





# Efecto de la Variabilidad lumínica en Detectores de Características Visuales

## *Effect of Light Variability on Visual Feature Detectors*

-  **Jorge Eduardo Sánchez-Trejo** es estudiante de posgrado de la Universidad Autónoma de Querétaro (México) ([jsanchez142@alumnos.uaq.mx](mailto:jsanchez142@alumnos.uaq.mx)), (<https://orcid.org/0009-0008-4814-2880>), Licenciado.
-  **Jorge Luis Pérez-Ramos** es profesor investigador de la Facultad de Informática de la Universidad Autónoma de Querétaro (México) ([jorge.luis.perez@uaq.mx](mailto:jorge.luis.perez@uaq.mx)), (<https://orcid.org/0000-0002-0444-9230>), Doctor.
-  **Daniel Cantón-Enríquez** es profesor investigador de la Facultad de Informática de la Universidad Autónoma de Querétaro (México) ([daniel.canton@uaq.mx](mailto:daniel.canton@uaq.mx)), (<https://orcid.org/0000-0002-6543-5078>), Maestro.
-  **Hugo Jiménez-Hernández** es profesor investigador de la Facultad de Informática de la Universidad Autónoma de Querétaro (México) ([hugo.jimenez@uaq.mx](mailto:hugo.jimenez@uaq.mx)), (<https://orcid.org/0000-0003-0827-6645>), Doctor.

**Resumen:** El uso de descriptores de características visuales en imágenes es una tarea fundamental en el contexto del uso de tecnologías 4.0, siendo crucial para procesos que involucran automatización, modelado y control de procesos. Sin embargo, las variaciones en las condiciones de iluminación afectan significativamente el rendimiento de estos algoritmos. En este estudio, se evaluaron imágenes sintéticas bajo diversas condiciones de iluminación y temperatura de color, comparando cuatro algoritmos ampliamente reconocidos para la detección de bordes: Sobel, Prewitt, Canny y Roberts. Se analizaron la precisión en la detección de bordes, la robustez ante variaciones lumínicas, y el tiempo de procesamiento de cada método. Los resultados muestran que el algoritmo Canny ofrece la mayor precisión y robustez frente a cambios en la iluminación, aunque con un costo computacional elevado. Por su parte, Sobel y Prewitt se destacan como alternativas balanceadas, proporcionando una buena detección de bordes con un consumo de recursos moderado. Finalmente, el método Roberts, aunque menos preciso y robusto, es el más eficiente en términos de velocidad, lo que lo convierte en una opción viable para sistemas embebidos con recursos limitados. Este trabajo sugiere la aplicación de cada algoritmo en función de los requerimientos específicos de precisión, robustez y disponibilidad de recursos computacionales.

**Palabras clave:** Detección de Características, Detección de Bordes, Características Locales, Procesamiento de Imágenes, Visión por Computadora.

**Cómo citar:** Sánchez-Trejo, J.E., Pérez-Ramos, J.L., Cantón-Enríquez, D., y Jiménez-Hernández, H. (2024). Efecto de la Variabilidad lumínica en Detectores de Características Visuales. *Tecnología, Ciencia y Estudios Organizacionales*, 6(12), pp. 94-105. <https://doi.org/10.56913/teceo.6.12.94-105>

Recepción: 24-09-2024  
Aprobación: 23-10-2024

**Abstract:** The use of visual feature descriptors in images is a fundamental task in the context of the use of 4.0 technologies, being crucial for processes involving automation, modeling and process control. However, variations in lighting conditions significantly affect the performance of these algorithms. In this study, synthetic images were evaluated under various lighting and color temperature conditions, comparing four widely recognized algorithms for edge detection: Sobel, Prewitt, Canny and Roberts. The accuracy in edge detection, robustness to lighting variations, and processing time of each method were analyzed. The results show that the Canny algorithm offers the highest accuracy and robustness to changes in lighting, although with a high computational cost. Meanwhile, Sobel and Prewitt stand out as balanced alternatives, providing good edge detection with moderate resource consumption. Finally, the Roberts method, although less accurate and robust, is the most efficient in terms of speed, making it a viable option for embedded systems with limited resources. This work suggests the application of each algorithm based on the specific requirements of accuracy, robustness and availability of computational resources.

