos y la reutilización y el reciclaje de los residuos.

- Eficiencia de los recursos: Esto se puede lograr mediante la reducción del consumo de energía y materiales en las operaciones de manejo de residuos.
- Ciclo de vida: Esto se puede lograr mediante la evaluación del impacto ambiental de los sistemas de manejo de residuos durante todo su ciclo de vida.

El manejo de los RSU es un problema complejo que requiere de soluciones integrales. La aplicación de los principios de la Ingeniería Verde y de la tecnología resiente pueden contribuir a mejorar la sostenibilidad ambiental y económica del manejo de los RSU en México.

### **2.6.El reciclaje y la gestión de los residuos sólidos urbanos.**

Se considera basura todo objeto que ya no tiene utilidad para el ser humano, y por tanto, no vale la pena conservarlo, lo que presupone un deseo de deshacerse de él ya que no se le atribuye ningún valor para conservarlo. La basura refleja suciedad, falta de higiene, mal olor, desagrado a la vista, contaminación, fecalismo, impureza, turbiedad, etc. Sin embargo, el término de residuos sólidos es más apropiado que el de desechos o basura. El diccionario de la Real Academia Española define residuos como: “lo que resulta de la descomposición o destrucción de una cosa; parte o porción que queda de una cosa”. Por otro lado, los residuos sólidos se dividen en dos grandes grupos: Los orgánicos y los inorgánicos. Los orgánicos son todos aquellos de origen biológico, que en algún momento tuvieron vida; es decir, todo aquello que nace, vive, se reproduce y muere. Generalmente están compuestos de desperdicios de la comida, la cocina y restos de plantas y vegetales. En tanto que los inorgánicos están constituidos por materiales tales como: vidrio, papel, plástico, metales, etc. Los cuales se caracterizan por su permanencia


Los residuos domésticos son los que se generan en los hogares como consecuencia de las actividades cotidianas. Asimismo, se consideran como tales

aquellos que se originan en los espacios urbanos (comercios, sectores servicios, entre otros), así como aquellos que se originan de la limpieza de la calle y las áreas verdes (Rodríguez García R. , Gómez Curquejo, Zarauza Cabrerizo, & Benítez Rodríguez, 2013). Los residuos domésticos que suelen generar las personas son:

- Restos de comida y poda (materia orgánica)
- Envases de plásticos, latas y briks
- Botellas, tarros y frascos de vidrio
- Residuos de papel y cartón
- Residuos voluminosos (muebles, etc.)
- Aceites domésticos
- Residuos textiles
- Aparatos eléctricos y electrónicos
- Escombros de pequeñas obras
- Otros (animales domésticos muertos, vehículos abandonados, entre otros)

El contenido de las bolsas de basura (figura 1) ha cambiado con los años. A pesar de que la porción mayoritaria (en peso) sigue siendo la materia orgánica (restos de comida, principalmente) el porcentaje de materiales plásticos o electrónicos va aumentando cada año.

La creciente generación de residuos derivados de la actividad humana constituye un grave problema social y ambiental que se ha convertido en una cuestión de suma importancia hacia la que se están dirigiendo políticas de intervención, información y gestión.



*Figura 1.- Desechos más comunes generados en los hogares (Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT), 2015)*

La generación de residuos puede provocar los siguientes impactos negativos, referidos no solo al ámbito ambiental, sino también al económico, sanitario y social (tabla 2).

*Tabla 2.- Problemática asociada a la generación de residuos (Junta de Andalucía, 2013)*

|                        |                                                                                                                                                                                                                                                                                                                                                                                      |
|------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Problemática ambiental | <ul style="list-style-type: none"> <li>- Sobreexplotación de recursos naturales</li> <li>- Ocupación del espacio</li> <li>- Deterioro del paisaje</li> <li>- Contaminación del suelo, agua y aire</li> <li>- Mayor riesgo de incendios</li> <li>- Olores</li> <li>- Alteración en los ciclos de vida de especies animales</li> <li>- Enfermedades o muerte en seres vivos</li> </ul> |
|------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|

|                        |                                                                                                                                                                                                                                                                                                                |
|------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
|                        | <ul style="list-style-type: none"> <li>- Bioacumulación de sustancias en especies que pasan a la cadena trófica y llegan hasta nosotros</li> <li>- Aumento de las emisiones de gases de efecto invernadero y potenciación del cambio climático</li> </ul>                                                      |
| Problemática económica | <ul style="list-style-type: none"> <li>- Alta inversión en la gestión de los residuos y su mantenimiento</li> <li>- Costos asociados a descontaminación y restauración de espacios</li> <li>- Despilfarro de posibles materias primas no utilizadas</li> <li>- Pérdida de valor económico del suelo</li> </ul> |
| Problemática social    | <ul style="list-style-type: none"> <li>- Deterioro del entorno</li> <li>- “Compra-venta” de residuos que convierten las regiones más pobres en vertederos</li> </ul>                                                                                                                                           |
| Problemática sanitaria | <ul style="list-style-type: none"> <li>- Proliferación de animales transmisores de enfermedades en los lugares de acumulación de residuos</li> <li>- Contaminación bacteriana</li> </ul>                                                                                                                       |

## 2.7. Inteligencia Artificial.

El modelo matemático de la máquina de Turing, concebido por el británico Alan Turing, impulsó la creación de los primeros prototipos de computadoras del siglo XX, lo cual lo convirtió en el pionero y fundador de la disciplina de Inteligencia Artificial (IA) Turing y otros científicos y filósofos de su época fueron los primeros en buscar una respuesta rigurosa a la cuestión: ¿pueden las máquinas pensar?, responderla requiere contar con una definición formal del concepto de inteligencia (Pérez Orozco, 2018).

Existen muchas definiciones de la inteligencia artificial, pero por objetivos coloquiales la IA es una rama de la computación donde las computadoras o las maquinas son capaces de imitar las funciones cognitivas propias de la mente humana, como: creatividad, sensibilidad, aprendizaje, entendimiento, percepción del ambiente y uso del lenguaje. Respetando los avances realizados hasta ahora, podemos definir la IA como la ciencia encargada de construir sistemas que i) piensan como humanos, ii) piensan racionalmente, iii) actúan como humanos y iv) actúan racionalmente.

Según Rodríguez D. (2023) existen muchas clasificaciones de la IA que está relacionada su aprendizaje, funcionamiento y características y objetivos; la clasificación por aprendizaje se divide en dos: aprendizaje automático y aprendizaje profundo en la tabla 3 y 4 se puede observar las características de cada uno de ellos, así como sus aplicaciones más comunes. La segunda clasificación de acuerdo con su funcionamiento podemos encontrar:

- Inteligencia Artificial basada en reglas: Se basa en un conjunto de reglas predefinidas que permiten a la máquina tomar decisiones y realizar tareas, como los chatbots y los sistemas expertos.
- Aprendizaje automático: Este tipo de inteligencia artificial permite aprender de los datos que se les proporcionan y mejorar su capacidad de tomar decisiones y realizar tareas. Ejemplos de esto son los algoritmos de clasificación y los sistemas de recomendación y sitios de ventas.

*Tabla 3.- Clasificación de la IA por su aprendizaje (aprendizaje automático) (Rodríguez D. , 2023)*

| Categoría                | Características | Subcategoría            | Descripción                              |
|--------------------------|-----------------|-------------------------|------------------------------------------|
| Aprendizaje automático o |                 | Aprendizaje supervisado | se entrenan utilizando datos etiquetados |

|                  |                                                                                                                                                                                                                                                                                                                                                                  |                              |                                                                                                                                   |
|------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|
| Machine Learning | <ul style="list-style-type: none"> <li>• Permite a los sistemas informáticos aprender automáticamente a partir de los datos.</li> <li>• Los algoritmos aprender patrones a partir de los datos</li> <li>• Los algoritmos son entrenados a partir de un conjunto de datos para que puedan generalizar y hacer predicciones precisas sobre nuevos datos</li> </ul> | Aprendizaje no supervisado   | se entrenan utilizando datos no etiquetados,                                                                                      |
|                  |                                                                                                                                                                                                                                                                                                                                                                  | Aprendizaje por refuerzo     | se entrenan para tomar decisiones a través de la retroalimentación continua de un entorno                                         |
|                  |                                                                                                                                                                                                                                                                                                                                                                  | Aprendizaje semi-supervisado | se utiliza una pequeña cantidad de datos etiquetados junto con una gran cantidad de datos no etiquetados para entrenar el modelo. |
|                  |                                                                                                                                                                                                                                                                                                                                                                  | Aprendizaje activo           | puede elegir qué datos etiquetados se utilizan para entrenar el modelo                                                            |

- Redes neuronales: Se basa en una estructura similar a la del cerebro humano, con capas de nodos interconectados que pueden ser entrenados para reconocer patrones y realizar tareas. Aquí cabe mencionar a los sistemas de reconocimiento de voz y los sistemas de visión artificial.

*Tabla 4.- Clasificación de las IA por su aprendizaje (aprendizaje profundo) (Rodríguez D. , 2023)*

| Categoría                            | Características                                                                                                                                                                                                           | Aplicaciones                                                                                                                                             |
|--------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------|
| Aprendizaje profundo o Deep Learning | <ul style="list-style-type: none"> <li>• Aprendizaje se basa en redes neuronales artificiales</li> <li>• Se utiliza para tareas que requieren una gran cantidad de datos y una alta capacidad de procesamiento</li> </ul> | Reconocimiento de voz<br>Reconocimiento de imágenes<br>Traducción automática<br>Traducción automática<br>Análisis de sentimiento<br>Juegos de estrategia |

- Inteligencia artificial evolutiva: Utiliza algoritmos genéticos y de evolución para crear soluciones a problemas complejos, como por ejemplo los sistemas de optimización y los juegos.
- Inteligencia artificial de procesamiento del lenguaje natural (NLP): Permite a las máquinas entender y procesar el lenguaje humano de forma natural, ejemplos asistentes de voz Siri y Alexa y ChatGPT.
- Inteligencia artificial cognitiva: Pretende emular la forma en que el cerebro humano procesa la información y realiza tareas, como la percepción, el razonamiento y la toma de decisiones. Ejemplos de esto son los sistemas de predicción de ventas y los sistemas de procesamiento de imágenes médicas.

Cabe destacar que estas categorías de inteligencia artificial no son mutuamente excluyentes, y a menudo se combinan en diferentes sistemas y aplicaciones.

La última clasificación que de acuerdo con Rodríguez D. (2023) es la clasificación por características y objetivos las cuales se describen a continuación:

- Inteligencia artificial débil vs. inteligencia artificial fuerte: La inteligencia artificial débil son sistemas diseñados para realizar tareas específicas, mientras que la inteligencia artificial fuerte se refiere a sistemas que tienen la capacidad de realizar tareas intelectuales como un ser humano.
- Inteligencia artificial simbólica vs. inteligencia artificial subsimbólica: La inteligencia artificial simbólica utiliza símbolos y reglas lógicas para representar y manipular la información, mientras que la inteligencia artificial subsimbólica utiliza redes neuronales y aprendizaje automático para representar y manipular la información
- Inteligencia artificial supervisada vs. inteligencia artificial no supervisada: Esta clasificación se refiere a los datos con los que se entrenan los sistemas de inteligencia artificial. La inteligencia artificial supervisada utiliza datos etiquetados mientras que la inteligencia artificial datos, no etiquetados
- Inteligencia artificial centrada en el usuario vs. inteligencia artificial centrada en la tarea: La inteligencia artificial centrada en el usuario se refiere a sistemas diseñados para satisfacer a los usuarios, mientras que la inteligencia artificial centrada en la tarea se refiere a sistemas que cumplen una tarea específica.

Existe una extensa clasificación, tipos y ramas en la IA como por ejemplo las que menciona APD (2023) las cuales se expresan a continuación: machine learning o aprendizaje automático, fuzzy logic o lógica difusa, vida artificial, sistemas expertos, data mining o minería de datos, redes bayesianas, ingeniería del conocimiento, redes neuronales, sistemas reactivos, sistemas basados en reglas, razonamientos basados en casos, redes semánticas, técnicas de representación de conocimiento, lingüística computacional y procesamiento del lenguaje natural.

