

Parámetros de caracterización en zonas urbanas para detectar residuos sólidos mediante visión artificial

Characterization parameters in urban areas to detect solid waste using artificial vision

Christian Zahir Díaz García



Diego Andrés Castellano Carvajal



Byron Medina Delgado



Sergio Alexander Castro Casadiego



Universidad Francisco de Paula Santander, Colombia

Carlos Vicente Niño Rondón



Pontificia Universidad Javeriana, Colombia

OPEN ACCESS

Recibido: 26/05/2023

Aceptado: 21/07/2023

Publicado: 27/10/2023

Correspondencia de autores:

christianzahirdiga@ufps.edu.co



Copyright 2020
by Investigación e
Innovación en Ingenierías

Resumen

Objetivo: Determinar las condiciones de adquisición de imágenes en zonas urbanas para detectar residuos sólidos mediante técnicas de visión artificial. **Metodología:** Se seleccionaron dos zonas urbanas, se definieron los parámetros de caracterización y se aplicaron las técnicas de segmentación por color y detectores en cascada, por último, se evaluó la eficiencia de las técnicas de detección de residuos aplicadas. **Resultados:** En los parámetros de caracterización para alturas de 1.5 m y 0.5 m, ángulos de inclinación de 60° y 20°, niveles de luminosidad entre 300 a 1800 Lux, se obtuvo la exactitud de la técnica de segmentación por color con valores del 71 % al 96 %, a su vez, la exactitud de la técnica de detector en cascada tuvo valores del 70 % al 96 %. **Conclusiones:** Se determinó que, tanto para el rendimiento de la técnica de segmentación por color como para la técnica de detector en cascada, el parámetro de caracterización que más afectó la eficiencia, es el ángulo de inclinación, obteniendo una exactitud promedio de 92.25 % y 94 % para un ángulo de 20°, mientras que, en un ángulo de 60° la exactitud promedio fue de 73 % y 76.75 %.

Palabras clave: Detector en cascada, parámetros de caracterización, residuos, segmentación por color, zonas urbanas.

Abstract

Objective: To determine the conditions for image acquisition in urban areas to detect solid waste using artificial vision techniques. **Methodology:** Two urban areas were selected, characterization parameters were defined and color segmentation and cascade detector techniques were applied. Finally, the efficiency of the applied residue detection techniques was evaluated. **Results:** In the characterization parameters for heights of 1.5 m and 0.5 m, inclination angles of 60° and 20°, brightness levels between 300 to 1800 Lux, the accuracy of the color segmentation technique was obtained with values from 71 % to 96 %, while the accuracy of the cascade detector technique had values from 70 % to 96 %. **Conclusions:** It was determined that, both for the performance of the color segmentation technique and for the cascade detector technique, the characterization parameter that most affected the efficiency is the tilt angle, obtaining an average accuracy of 92.25 % and 94 % for an angle of 20°, while, at an angle of 60° the average accuracy was 73 % and 76.75 %.

Keywords: Cascade detector, characterization parameters, Waste, color segmentation, urban areas.

Introducción

La visión artificial es un campo que se centra en el procesamiento de imágenes y videos utilizando técnicas de inteligencia computacional. Su objetivo es extraer información relevante de estos archivos visuales con el fin de facilitar la toma de decisiones. El campo de la visión artificial abarca una serie de procesos, tales como la adquisición de imágenes, el procesamiento, la detección de bordes, la segmentación, la extracción de características, el reconocimiento y la localización, y la interpretación [1]. La visión artificial es empleada regularmente en sectores de la industria e investigación, por causa de los elementos visuales presentes en sus aplicaciones tecnológicas [2].

El manejo inadecuado de los residuos es uno de los mayores problemas que atraviesa la sociedad a nivel mundial, debido al continuo crecimiento de la población, a su vez, el aumento de la producción de artículos de un solo uso, repercute directamente en la aceleración de los residuos generados [3]. Una de las formas de abordar el problema relacionado con los residuos son las herramientas de visión artificial, en el que la detección de objetos se ha transformado en uno de los campos de investigación y desarrollo más activos, en el cual, la detección de residuos hace parte de la aplicación de detección de objetos por medio de las herramientas de visión artificial, caracterizándose por emplear técnicas de procesamiento de imágenes, aprendizaje automático y aprendizaje profundo, utilizando equipos de cómputo con mayor capacidad para manejar volúmenes de datos que faciliten el entrenamiento de los clasificadores y detectores de objetos [4].