**Keywords:** Feature Detection, Edge Detection, Local Features, Image Processing, Computer Vision.

## Introducción

En visión por computadora, una de las áreas más importantes de trabajo en recientes años ha sido la detección de características visuales en imágenes, siendo una herramienta primordial en procesos de seguimiento de objetos (Beard, et al., 2020), reconocimiento de imágenes (Sharma & Mishra, 2018), reconstrucción de escenarios (Liu & Lam, 2018), SLAM (Aulinas et al., 2008), reconocimiento de patrones (Beyerer et al., 2024), entre otras tareas. En este sentido, se entiende que una característica en imágenes hace referencia a una estructura con características específicas que pueden ser identificadas en una imagen. Esta teoría permite a las computadoras poder identificar características específicas en imágenes, lo que facilita el análisis y entendimiento de la información que una imagen puede llegar a proporcionar.

Las características en las imágenes se pueden clasificar en dos tipos principales: características globales y características locales. Las características globales describen una imagen completa mediante un vector característico, lo que permite comparar diferentes imágenes. En contraste, las características locales se definen como un conjunto de propiedades presentes en regiones específicas de la imagen. Los resultados de los detectores de características locales suelen ser localizaciones en la imagen que corresponden a puntos clave, denominados puntos característicos. A su vez, los detectores de características locales se subdividen en dos categorías: detectores y descriptores de características. Los detectores se centran en identificar un conjunto estable de características (conjunto invariante) en puntos o regiones de interés. Por otro lado, los descriptores de características codifican la información visual (como textura, orientación, etc.) en un vector numérico característico, el cual está asociado a la disposición de los píxeles alrededor de un punto de interés o una región particular de análisis.

Los métodos convencionales de detección y descripción de características tienden a fallar cuando se enfrentan a transformaciones y distorsiones como escalado, rotación, compresión, ruido y cambios en la iluminación, denominados generalmente como distorsiones o transformaciones.

Los algoritmos de detección de características son de gran relevancia en el campo de las tecnologías 4.0, siendo aplicados como filtros permitiendo la reducción de los datos necesarios para procesar una imagen y detectar las propiedades estructurales más importantes. Por otro lado, es evidente que las tecnologías 4.0 como la visión por computadora, procesamientos de imágenes

y la robótica, permite la detección de defectos en productos manufacturados o evaluar la calidad de una línea de producción.

Este trabajo se centra en generar una comparativa entre descriptores bien conocidos del estado del arte, comparando el efecto del cambio lumínico de un foco inteligente variando la intensidad luminosa y viendo el efecto en las técnicas en las extracciones de características en una imagen con condiciones controladas.

### Trabajos relacionados con técnicas de extracción de características

En la literatura existen gran variedad de técnicas para extraer características en el procesamiento de imágenes, numerosos autores clasifican estas técnicas en grupos basados en el enfoque en el que extraen esta información, estas se mencionan a continuación:

1. **Técnicas basadas en puntos aislados:** Este enfoque permite analizar mediante un histograma la frecuencia de presencia de diferentes colores en una imagen, esta distribución de colores se puede analizar bajo diferentes espacios de color, siendo los más usuales el RGB, HSV o el modelo CIELAB (Busin et al., 2008; Kwok et al., 2009).
2. **Técnicas basadas en bordes:** Es de los principales enfoques que permiten detectar bordes mediante filtros o gradientes evaluando la direccionalidad y/o magnitud en el cambio de intensidades en la imagen. Algunos métodos se basan en filtros que detectan áreas de intensidad que presentan cambios abruptos permitiendo detectar la orientación de un borde en específico. En este grupo podemos encontrar técnicas bien conocidas en la literatura como: Sobel (Mathur et al., 2016), Prewitt (Rahmawati et al., 2021), y Canny (Xuan & Hong, 2017), como los más representativos.
3. **Técnicas basadas en texturas:** En este enfoque podemos encontrar el análisis por medio de Matriz de co-ocurrencia en niveles de grises (GLCM, por sus siglas en inglés) definida un histograma en forma matricial, donde cada valor de gris es asociado a un valor de ocurrencia en una vecindad definida separados una distancia  $d$  y con un ángulo  $\phi$  (Ríos-Díaz et al., 2009). Al analizar ventanas pequeñas en diferentes direcciones angulares pueden describir ciertas propiedades o patrones presentes en las imágenes.
4. **Técnicas basadas en formas:** En este enfoque está orientado a la identificación y análisis de contornos y Figuras geométricas. Para ello, se emplean algoritmos como la Transformada de Hough, la cual permite detectar líneas, círculos y formas geométricas. El funcionamiento de este método se basa en la conversión de los píxeles de la imagen en un espacio paramétrico donde los píxeles alineados en una forma específica (por ejemplo, una línea o un círculo) generan intersecciones en ese espacio lo que permite detectar formas geométricas. La evolución reciente de estos métodos ha integrado enfoques de aprendizaje profundo que refinan la detección de formas con mayor precisión, mejorando aplicaciones en reconocimiento de objetos y análisis estructural en imágenes complejas (Xu et al., 2022).
5. **Técnicas basadas en patrones:** El análisis de patrones busca identificar configuraciones repetitivas en las imágenes, como texturas, colores o formas. Su funcionamiento se basa en uso de capas convolucionales que aplican filtros a la imagen para extraer características locales. Conforme la imagen va atravesando las diferentes capas, se identifican patrones más complejos. Este tipo de técnicas ha demostrado ser altamente efectivo en la

clasificación y segmentación de imágenes, especialmente en conjuntos de datos grandes (LeCun et al., 2015).

6. **Técnicas basadas en regiones:** Dentro de este enfoque se segmenta la imagen en regiones homogéneas basadas en características como el color y textura. Algoritmos como el Mask R-CNN permiten la segmentación precisa de regiones en objetos, y la detección de objetos en tiempo real. Estas técnicas son ampliamente utilizadas en el área de visión por computadora y en la segmentación semántica en imágenes médicas, al igual que en la identificación de múltiples objetos en escenas complejas (He et al., 2020).
7. **Técnicas basadas en Deep Learning (DL):** El Deep Learning ha transformado la manera que se extraen características de las imágenes. Las Redes Neuronales (CNN), gracias a su capacidad de aprender patrones a través de las múltiples capas convolucionales, extraen características cada vez más abstractas y complejas. Esto las convierte en una herramienta poderosa para la clasificación de imágenes, la detección de objetos y la segmentación precisa (He et al., 2016). U-Net, por su parte, ha sido fundamental en tareas de segmentación médica, donde la precisión en la detección de bordes y regiones es crítica (Ronneberger et al., 2015).

A continuación, en la Tabla 1 se resume las principales técnicas de extracción de características mencionadas en los trabajos relacionados. Cada técnica se clasifica según el enfoque y la ecuación asociada. Se tiene una visión general de las técnicas representativas, logrando una comparación sencilla, pero destacando sus principales características y la ecuación que la describe.

**Tabla 1**

*Técnicas basadas en diferentes enfoques de detección de características en imágenes.*