### 2.7.1. Principales Áreas y Aplicaciones de la IA.

La inteligencia artificial se usa en múltiples aplicaciones de todos los sectores, incluidos sector salud, el industrial y las administraciones públicas. Una de las aplicaciones que podemos mencionar a continuación se exponen algunos casos de uso específicos como el del control de calidad y mantenimiento prescriptivo que ayudan a mejorar la producción, fabricación mediante un marco abierto para la TI/OT. Las soluciones permiten mejores decisiones de mantenimiento, automatización, y mejoran procesos de control de calidad al implementar técnicas de visión de computación basadas en la IA. Otra aplicación se puede encontrar en el procesamiento de habla y lenguaje mediante la transformación de datos de audio, automatiza la comprensión del lenguaje escrito y hablado que usan procesamiento del lenguaje natural, análisis de conversaciones a texto, búsqueda biométrica o supervisión de llamadas en vivo. En el campo de la visión artificial, la videovigilancia y análisis de vídeo analiza para detectar eventos, desvelar identidades, entorno y personas, y obtener conocimientos operativos. Por último, la conducción autónoma se basa en una plataforma de consumo de datos de que permite a los desarrolladores crear una solución de conducción autónoma (Hewlett Packard Enterprise, 2024).

Se pueden observar algunas otras aplicaciones en la figura 2 sobre algunos otros casos de la IA. La universidad de Castilla- La Mancha (2021) muestra algunos otros campos de aplicación, como en la agricultura, que, por medio de cultivos óptimos, se podrían evitar fraudes con el uso de la IA en la Banca, detección y tratamiento de ataques en el área de la ciberseguridad, en el sector salud se pueden implementar el uso de diagnóstico de pacientes. También en la logística la IA puede generar rutas y optimización de los recursos, optimización de redes en las telecomunicaciones, mejoras en los juegos mediante la creación de agentes inteligentes y aplicaciones en el arte mejorando las ideas y la creatividad.



Figura 2.- Aplicaciones de machine learning en la industria (SinergiaSys, 2024)

## 2.7.2. Técnicas de la Inteligencia Artificial.

Los ámbitos de aplicación de la Inteligencia Artificial son sumamente diversos. Por esta razón, existen una gran variedad de técnicas que podemos aplicar en función del problema al que nos enfrentemos; no existe un algoritmo maestro que nos permita abordar. Es importante destacar que cada una de las técnicas requeriría de múltiples páginas para explicarlas y detallarlas de manera precisa, lo que permitirá explicar los conceptos más selectos de manera que acceda al lector a (Sobrado Malpartida, 2003) conocer algunas de las técnicas más relevantes de la IA, esta información es recabada del documento desarrollado por la Universidad de Castilla la Mancha (2021).

---

### **2.7.2.1. Algoritmo de búsqueda**

Los algoritmos de búsqueda son útiles para resolver problemas en los que se requieren varias acciones para alcanzar un objetivo, como encontrar un camino a través de un laberinto o determinar el mejor movimiento. Los algoritmos de búsqueda proporcionan formas inteligentes de evaluar el espacio de búsqueda y se utilizan en ámbitos tan diversos como, por ejemplo, motores de búsqueda, aplicaciones de mapas e incluso en videojuegos. Se suelen utilizar estructuras de datos como grafos y árboles.

### **2.7.2.2. Algoritmos evolutivos**

Basados en la teoría de la evolución de Charles Darwin, se aprovecha el aprendizaje de la evolución biológica para encontrar soluciones óptimas a problemas prácticos generando diversas soluciones y convergiendo en las más eficaces. Los algoritmos genéticos son una serie de algoritmos específicos de tipo evolutivo. Se utilizan para evaluar grandes áreas de búsqueda y tratar de encontrar una solución adecuada. Es importante señalar que los algoritmos genéticos no garantizan que se encuentre la mejor de las soluciones, pero sí una de las mejores.

### **2.7.2.3. Aprendizaje Automático (machine learning)**

El aprendizaje automático se centra en el enfoque estadístico para entrenar modelos que aprendan de los datos. El campo del aprendizaje automático dispone de una gran variedad de algoritmos que pueden usarse para mejorar la comprensión de las relaciones entre los datos, para tomar decisiones y para hacer predicciones basadas en esos datos.

Existen tres técnicas principales de aprendizaje automático:

- Aprendizaje supervisado: consiste en entrenar modelos con algoritmos cuando los datos de entrenamiento tienen resultados conocidos para una determinada pregunta.
- Aprendizaje no supervisado: trata de descubrir relaciones y estructuras ocultas dentro de los datos que nos guían a la hora de formular las preguntas relevantes sobre el conjunto de datos.
- Aprendizaje por refuerzo: Describe cómo se recompensa a un individuo si se realiza una acción positiva y se le penaliza si se realiza una acción negativa. El aprendizaje por refuerzo es útil para explorar cómo los programas informáticos o los robots interactúan con entornos dinámicos.

De manera resumida, podemos sintetizar los pasos implicados en el aprendizaje automático:

- Recolección y comprensión de los datos.
- Preparación de los datos: es adaptar los datos al formato correcto y admitido por los algoritmos, corregir, eliminar o adaptar aquellos datos incompletos o cualitativos que necesiten ser cambiados a valores cuantitativos.
- Entrenamiento del modelo: para realizar predicciones utilizando el modelo, se debe utilizar el algoritmo correcto en función de la información que queramos obtener y los datos de los que dispongamos. Por ejemplo, la regresión lineal es uno de los algoritmos de aprendizaje automático más simples; busca relaciones entre dos variables y realiza predicciones de una de ellas (variable dependiente) en función de la otra (variable independiente), basándose en las ecuaciones de la recta ( $y = c + mx$ ) y la inferencia de la pendiente ( $m$ ) y el valor donde la recta intercepta al eje Y © mediante algún método de ajuste como, por ejemplo, el de los mínimos cuadrados.

- Probar el modelo: para ello, se mide la precisión del modelo con ejemplos ya conocidos de antemano y comprobando si el modelo arroja los resultados esperados. Cabe destacar, que no se puede probar el modelo con los mismos datos que se han usado para entrenarlo. Normalmente se suele reservar un 20 % de los datos disponibles para realizar las pruebas, y un 80 % para entrenar el modelo.
- Mejorar la precisión del modelo: en caso de que al medir la precisión del modelo durante las pruebas no se haya obtenido la precisión deseada, habría que volver a iterar sobre alguno de los pasos anteriores. Algunas de las recomendaciones que se suelen seguir en este caso serían i) recopilar más datos, ii) preparar o adaptar los datos usando otras técnicas, iii) seleccionar otras características de los datos, o iv) usar un algoritmo diferente para entrenar el modelo como, por ejemplo, árboles de decisión en caso de que nos enfrentemos a problemas de clasificación.

### **2.7.2.3.1. Redes neuronales artificiales.**

Las redes neuronales artificiales (ANN. Por sus siglas en inglés) es una potente herramienta dentro del ámbito del aprendizaje automático, utilizada de diversas maneras para conseguir distintos objetivos: reconocimiento de imágenes, procesamiento del lenguaje natural o resolución de problemas derivados de los juegos. Las ANN aprenden de forma similar a otros algoritmos de aprendizaje automático: utilizando datos para ser entrenadas, pero, se adaptan mejor a los datos no estructurados en los que es difícil entender cómo se relacionan las características entre sí.

Se entienden a las ANN como otro modelo a utilizar en el proceso de aprendizaje automático que deberá ser entrenado y probado correctamente, estas se inspiran por la biología, creando analogías entre elementos del cerebro humano y los componentes de las ANN. El elemento base de una ANN: el perceptrón, que no es ni más ni menos que

la representación lógica de una única neurona del cerebro y el sistema nervioso humanos. Como las neuronas, el perceptrón recibe entradas (como las dendritas), modifica esas entradas en base a algún criterio (como las sinapsis) y produce un resultado (como los axones).

### **2.7.2.3.2. Deep Learning.**

El aprendizaje profundo (del inglés, deep learning), que se deriva del aprendizaje automático, es una familia más amplia de técnicas y algoritmos que se utilizan para lograr una inteligencia limitada (débil), pero con el objetivo de alcanzar una inteligencia general (fuerte). El aprendizaje profundo suele implicar que el enfoque intenta resolver un problema de forma más general, como el razonamiento espacial, o que se aplica a problemas que requieren más generalización, como la visión por computador y el reconocimiento del habla.

Los enfoques de aprendizaje profundo suelen emplear muchas capas de ANN. Al aprovechar diferentes capas de componentes inteligentes, cada capa resuelve problemas especializados; juntas, las capas resuelven problemas complejos tendiendo a cumplir un objetivo mayor. Por ejemplo, identificar cualquier objeto en una imagen es un problema general, pero puede dividirse en la comprensión del color, el reconocimiento de las formas de los objetos y la identificación de las relaciones entre los objetos para lograr un objetivo.


## **2.8. Visión Artificial.**

La visión artificial su función principal es reconocer y localizar objetos en el ambiente mediante el procesamiento de las imágenes. La visión computacional o artificial es el estudio de procesos de reconocimiento de objetos, para entenderlos y construir


maquinas con capacidades similares (Sucar & Gómez, 2024). En la figura 3 y 4 se observa la manera general el procesamiento de imágenes y la visión artificial.

La mayoría de las aplicaciones de la visión artificial podemos clasificarlas por el tipo de tarea:

- La medición o calibración se refiere a que las mediciones cumplan con las especificaciones del diseño. Por ejemplo, el comprobar que un cable tenga el espesor recomendado.
- La detección de fallas involucra la detección de defectos o artefactos no deseados, con forma desconocida en una posición desconocida. Por ejemplo, encontrar defectos en la pintura de un auto nuevo, o agujeros en hojas de papel.
- La verificación es el chequeo en una operación de ensamblaje ha sido llevada a cabo correctamente. Por ejemplo, que no falte ninguna tecla en un teclado, o que no falten componentes en un circuito impreso.
- El reconocimiento involucra la identificación de un objeto con base en descriptores asociados con el objeto. Por ejemplo, la clasificación de cítricos (limones, naranjas, mandarinas, etc.) por color y tamaño.
- La identificación es el proceso de identificar un objeto por el uso de símbolos en el mismo. Por ejemplo, el código de barras, o códigos de perforaciones empleados para distinguir hule de espuma de asientos automotrices.
- El análisis de localización es la evaluación de la posición de un objeto. Por ejemplo, determinar la posición donde debe insertarse un circuito integrado.
- Guía significa proporcionar adaptativamente información posicional de retroalimentación para dirigir una actividad. El ejemplo típico es el uso de un Sistema de Visión para guiar un brazo Robótico mientras suelda o manipula partes. Otro ejemplo sería la navegación en vehículos autónomos.



*Figura 3.- Esquema general del procesamiento de imágenes (Sucar & Gómez, 2024)*



*Figura 4.- Esquema general de visión por computadora (Sucar & Gómez, 2024)*

## **2.8.1. Etapas de la visión artificial.**

En un sistema de visión artificial se incluyen diversas técnicas, tales como el procesamiento de imágenes (captura, transformación, codificación de imágenes) o como el reconocimiento de formas (teoría estadística de decisiones, enfoques sintácticas y neuronales aplicados a la clasificación de patrones). En este tipo de sistemas, además se incluyen técnicas de modelado geométrico y procesos de conocimiento, de acuerdo con Sobrado (2003) a continuación se describen las etapas para el proceso de adquisición de imágenes. (Sobrado Malpartida, 2003)

### 2.8.1.1. Adquisición de imagen.

El sistema que permite la captura y/o adquisición de la imagen, está formado por los siguientes elementos:

- **Cámara:** Es el elemento encargado de transformar las señales luminosas que aparecen en la escena, en señales analógicas capaces de ser transmitidas por un cable coaxial. Se divide en dos partes, el sensor, que captura las propiedades del objeto en forma de señales luminosas y lo transforma en señales analógicas, y la óptica que se encarga de proyectar los elementos adecuados de la escena ajustando una distancia focal adecuada. Los sensores de visión usados son los basados en matrices, estos transductores proporcionan una señal con amplitud proporcional a la luminosidad de la escena y realizan una digitalización espacial completa en dos dimensiones (líneas y columnas), pues descomponen la imagen en una matriz de puntos.
- **Digitalizador:** es el encargado de transformar la señal de vídeo, cualquiera que sea el formato utilizado (NTSC, PAL), en una señal digital capaz de ser capturada, almacenada en memoria y procesada por una computadora. Las principales características de las tarjetas digitalizadoras son precio, controlabilidad, resolución, velocidad y almacenaje.
- **Sistema de iluminación:** la iluminación de la escena juega un papel crucial en el desarrollo de un sistema visual. Antes de intentar corregir un problema de iluminación, es mejor prestar atención e implantar un sistema de iluminación adecuado, para que la captura de la imagen sea correcta. Es mejor un buen sistema de iluminación, que intentar corregir ese problema por software, pues la velocidad de procesamiento será mayor con algoritmos más sencillos. Se tienen diferentes sistemas de iluminación:
  - **Retroiluminación Difusa:** Es la más adecuada, si para el reconocimiento o medida de una pieza solo se necesita el contorno y es posible apoyar dicha pieza sobre una superficie transparente. Consiste en iluminar contra la

cámara, dejando el objeto entre la cámara y la lámpara. Las principales aplicaciones donde se comporta bien esta técnica de iluminación son para medir el grado de porosidad de ciertas sustancias y en inspección dimensional para calcular el tamaño de una pieza.