El desempeño de los sistemas de visión artificial está relacionado directamente con la calidad de la imagen, por lo que toman importancia factores claves en la adquisición de imágenes como lo son, la iluminación, la altura de la ubicación de la cámara y el ángulo de visión [5]. Por lo tanto, al aplicar esta tecnología en entornos no controlados, en donde las condiciones del lugar varían, resultan afectadas la perspectiva y la resolución de las imágenes, como también la calidad de estas, por lo que se hace propicio la presencia de fallas en el rendimiento de los sistemas de visión artificial [6].

En este artículo se propone la identificación de las condiciones de adquisición de imágenes en zonas urbanas para detectar residuos sólidos mediante visión artificial. Se emplean las técnicas de segmentación por color y detectores en cascada entrenados con conjuntos de imágenes propias, y se muestra la comparación de eficiencia de ambas técnicas con respecto a la exactitud, número de detecciones realizadas, falsos positivos y falsos negativos. La programación se realizó en lenguaje de programación Python, además, se emplearon librerías de acceso abierto de visión computacional, así como la herramienta Cascade Trainer GUI. Las pruebas se realizaron en la ciudad de Cúcuta, Colombia.

Metodología

La metodología está compuesta por cuatro etapas: la selección de las zonas urbanas, los parámetros de caracterización que evalúan las condiciones de adquisición de imágenes, aplicación de técnicas para la detección de residuos y la evaluación de las técnicas de detección de residuos.

Selección de zonas urbanas

Se seleccionaron dos zonas urbanas ubicadas alrededor del Canal Bogotá de la ciudad de Cúcuta, en relación a la generación de residuos en el área urbana de Cúcuta [7]. Para la selección, se realizó una revisión visual de las zonas con el fin de verificar la presencia de residuos en las zonas y analizar las características propias de las zonas. Además de esto, se llevó a cabo una consulta en mapas de la ciudad para el reconocimiento de las áreas con densidad poblacional, como también de zonas residenciales, domiciliarias e industriales, ya

que estos sectores tienen gran influencia en el origen de los residuos sólidos, lo que simboliza una buena muestra de los residuos presentes en el área urbana [8]. La descripción de las zonas seleccionadas, como su ubicación geográfica y características relevantes se presentan a continuación:

Zona 1:

a) Ubicación: Compreendida por el tramo del canal Bogotá que va desde el SENA (Servicio Nacional de Aprendizaje) hasta la Avenida Diagonal Santander.

b) Características: Esta zona se encuentra ubicada entre los barrios Merced y Lleras, la cual cuenta con una alta presencia de tránsito. Este ha sido un sitio en el que en ocasiones anteriores ya se ha presentado una problemática de basuras, evidenciando una disconformidad de la población con respecto a este tipo de situaciones [9].

Zona 2:

a) Ubicación: Compreendida por el tramo del canal Bogotá que va desde el centro comercial Unicentro hasta la urbanización La Ceiba.

b) Características: Esta zona se localiza en la zona sur de la ciudad y se caracteriza por tener zonas residenciales y comerciales. Dicha zona se ha visto afectada anteriormente por problemáticas relacionadas con el mal manejo de basuras y la contaminación que esto genera, en donde debido al alto nivel de presencia de residuos sólidos en este lugar, se considera como un sitio relevante [10].

Parámetros de caracterización

Los parámetros de caracterización que se utilizaron para determinar las condiciones de adquisición de imágenes en zonas urbanas son: la altura de la cámara, el ángulo de inclinación y el nivel de luminosidad en la zona donde se tomaron las imágenes [11].

a) Altura de la cámara: Las imágenes se tomaron en las zonas seleccionadas a alturas de 0.5 m y 1.5 m con respecto a la superficie del canal. Estas posiciones se definieron mediante el análisis de factores como, la perspectiva, una menor variabilidad en el tamaño de los residuos observados, y a su vez no perder detalles relevantes en el proceso de detección de residuos [12]. Para la adquisición de las imágenes, se emplearon dos dispositivos de captura de 12 MP f/1.6, OIS y 64 MP OIS f/1.9.