Técnica	Enfoque	Ecuación
Puntos aislados	Histograma de colores en la imagen y análisis de espacios de color. Donde $H(i)$ es el histograma de color y $C(p)$ la cantidad de píxeles del color	$H(i) = \sum_{p=0}^n C(p)$
Bordes	Detección de cambios abruptos de intensidad en la imagen. Donde $G_x$ y $G_y$ son las derivadas de los ejes X y Y	$G = \sqrt{(G_x^2 + G_y^2)}$
Texturas	Análisis de patrones repetitivos en la imagen, con análisis de transformada de Fourier o de Wavelet	$f(x) = \sum_k c_{j_0}(k) \phi_{j_0,k} + \sum_{j=j_0}^{\infty} \sum_k d_j(k) \psi_{j,k}(x)$
Formas	Detección de formas geométricas (líneas, círculos, elipse, etc.) en la imagen	$(x - a)^2 + (y - b)^2 = r^2$ (ecuación de la circunferencia)
Patrones	Identificación de configuraciones repetitivas	$f(x) = w \cdot x + b$ (capa convolucional)
Regiones o áreas	Segmentación de regiones homogéneas según las características	$L(x) = \sum region(x)$
Deep Learning (DL)	Extracción automática de características complejas a través de redes neuronales	$f(x) = \sigma(W \cdot x + b)$ (activación de neurona en una CNN)

## Transformaciones críticas en el procesamiento de imágenes digitales

Es crucial entender la amplia gama y naturaleza de las variables que pueden influir en la calidad y los resultados de las técnicas utilizadas para extraer características en el procesamiento de imágenes. A continuación, se detallan las variables más relevantes que pueden afectar estos procesos y que deben ser consideradas, desde las de tipo geométrico y algunas otras que dependen de factores externos referentes a la cámara con la que se capturas las imágenes como apertura de la lente, entre otras. En la Tabla 2 se resumen tanto como las más importantes consideradas en la literatura y las invarianzas dependiendo del algoritmo aplicado.

**Tabla 2**

*Comparación de variables y transformaciones a los que son invariantes las principales técnicas de detección de características en imágenes.*

Técnica	Aplicación	Variables									
		R e f l e x i ó n	E s c a l a	R o t a c i ó n	I l u m i n a c i ó n	R u i d o	T r a s l a c i ó n	R e s o l u c i ó n	P e r s p e c t i v a	C o l o r	T e x t u r a
Harris	Detección de esquinas	■	■	■	*	■	■	*	*	*	*
Roberts	Detección de bordes	*	*	*	*	*	■	*	*	*	*
Prewitt	Detección de bordes	*	*	*	*	*	■	*	*	*	*
Sobel	Detección de bordes	*	*	*	*	*	■	*	*	*	*
SIFT	Detección y descripción de características locales	■	■	■	*	■	■	■	*	*	*
SURF	Detección y descripción de características locales	■	■	■	*	■	■	■	*	*	*
Canny	Detección de bordes	*	*	*	*	■	■	*	*	*	*
GLMC	Análisis de textura	*	*	*	*	■	■	*	*	*	■
LBP	Análisis de textura mediante patrones	*	*	*	*	■	■	*	*	*	■
Transformada de Hough	Detección de formas ruidosas o incompletas en la imagen.	■	■	■	*	*	■	*	■	*	*

*Nota. ■ La técnica es invariante; \* caso contrario.*

En la Tabla 2 se observa de forma general las transformaciones comunes encontradas en el procesamiento de imágenes a las que son invariantes algunas técnicas encontradas en la literatura. Este análisis permitirá observar las brechas de los métodos a analizar y comparar el efecto de variables específicas en sus resultados.

El análisis destaca las limitaciones y fortalezas de cada uno de los métodos, considerando variables como la reflexión, la escala y, especialmente, la iluminación, lo que permite identificar brechas entre ellos. A partir de estos resultados, se evidencia que los algoritmos responden de manera diversa ante las distintas condiciones de la imagen, lo que puede afectar significativamente su

desempeño en aplicaciones reales. En este trabajo, se centra en los algoritmos clásicos de detección de bordes, como Sobel, Prewitt, Roberts y Canny, responden ante variaciones en la iluminación, evaluando su robustez bajo distintas condiciones lumínicas.

### Método

En esta investigación, aunque se reconoce la importancia de las diversas variables como la reflexión, la escala y la rotación, el enfoque experimental se centrará en la variación de iluminación y temperatura de color configurable en un foco inteligente. Se evaluarán los cambios en las condiciones lumínicas, tales como la intensidad y la presencia de sombras, que afectan el rendimiento de los algoritmos clásicos de detección de bordes, como Sobel, Prewitt, Roberts y Canny.