- Iluminación Frontal: es la más usada, y consiste en iluminar frontalmente la pieza. Presenta más problemas para obtener un buen contraste entre la pieza y el fondo, debido a la aparición de brillos y sombras que alteran las propiedades de las piezas a estudio.
- Luz Direccional: consiste en una iluminación direccionada en algún sentido en el espacio para destacar una característica. La principal virtud es la creación de sombras sobre el objeto, lo que puede ayudar a aumentar el contraste de partes tridimensionales y obtener la consiguiente información 3D.
- Luz Estructurada: consiste en proyectar sobre la pieza unos patrones de luz conocidos modulados y observando la luz reflejada, que también viene modulada, obtener información sobre la estructura de la superficie del objeto, la cual puede ser reconstruida mediante triangulación.
- Fuentes de iluminación: lámparas incandescentes, tubos fluorescentes, fibra óptica, láseres.

### **2.8.1.2. Preprocesamiento de la Imagen.**

Etapa donde la transformación de la imagen original en otra imagen donde hayan sido eliminados los problemas de ruido granular de cuantización o de iluminación espacialmente variable. La utilización de estas técnicas permite el mejoramiento de las imágenes digitales adquiridas. Se mencionan algunas técnicas de preprocesamiento.

- Conversión a Escala de Grises: en esta parte se trata la conversión de una imagen en color a escala de grises, el equivalente a la luminancia de la imagen. Como sabemos el ojo percibe distintas

- Filtro espacial: es el empleo de máscaras espaciales para el procesamiento de las imágenes, y las propias máscaras se denominan filtros espaciales. Dentro del filtrado espacial, existen los filtros suavizantes, que se emplean para hacer que la imagen aparezca algo borrosa y también para reducir el ruido.

### **2.8.1.3. Segmentación.**

La segmentación es el proceso mediante el cual una imagen se descompone en regiones o elementos que pueden corresponder a objetos o parte de objetos. El proceso de segmentación se encarga de evaluar si cada pixel de la imagen pertenece o no al objeto de interés.

- Segmentación basada en Píxeles: el objetivo de este método es el de encontrar de una manera óptima los valores característicos de la imagen que establecen la separación del objeto de interés, con respecto a las regiones que no pertenecen al mismo.
- Operaciones Morfológicas: son métodos para procesar imágenes binarias basado sobre formas. Estas operaciones toman una imagen binaria como entrada y dan como resultado una imagen binaria como salida.

### **2.8.1.4. Descripción.**

Con el objeto de poder analizar una imagen será necesario tener una descripción en la memoria de la computadora. Esta descripción no es otra cosa que un modelo que representa las características de la imagen de relevancia para los fines del Sistema de Visión Artificial específicos. Los modelos que describen una imagen pueden ser estadísticas, estructurales, etc. pero todos ellos se obtienen a partir de imágenes previamente segmentadas y analizadas.

### 2.8.1.5. Reconocimiento

Una vez que se han realizado las etapas de preprocesamiento, segmentación y extracción de características, se procede a realizar el reconocimiento. La fase de reconocimiento consistirá en la clasificación de los objetos presentes en la imagen de acuerdo a sus modelos respectivos.

### 2.9. Modelo YOLO.

Existen varias arquitecturas de detección de objetos como los sistemas de ventana deslizante, R-CNN, el single shot detection, retinanet, entre otros, para los fines de este trabajo se utilizará el sistema YOLO. YOLO se distingue de entre otros modelos, solo requiere ver la imagen una vez, lo que permite hacer la detección de manera más rápida y permite detectar objetos en tiempo real con precisión (Enrique, 2019).

Como ya se comentó YOLO (You Only Look Once) es una arquitectura de detección de objetos muy rápida y precisa, consiste en una red neuronal convolucional que predice simultáneamente múltiples cuadros delimitadores y las probabilidades de la clase de objeto que delimitan dichos cuadros. Los beneficios que se pueden mencionar de este modelo son:

- Es un sistema muy rápido, debido a que se reduce la detección a un problema de regresión lineal.
- Para hacer las predicciones, a diferencia de los métodos anteriores, este sistema consume la imagen completa.
- Aprende representaciones generalizables de objetos, lo que hace que, si se introducen datos de entrada nuevos

La primera publicación de YOLO fue efectuada en el año 2015 por Joseph Redmon, quien ejerció el papel de principal autor. Presentando una estructura de

detección de objetos rápida y precisa, lo que la convierte en una herramienta idónea para su utilización en tiempo real. El autor abordó la detección de objetos como una tarea de regresión desde los píxeles de la imagen hasta las coordenadas de la caja delimitadora y las probabilidades de clase, lo cual se logra mediante la división de la imagen en una cuadrícula y prediciendo las cajas delimitadoras y las probabilidades de clase para cada celda de la cuadrícula. Este procedimiento disminuye significativamente el cálculo, dado que tanto la detección como el reconocimiento son efectuados por células de la imagen, no obstante, genera una gran cantidad de predicciones duplicadas. Con el fin de solventar estas dificultades, YOLO sugiere la supresión de todos los cuadros delimitadores que poseen una probabilidad superior (Arregui Arias, 2023).

El modelo YOLO (2015) a partir de su publicación a la fecha presenta 9 versiones que han adquirido diferentes características que han permitido mejorar el procesamiento de los datos, a continuación, se mencionan las principales características por modelo:

- YOLO-v2 (2017): mejora las deficiencias del modelo original respecto a la detección de objetos pequeños y la precisión de la localización, por lo que normaliza los lotes llevando al aumento de la convergencia del modelo dando lugar a un entrenamiento más rápido incluso un aumento del 2%, mejora la resolución, reduce los cuadros de anclaje para predecir el cuadro delimitador dando lugar a una localización más precisa.
- YOLO-v3 (2018): centran la predicción de la caja delimitadora, de la clase y el extractor de características. Consiguiendo un rendimiento comparable a otros métodos, manteniendo la rapidez, se consiguió detectar objetos de pequeño tamaño, aunque comenzaron a tener problemas con los de mayor tamaño.
- YOLO-v4 (2020): El modelo fue retomado por otros investigadores y agregaron conexiones residuales ponderadas, normalización cruzada de mini lotes, conexiones parciales de etapas cruzadas, entrenamiento autoadversario y activación Mish como cambios metodológicos entre los métodos modernos de regularización y aumento de datos.

- YOLO-v5 (2020): la empresa Ultralytics lanzó la versión 5 oficial de YOLO, sin embargo, no se reportaron los cambios realizados que hicieron que se convirtiera en el modelo más rápido de esta fecha.
- YOLO-v6 (2022): Desarrollado por el Departamento de Inteligencia Visual de Meituan logrando un rendimiento más sólido que YOLOv5; ofrece un notable equilibrio entre velocidad y precisión, lo que lo convierte en una elección popular para aplicaciones en tiempo real. Este modelo introduce varias mejoras notables en su arquitectura y esquema de entrenamiento.
- YOLO-v7 (2022): Publicado por Chien-Yao Wang y Bochkovskiy convirtiendo está ultima en el detector de objetos con mayor velocidad y precisión hasta el momento, supera a todos los detectores de objetos conocidos tanto en velocidad como en precisión en el rango de 5 FPS a 160 FPS. Tiene la mayor precisión (56,8% AP) entre todos los detectores de objetos en tiempo real conocidos (YOLOR, YOLOX, Scaled-YOLOv4, YOLOv5, y muchos otros. A diferencia de los detectores de objetos en tiempo real tradicionales, que se centran en la optimización de la arquitectura, YOLOv7 introduce un enfoque en la optimización del proceso de entrenamiento.

### **2.9.1. YOLO-v8 (2023).**

Es una versión mejorada por Ultralytics, La última iteración de la serie YOLO de detectores de objetos en tiempo real, que ofrece un rendimiento óptimo en cuanto a precisión y velocidad. De acuerdo con los progresos de las versiones anteriores de YOLO, YOLOv8 introduce nuevas funciones y optimizaciones que lo convierten en la opción ideal para diversas tareas de detección de objetos en una amplia variedad de aplicaciones (Jocher, Laughing, Chaurasia, & Cayatay Akyon, 2023).

---

### 2.9.1.1. Características principales

YOLOv8 emplea arquitecturas de espina dorsal y cuello de última generación, lo que mejora la extracción de características y el rendimiento de la detección de objetos, además adopta un cabezal dividido sin anclajes Ultralytics, que contribuye a una mayor precisión y a un proceso de detección más eficaz en comparación con los enfoques basados en anclajes.

Tiene un compromiso optimizado para mantener un equilibrio óptimo entre precisión y velocidad, YOLOv8 es adecuado para tareas de detección de objetos en tiempo real en diversas áreas de aplicación. También ofrece una gama de modelos preentrenados para atender a diversas tareas y requisitos de rendimiento, lo que facilita encontrar el modelo adecuado para cada caso de uso específico.

### 2.9.1.2. Tareas y modos admitidos.

La serie YOLOv8 presenta una amplia variedad de modelos, cada uno de ellos enfocado en tareas específicas de visión por computadora. Los modelos están diseñados para satisfacer diversos requisitos, desde la identificación de objetos hasta tareas más complejas, tales como la segmentación de instancias, la identificación de poses/puntos clave, la identificación de objetos orientados y la clasificación.

Cada variante de la serie YOLOv8 se encuentra optimizada para su tarea específica, lo que garantiza un alto rendimiento y precisión. Asimismo, estos modelos son compatibles con diversos métodos operativos, como la Inferencia, la Validación, el Entrenamiento y la Exportación, lo que facilita su uso en diferentes etapas de despliegue y desarrollo.

La tabla 5 proporciona una visión general de las variantes del modelo YOLOv8, destacando su aplicación en tareas específicas y su compatibilidad con diversos modos

operativos, tales como Inferencia, Validación, Entrenamiento y Exportación. Se exhibe la capacidad y robustez de la serie YOLOv8, lo cual las convierte en una aplicación idónea para una amplia variedad de aplicaciones en visión por ordenador.

*Tabla 5.- Variantes del modelo YOLOv8 y sus aplicaciones (ultralitics, 2023)*

| Modelo      | Tarea                      | Inferencia | Validación | Formación | Exportar |
|-------------|----------------------------|------------|------------|-----------|----------|
| YOLOv8      | Detección                  | ✓          | ✓          | ✓         | ✓        |
| YOLOv8-seg  | Segmentación de instancias | ✓          | ✓          | ✓         | ✓        |
| YOLOv8-pose | Pose/Puntos clave          | ✓          | ✓          | ✓         | ✓        |
| YOLOv8-obbb | Detección Orientada        | ✓          | ✓          | ✓         | ✓        |
| YOLOv8-cls  | Clasificación              | ✓          | ✓          | ✓         | ✓        |

# **CAPÍTULO 3**

## **ESTADO DEL ARTE**

### 3. Estado del Arte.

El avance de la tecnología de los últimos 20 años ha permitido que muchos investigadores, científicos, ingenieros y desarrolladores de tecnología propongan diferentes soluciones masivas a la separación de basura doméstica. Una de las soluciones más sencillas que se han propuesto tanto para instituciones y hogares son métodos manuales de separación de residuos, el cual consiste en delegar la responsabilidad y educar a las personas de colocar los diferentes residuos en contenedores específicos los cuales contendrán los residuos sólidos clasificados de acuerdo a diferentes normativas tanto nacionales e internacionales que rigen la forma en que se separa la basura, la forma como se clasifica la basura se podría definir desde una clasificación sencilla hasta lo más compleja, con lo anterior se refiere que la basura se puede clasificar por su naturaleza organica e inorgánica (Separación de Residuos Sólidos Urbanos (SEDEMA), 2013) y de esta manera aumentar su complejidad de separación utilizando clasificaciones más específicas dependiendo de la naturaleza de los residuos, así como de las características y composiciones de los materiales de los que están conformados (ASECA, 2018).

