

# Object Recognition Through Artificial Intelligence Techniques

José-Luis Ramírez-Arias; Astrid Rubiano-Fonseca; Robinson Jiménez-Moreno

**Citación:** J.-L. Ramírez-Arias, A. Rubiano-Fonseca, and R. Jiménez-Moreno, “Object Recognition Through Artificial Intelligence Techniques,” *Revista Facultad de Ingeniería*, vol. 29 (54), e10734, 2020.

<https://doi.org/10.19053/01211129.v29.n54.2020.10734>

**Recibido:** Febrero 18, 2020; **Aceptado:** Marzo 24, 2020;

**Publicado:** Abril 10, 2020

**Derechos de reproducción:** Este es un artículo en acceso abierto distribuido bajo la licencia [CC BY](#)



**Conflicto de intereses:** Los autores declaran no tener conflicto de intereses.

# Object Recognition Through Artificial Intelligence Techniques

José-Luis Ramírez-Arias<sup>1</sup>

Astrid Rubiano-Fonseca<sup>2</sup>

Robinson Jiménez-Moreno<sup>3</sup>

## Abstract

This paper describes a methodology for object recognition categorized as polyhedron and non-polyhedron. This recognition is achieved through digital image processing combined with artificial intelligence algorithms, such as Hopfield networks. The procedure consists of processing images in search of patterns to train the system. The process is carried out through three stages: i) Segmentation, ii) Smart recognition, and iii) Feature extraction; as a result, images of objects are obtained and trained in the designed neuronal network. Finally, Hopfield's network is used to establish the object type as soon as it receives one. The proposed methodology was evaluated in a real environment with a considerable number of detected images; the noisy images recognition uncertainty was 2.6%, an acceptable result considering variable light, shape and color. The results obtained from this experiment show a high recognition level, which represents 97.4%. Out of this procedure, we can assume that it is possible to train new patterns, and it is expected that the model will be able to recognize them. Potentially, the proposed methodology could be used in a vast range of applications, such as object identification in industrial environments, grasping objects using manipulators or robotic arms, tools for blind patients, among other applications.

---

<sup>1</sup> Ph. D. Universidad Militar Nueva Granada (Cajicá-Cundinamarca, Colombia). [jose.ramirez@unimilitar.edu.co](mailto:jose.ramirez@unimilitar.edu.co). ORCID: [0000-0002-7126-5378](https://orcid.org/0000-0002-7126-5378).

<sup>2</sup> Ph. D. Universidad Militar Nueva Granada (Cajicá-Cundinamarca, Colombia). [astrid.rubiano@unimilitar.edu.co](mailto:astrid.rubiano@unimilitar.edu.co). ORCID: [0000-0002-8894-7121](https://orcid.org/0000-0002-8894-7121).

<sup>3</sup> Ph. D. Universidad Militar Nueva Granada (Cajicá-Cundinamarca, Colombia). [robinson.jimenez@unimilitar.edu.co](mailto:robinson.jimenez@unimilitar.edu.co). ORCID: [0000-0002-4812-3734](https://orcid.org/0000-0002-4812-3734).