b) Ángulo de inclinación: La inclinación del ángulo del dispositivo de captura de imágenes fueron de 20° y 60°. Estos ángulos se establecieron teniendo en cuenta las características propias del área urbana, contemplando el cómo esto afecta la perspectiva de las imágenes, ajustando los ángulos para la obtención de una visión adecuada de los residuos, teniendo en cuenta también las propias restricciones del lente de la cámara que determinan el ángulo de visión en la captura de las imágenes [13].

c) Luminosidad: Para evaluar el nivel de luminosidad al momento de realizar la adquisición de imágenes se empleó un luxómetro digital, ya que, una buena iluminación facilita la extracción de los rasgos más relevantes de una imagen, incidiendo en la ejecución de los algoritmos de los sistemas de visión artificial [14].

Técnicas para la detección de residuos

En esta sección se detallan los fundamentos técnicos requeridos para la detección de residuos por medio de las técnicas de segmentación por color y detector en cascada.

- Segmentación por color: Este método de detección de residuos hace uso de la información de color, reduciendo la influencia de sombras y brillo en la imagen por medio de representaciones en el espacio de color HSV, umbralización y aplicación de operaciones morfológicas [15].

a) Espacio de color HSV: Para segmentar la imagen, se convirtió inicialmente de RGB (Red, Green y Blue, por sus siglas en inglés) al espacio de color HSV (Hue, Saturation y Value, por sus siglas en inglés), el cual está formado por los canales de: matiz, saturación y luminosidad. En este apartado se definieron los rangos de los colores específicos a detectar de los residuos, las conversiones de los componentes de color RGB al espacio de color HSV están presentadas por las ecuaciones 1, 2 y 3.

$$= \left\{ \begin{array}{l} 60 \cdot \frac{G-B}{\max(R,G,B) - \min(R,G,B)} + 0, \text{ donde } \max(R, G, B) = R \\ 60 \cdot \frac{B-R}{\max(R,G,B) - \min(R,G,B)} + 120, \text{ donde } \max(R, G, B) = G \\ 60 \cdot \frac{R-G}{\max(R,G,B) - \min(R,G,B)} + 240, \text{ donde } \max(R, G, B) = B \end{array} \right\} \quad (1)$$

$$S = \frac{\max(R,G,B) - \min(R,G,B)}{\max(R,G,B)} \quad (2)$$

$$V = \max(R, G, B) \quad (3)$$

El valor de H representa la tonalidad, está definido entre 0 y 360°, mientras que S indica la pureza del color y toma valores de 0 a 100 %. Por último, el valor V se refiere a la luminosidad del color, varía entre 0 % y 100 % (negro y blanco) [16]. En la Tabla 1 se muestra la configuración realizada de los colores con respecto a los parámetros en el espacio de color HSV.

Tabla 1. Configuración de los parámetros HSV.

Espacio de color	Componente (H,S,V)
Blanco inferior	0, 0, 200
Blanco superior	255, 45, 255
Azul inferior	100, 50, 50
Azul superior	270, 255, 255
Rojo inferior	0, 146, 110
Rojo superior	30, 217, 243

Fuente: Elaboración propia.

b) Umbralización: se aplicó la técnica de umbralización al espacio de color segmentado HSV para separar los píxeles correspondientes al residuo con respecto al fondo de la imagen, lo que permite binarizar la imagen a partir de un determinado umbral [17]. El valor del umbral establecido es de 35, asignando al segmento de imagen si es menor que el umbral el valor de píxel de 0, y en caso contrario el valor de píxel es 1.

c) Operaciones morfológicas: Se emplearon operaciones morfológicas para eliminar imperfecciones y mejorar la calidad de las imágenes binarizadas [18]. Las operaciones morfológicas empleadas son dilatación, erosión y cierre, y están definidas por las ecuaciones 4, 5 y 6 respectivamente. Se creó un elemento morfológico unitario de 5x5.

$$X \oplus Y = \{f | (\hat{Y})_f \cap X \neq \varphi\} \quad (4)$$

$$X \pm Y = \{f | (Y)_f \cap X \neq \varphi\} \quad (5)$$

$$X \cdot Y = (X(+Y)(-Y)) \quad (6)$$

- Detector en cascada: Consiste en combinar múltiples clasificadores débiles, donde estos son entrenados para detectar una característica en particular de los residuos que se desean detectar [19].