Actualmente existen soluciones para la separación de basura que contemplan el uso de la tecnología, específicamente el uso de dispositivos eléctricos y electrónicos, así como el uso de las ciencias computacionales; algunas otras soluciones plantean tecnologías para facilitar la separación de residuos manualmente mediante el diseño físico y mecánico de contenedores (Jiménez Loya, 2012).

Se es consciente de la problemática que existe en el cuidado de nuestro medio ambiente, sabemos que gran cantidad de empaques desechados como papel, aluminio, lata, plástico, cartón, etc. Existen depósitos especiales para reciclar y saber que este producto (PET) es destinado a los desechos Inorgánicos. Pues al separar este empaque se ayuda a que se promueva y facilite su recolección y reciclaje (ISAN, 2016).

Los antecedentes más relevantes que se pueden encontrar relacionados al presente trabajo son varios ya que depende del modelo utilizado para realizar la visión artificial, los que a continuación se mencionan tiene que ver con el uso de tecnología basada principalmente en el uso de métodos de inteligencia artificial como el aprendizaje profundo y el uso de redes neuronales convolucionales, de esta manera existen diferentes propuestas relacionadas a la separación de residuos sólidos utilizando el procesamiento de imágenes por medio de computadora (Sanjai, Balaji, Pranav, & Aravindan, 2019). Por otra parte, para este tipo de proyectos es importante definir los materiales que se pueden clasificar mediante el uso de los diferentes elementos electrónicos (Peng & Zhou, 2019). Mediante métodos mas avanzados se propone el uso de algoritmos de aprendizaje automático al cual llaman Máquina de soporte de vectores que usa la visión artificial para comparar imágenes, además se hace uso de diferentes sensores para reconocer basura húmeda o con efectos eléctricos (Akshita, Pushkala, Nivetha, & Ramesh Subashka, 2020).

A continuación, se muestran algunos trabajos que se consideran de relevancia y de los cuales se pueden obtener datos relevantes para el uso de y manipulación del modelo que usará para la detección de imágenes en este trabajo, son los más destacables por considerar que aportan elementos relacionados los métodos utilizados en este trabajo y que algunos orientan el desarrollo de este de los cuales se pueden destacar que son aplicados al mismo fin que pretende en presente trabajo.

Se comienza con el trabajo de Otero, Toro & Hoyos (2021), quienes abordan la clasificación de imágenes trabajando con vectores de las imágenes construidos por pixeles y otro por las características, como algoritmos de clasificación utilizan regresión logística (Logistic Regression, . LG), K vecinos más cercanos (K Nearest Neighbors.- KNN) y máquinas de vectores de soporte (Support Vector Mechines.- SVM), determinando que estos modelos tienen mejoras cuando se trabajan con valores de pixeles y logran la mejor exactitud con el modelo SVM logrando una exactitud del 84% (Otero Gómez, Toro, & Hoyos, 2021). Adedeji & Wang usan un modelo pre entrenado

ResNet-50 de un modelo de red neuronal convolucional (Convolutional Neural Network.- CNN) como herramienta de aprendizaje y una SVM que es usada para clasificar los residuos en diferentes grupos y tipos como el vidrio, metal, papel y plástico, ellos utilizan un conjunto de datos desarrollado por Thung & Yang (2016), su base de datos contiene imágenes de objetos reciclables clasificados en 6 clases con alrededor de 500 fotos cada uno (Yang & Thung, 2016), el modelo entrenado tiene la capacidad de reconocer el 87 % de las imágenes presentadas de la base de datos (Adedeji & Wang, 2019).

La propuesta de un modelo de clasificación de imágenes de residuos reciclables basado en aprendizaje profundo (Deep Learning, DL) y que asegura presenta ciertas ventajas como mejorar la capacidad de representación del mapa de características y puede extraer automáticamente las características de diferentes tipos de imágenes de desechos, es desarrollado por Zhang, Zhang, Mu, Wang, Tian, Wang & Liu (2021), su principal aportación es que utilizan un modelo pre entrenado ResNet 18, basado en métodos de DL, este modelo presento 95.87% de exactitud utilizando bases de datos TrashNet (Zhang, y otros, 2021).

Otros modelos que utilizan una red neuronal (CNN) y algunos modelos como DenseNet169, MobileNetV2, and ResNet50V2 es el desarrollado por Mittal, Tiwari, Rana & Singh (2020), utilizaron varias bases de datos con varias clasificaciones y varios tamaños de datos, realizaron pruebas con esas bases de datos y obtuvieron precisiones de entrenamiento, las precisiones van desde 80 hasta 91% en el caso de la exactitud en el entrenamiento hasta el 78 al 81 % en el caso de las pruebas de test (Mittal, Tiwari, Rana, & Singh, 2020). Caso muy similar que desarrollan Basher, Alotaibi, Al- Qahtani & otros, quienes utilizan la visión por computadora con la red neuronal (CNN) y algunos modelos como DenseNet169, MobileNetV2, y ResNet50V2, concluyeron que el CNN lograron 88.52% de exactitud, mientras que en otros modelos que han sido entrenados previamente obtuvieron DenseNet169, MobileNetV2, and ResNet50V2, alcanzaron 94.40%, 97.60%, y 98.95% de exactitud, respectivamente (Basheer Ahmed, y otros, 2023).

Existen varios modelos utilizados para el desarrollo de la inteligencia artificial sin embargo uno de los pre-modelos que ha alcanzado popularidad entre la comunidad científica y técnica que desarrolla modelos de visión artificial basados en estos modelos pre-entrenados es YOLOv8, modelo que brinda algunas características que facilitan la implementación de aplicaciones, como las que se describen a continuación; Reis, Kupec, Hong & Daoudi (2023) quienes utilizan este modelo para el reconocimiento en la industria aeronáutica, este artículo permite destacar la aplicación del modelo utilizado en el presente trabajo en diversos campos y se toma como referencia por la novedad que tiene el modelo YOLOv8, una versión muy reciente que requiere ver las aplicaciones que tiene en los últimos meses, en particular este artículo describe el uso del modelo en general donde entrenaron a su modelo con YOLOv8, posteriormente realizaron el aprendizaje priorizando los datos más representativos y posteriormente generar su modelo, el reconocimiento de objetos voladores representó un desafío por las características de los objetos captados y las condiciones en las que estos se encuentran, para disminuir algunos de estos parámetros se utiliza la última generación de YOLOv8 que promete un mejor equilibrio entre la velocidad de inferencia y mapa, lo que permite mejorar la velocidad de inferencia y lograr una exactitud del 95% de una inicial de 83.5% (Reis, Kupec, Hong, & Daoudi, 2023). Otro trabajo que hacen un exitoso uso del modelo YOLOv8 es el de Arregui (2023) que utiliza el modelo para la detección de cascos de seguridad en tiempo real, dentro de los modelos pre-entrenados que expone para la solución a la problemática planteada se pueden mencionar R-CNN, Fast R-CNN, single shot multibox detector, Retina Net y EfficientDet, hace uso de los modelos de EfficientDet, YOLOv5 y YOLOv8 para hacer varias pruebas para su entrenamiento, pero encontró mejores resultados en el último modelo (Arregui Arias, 2023).

Un modelo de YOLO que fue creado para aplicaciones autónomas de bajo tamaño y que tiene funciones especiales para su uso en proyectos del medio ambiente es el que uso Lin (2021) busca la aplicación de redes neuronales profundas por tener pocas investigaciones utilizando ese modelo, se centran en el modelo YOLO Green que es un

modelo específicamente diseñado para la detección de basura en tiempo real, este modelo ya contiene un conjunto de datos recopilados y se clasifican en 7 de los tipos más comunes de desechos sólidos; como resultados se obtienen un modelo con poco entrenamiento y una precisión de 78.04% y teniendo un modelo de tamaño de 117 MB, el modelo YOLO Green resulto ser más eficiente que le modelo YOLOv4 y otros modelos del momento, se destaca la exactitud y el tamaño del modelo, lo que se convierte en un buen modelo a destacar para próximas aplicaciones de la detección de residuos sólidos (Lin, 2021).

Amaya (2022) diseñó un sistema para detectar botellas de plástico y vidrio en los residuos mediante el uso del modelo Yolov5, con una exactitud del 76 % y una precisión del 86 %. El sistema utilizó una banda transportadora y una cámara para detectar los tipos de botella (Amaya Lopez, 2022). No obstante, está propenso a confundirse por algunos cambios de posición que podrían tener las botellas al momento de sujetarla. Giraldo Quiñones (2022), empleó una red neuronal convolucional para detectar 12 grupos de residuos, tales como papel, cartón, lata, plástico, botellas plásticas, revistas, entre otros. Su base de datos fue obtenido a través de fotografías e internet, con un total de 3800 imágenes. En el entrenamiento obtuvo una precisión del 86 % con imágenes no conocidas y el 98 % con imágenes conocidas. El algoritmo fue ejecutado en tres sistemas distintos, tales como NVIDIA Jetson Nano, Dev Board Coral y Raspberry Pi. La velocidad de respuesta de su algoritmo en estos sistemas fue de entre 0.6 y 1.4 segundos (Giraldo Quiñones, 2022).

Gómez (2022), establecieron un clasificador de residuos sólidos a través de una red neuronal. Su base de datos está compuesta por tres clases y entreno su algoritmo con un total de 800 imágenes tomadas desde un dispositivo y descargadas de internet. El algoritmo fue desarrollado a través de Google Teachable Machine, el código abierto de tensorflow y el editor P5.js, y obtuvieron una precisión del 89,63 % (Gómez Vargas & Tamayo Saavedra +, 2022). Chen (2020) planteó utilizar una mejora del modelo de Yolov4 para detectar y clasificar 15 categorías de basura. La base de datos estaba

compuesta por 22,000 imágenes para el conjunto de entrenamiento y 6,600 en el de prueba. Experimento una comparativa de los modelos YOLOv3, YOLOv4 y la propuesta. Por consiguiente, el modelo que tuvo un rendimiento mejor fue la propuesta con un mAP del 64 % y una velocidad de 92 FPS (Chen & Xiong, 2020). Ye (2020) un nuevo modelo de red neuronal de YOLO con el objetivo de acelerar el tiempo de procesamiento y precisión del reciclaje automatizado de basura. El rendimiento de su propuesta fue del 69.70 %, alcanzando una velocidad de 60 FPS, lo que es más rápido que YOLO v1 y Fast R-CNN (Ye, Pang, Jin, & Cui, 2020). Como se puede apreciar en la literatura, existe un gran interés en clasificar los desperdicios humanos mediante la utilización de versiones antiguas de YOLO, tales como De Carolis (De Carolis, Ladogana, & Macchiarulo, 2020) y Wu (Wu, y otros, 2021).

El último artículo revisado fue el de Wahyutama & Hwang, quienes exponen una aplicación similar pero con el uso de YOLOv5, este artículo se describe de la detección de objetos en tiempo real por YOLOv5, utilizaron una base de datos aumentada lo que les permitió tener mejores resultados, esta propuesta solo permite identificar papel, plástico y latas, obtuvieron un 91% de precisión en sus resultados, El entrenamiento del modelo se efectuó mediante 6000 iteraciones, las imágenes fueron obtenidas por diversos medios en la web en total hicieron el entrenamiento con un 80% de la muestra de 1000 imágenes 250 por clasificación (papel, plástico, latas y otros), el resto se dejó para validación del entrenamiento del modelo (Wahyutama & Hwang, 2022).

# **CAPÍTULO 4**

# **JUSTIFICACIÓN**

### 4. Justificación.

En la actualidad, una considerable cantidad de residuos en el mundo carecen de la atención adecuada para su descomposición. Como resultado, los ecosistemas son afectados directamente por la enorme cantidad de basura acumulada. Actualmente las comunidades afrontan esta problemática con la recolección de materiales y la reutilización de los desechos sólidos, por lo mismo se ven afectadas las vialidades y al igual afecta la salud de los seres vivos.

La generación de residuos sólidos debido al consumismo humano ha crecido en los últimos años generando impactos irreversibles en el medio ambiente afectando a los seres vivos modificando así su habitat, se calcula que antes de la pandemia causada por el virus SARS COV 2 la basura doméstica generada por habitante era del 1.5 kilogramos, se estima que para la pandemia las personas han aumentado la generación de residuos sólidos domésticos derivados del papel, plástico, metal, entre otros. A nivel mundial se generan 3.8 mil millones de toneladas de basura diaria en América latina y el caribe 540 mil toneladas. México genera 115 mil toneladas diarias que se traduce en 103 mil toneladas diarias de basura doméstica. En el Estado de México se generan 18 624 toneladas de residuos sólidos urbanos; de acuerdo con el INEGI una persona produce diariamente 854 gramos de residuos del hogar. Si bien existen distintos métodos que han permitido el control masivo de los residuos no se ha logrado disminuir ni erradicar la contaminación ocasionada por el consumo humano en las comunidades humanas.