**Keywords:** Hopfield network; morphologic operations; neuronal networks; objects recognition as of 2D images.

## **Reconocimiento de objetos a través de técnicas de inteligencia artificial**

### **Resumen**

En el presente artículo se describe una metodología para la identificación de objetos clasificados en poliedros y no poliedros, este reconocimiento se logra mediante el procesamiento digital de imágenes combinado con el uso de algoritmos de inteligencia artificial, como las redes neuronales de *Hopfield*. El procedimiento consiste en procesar las imágenes con el fin de obtener los patrones a entrenar, dicho proceso fue desarrollado en tres etapas: *i)* Segmentación, *ii)* Reconocimiento inteligente, y *iii)* Extracción de características; a partir de los resultados obtenidos, en este caso imágenes de los objetos, estos elementos se entrenan en la red neuronal diseñada; finalmente, se usa la red neuronal de *Hopfield*, la cual, al recibir un nuevo elemento o imagen de un objeto, determinará el tipo de objeto. La metodología propuesta fue evaluada en un ambiente real con un amplio número de imágenes detectadas, la incertidumbre al reconocer imágenes ruidosas, representa el 2.6% de la muestra, ofreciendo una respuesta aceptable frente a condiciones de luz, forma y color variables. Los resultados obtenidos a partir del experimento evidencian un grado alto de reconocimiento, lo cual representa el 97.4 por ciento. A partir de este procedimiento es posible entrenar nuevos patrones con novedosas formas, y se espera que este modelo de reconocimiento sea capaz de reconocer patrones completamente nuevos. La metodología propuesta potencialmente puede tener diferentes aplicaciones, tales como la identificación de objetos en procesos industriales; funciones de agarre de objetos mediante el uso de manipuladores o brazos robóticos; así como en el área de la rehabilitación para ayudar a personas con limitaciones visuales, entre otras.

**Palabras clave:** operaciones morfológicas; reconocimiento de imágenes en 2D; red de *Hopfield*; redes neuronales.

## **Reconhecimento de objetos através de técnicas de inteligência artificial**

### **Resumo**

No presente artigo descreve-se uma metodologia para o reconhecimento de objetos, os quais se tem classificado em poliedros e não poliedros, este reconhecimento logra-se mediante processamento digital de imagens combinada com o uso de algoritmos de inteligência artificial, como são as redes neurais de *Hopfield*. Em uma primeira etapa processam-se as imagens, com o fim de obter os padrões para treinar, dito processo foi desenvolvido em três etapas: i.) Segmentação, ii.) Reconhecimento inteligente, iii.) Extração de características, a partir dos resultados obtidos, neste caso imagens dos objetos, estes elementos treinam-se na rede neuronal desenhada, finalmente faz-se uso da rede neuronal de *Hopfield* proposta, a qual, ao receber um novo elemento ou imagem de um objeto, determinará o tipo de objeto. A metodologia proposta foi avaliada em um ambiente real, mostrando um amplo número de imagens detectadas; a incerteza ao reconhecer imagens ruidosas, representa 2,6% da amostra, oferecendo uma resposta aceitável frente a condições de luz, forma e cor variáveis, os resultados obtidos a partir do experimento evidenciam um grau alto de reconhecimento de 97.4%, conseqüentemente, a partir deste procedimento é possível treinar novos padrões com novas formas, e espera-se que este modelo de reconhecimento seja capaz de reconhecer padrões completamente novos. A metodologia proposta potencialmente pode ser utilizada em diferentes aplicações, como é a identificação de objetos em processos industriais, funções de agarre de objetos mediante o uso de manipuladores ou braços robóticos, na área da reabilitação como ajuda a pessoas com limitações visuais, entre outras.

**Palavras chave:** operações morfológicas; reconhecimento de imagens em 2D; rede de *Hopfield*; redes neurais.

## I. INTRODUCCIÓN

La visión artificial es una importante línea de investigación que se puede aplicar en la robótica, en los procesos industriales y en los dispositivos para personas con discapacidades visuales, entre otros. La inteligencia artificial es una de las áreas del conocimiento más importantes en la visión artificial, pues hace uso de diferentes algoritmos, técnicas y métodos, con lo cual se logra el procesamiento de información contenida en imágenes digitales.

Particularmente, para dar solución al reconocimiento de objetos se han planteado múltiples algoritmos [1] que involucran diferentes operaciones morfológicas, las cuales permiten adecuar las imágenes capturadas que presentan alta variabilidad debido a las condiciones de luz, al dispositivo de captura de la imagen, e incluso, al objeto a reconocer en sí, entre otras posibilidades.

Por otra parte, de forma complementaria a las metodologías propuestas se utilizan algoritmos de inteligencia artificial, como la implementación de redes neuronales, específicamente las de tipo *Hopfield* [2-10].

De tal modo que en el procedimiento de esta investigación se propone un algoritmo de visión artificial que permita reconocer un grupo de objetos base, como los poliedros y los no-poliedros, bajo condiciones de luminosidad variables. Debido a las condiciones, el procedimiento propuesto involucra dos fases: *i)* Procesamiento de la imagen capturada y *ii)* Aplicación de una red neuronal.