El conjunto de datos utilizado en el entrenamiento del detector en cascada está formado por imágenes en formato “jpg”, el cual está dividido en dos carpetas: una carpeta contiene la información de los residuos que se desean detectar (imágenes positivas) compuesta de 160 elementos, mientras que la segunda carpeta contiene 500 elementos que corresponden a la información que no se desea detectar (imágenes negativas) [20].

Para el entrenamiento del detector en cascada se hizo uso del software Cascade Trainer GUI, el cual solo está disponible para el sistema operativo Windows. En este software se cargó el conjunto de datos, y posteriormente se configuraron los parámetros de entrenamiento como el número de muestras positivas y negativas anteriormente especificado. A su vez, se definió como 15 el número de etapas y se establecieron las dimensiones de las imágenes como 48x70 píxeles [21]. En la figura 1 se presenta la estructura para la obtención del modelo de detección de residuos.

Figura 1. Estructura para la obtención del modelo de detección de residuos.



Fuente: Elaboración propia.

Evaluación de las técnicas de detección de residuos

Para la ejecución de las técnicas de detección de residuos se utilizó una computadora personal con procesador AMD Ryzen 5 con frecuencia de reloj de 2400 MHz y memoria RAM de 8 GB. Los algoritmos de las técnicas de detección de residuos fueron codificados a través del lenguaje de programación Python en la versión 3.11 en el sistema operativo Windows 10. Adicionalmente, se empleó el entorno de desarrollo integrado Visual Studio Code. Se emplearon las librerías OpenCV en la versión 4.7 y numpy en la versión 1.24.

La evaluación de los parámetros de caracterización (altura de la cámara, ángulo de inclinación y luminosidad de las zonas) se realizó mediante la comparación del rendimiento de las técnicas de segmentación por color y detector en cascada, evaluando aspectos como las detecciones realizadas, falsos positivos y falsos negativos con respecto a las condiciones de adquisición de imágenes. Con la obtención de estos datos se calculó la exactitud, la cual, en este caso se empleó para determinar la eficacia de cada técnica, determinando la proporción de predicciones que las técnicas detectaron exitosamente. La ecuación 8 se utiliza para calcular la exactitud [22, 23].

$$\text{Exactitud} = \frac{\text{Número de predicciones correctas}}{\text{Número total de predicciones}} \quad (8)$$

Resultados

En la aplicación de las técnicas de detección de residuos, se realizó la captura de imágenes en las dos zonas seleccionadas, en dicha acción se llevó a cabo la medición de la luminosidad por medio del luxómetro digital y se encontró que, en las imágenes capturadas en el horario de 10:00 a.m. a 11:30 a.m. el nivel de luminosidad varió entre 610 Lux a 1800 Lux, mientras que, en las imágenes capturadas en el horario de 4:00 p.m. a 5:30 p.m. el nivel de luminosidad varió entre 300 Lux a 500 Lux.

Luego de ejecutar los procesos de representación de la imagen en el espacio de color HSV, umbralización y la utilización de operaciones morfológicas, se puede visualizar el resultado de la aplicación de la técnica de segmentación por color en la Figura 2 bajo las condiciones de iluminación de: 300 a 500 Lux y 610 a 1800 Lux. En la sección (a) muestra el resultado de la aplicación de la técnica en la altura de 1.5 m y ángulo de inclinación de 60°, mientras que en (b) se aplicó en la altura de 1.5 m y ángulo de inclinación de 20°. En la sección (c) se presenta el resultado en la altura de 0.5 m y ángulo de inclinación de 60°. Asimismo en la sección (d) se muestra el resultado de la técnica en una altura de 0.5 m y ángulo de inclinación de 20°.

Figura 2. Detección de residuos mediante segmentación por color. (a) altura de 1.5 m y ángulo de inclinación de 60°. (b) altura de 1.5 m y ángulo de inclinación de 20°. (c) altura de 0.5 m y ángulo de inclinación de 60°. (d) altura de 0.5 m y ángulo de inclinación de 20°.