Las estrategias para combatir el gran problema de la generación de residuos sólidos urbanos a nivel mundial está relacionado por una parte con la cultura, hábitos y conciencia de cuidado al medio ambiente de las personas y con métodos de reciclaje que permiten la separación y el aprovechamiento de materiales solidos que pueden ser reutilizables, sin embargo, no se ha logrado disminuir el impacto de los residuos, por lo que considerando que el principal foco de generación de este tipo de residuos son los hogares, es por ello que por medio del uso de la ciencia, y la tecnología se plantean

soluciones que le permita a las personas y sociedad disminuir el impacto de la contaminación resolviendo el problema desde la raíz aplicando métodos de selección y clasificación de residuos evitando así la contaminación de los residuos mezclándolos entre ellos mismos, lo que dificulta posteriormente su separación en algunos casos se vuelve algo imposible.

La Asociación Internacional de Ingeniería Sanitaria y Ambiental (AIDIS) ha informado que desde el año 2016, los países latinoamericanos continúan empleando vertederos y botaderos de basura en el cielo abierto sin las especificaciones técnicas, lo que ha generado la práctica de recolección sin clasificación. En un comparativo, solo el 17 % de los desperdicios humanos se encuentran reciclados debido a lo previamente mencionado. A diario, llegan toneladas de residuos mal clasificados, lo que genera vectores contaminantes. Asimismo, las personas que llevan a cabo esta actividad de forma manual no están en las mejores condiciones de higiene y están expuestas a infecciones, lesiones o enfermedades. En general, la clasificación actual de estos desperdicios humanos provoca que se pierda materia prima y se pueda reintegrarse al ciclo de vida útil.

Una de las principales preocupaciones de las comunidades en México es la contaminación de los suelos y la mayoría de los materiales no son el cien por ciento reciclables tenemos como propósito reducir las cantidades de desechos que se generan con ayuda del prototipo que se diseñara.

Así mismo se pretende la mejora del medio ambiente y hacer que la gente tome conciencia sobre la problemática que existe y que ellos puedan mejorar la calidad del entorno donde viven.

El desarrollo de un sistema que permita el reconocimiento y clasificación mediante de estos desechos utilizando la tecnología de la inteligencia artificial y la visión artificial pretende que posteriormente pueda ser utilizado para hacer aplicaciones que conectadas a medios de actuación física consienta y facilite la clasificación de los residuos sólidos

---

por lo que esto ayudará a otros entusiastas en el cuidado del medio ambiente y la reducción de desechos que amplie la aplicación en combinación con otras tecnologías, impactando así en el desarrollo tecnológico y el cuidado del medio ambiente.

# **CAPÍTULO 5**

## **OBJETIVOS**

---

## 5. Objetivos

### 5.1. Objetivo General

Generar un modelo de visión artificial mediante el uso de Deep Learning, específicamente el modelo de YOLOV8 para detectar e identificar en tiempo real 5 clases diferentes de residuos sólidos por medio de una cámara web.

### 7.2 Objetivos Específicos

- Revisar el estado de arte y los antecedentes de desarrollos similares.
- Definir el marco teórico relacionado con la clasificación y tipos de residuos sólidos documentados.
- Definir las características y propiedades físicas y químicas de los principales residuos sólidos domésticos.
- Especificar la metodología para el entrenamiento del modelo
- Aplicar el uso del modelo YOLOv8 para entrenar el modelo.
- Realizar las pruebas de entrenamiento y obtener un modelo final.

# **CAPÍTULO 6**

# **DESARROLLO**

# **EXPERIMENTAL**

### 6. Desarrollo experimental.

A continuación, se describe el método que se empleará para desarrollar el modelo de detección de objetos, para obtener el modelo se divide en tres artes: análisis del conjunto de datos, entrenamiento y exportación; en la figura 5 se puede observar la forma general que consideradas las fases para desarrollar una Inteligencia artificial.



*Figura 5.- Fases de la Inteligencia Artificial (elaboración propia)*

La Figura 6 describe un modelo de entrenamiento de inteligencia artificial que muestra con más detalle las fases de entrenamiento y el proceso de prueba; como se puede ver en la figura 7 que presenta el proceso para el desarrollo de la visión artificial. De las figuras anteriores en la figura 8 se muestra un esquema simplificado que permitirá establecer el procedimiento para el desarrollo de este trabajo donde se muestran los pasos y la forma en que se abordara el desarrollo y obtención del modelo (figura 9).



Figura 6.- Modelo de entrenamiento de inteligencia artificial de Tensorflow y proceso de pruebas (Polo, 2019)





Figura 7.- Proceso de procesamiento de datos de la visión artificial (Sobrado Malpartida, 2003)



*Figura 8.- Proceso de entrenamiento para el reconocimiento mediante la visión artificial (elaboración propia)*



*Figura 9.- Método a seguir para el desarrollo del modelo de entrenamiento (elaboración propia)*

# **CAPÍTULO 7**

# **RESULTADOS**

## 7. Resultados.

### 7.1. Análisis conjunto de datos.

Con base a la teoría se definieron las clasificaciones de los residuos sólidos urbanos más abundantes y comunes que se desechan en los hogares mexicanos, en la figura 1 podemos observar que uno de los desechos más comunes son los residuos orgánicos, seguido de los derivados del papel, plástico, vidrio y metal, por lo que se eligieron estos 5 desechos como las clases necesarias para comenzar el entrenamiento.

Después de que se establecieron los desechos más frecuentes en los hogares y se establecieron que estos determinarían las clases, se debe de obtener el conjunto de datos (base de imágenes) que servirán el inicio del entrenamiento, por lo que era necesario atender, de tal manera que se procedió a realizar la captura de las imágenes que lo conformarían.


El conjunto de datos se conformó de 2000 imágenes que se obtuvieron mediante la utilización de cinco cámaras de teléfono celular con una resolución de 4160 x 1968. Se seleccionó cuidadosamente los objetos para la base en diversos ángulos de cámara y puntos de vista, las imágenes obtenidas de fotografías tomadas a desechos reales, de las que se crearon 5 clases de desechos que se definieron como con las etiquetas: “Plástico”, “Papel”, “Metal”, “Vidrio” y “Basura orgánicos”, El banco de datos se mejoró con un nuevo conjunto de imágenes de acceso libre del buscador de Google. Las imágenes tienen una resolución de 4160 x 1968 píxeles, y una profundidad de 32 bits (tres canales) de tipo .jpg. La base se compone de 400 imágenes por clase o categoría, en la figura 10 se muestran algunas imágenes que conforman la base de datos.

Una vez que se obtiene el conjunto de datos se debe de procesar las imágenes para su posterior entrenamiento. Con la ayuda de la herramienta BBox-Label-tool, la cual puede ser descargada de <https://github.com/xiaqunfeng/BBox-Label-Tool> y tiene que ser ejecutada en el software de SPYDER como se ve en la Figura 11 posteriormente después de abrirlo se ejecuta y permitirá realizar el procesamiento de las imágenes, donde se

selecciona el área de las imágenes y se etiqueta de acuerdo a las clases que se definieron para el entrenamiento, como se muestra en la Figura 12. Este procedimiento se realizó, solo para el 80% de las imágenes que se utilizaran para el entrenamiento, ya que el 20% restante se utilizara para la fase de pruebas, por lo que la totalidad de imágenes fueron sometidas a el proceso antes mencionado



*Figura 10.- Ejemplos de imágenes que conforman el conjunto de datos (elaboración propia)*



```

1 from tkinter import *
2 from tkinter import filedialog
3 from tkinter import messagebox
4 from tkinter import ttk
5 from PIL import Image, ImageTk
6 import os
7 import glob
8 import random
9
10 # colors for the bboxes
11 COLORS = ['red', 'blue', 'pink', 'cyan', 'green', 'black']
12 # image sizes for the examples
13 SIZE = 256, 256
14
15 class LabelTool():
16     def __init__(self, master):
17         # set to the main frame
18         self.parent = master
19         self.parent.title("LabelTool")
20         self.frame = Frame(self.parent)
21         self.frame.pack(fill=BOTH, expand=1)
22         self.parent.resizable(width=FALSE, height=FALSE)
23
24         # initialize global state
25         self.imageDir = ''
26         self.imageList = []
27         self.egDir = ''
28         self.egList = []
29         self.outDir = ''
30         self.cur = 0
31         self.total = 0
32         self.category = 0
33         self.imagename = ''
34         self.labelfilename = ''
35         self.king = None
36         self.currentlabelclass = ''
37         self.class_candidate = []
38         self.classcandidate_filename = 'class.txt'
39
40         # initialize mouse state
41         self.STATE = {}
42         self.STATE['click'] = 0
43         self.STATE['x'], self.STATE['y'] = 0, 0
44
45         # reference to bbox
46         self.bboxIdList = []
47         self.bboxId = None
48         self.bboxList = []
49         self.hl = None
50         self.vl = None
51
52         # ----- GUI stuff -----
53         # dir entry & load
54         # input image dir button
55         self.srcDirBtn = Button(self.frame, text="Image input folder", command=self.selectSrcDir)

```

Figura 11.- Programa de BBox-Label-Tool en rgáni con Syder(Python 3.11)  
(elaboración propia)

La herramienta Bbox-Label-Tool, permite identificar en cada imagen el tipo de clase al que pertenece cada elemento de las imágenes; esta herramienta genera un conjunto de datos compuestos un componente de un .txt por cada imagen, el cual se observa en la figura 13 en forma de ejemplo, que señala los vectores de las imágenes que se presentaron, estos archivos son almacenados en un directorio específico, esto se realiza con el conjunto de datos que se tiene. El primer número establece la categoría a la que pertenece el objeto, mientras que los otros valores establecen el tamaño y los puntos de localización del objeto de interés en la imagen.




Figura 12.- Uso de la herramienta Bbox-Label-Tool para Python (elaboración propia)




Figura 13.- Resultado de la selección y clasificación de las imágenes por medio de Bbox-Label-Tool (elaboración propia)

Después de realizar la vectorización de todas las imágenes, se desarrolla el código para el entrenamiento mediante el uso del software Anaconda.Navigator y su paquetería de Spider 5.4.3 (figura 14), este último tiene funciones especiales y las librerías necesarias para ejecutar el código que permita desarrollar el entrenamiento mediante el uso de las Etiquetas desarrolladas en el paso anterior.



*Figura 14.- Software utilizado para el entrenamiento del modelo (elaboración propia)*

Primero con las etiquetas se compone un archivo de tipo YAML compuesto por la configuración de YOLO. En la figura 15 se puede observar el utilizado en este proyecto. Que está compuesto por las siguientes líneas:

- train: ../train/images: indica la ruta o directorio donde se encuentran las imágenes de entrenamiento.
- val: ../valid/images: indica la ruta o directorio donde se encuentran las imágenes de validación.
- nc: 5: representa el número de clases en tu conjunto de datos. En este caso, hay 5 clases: Metal, Papel, Plástico, Basura orgánica y Vidrio.
- names: ['Metal', 'Papel', 'Plástico', 'Basura orgánica', 'Vidrio']: proporciona una lista de nombres de las clases en el mismo orden en que se enumeran en el número de clases. Es decir, Metal corresponde a la clase 0, Papel corresponde a la clase 1, plástico correspondería a la clase 2, Basura orgánica sería la clase 3 y Vidrio corresponde a la clase 4, de los archivos TXT de anotación.

```
! basura.yaml X
C: > Users > ivan_ > Downloads > tesis > ! basura.yaml
1  # Dataset Path
2  path: D:\yolov8-gpu\data\base_datos
3
4  train: images\train # relative to path
5  val: images\val # relative to path
6  test: images\test # relative to path
7
8  # Class Names
9  names: [Metal,Papel,Plástico,Basura organica,Vidrio]
```

*Figura 15.- Archivo YAML para el modelo Yolo (elaboración propia*

Resulta imperativo llevar a cabo una serie de modificaciones en el conjunto de datos. Se examinaron las 2000 imágenes que lo conforman, y se hicieron las modificaciones que se describen a continuación:

1. Eliminación de la etiqueta
2. Etiquetado de objetos sin etiquetar
3. Eliminación de etiquetas no validas

Para ello se hizo uso de la herramienta de anotación de imágenes gráficas Labellmg la cual se puede descargar en el siguiente enlace: <https://github.com/heartexlabs/labelimg>. La herramienta está desarrollada en Python y usa Qy para su interfaz gráfica. La interfaz es muy intuitiva para el usuario, por lo que facilitó la realización de las modificaciones. Dentro de la herramienta se seleccionó formato “YOLO”, almacenando todas las modificaciones en los archivos TXT correspondientes a cada una de las imágenes.