Si bien las como la rotación y el ruido aleatorio pueden influir en los resultados de ese estudio, se busca ofrecer un análisis profundo del efecto de la iluminación, dejando abiertas futuras investigaciones para explorar el impacto de estas, y otras variables. Se realizará la experimentación, en un espacio controlado, el cual se someterá a N transformaciones, para poner a prueba y comparar la robustez de los métodos seleccionados. Para la parte experimental se utilizará un foco comercial de la marca Steren, modelo Shome-120, el cual es un foco LED RGB, con una intensidad de hasta 800 lúmenes y un consumo de energía de 10 W. Este foco tiene la particularidad de poder ajustar la intensidad de la luz desde su aplicación.

### Proceso experimental

Se experimentará con diferentes cambios lumínicos desde el 1, 30, 60 y 100% de iluminación que ofrece un foco inteligente convencional, siendo estos incrementos donde se apreciaba de forma visual una variación en la adquisición de la imagen, estas pruebas también se extenderán con diferentes temperaturas del color, se entiende como las distintas tonalidades que un foco de luz pueda tener, se mide en grados Kelvin y se clasifica en 3 grupos principales: Luz Cálida o Blanco Cálido (2200-3200 K), luz de día (3200-5200 K) y luz Fría (5200-6500 K).

La implementación de los algoritmos de detección de bordes de Canny, Prewitt, Sobel y Roberts se realiza en el lenguaje de programación Python, esto permite hacer experimentación para diferentes imágenes. Es escenario elegido consiste en un cubo de Rubik (ver Figura 1) en fondo negro evitando que sombras generen falsos positivos orientando la cantidad de características detectadas por un algoritmo sensible a estos fondos.

**Figura 1.** Imágenes analizadas en (a) RGB y (b) escala de grises.



## Resultados

En este estudio, se evalúa el desempeño de cuatro métodos ampliamente reconocidos en la literatura para la detección de bordes en imágenes artificiales de tamaño de  $1280 \times 720$  px, considerando diferentes condiciones de iluminación y temperatura de color. En la tabla 3 observamos que el algoritmo de Canny mostró una mayor robustez frente a cambios de temperatura y cambios de iluminación, por mucho comparado con las demás técnicas, detectando una cantidad mayor de características.

Por otro lado, mientras que Sobel y Prewitt demostraron obtener menor número de características presentaron una mejor sensibilidad a variaciones en la iluminación. Además, encontramos evidencia suficiente para demostrar que el algoritmo de Roberts tiene una baja precisión significativa, ante el cambio de las dos variables.

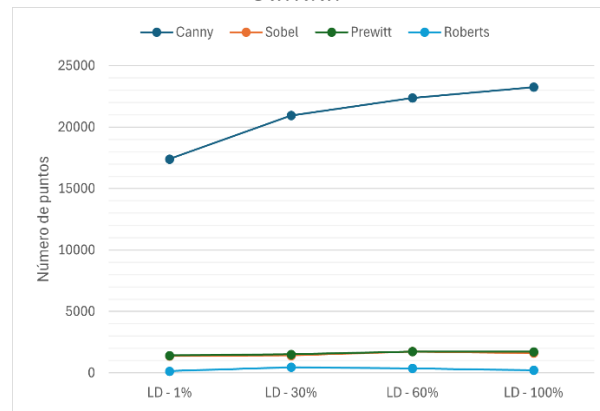
**Tabla 3**

*Características detectadas por cada una de las técnicas variando la temperatura del color.*


Temperatura del color	Iluminación	Técnicas			
		Canny	Sobel	Prewitt	Roberts
Luz Cálida (2200-3200 K)	1%	17,321	1,330	1,375	314
	30%	20,252	1,802	1,554	96
	60%	20,992	1,731	1,604	95
	100%	21,603	1,202	1,112	565
Luz de día (3200-5200 K)	1%	17,405	1,375	1,426	144
	30%	20,942	1,417	1,505	466
	60%	22,370	1,741	1,745	374
	100%	23,257	1,623	1,726	221
Luz Fría (5200-6500 K)	1%	16,139	1,357	1,337	52
	30%	20,272	1,159	1,146	502
	60%	20,722	1,640	1,623	55
	100%	21,481	1,652	1,726	162