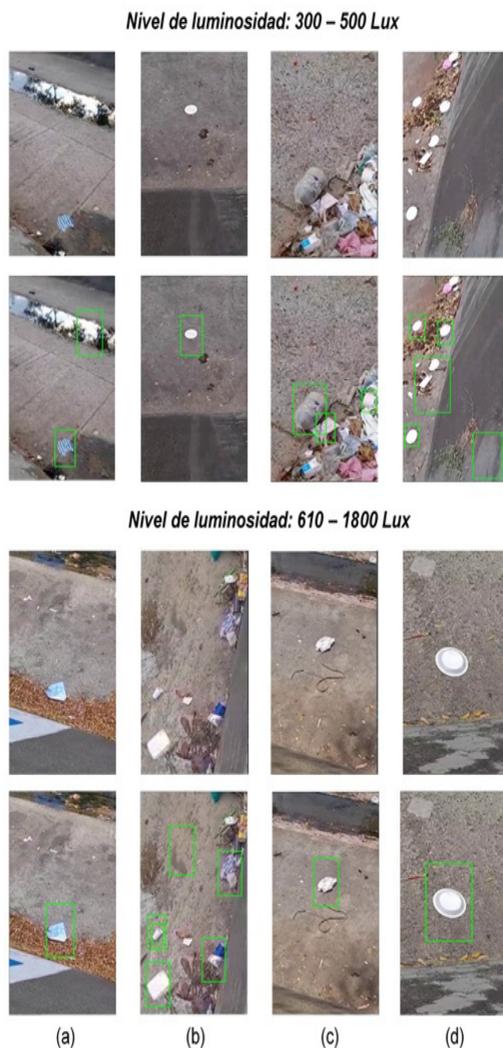


Fuente: Elaboración propia.

La detección de residuos por medio del detector en cascada obtenido a través de la herramienta Cascade Trainer GUI, se aplicó a las imágenes capturadas en las zonas urbanas bajo las condiciones de iluminación de: 300 a 500 Lux y 610 a 1800 Lux. En la Figura 3 se muestra el funcionamiento del detector de residuos en

cascada, en donde, en la sección (a) se observa el resultado de la aplicación de la técnica en la altura de 1.5 m y ángulo de inclinación de 60°, mientras que en (b) se aplicó en la altura de 1.5 m y ángulo de inclinación de 20°. En la sección (c) se presenta el resultado en la altura de 0.5 m y ángulo de inclinación de 60°. Asimismo en la sección (d) se muestra el resultado de la técnica en una altura de 0.5 m y ángulo de inclinación de 20°.

Figura 3. Detección de residuos por medio del detector en cascada. (a) altura de 1.5 m y ángulo de inclinación de 60°. (b) altura de 1.5 m y ángulo de inclinación de 20°. (c) altura de 0.5 m y ángulo de inclinación de 60°. (d) altura de 0.5 m y ángulo de inclinación de 20°.



Fuente: Elaboración propia.

En la Tabla 2, se comparan los resultados obtenidos de la técnica de segmentación por color. Esta comparación mediante las tablas permite evaluar la exactitud de las dos técnicas de detección de residuos utilizadas con respecto a los parámetros de caracterización evaluados.

Tabla 2. Comparación de los resultados obtenidos de la técnica de segmentación por color.

Comparativa de la técnica de segmentación por color							
Nivel de luminosidad	Altura	Ángulo de inclinación	Número real de residuos	Detecciones correctas	FP	FN	Exactitud
610 - 1800 Lux	0.5 m	60°	50	42	10	0	81%
610 - 1800 Lux	0.5 m	20°	50	48	3	1	92%
610 - 1800 Lux	1.5 m	60°	50	46	6	4	82%
610 - 1800 Lux	1.5 m	20°	50	49	3	2	91%
300 - 500 Lux	0.5 m	60°	50	42	12	5	71%
300 - 500 Lux	0.5 m	20°	50	49	1	1	96%
300 - 500 Lux	1.5 m	60°	50	44	10	6	73%
300 - 500 Lux	1.5 m	20°	50	46	1	4	90%

Fuente: Elaboración propia.

Asimismo, en la Tabla 3 se comparan los resultados obtenidos del detector de residuos en cascada, según el número de falsos positivos (FP) y falsos negativos (FN).

Tabla 3. Comparación de los resultados obtenidos de la técnica de detector en cascada.