---

### 7.2. Entrenamiento del modelo.

El presente proyecto se llevará a cabo mediante la técnica de transfer Learning Feature Extraction, específicamente, mediante un modelo ya incorporado, y únicamente reensamblando su capa última para que se adapte al problema planteado. En consecuencia, se debe otorgar al modelo de detección de objetos la habilidad de detectar en tiempo real alguno de los desechos sólidos establecidos en el apartado anterior.

Para ello se pondrá a prueba el modelo seleccionado capaces de conseguir el objetivo (ejecución en tiempo real) en el momento del comienzo del desarrollo del proyecto YOLOv8.

Existen múltiples opciones para llevar a cabo el entrenamiento, tales como la utilización de Google Colab, un producto similar al Jupyter Notebook de Google Research. Mediante Colab, se puede ejecutar código de Python mediante un dispositivo web, ya que el entorno de desarrollo y el intérprete de Python se encuentran alojados en la nube. La plataforma Colab ofrece la posibilidad de acceder de forma gratuita a una infraestructura informática, tales como almacenamiento, memoria, capacidad de procesamiento, unidades de procesamiento de gráficos (GPU) y tensor (TPU). Sin embargo, esta plataforma es limitada en la versión gratuita por lo que se decidió hacer el desarrollo de manera local en una computadora con características de Workstation, que permitirá dejar corriendo el entrenamiento

La base de datos de imágenes y sus archivos .txt fueron divididos en tres conjuntos: entrenamiento, validación y el de prueba. El conjunto de entrenamiento se compone de imágenes que el modelo utilizara para entrenar y extraer las características de los objetos encontrados en las coordenadas de los Labels. El segundo grupo se usa para obtener el rendimiento del modelo durante cada una de las épocas de entrenamiento, lo cual es sumamente útil para guardar el modelo con mejor rendimiento. Finalmente, el conjunto de prueba se emplea para evaluar el rendimiento del modelo en imágenes que estuvieron fuera del entrenamiento. La literatura aconseja dividir la base

---

de datos total en 80 % para el conjunto de entrenamiento, 10 % para el conjunto de prueba y 10 % para el conjunto de validación.

Para realizar el entrenamiento del modelo, se requiere la inclusión de imágenes del conjunto de entrenamiento, validación y los Labels. Los parámetros utilizados en este proceso se presentan en la tabla 6.

*Tabla 6.- Parámetros de entrenamiento (elaboración propia)*

| Parámetro                   | Dato      |
|-----------------------------|-----------|
| Número de épocas            | 140       |
| Batch                       | 2         |
| Modelo                      | Yolov8l   |
| Tamaño de imagen de entrada | 640 x 640 |

El número de épocas empleadas en este trabajo fue de 140. El batch es el lote de imágenes que entran en la red neuronal antes de actualizar los pesos. Con el fin de alcanzar una precisión óptima y una mayor velocidad, se empleó el modelo de Yolov8. La resolución de la imagen de entrada en la capa convolucional se encuentra normalizada por defecto en un tamaño de 640 x 640. Yolov8 utiliza diversas funciones durante el entrenamiento para tomar decisiones en cada época. La función de checkpoint posibilita detectar y guardar los pesos con mayor rendimiento durante el entrenamiento en un archivo denominado best.pt. Por lo otro lado, el sobreajuste de los pesos se produce cuando no hay mejoras en el rendimiento después de una determinada cantidad de épocas. El modelo usa la función patience para detener el entrenamiento cuando se rebase un número de épocas después de la última mejora. Existen una gran variedad de métricas para evaluar modelos de clasificación binaria y multiclase. Con Yolov8 se pretende clasificar cinco categorías de desechos humanos, lo cual constituye un problema multiclase. La matriz de confusión en modelos de este tipo es mostrada en la

tabla 7 (Markoulidakis, y otros, 2021). En la figura 16 se muestra el código para realizar el entrenamiento, donde se pueden apreciar los parámetros antes mencionados.

```

1  import yolo
2  yolo detect train
3  model=yolov8n.pt
4  data=data/basura.yaml
5  imgsz=640 workers=8 batch=8
6  device=0 epochs=10000
7  patience=150 name=basura
    
```

Figura 16.- Instrucciones del entrenamiento (elaboración propia)

Tabla 7.- Matriz de aprendizaje multiclase (elaboración propia)

|                  |       | Categoría predicha |       |     |           |
|------------------|-------|--------------------|-------|-----|-----------|
|                  |       | $C_1$              | $C_2$ | ... | $C_N$     |
| Categoría actual | $C_1$ | $C_{1,1}$          | FP    | ... | $C_{1,N}$ |
|                  | $C_2$ | FN                 | TP    | ... | FN        |
|                  | ...   | ...                | ...   | ... | ...       |
|                  | $C_N$ | $C_{N,1}$          | FP    | ... | $C_{N,N}$ |

La matriz de confusión de la tabla 7 se compone de N filas por N columnas, donde N es el número de categorías. Se aplica la ecuación 1, para obtener la precisión en un problema multiclase, la cual mide el porcentaje de predicciones positivas del modelo. En el caso de la sensibilidad, se mide la proporción de casos positivos reales que el modelo detectó correctamente. Esta métrica se calcula mediante la ecuación número 2.

$$TPR(C_i) = \frac{TP(C_i)}{TP(C_i) + FN(C_i)} \quad (1)$$

$$PPV(C_i) = \frac{TP(C_i)}{TP(C_i) + FP(C_i)} \quad (2)$$

Donde:

*TP*: Verdaderos positivos

*FP*: Falsos positivos

*FN*: Falsos negativos

Los verdaderos positivos son objetos detectados por el modelo y que en realidad pertenecen a la categoría que se encuentra. Los falsos positivos son objetos detectados, no obstante, no corresponden a la categoría real. En el caso de los falsos negativos, se trata de objetos que no detecto el modelo, pero se encontraban en la imagen. Para evaluar el rendimiento en la detección de objetos del modelo, es necesario incluir la precisión y sensibilidad en un valor único. La precisión media (mAP) promedia todas las categorías, proporcionando un solo valor. En un gráfico, la precisión se ubica en el eje Y y la sensibilidad se ubica en el eje X, con el fin de obtener la métrica AP. Lo que se pretende obtener con este gráfico es el área que se encuentra debajo de la curva entre estos dos valores, el cual está definido por la ecuación 3 (Simón Rodríguez & Ruz Gómez, 2020).


$$AP = \int_0^1 p(r) dr \quad (3)$$

Los límites son del 1 al 0, debido a que los porcentajes del AP varía entre esos valores. La integral de la precisión en función de la sensibilidad es el área que se encuentra debajo de la curva de estas dos métricas para obtener el valor de AP. Durante el entrenamiento, se lleva a cabo la evaluación del modelo obtenido de esa época, junto

con el conjunto de validación, con el fin de obtener las métricas previamente mencionadas. Para lograrlo, el AP utiliza un algoritmo denominado (IoU) que se utiliza para determinar si el objeto detectado pertenece a una clase real o no.

$$IoU = \frac{\text{Área de intersección}}{\text{Área total de la unión}} \quad (4)$$

IoU es la relación entre el área de intersección y el área de unión del cuadro delimitador predicho (ecuación 4). El conjunto de validación contiene imágenes previamente etiquetadas con Labelimg, las cuales tienen Labels con las coordenadas del objeto de interés. Este cuadro delimitador, enmarcado manualmente, se emplea para comparar con el cuadro delimitador detectado por el modelo.



*Figura 17.- Ejemplo de IoU de los dos cuadros delimitadores (elaboración propia)*

La figura 17 presenta 2 cuadros marcados en el objeto de interés. El color azul representa el cuadro delimitador previamente marcado en el Labelimg, mientras que el negro representa el cuadro delimitador marcado por el modelo. El IoU para este ejemplo podría ser aproximadamente de 0.35, lo cual podría no considerarse una buena detección. En la figura 18, se muestra un ejemplo de la división de áreas.



*Figura 18.- Intersección entre los dos cuadros delimitadores (elaboración propia)*

El IoU ayuda a determinar si la detección es un verdadero positivo o verdadero negativo. La toma de esta decisión se fundamenta en un umbral, y si el IoU es superior al umbral seleccionado, se considera un verdadero positivo. En caso contrario, la detección se considerará como un verdadero negativo. La métrica mAP50 se refiere a la correlación entre la precisión y la sensibilidad del modelo mediante un umbral de 0.5 en el IoU, el cual fue empleado en este trabajo. Los resultados del mejor modelo que guardo el entrenamiento con el conjunto de validación se presentan en la tabla 8.

*Tabla 8.- Métricas obtenidas (elaboración propia)*

| <b>Clase</b>    | <b>Precisión</b> | <b>Sensibilidad<br/>(Recall)</b> | <b>mAP50</b> |
|-----------------|------------------|----------------------------------|--------------|
| Metal           | 0.831            | 0.799                            | 0.878        |
| Plástico        | 0.892            | 0.493                            | 0.667        |
| Basura orgánica | 0.898            | 0.792                            | 0.869        |
| Papel           | 0.846            | 0.783                            | 0.779        |
| Vidrio          | 0.853            | 0.657                            | 0.782        |
| Total           | 0.864            | 0.705                            | 0.795        |

Las métricas obtenidas del modelo con mejor rendimiento durante las 140 iteraciones se presentan en la tabla número 9. La clase plástico presenta dificultades en la clasificación debido a la presencia de aglomeración de estos en el conjunto de validación, lo que puede dar como resultado una dificultad para detectar.

# **CAPÍTULO 8**

# **DISCUSIÓN DE**

# **RESULTADOS**

### 8. Discusión de resultados.

Con el objetivo de realizar las pruebas correspondientes, en la figura 19 se puede observar las instrucciones que se dieron en el software Spyder para que pudiera ejecutar el modelo entrenado.

```
1  from ultralytics import YOLO
2
3  # Load the model
4  model = YOLO('86.pt')
5
6  # Classification result
7  results = model.predict(source="0", show=True)
8
9  print(results)
```

*Figura 19.- Instrucción para ejecutar el modelo entrenado (elaboración propia)*

La primera revisión del modelo detectó los materiales correctamente y fue probado utilizando diferentes tipos de basura urbana.



a)



b)



c)




Figura 20.- Detecciones en imágenes del conjunto prueba (elaboración propia)




Figura 21.- Detecciones incorrectas (elaboración propia)

Como se muestra en la figura 20, el modelo entrenado realizó algunas de las detecciones. No obstante, el modelo fue implementado en una cámara web y se puede observar en la figura 21 que la clase metal y papel los confunde con otro objeto. Se llevó

a cabo una segunda prueba con dos metales para efectuar una detección en la cámara web con este tipo de material.



a)



b)

*Figura 22.- Detecciones de la clase metal (elaboración propia)*

En la figura 22, se muestra que detecto correctamente los objetos de la clase metal a pesar del ruido y del desenfoque de la imagen. Al realizar estas detecciones con el conjunto de prueba (figura 23), se obtuvieron los siguientes resultados (tabla 9).

```
1 import torch
2 from ultralytics import YOLO
3 model = YOLO('basura.pt')
4 test_dataset = LoadImagesAndLabels(test_images_folder, test_labels_folder)
5 results = model.test(data=test_dataset)
6 results.save()
7 results.show()
8 results.print()
9 precision, recall, AP, f1, ap_class = ap_per_class(results)
```

*Figura 23.- Instrucciones para hacer las mediciones con el conjunto prueba (elaboración propia)*

*Tabla 9.- Resultados del conjunto prueba (elaboración propia)*

| Clase           | Precisión | Sensibilidad<br>(Recall) | mAP50 |
|-----------------|-----------|--------------------------|-------|
| Metal           | 0.763     | 0.651                    | 0.715 |
| Plástico        | 0.874     | 0.641                    | 0.826 |
| Basura orgánica | 0.869     | 0.827                    | 0.896 |
| Papel           | 0.894     | 0.619                    | 0.747 |
| Vidrio          | 0.922     | 0.556                    | 0.695 |
| Total           | 0.864     | 0.659                    | 0.776 |

Los resultados de la tabla 9 muestran la precisión, la sensibilidad y el mAP50, con un conjunto de imágenes no utilizadas durante el entrenamiento. El modelo podría tener un fallo en la detección o reconocimiento incorrecto de ciertos objetos pertenecientes a la clase de papel y metal. La clasificación requiere 51 ms para determinar la categoría del desecho humano en la imagen. Esta sería la velocidad que requeriría procesar cada fotograma de la cámara.