La primera fase permite reducir y adecuar la imagen a través de: *i)* Segmentación, *ii)* Reconocimiento inteligente y *iii)* Extracción de características. En la segunda fase se utiliza una red neuronal de *Hopfield*, la cual aprende a reconocer diferentes patrones previamente entrenados y, posteriormente, nuevas imágenes se presentan a la red para que de forma automática y autónoma reconozcan los objetos presentados.

Consecuentemente, el presente artículo se divide en tres secciones, en la primera se presentan los métodos y materiales, en esta sección se detalla el procesamiento digital de imágenes, particularmente, la fase de la segmentación; posteriormente, se presenta el modelo de inteligencia artificial propuesto; a continuación, en la sección de resultados se describe la fase experimental que permite validar el

modelo propuesto, presentando los resultados obtenidos una vez aplicado el sistema de inteligencia artificial; finalmente, la sección de discusión y conclusiones.

## II. MÉTODOS Y MATERIALES

El reconocimiento de objetos en una escena convencionalmente se logra mediante el procesamiento digital de imágenes [11], cuyo propósito está directamente relacionado con la visión artificial o la visión por computadora. La visión artificial tiene como objetivo detectar, segmentar, localizar y reconocer determinados objetos. Para lograr este objetivo se propone la siguiente metodología: a) Segmentación, b) Reconocimiento inteligente y c) Extracción de características, las cuales se describen a continuación.

### A. Segmentación

El procesamiento propuesto de la imagen consiste en convertir la imagen a escala de grises, obteniendo así un formato de imagen más liviano. Posteriormente, se detectan los bordes mediante el método de la derivada, a continuación, se dilata y erosiona la imagen para cerrar los bordes encontrados; finalmente, se rellenan los bordes logrando una máscara que identifica la posición del objeto dentro de la imagen. A continuación, se describe a detalle cada una de las etapas:

**1) Transformación a escala de grises.** Consiste en determinar el equivalente de la luminancia, la cual se define como la luz recibida sobre una superficie, es decir, la relación del flujo luminoso sobre el área iluminada [12]. El concepto de *luminancia* se asocia con la forma como el ojo humano percibe distintas intensidades de la luz [13]. La luminancia se calcula con base en la media ponderada de los componentes de color de cada pixel, como se muestra en la Ecuación 1, donde  $L$  corresponde a la luminancia;  $R$  es la componente de rojo;  $G$  la componente de verde, y  $B$  la componente de azul.

$$L = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (1)$$

Al aplicar la Ecuación 1 a todos los pixeles de una imagen se obtendrá como resultado su representación en escala de grises. Esta técnica es aplicada a la

imagen capturada obteniendo la representación de la imagen en escala de grises, necesaria para la detección de bordes.

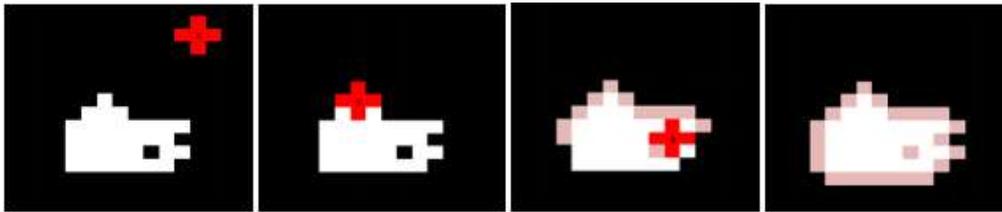
**2) Detección de bordes.** La imagen obtenida en el paso anterior se puede representar como una función discreta en 2D, la cual se define por las coordenadas de cada pixel denominadas, en este caso,  $m$  y  $n$ . El valor discreto de la función evaluada en un punto específico es conocido como brillo o intensidad del pixel. Los bordes están definidos por el cambio de tono en los pixeles de la misma, de esta forma, cuando estos cambios superan un valor umbral se considera que existe un borde. Diferentes métodos para la identificación de bordes se han propuesto, uno de ellos, es la determinación del gradiente de intensidad de cada pixel, haciendo uso de una máscara de convolución, luego calcular su magnitud, para finalmente someter los resultados a un proceso de umbralización [14]. La mayoría de las técnicas para la detección de bordes utilizan operadores locales [15], a partir de distintas aproximaciones discretas de la primera y segunda derivada de los niveles de grises de la imagen, a continuación, se describirá el operador propuesto, el cual se basa en la primera derivada de la imagen.