Comparativa de la técnica de detector en cascada							
Nivel de luminosidad	Altura	Ángulo de inclinación	Número real de residuos	Detecciones correctas	FP	FN	Exactitud
610 - 1800 Lux	0.5 m	60°	50	36	1	14	71%
610 - 1800 Lux	0.5 m	20°	50	47	0	2	96%
610 - 1800 Lux	1.5 m	60°	50	38	0	10	79%
610 - 1800 Lux	1.5 m	20°	50	49	1	3	92%
300 - 500 Lux	0.5 m	60°	50	35	3	12	70%
300 - 500 Lux	0.5 m	20°	50	50	2	1	94%
300 - 500 Lux	1.5 m	60°	50	39	3	12	72%
300 - 500 Lux	1.5 m	20°	50	48	1	2	94%

Fuente: Elaboración propia.

El resultado con un valor mayor de exactitud de la técnica de segmentación por color, se presentó en los parámetros de caracterización correspondientes al nivel de luminosidad de 300 a 500 Lux, con la cámara ubicada a una altura de 0.5 m y ángulo de inclinación de 20°, en estas características se logró el resultado de mayor rendimiento con respecto a las otras condiciones de adquisición de imágenes. En estos parámetros se obtuvo un 96% de exactitud, en donde se realizaron 49 detecciones correctas de 50 posibles, con 1 falso positivo y 1 falso negativo. Mientras que, en las condiciones de caracterización correspondientes al nivel de luminosidad de 300 a 500 Lux, con la cámara ubicada a una altura de 0.5 m y ángulo de inclinación de 60°, se obtuvieron los resultados con el número de aciertos más bajo, ya que se logró una exactitud de 71 %, con 12 falsos positivos y 5 falsos negativos.

Respecto a la técnica de detector en cascada, la exactitud con mayor valor se logró en las condiciones de nivel de luminosidad de 610 a 1800 Lux, con la cámara ubicada en la altura de 0.5 m y ángulo de inclinación

de 20°. En estas condiciones se obtuvo un 96 % de exactitud con 2 falsos negativos y ningún falso positivo. Mientras que, la exactitud más baja se presentó a un nivel de luminosidad de 610 a 1800 Lux, con una altura de la cámara de 0.5 m y un ángulo de inclinación de 60°. En la cual, se logró una exactitud de 71 % con 14 falsos negativos y 1 falso positivo.

En términos generales, las dos técnicas de detección de residuos presentaron un mayor valor de exactitud al estar ubicada la cámara para la adquisición de imágenes en un ángulo de inclinación de 20°, en donde se obtuvo una exactitud promedio de 92.25 % en la técnica de segmentación por color y una exactitud promedio de 94 % en la técnica de detector en cascada. Por el contrario, con el ángulo de inclinación de 60° se encontraron los valores más bajos de exactitud, ya que, en la técnica de segmentación por color se obtuvo una exactitud promedio de 76.75 % y, en la técnica de detector en cascada la exactitud promedio obtenida es de 73 %.

Conclusiones

El parámetro de caracterización que más influyó en el rendimiento de las técnicas de detección de residuos fue el ángulo de inclinación, ya que, a un ángulo de 60° la exactitud promedio de las técnicas alcanzó el 73 % y 76.75 %, mientras que, para el ángulo de inclinación de 20°, la exactitud promedio aumentó a valores de 92.25 % y 94 %, correspondientes a las técnicas de segmentación por color y detector en cascada respectivamente.

Al aplicar etapas de procesamiento de imágenes (morfología matemática), se mitigaron los efectos generados por factores como variabilidad de forma y tamaño de los residuos sólidos, así como su diferenciación del fondo de la imagen y demás objetos presentes en el cuadro de la misma. Con esto, se eliminan las imperfecciones generadas por ruido, y se determina una región de interés, considerando información relevante de bordes, contorno y tamaños. Además, los objetos parcialmente visibles logran ser considerados posterior a la aplicación de las etapas de morfología.

Los datos obtenidos en la aplicación de la técnica de segmentación por color en comparación con el detector en cascada permitieron determinar la efectividad de esta técnica para la detección de residuos en zonas urbanas y la importancia del ajuste de los espacios del color en cuanto a las variaciones del nivel de luminosidad que se pueden presentar, influyendo de esta manera en el número de falsos positivos y falsos negativos de las detecciones realizadas.