El modelo puede detectar vidrio, metal, plástico, basura orgánica y papel con una precisión superior al 86 %. No obstante, en ocasiones, se puede confundir el metal y el plástico. Se verificó que la clase plástico y vidrio detecta correctamente y la clase metal en ocasiones se confunde con la categoría plástico. La proximidad a la cámara hacia el objeto de metal aumenta su clasificación óptima. Las categorías papel y basura orgánica tienen un menor rendimiento, ya que el modelo a veces detecta esos materiales como plástico o vidrio. Los problemas que surgieron se debieron a la posible presencia de fotografías desenfocadas y algunas de baja calidad obtenidas por la red.

Este modelo fue implementado en tiempo real mediante la utilización de una cámara web para comprobar su velocidad y capacidad de detectar los objetos en el fotograma. La velocidad de procesamiento por fotograma es de 51 ms, lo cual significa

que es menor con respecto a otros modelos, por mencionar alguno el modelo SSD MobileNet (Barba Guaman, 2021), esto puede ser causado al momento de clasificar los objetos, derivado del tamaño de la imagen de entrada o por las mismas características del equipo, pero se compensa con la precisión. Se propone como trabajo futuro entrenar el modelo con más imágenes en todas las categorías para aumentar la precisión, la sensibilidad y el mAP50. Asimismo, se incrementaría el número de épocas hasta 1000, con el fin reducir la cantidad de falsos positivos y detecciones incorrectas. Y, por último, usar un modelo más ligero como Yolov8n o Yolov8s para aumentar la velocidad de procesamiento en cada fotograma.

# **CAPÍTULO 9**

# **CONCLUSIONES Y**

# **RECOMENDACIONES**

### 9. Conclusiones y Perspectivas.

La preservación del medio ambiente ha adquirido un papel fundamental en la salvaguarda de las generaciones actuales y venideras. Los incrementos de los volúmenes de residuos sólidos asociados a patrones insostenibles de producción y consumo representan una grave externalidad ambiental que se requiere afrontar.

El objetivo de este trabajo fue contribuir a este desafío mediante la exploración de técnicas de Inteligencia Artificial para la identificación automatizada de residuos. Se entrenó un modelo de detección visual basado en Deep Learning (YOLOv8) que permite diferenciar vidrio, metal, plástico, materia orgánica y papel con una precisión superior al 86% y en tiempo real (50 ms por cuadro)

A pesar de que estos resultados son estimulantes, también se evidenció la necesidad de modificar las medidas para garantizar la solución ante alteraciones en la apariencia, posición y fondo de los objetos. Por consiguiente, se recomienda aumentar el número y diversidad de imágenes de entrenamiento, probar diferentes configuraciones algorítmicas e incluso arquitecturas más recientes como YOLOv9.

Asimismo, se encuentra una oportunidad para enriquecer el modelo mediante la utilización de sensores multimodales, el aprendizaje por refuerzo y la validación cruzada con el fin de mejorar su generalización. Una alternativa prometedora sería la evolución del enfoque para evaluar el estado y destino óptimo de cada residuo, más allá de su mera clasificación.

Además de estos progresos técnicos, resulta esencial investigar modelos económicos y marcos regulatorios habilitadores que incentiven el retorno de materiales reciclables a la cadena productiva mediante este tipo de sistemas automatizados. Asimismo, resulta fundamental fomentar la concienciación ciudadana acerca de la relevancia de sus conductas de consumo, separación y disposición de desechos.

En resumen, este proyecto constituyó una primera contribución que esperamos impulsar nuevos desarrollos multi e interdisciplinarios, con el propósito de concluir ciclos de materiales mediante la aplicación de la tecnología para el bienestar colectivo. Se requiere transitar hacia modelos circulares para aliviar presiones indebidas sobre recursos finitos y restaurar el delicado equilibrio de la Tierra que nos acoge.

Además, también es necesario afrontar el desafío de la creciente contaminación oceánica por plásticos que provienen de fuentes terrestres. Un ámbito fértil sería diseñar alternativas para la identificación temprana de estos residuos en cursos fluviales a través del proceso de procesamiento de video en tiempo real.

Los puntos críticos de acumulación podrían ser georreferenciados con el fin de alertar y enfocar operativos en los vectores principales. La vigilancia automatizada debería combinarse con modelización de propagación, estudios de dinámica fluvial y análisis de opciones técnico-económicas para interceptación/recolección de los residuos plásticos.

Es imperativo que se implementen políticas que fomenten la responsabilidad amplia del productor, alternativas asequibles con el medio ambiente y estrategias localizadas para minimizar fugas en puntos calientes, tales como canales pluviales y plantas de tratamiento. La comunicación pública desempeña un papel esencial en la promoción de la concienciación ciudadana a través de campañas enfocadas y micro-aprendizajes a través de dispositivos móviles.

Con un enfoque sistemático de carácter estratégico, empleando la tecnología para el bienestar colectivo y fomentando la ciudadanía responsable, nuestro país y región pueden contribuir con iniciativas frente a posibles riesgos como la contaminación marina, alineados con el cumplimiento de los objetivos de los ODS.

# **CAPÍTULO 10**

# **BIBLIOGRAFÍAS Y**

# **REFERENCIAS**

### 10. Bibliografía y Referencias

Adedeji, O., & Wang, Z. (2019). Intelligent Waste Classification System Using Deep Learning Convolutional Neural Network. *Procedia Manufacturing*, 607-612.

Obtenido de

<https://www.sciencedirect.com/science/article/pii/S2351978919307231>

ADP. (5 de septiembre de 2023). *Las ramas de la inteligencia artificial y sus diferentes aplicaciones*. Obtenido de [www.apd.es](http://www.apd.es): <https://www.apd.es/tecnicas-de-la-inteligencia-artificial-cuales-son-y-para-que-se-utilizan/>

Akshita, V., Pushkala, R., Nivetha, R., & Ramesh Subashka, S. (2020). Garbage Segregation System using Support Vector Machine. *Proceedings of the First International Conference on Advanced Scientific Innovation in Science, Engineering and Technology, ICASISSET 2020*.

Amaya Lopez, D. E. (2022). *Diseño e implementación de un prototipo para detección de envases en residuos sólidos por medio de visión artificial*. Bogotá: Universidad Santo Tomas.

ambientum.com. (28 de noviembre de 2022). *Características químicas de los residuos sólidos urbanos*. Obtenido de [ambientum.com](http://ambientum.com): [https://www.ambientum.com/enciclopedia\\_medioambiental/suelos/caracteristicas\\_quimicas\\_de\\_los\\_rsu.asp](https://www.ambientum.com/enciclopedia_medioambiental/suelos/caracteristicas_quimicas_de_los_rsu.asp)

Arregui Arias, A. B. (2023). *Detección de cascos de seguridad en tiempo real mediante modelos de Deep Learning*. Cartagena: Universidad Politécnica de Cartagena.

ASECA. (24 de Septiembre de 2018). *Separación correcta de la basura*. Obtenido de [aseca.com](http://aseca.com): <https://aseca.com/separacion-correcta-de-la-basura/>

- 
- Barba Guaman, L. R. (2021). *Uso de técnicas deep learning para reconocimiento de objetos en áreas rurales*. Madrid: E.T.S.I. de Sistemas Informáticos (UPM).
- Basheer Ahmed, M., Alotaibi, R., Al-Qahtani, R., Al-Qahtani, R., Al-Hetela, S., Al-Matar, K., . . . Krishnasamy, G. (2023). Deep Learning Approach to Recyclable Products Classification: Towards Sustainable Waste Management. *Sustainability MDPI*.  
Obtenido de <https://www.mdpi.com/2071-1050/15/14/11138>
- Cárdenas, S., & Várcel, M. (2000). *Atomatización y miniaturización en química analítica*. Barcelona: Springer.
- Cárdenas-Valbuena, R. d.-Q.-M.-G.-N.-Q.-P. (2022). Impacto ambiental y riesgos potenciales generados en los rellenos sanitarios. . *Revista Investigación En Salud Universidad de Boyacá*, 100-117.
- Carranza, M. (5 de junio de 2020). *Calcúlenle: Cada mexicano genera 854 gramos de basura todos los días*. Obtenido de [www.sopitas.com](http://www.sopitas.com):  
<https://www.sopitas.com/noticias/cuanta-basura-mexico-tira-cada-persona-promedio-inegi-dia-mundial-ambiente/#:~:text=Resulta%20que%20todos%20los%20d%C3%ADas,culturales%20de%20la%20vida%20cotidiana%E2%80%9D>.
- Carrasco Romero, F. E., & Morocho Vera, I. L. (2015). *Diseño del sistema de gestión de desechos solidos reciclable para la urbanización villa del rey, etapa princesa diana, ubicada en el km. 14 av. León febres cordero, la aurora–daule*. Guayaquil: Escuela Superior Politécnica.
- Chen, Q., & Xiong, Q. (2020). Garbage Classification Detection Based on Improved YOLOV4. *Journal of Computer and Communications*, 285-294. Obtenido de [https://www.scirp.org/pdf/jcc\\_2021011322480971.pdf](https://www.scirp.org/pdf/jcc_2021011322480971.pdf)
-

Cruz Aburto, É. Y. (6 de febrero de 2018). *La basura que día con día generamos*.

Obtenido de uv.mx:

<https://www.uv.mx/cienciauv/blog/labasuraquediaadiageneramos/>

De Carolis, B., Ladogana, F., & Macchiarulo, N. (2020). YOLO TrashNet: Garbage Detection in Video Streams. *2020 IEEE Conference on Evolving and Adaptive Intelligent Systems (EAIS)*.

Diaz Colorado, C. F., & Caldas Vega, J. A. (2018). *Sistema de control automático para el reconocimiento y clasificación de residuos reciclables para un punto ecológico*. Bogotá : Universidad Católica de Colombia.

Enrique, A. (30 de abril de 2019). *Detección de objetos con YOLO: implementaciones y como usarlas*. Obtenido de medium.com:

<https://medium.com/@enriqueav/detecci%C3%B3n-de-objetos-con-yolo-implementaciones-y-como-usarlas-c73ca2489246>

Giraldo Quiñones, J. D. (2022). *Clasificador de residuos sólidos haciendo uso de deep learning*. Santiago de Cali: Universidad Autónoma de Occidente.

GISA. (29 de diciembre de 2023). *La importancia del buen manejo de los residuos sólidos urbanos*. Obtenido de grupogisa.mx: <https://grupogisa.mx/importancia-del-buen-manejo-de-los-residuos-solidos-urbanos/>

Gómez Cívicos, J. (2008). Ingeniería Verde: 12 principios para la sostenibilidad. *Ingeniería Química*, 168-175.

Gómez Vargas, D. L., & Tamayo Saavedra +, A. K. (2022). Clasificador de residuos sólidos para la i.e. Juan XXIII del municipio de Algeciras con aplicación de Machine Learning. *Revista Sennova: Revista Del Sistema De Ciencia, Tecnología E Innovación*.

Gupta, N., Yadav, K., & Kumar, V. (2015). A review on current status of municipal solid waste management in India. *Journal of Environmental Sciences*, 206-217.

Hewlett Packard Enterprise. (1 de enero de 2024). *Inteligencia artificial*. Obtenido de [www.hpe.com: https://www.hpe.com/mx/es/what-is/artificial-intelligence.html#:~:text=La%20inteligencia%20artificial%20se%20clasifica,inteligencia%20artificial%20basada%20en%20capacidades](https://www.hpe.com/mx/es/what-is/artificial-intelligence.html#:~:text=La%20inteligencia%20artificial%20se%20clasifica,inteligencia%20artificial%20basada%20en%20capacidades).