En la Figura 2 se observa de forma gráfica el impacto de la variabilidad del porcentaje de brillo ofrecida por la fuente de luz en 4 niveles, 1, 30, 60 y 100%, obteniendo en todos los casos un mayor número de características conforme el brillo aumenta. También, se observa la variabilidad en los experimentos en los tres niveles de temperatura de color sin detectar evidencia suficiente para considerar un impacto notable en los cuatro algoritmos.


**Figura 2.** Gráficos comparando los pixeles que describen características por cada una de las técnicas ante cambios lumínicos y temperatura de color; (a) Luz de día, (b) Luz fría y (c) Luz Cálida.



(a)



(b)



(c)

*Nota: LD, LF y LC; Luz de día, Luz fría y Luz Cálida respectivamente.*

Por último, en la Tabla 4, presentamos los resultados de forma visual de los resultados de la detección de bordes generada al aplicar el algoritmo de Canny en su versión básica, al variar la temperatura de color y el porcentaje de brillo.

Se observa buena estabilidad y robustez en la detección de los bordes describiendo fielmente el objeto sin pérdidas significativas, reduciendo la necesidad de aplicarle algún filtro en el preprocesamiento. Estos resultados sugieren que la elección de la técnica de detección de bordes debe considerar cuidadosamente las condiciones ambientales en las que se aplicará.

**Tabla 4**

*El algoritmo de Canny aplicando con diferentes condiciones de brillo y temperatura de color.*

		Temperatura de color					
		Luz Cálida (2200-3200 K)		Luz de día (3200-5200 K)		Luz Fría (5200-6500 K)	
Nivel de brillo	1%						
	30%						
	60%						
	100%						

### Discusión

Los resultados obtenidos demuestran el efecto de la variación de condiciones lumínicas y temperatura de color en los cuatro algoritmos estudiados. En un primer punto se destaca la eficiencia de algoritmo de Canny contra las otras técnicas, encontrado gran número de características que conforman los bordes aun con la presencia de variabilidades. Muy por debajo de este se encuentra en un mismo nivel comparativo el algoritmo de Sobel y Prewitt detectando un numero satisfactorio de características permitiendo definir las formas generales de la estructura del objeto estudiado.

Como se describe en la literatura al aplicar filtros de suavizado Gaussianos se puede mejorar la robustez del algoritmo de Canny ante presencia de ruido. En cambio, Sobel y Prewitt muestran una sensibilidad considerable a los gradientes o zonas en la imagen que cuentan con reflejos producidos por la incidencia de la luz en ciertos ángulos.

Por otro lado, el algoritmo de Roberts, resulta el menos eficiente de los cuatro, detectando el menor número de características para definir bordes, no obstante, es el algoritmo más simple de los cuatro, con una menor complejidad computacional obteniendo buenos resultados en la velocidad de cómputo. Este será una buena opción en aplicaciones donde se necesita simplicidad de características y es necesario velocidad de cómputo. En el contexto de aplicaciones prácticas, Canny ofrece el proceso más robusto para ser aplicado en detección de bordes donde es necesaria la precisión, como en imágenes médicas, robótica, etc. Si es necesario un equilibrio entre precisión y requerimientos de recursos considerables Sobel y Prewitt es la mejor opción por su simplicidad. Finalmente, en aplicaciones donde la calidad de detección no sea una prioridad, pero si se cuenta con recursos mínimos para procesamiento Roberts sería la elección más adecuada.

Existen ciertas limitaciones en la comparativa, hay que en un escenario real existen condiciones de luz que no pueden ser controlada impactando de mayor forma en los descriptores, además de ser un número mayor de ellas.