Al emplear el sistema de detector en cascada con el conjunto de imágenes propio, se priorizaron factores como eficiencia computacional, ya que, al ser una técnica que no enfatiza en identificar residuos sólidos sino en eliminar de la consideración todos aquellos píxeles de imagen que no correspondan a dichos residuos, se reducen significativamente los recursos computacionales, así como un menor tiempo de entrenamiento, permitiendo iterar y ajustar el modelo de clasificador en cascada rápidamente. Además, de esta forma, se presenta un menor riesgo de sobreajuste y se mejora la generalización del modelo para detectar objetos nuevos.

Referencias

1. V. Alvear-Puertas, P. Rosero-Montalvo, D. Peluffo-Ordóñez, y J. Pijal-Rojas, "Internet de las Cosas y Visión Artificial, Funcionamiento y Aplicaciones: Revisión de Literatura", *Enfoque UTE*, vol. 8, núm. 1, pp. 244–256, 2017, DOI: <https://doi.org/10.29019/enfoqueute.v8n1.121>.
2. A. Ceballos-Arroyo, S. Robles-Serrano, y G. Sanchez-Torres, "Remoción de lluvia en imágenes por medio de una arquitectura de autoencoder", *Investigación e Innovación en Ingenierías*, vol. 8, núm. 1, pp. 140–167, mar. 2020, DOI: <https://doi.org/10.17081/invinno.8.1.3608>.
3. S. Majchrowska *et al.*, "Deep learning-based waste detection in natural and urban environments", *Waste Management*, vol. 138, pp. 274–284, feb. 2022, DOI: <https://doi.org/10.1016/j.wasman.2021.12.001>.
4. G. Rincón-Ramírez y C. F. Baquero-Barreto, "Método automático computacional para la detección de residuos sólidos en parques (Proyecto final de pregrado)", Universidad Católica de Colombia. Bogotá, Colombia, 2022.
5. E. S. Jeon *et al.*, "Human detection based on the generation of a background image by using a far-infrared light camera", *Sensors (Switzerland)*, vol. 15, núm. 3, pp. 6763–6788, mar. 2015, DOI: [10.3390/s150306763](https://doi.org/10.3390/s150306763).
6. I. Adjabi, A. Ouahabi, A. Benzaoui, y A. Taleb-Ahmed, "Past, present, and future of face recognition: A review", *Electronics (Basel)*, vol. 9, núm. 8, pp. 1–53, ago. 2020, DOI: <https://doi.org/10.3390/electronics9081188>.
7. R. Klinger, J. Olaya, L. Marmolejo, y C. Madera, "Plan de muestreo para la cuantificación de residuos sólidos residenciales generados en las zonas urbanas de ciudades de tamaño intermedio", *Revista Facultad de Ingeniería Universidad de Antioquia*, núm. 48, pp. 76–86, 2009.
8. T. M. Cárdenas-Ferrer, R. F. Santos-Herrero, A. M. Contreras-Moya, E. Rosa-Domínguez, y J. Domínguez-Núñez, "Propuesta Metodológica Para el Sistema de Gestión de los Residuos Sólidos Urbanos en Villa Clara", *Tecnología Química*, vol. 39, núm. 2, pp. 471–488, 2019.
9. Caracol Radio, "Habitantes piden solución al problema ambiental del canal Bogotá". <https://caracol.com.co/2023/06/21/damnificados-por-ola-invernal-de-2020-volvieron-a-protestar-frente-a-la-alcaldia-de-cucuta/> (consultado el 20 de junio de 2023).
10. cucuta.gov.co, "Remueven 4 toneladas de basuras del Canal Bogotá". <https://cucuta.gov.co/remueven-4-toneladas-de-basuras-del-canal-bogota/#:~:text=Cerca%20de%204%20toneladas%20de,Veolia%20Colombia%20y%20el%20Sena.> (consultado el 20 de junio de 2023).
11. G. Marchena Teodoro Alberto, C. Alva Fatima del Rocio, I. Ruiz Jhoselem Danuska, L. Escobedo Jorge Luis, R. Salirrosas Juleisy Arlette, y G. Terry Piero Jesús, "Detección del uso de mascarillas mediante Visión Artificial y Redes Neuronales frente al Covid-19", *INGnosis*, vol. 8, núm. 1, pp. 1–9, 2022, [En línea]. Disponible en: <https://orcid.org/0000-0002-0599-0141>
12. A. F. Quintana-Loaiza, D. A. Herrera-Manzano, y L. E. Salazar-Múnera, "Sistema de visión artificial para conteo de objetos en movimiento", *El Hombre y la Máquina*, núm. 40, pp. 87–101, 2012. Consultado: el 20 de junio de 2023. [En línea]. Disponible en: <http://hdl.handle.net/10906/79557>
13. R. A. Castillo, I. A. Díaz-López, y M. Huertas-León, "Localización espacial de un punto en XYZ mediante visión artificial", *Ciencia e Ingeniería Neogranadina*, vol. 16, núm. 1, pp. 15–27, 2006, DOI: <https://doi.org/10.18359/rcin.1243>.
14. J. Cáceres-Tello, "La visión artificial y las operaciones morfológicas en imágenes binarias", *Una Perspectiva de la Inteligencia Artificial en su 50 Aniversario*, vol. 2, pp. 570–575, 2006.