Huerta, V. (6 de junio de 2022). *¿A dónde va la basura que generan los municipios del Estado de México?* Obtenido de [elsoldetoluca.com.mx: https://www.elsoldetoluca.com.mx/local/a-donde-va-la-basura-que-generan-los-municipios-del-estado-de-mexico-8390055.html](https://www.elsoldetoluca.com.mx/local/a-donde-va-la-basura-que-generan-los-municipios-del-estado-de-mexico-8390055.html)

iresiduo.com. (27 de Junio de 2017). *Nueva planta automatizada para el reciclaje de residuos sólidos urbanos*. Obtenido de [iresiduo.com: https://iresiduo.com/noticias/mexico/conacyt/17/06/27/nueva-planta-automatizada-reciclaje-residuos-solidos-urbanos](https://iresiduo.com/noticias/mexico/conacyt/17/06/27/nueva-planta-automatizada-reciclaje-residuos-solidos-urbanos)

ISAN, A. (03 de 07 de 2016). *Ecología verde* . Obtenido de [Veneficios de Resiclar : http://www.ecologiaverde.com/los-beneficios-de-reciclar/](http://www.ecologiaverde.com/los-beneficios-de-reciclar/)

Jiménez Loya, M. (2012). *Diseño de botes-separadores de residuos sólidos para viviendas de interés social de la zona conurbada Veracruz -Boca del Río-Medellín, México*. Veracruz : Universidad Veracruzana.

Jocher, G., Laughing, Chaurasia, A., & Cayatay Akyon, F. (12 de noviembre de 2023). *YOLOv8*. Obtenido de [docs.ultralytics.com: https://docs.ultralytics.com/es/models/yolov8/](https://docs.ultralytics.com/es/models/yolov8/)

Junta de Andalucía. (2013). *Educación ambiental, residuos y reciclaje*. Andalucía: Consejería del Medio Ambiente y Ordenación del Territorio de la Junta de Andalucía.

- Kumar, S., Smith, S., Fowler, G., Velis, C., & Kumar, J. (2017). Challenges and opportunities associated with waste management in India. *Royal Society Open Science*, 1-10.
- Lin, W. (2021). YOLO-Green: A Real-Time Classification and Object Detection Model Optimized for Waste Management. *2021 IEEE International Conference on Big Data*. Obtenido de <https://ieeexplore.ieee.org/abstract/document/9671821#citations>
- Madhava Das, M., Sanjai, N., Tharun, R., & Vishnu Bharath, N. (2021). Smart Garbage System. *International Journal of Recent Advances in Multidisciplinary Topics*, 64-66.
- Manrique López-Henares, I. (Diciembre de 2021). *Economía circular y gestión de residuos en el mercado español*. Obtenido de repositorio.comillas.edu: <https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/61928/TFM%20-%20Manrique%20Lopez-Henares%20Ignacio.pdf?sequence=1&isAllowed=y>
- Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Multi-class confusion matrix reduction method and its application on net promoter score classification problem. *Technologies 2021*. Obtenido de <https://www.mdpi.com/2227-7080/9/4/81>
- Medina Delgado, R. (2016). *El reciclaje es la solución*. México: Sindicato Nacional de Trabajadores de la Educación.
- Mittal, I., Tiwari, A., Rana, B., & Singh, P. (2020). Trash Classification: Classifying garbage using Deep Learning. *Journal of Engineering Sciences*, 61-68.
- Mota Ávila, A. (2011). *Química del Medio Ambiente*. Obtenido de [www.ugr.es: https://www.ugr.es/~mota/Quimica\\_Medio\\_Ambiente.html](http://www.ugr.es/~mota/Quimica_Medio_Ambiente.html)

- Organización Panamericana de la Salud. (2000). *La salud y el medio ambiente en el desarrollo sostenible*. Obtenido de paho.org:  
<https://www1.paho.org/hq/dmdocuments/salud-ambiente-desarrollo-sostenible2000.pdf>
- Otero Gómez, D., Toro, M., & Hoyos, W. (2021). Solid Domestic Waste classification using Image Processing and Machine Learning. *OSFPREPRINTS*, 2-11.
- Peng, H., & Zhou, J. (2019). Study on urban domestic waste recycling process and trash can automatic subdivision standard. *IOP Conf. Series: Earth and Environmental Science*, 1-8.
- Pérez Orozco, B. (2018). Inteligencia Artificial. *Oficina de Información científica y tecnológica para el congreso de la unión*, 1-6.
- Polo, J. D. (29 de marzo de 2019). *Cómo podría ayudar la Inteligencia Artificial al sector del Hosting*. Obtenido de es.godaddy.com: <https://es.godaddy.com/blog/como-podria-ayudar-la-inteligencia-artificial-al-sector-del-hosting-2/>
- Raza Carrillo, D., & Acosta, J. (2022). Planificación ambiental y el reciclaje de desechos sólidos urbanos. *Economía, Sociedad y Territorio*, 519-544.
- Reis, D., Kupec, J., Hong, J., & Daoudi, A. (17 de mayo de 2023). *Real-Time Flying Object Detection with YOLOv8*. Obtenido de arxiv.org:  
<https://arxiv.org/abs/2305.09972>
- Rodríguez García, R., Gómez Curquejo, N., Zarauza Cabrerizo, P., & Benítez Rodríguez, A. (2013). *Educación ambiental, residuos y reciclaje*. Andalucía: Consejería de Medio Ambiente y Ordenación del Territorio, Junta de Andalucía.
- Rodríguez García, R., Gómez Curquejo, N., Zarauza Cabrerizo, P., & Benítez Rodríguez, A. (2013). *Educación ambiental, residuos y reciclaje*. Andalucía:

Consejería de Medio Ambiente y Ordenación del Territorio de la Junta de Andalucía.

Rodríguez, D. (4 de abril de 2023). *Algunas clasificaciones de las inteligencias artificiales*. Obtenido de informacionytic.com:  
[https://informacionytic.com/es\\_ar/2023/04/04/algunas-clasificaciones-de-las-inteligencias-artificiales/](https://informacionytic.com/es_ar/2023/04/04/algunas-clasificaciones-de-las-inteligencias-artificiales/)

Rodríguez, H., & López, D. (2019). Aplicaciones de la inteligencia artificial en la gestión de residuos urbanos. *Tecnología y Sostenibilidad*, 210-222.

Sanjai, J., Balaji, V., Pranav, K., & Aravindan, B. (2019). Automated domestic waste segregator using image processing. *International Research Journal of Engineering and Technology*, 357-360.

Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT). (2015). *Informe de la situación del Medio Ambiente en México 2015*. México: Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT).

Secretaría de Medio Ambiente y Recursos Naturales. (25 de marzo de 2008). *Programa nacional para la prevención y gestión integral de los residuos*. Obtenido de <http://aplicaciones.semarnat.gob.mx/>:  
<http://aplicaciones.semarnat.gob.mx/residuos/bibliovirtual/PNPGIR.pdf>

Secretaría de Medio Ambiente y Recursos Naturales. (10 de enero de 2017). *Residuos Sólidos Urbanos (RSU)*. Obtenido de [www.gob.mx/semarnat](http://www.gob.mx/semarnat):  
<https://www.gob.mx/semarnat/acciones-y-programas/residuos-solidos-urbanos-rsu>

Secretaría de Medio Ambiente y Recursos Naturales. (2020). *Diagnóstico de la gestión integral de residuos sólidos urbanos en México*. México: Secretaría de Medio Ambiente y Recursos Naturales.

semarnat.gob.mx. (29 de enero de 2023). *Residuos*. Obtenido de semarnat.gob.mx:  
<https://apps1.semarnat.gob.mx:8443/dgeia/informe18/tema/cap7.html>

Separación de Residuos Sólidos Urbanos (SEDEMA). (2013). *Norma Ambiental NADF-024-AMBT 2013 sobre Separación, Clasificación, Recolección Selectiva y Almacenamiento de los Residuos del Distrito Federal*. Obtenido de SEDEMA:  
[http://data.sedema.cdmx.gob.mx/nadf24/NADF\\_024.html](http://data.sedema.cdmx.gob.mx/nadf24/NADF_024.html)

Simón Rodríguez, A., & Ruz Gómez, R. (2020). *Evaluación de algoritmos de machine learning para conducción*. Madrid: Universidad Complutense de Madrid.

SnergiaSys. (7 de enero de 2024). *Modelos y Aplicaciones*. Obtenido de sinergiasys.com: <https://www.sinergiasys.com/inteligencia-artificial-modelos-y-aplicaciones-2/>

Sobrado Malpartida, E. A. (2003). *Sistema de visión artificial para para el reconocimiento y manipulación de objetos utilizando un brazo robot*. Lima: Pontificia Universidad Católica de Perú.

Sucar, E., & Gómez, G. (19 de enero de 2024). *Visión Computacional*. Obtenido de <https://ccc.inaoep.mx/>: <https://ccc.inaoep.mx/~esucar/Libros/vision-sucar-gomez.pdf>

Tchobanoglous, G., Theissen, H., & Eliassen, R. (1982). *Desechos Sólidos: Principios de ingeniería y administración*. Venezuela: Serie: Ambiente y los Recursos Naturales Renovables.

ultralytics. (12 de noviembre de 2023). *YOLOv8*. Obtenido de docs.ultralytics.com: <https://docs.ultralytics.com/es/models/yolov8/>

unep.org. (21 de noviembre de 2017). *Aumenta la generación de residuos en América Latina y el Caribe mientras 145.000 toneladas aún se disponen de forma inadecuada cada día*. Obtenido de unep.org: <https://www.unep.org/es/noticias-y->

reportajes/reportajes/aumenta-la-generacion-de-residuos-en-america-latina-y-el-caribe#:~:text=La%20generaci%C3%B3n%20de%20residuos%20s%C3%B3lidos,presentados%20en%20un%20evento%20de

Universidad de Castilla-La Mancha, Escuela Superior de Informática Ciudad Real. (25 de noviembre de 2021). *Modelos de Inteligencia Artificial*. Obtenido de es.scribd.com: <https://es.scribd.com/document/542387817/M1-MIA-S01>

Velazco, K. (29 de Junio de 2017). *¿QUÉ ES EL TRL? DE LA IDEA A LA INNOVACIÓN?* Obtenido de ipicyt.edu.mx: [https://ipicyt.edu.mx/noticias\\_resumen.php?noticia=2070&anio=2017#:~:text=El%20Technology%20Readiness%20Level%20o,industriales%20en%20todo%20el%20mundo](https://ipicyt.edu.mx/noticias_resumen.php?noticia=2070&anio=2017#:~:text=El%20Technology%20Readiness%20Level%20o,industriales%20en%20todo%20el%20mundo).

Venegas, P. (19 de febrero de 2022). *Concesión de la basura costará al gobierno de Coacalco 9 millones de pesos mensuales*. Obtenido de elsoldetoluca.com.mx: <https://www.elsoldetoluca.com.mx/local/concesion-de-la-basura-costara-al-gobierno-de-coacalco-9-millones-de-pesos-mensuales-7886358.html>

Wahyutama, A., & Hwang, M. (2022). YOLO-Based Object Detection for Separate Collection of Recyclables and Capacity Monitoring of Trash Bins. *Electronics MDPI*. Obtenido de <https://www.mdpi.com/2079-9292/11/9/1323>

Wua, Z., Zhan, D., Shao, Y., Zhang, X., Zhang, X., Feng, Y., & Cui, P. (2021). Using YOLOv5 for Garbage Classification. *Conference: 2021 4th International Conference on Pattern Recognition and Artificial Intelligence*, 35-38.

ww.24horas.cl. (5 de Diciembre de 2017). *Creadores: Proyecto Basurero inteligente*. Obtenido de ww.24horas.cl: <https://www.24horas.cl/creadores/creadores-proyecto-basurero-inteligente-2581512>

www.gob.mx. (10 de enero de 2017). *Clasificación, reciclaje y valoración de los RSU.*

Obtenido de www.gob.mx: <https://www.gob.mx/semarnat/acciones-y-programas/clasificacion-reciclaje-y-valoracion-de-los-rsu>

Yang, M., & Thung, G. (2016). *Classification of Trash for Recyclability Status.* Obtenido de semanticscholar.org: [https://www.semanticscholar.org/paper/Classification-of-Trash-for-Recyclability-Status-Thung-](https://www.semanticscholar.org/paper/Classification-of-Trash-for-Recyclability-Status-Thung-Yang/c90811082924011c73fea6252f42b01af9076f28#paper-topics)

[Yang/c90811082924011c73fea6252f42b01af9076f28#paper-topics](https://www.semanticscholar.org/paper/Classification-of-Trash-for-Recyclability-Status-Thung-Yang/c90811082924011c73fea6252f42b01af9076f28#paper-topics)

Ye, A., Pang, B., Jin, Y., & Cui, J. (2020). A YOLO-based Neural Network with VAE for Intelligent Garbage Detection and Classification. *ACAI '20: Proceedings of the 2020 3rd International Conference on Algorithms, Computing and Artificial Intelligence*, 1-7.

Zhang, Q., Zhang, X., Mu, X., Wang, Z., Tian, R., Wang, X., & Liu, X. (2021). Recyclable waste image recognition based on deep learning. *Resources, Conservation and Recycling*.