### Conclusiones

Este trabajo muestra un proceso experimental donde se logra demostrar los efectos de dos variables a considerar en cualquier procesamiento de imágenes que tiene fuentes de iluminación artificial, variando el porcentaje de brillo de incidencia y la temperatura del color incidente en objetos. Bajo este contexto, si se desea una detección robusta y precisa de bordes en aplicaciones detalladas se recomienda el uso del algoritmo de Canny con una etapa de filtrado Gaussiano en el proceso previo, esto genera mayor necesidad de recursos computacionales a costa de la robustez.

La elección equilibrada de precisión y cómputo sería aplicar el algoritmo de Sobel y Prewitt. Por último, Roberts demuestra ser el algoritmo menos robusto y preciso sin embargo demuestra ser la opción más óptima en implementaciones con recursos limitados de cómputo, o necesidad de velocidad de procesamiento.

### Trabajos futuros

En futuros trabajos, se puede considerar extender el análisis del efecto de más transformaciones, ruido y variables, para hacer más robusta la comparativa, así como meter mejoras de los algoritmos base y metodologías híbridas, y así poder actualizar la comparativa y efectos en los resultados de cada uno de los descriptores. Incluso extender el análisis y someterlo a pruebas de correlaciones entre variables.

### Referencias

- Aulinas, J., Petillot, Y., Salvi, J., & Lladó, X. (2008). The SLAM problem: a survey. *Artificial Intelligence Research and Development*, 363-371.
- Beard, M., Vo, B. T., & Vo, B. N. (2020). A solution for large-scale multi-object tracking. *IEEE Transactions on Signal Processing*, 68, 2754-2769.

- Beyerer, J., Hagmanns, R., & Stadler, D. (2024). *Pattern recognition: Introduction, features, classifiers and principles*. Walter de Gruyter GmbH & Co KG.
- Busin, L., Vandenbroucke, N., & Macaire, L. (2008). Color spaces and image segmentation. *Advances in Imaging and Electron Physics*, 151(1), 1.
- Fan, H., Lin, L., Yang, F., Chu, P., Deng, G., Yu, S., ... & Ling, H. (2019). Lasot: A high-quality benchmark for large-scale single object tracking. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 5374-5383).
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2020). Mask R-CNN for object detection and instance segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 386-397.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770-778.
- Kwok, N. M., Ha, Q. P., & Fang, G. (2009, October). Effect of color space on color image segmentation. In *2009 2nd International Congress on Image and Signal Processing* (pp. 1-5). IEEE.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Liu, P. Y., & Lam, E. Y. (2018). Image reconstruction using deep learning. *arXiv preprint arXiv:1809.10410*.
- Mathur, N., Mathur, S., & Mathur, D. (2016). A novel approach to improve sobel edge detector. *Procedia Computer Science*, 93, 431-438.
- Rahmawati, S., Devita, R., Zain, R. H., Rianti, E., Lubis, N., & Wanto, A. (2021, June). Prewitt and canny methods on inversion image edge detection: an evaluation. In *Journal of Physics: Conference Series* (Vol. 1933, No. 1, p. 012039). IOP Publishing.
- Ríos-Díaz, J., Martínez-Payá, J. J., & del Baño Aledo, M. E. (2009). El análisis textural mediante las matrices de co-ocurrencia (GLCM) sobre imagen ecográfica del tendón rotuliano es de utilidad para la detección cambios histológicos tras un entrenamiento con plataforma de vibración. *Cultura, Ciencia y Deporte*, 91-102.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 234-241.
- Sharma, N., Jain, V., & Mishra, A. (2018). An analysis of convolutional neural networks for image classification. *Procedia Computer Science*, 132, 377-384.

- Xuan, L., & Hong, Z. (2017, November). An improved canny edge detection algorithm. In *2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS)* (pp. 275-278). IEEE.
- Xu, Z., Liu, H., & Shi, Y. (2022). Shape detection with advanced Hough transform and deep learning. *Journal of Visual Communication and Image Representation*, 85, 102472.