15. P. Gil, F. Torres, y F. G. Ortiz-Zamora, "Detección de objetos por segmentación multinivel combinada de espacios de color", 2004, Consultado: el 20 de junio de 2023. [En línea]. Disponible en: <http://hdl.handle.net/10045/2179>
16. N. Velázquez-López, Y. Sasaki, K. Nakano, J. MMejía-Muñoz, y E. Romanchik-Kriuchkova, "Detección de cenicilla en rosa usando procesamiento de imágenes por computadora", *Rev Chapingo Ser Hortic*, vol. 17, núm. 2, pp. 151–160, 2011, Consultado: el 19 de junio de 2023. [En línea]. Disponible en: <https://www.redalyc.org/articulo.oa?id=60920970007>
17. J. A. Cortés-Osorio, J. A. Chaves-Osorio, y J. A. Mendoza-Vargas, "Comparación cualitativa y cuantitativa de las técnicas básicas de umbralización local para el procesamiento digital de imágenes", *Scientia et Technica*, vol. 2, núm. 51, pp. 236–241, 2012, DOI: <https://doi.org/10.22517/23447214.7561>.
18. M. Elhoseny, "Multi-object Detection and Tracking (MODT) Machine Learning Model for Real-Time Video Surveillance Systems", *Circuits Syst Signal Process*, vol. 39, núm. 2, pp. 611–630, feb. 2020, DOI: <https://doi.org/10.1007/s00034-019-01234-7>.
19. M. V. Urgilez-Jaramillo, "Procesamiento digital de imágenes en detección de material contaminante inorgánico en orillas de lagunas (Tesis de maestría)", Escuela Superior Politécnica de Chimborazo. Riobamba, Ecuador, 2022.
20. M. A. Vivar-Olvera y E. Vásquez-Santacruz, "Desarrollo de un sistema basado en software para la identificación automática de especies marinas", *Ingeniantes*, núm. 1, pp. 1–10, 2022.
21. L. E. Chuquimarca-Jimenez, S. Pinzón-Tituana, y A. Rosales-Pincay, "Detección de mascarilla para COVID-19 a través de Aprendizaje Profundo usando OpenCV y Cascade Trainer GUI", *Revista Científica y Tecnológica UPSE*, vol. 8, núm. 1, pp. 68–73, jun. 2021, DOI: <https://doi.org/10.26423/rctu.v8i1.572>.
22. C. A. Ruíz Ramírez, D. M. Montoya Quintero, y J. A. Jimenez Builes, "Un Ambiente visual integrado de desarrollo para el aprendizaje de programación en robótica", *Investigación e Innovación en Ingenierías*, vol. 9, n.º 1, pp. 7–21, 2021. DOI: <https://doi.org/10.17081/invinno.9.1.3957>
23. Y. Kulkarni, S. Bodkhe, A. Kamthe, y A. Patil, "Automatic number plate recognition for motorcyclists riding without helmet", en *International Conference on Current Trends towards Converging Technologies*, IEEE, 2018, pp. 1–6. DOI: 10.1109/ICCTCT.2018.8551001.