**3) Operadores basados en la primera derivada.** La derivada de una señal continua proporciona las variaciones locales con respecto a la coordenada, de forma que el valor de la derivada es mayor cuando más rápidas son estas variaciones. En el caso de funciones bidimensionales  $f(x, y)$ , la derivada es un vector que apunta en la dirección de la máxima variación de  $f(x, y)$  y cuyo módulo es proporcional a dicha variación. Este vector se denomina gradiente [16] y se define como  $\nabla f(x, y) = \left[ \frac{\partial f(x, y)}{\partial x} \quad \frac{\partial f(x, y)}{\partial y} \right]^T$ , su magnitud se define como  $Mag[\nabla f(x, y)] = \sqrt{\left(\frac{\partial f(x, y)}{\partial x}\right)^2 + \left(\frac{\partial f(x, y)}{\partial y}\right)^2}$ , y su dirección está dada por  $\theta = \arctang\left(\frac{\frac{\partial f(x, y)}{\partial y}}{\frac{\partial f(x, y)}{\partial x}}\right)$ .

**4) Operaciones morfológicas.** La morfología se refiere al estudio del contorno y la forma de los objetos dentro de una imagen. La base de la morfología matemática es la aplicación de operaciones de conjuntos a las imágenes y a sus operadores [17]. Los conjuntos representan la forma de los objetos contenidos en una imagen, y para extraer una estructura geométrica de un conjunto se debe utilizar formas conocidas como elementos estructurantes. Entonces, la técnica consiste en aplicar

un elemento estructurante a una imagen de entrada, el valor de cada pixel en la imagen de salida resulta de comparar cada pixel correspondiente a la imagen de entrada con sus vecinos [18]. Las operaciones morfológicas comúnmente utilizadas son la dilatación y la erosión, entre otros.

**5) Dilatación.** Es una operación morfológica que permite aumentar el tamaño de los objetos y, por ende, reducir el tamaño del fondo. El resultado que se obtiene con la dilatación depende del elemento estructurante que se escoja, por ejemplo, para dilatar la imagen mostrada en la Fig. 1a se utilizó como elemento estructurante una cruz (+) de color rojo, posteriormente, se hace coincidir el centro del elemento estructurante con cada uno de los elementos de la imagen de entrada, como se muestra en la Fig. 1b; es decir, se reemplaza cada pixel blanco de la imagen Original (Fig. 1a) por una réplica del elemento estructurante, como se muestra en la Fig. 1c, los pixeles aumentados aparecen en color rosado como se visualiza en la Fig. 1d.



**Fig. 1.** Ejemplo de una dilatación. (a) Imagen Original, (b) Paso Inicial, (c) Paso Intermedio, (d) Erosión.

**6) Erosión.** Es una operación morfológica que funciona de manera similar a la dilatación, mediante la cual se obtiene un resultado inverso a la dilatación; este proceso reduce el tamaño de los objetos extendiendo los límites del fondo y eliminando objetos pequeños.

**7) Relleno de bordes.** Consiste en completar aquellos bordes incompletos. Los bordes se definen como la transición entre dos regiones de niveles de gris considerablemente diferentes, a partir de estos es posible determinar el límite o el contorno de un objeto.

La Fig. 2 presenta la síntesis del proceso de segmentación de la imagen, el cual permite identificar la posición del objeto dentro de la imagen; sin embargo, como se

observa en la parte derecha, el resultado de la segmentación no es contundente y aún no es posible identificar con claridad el borde del objeto, siendo el sistema altamente sensible a los errores, por esta razón es necesario el uso de la inteligencia artificial.

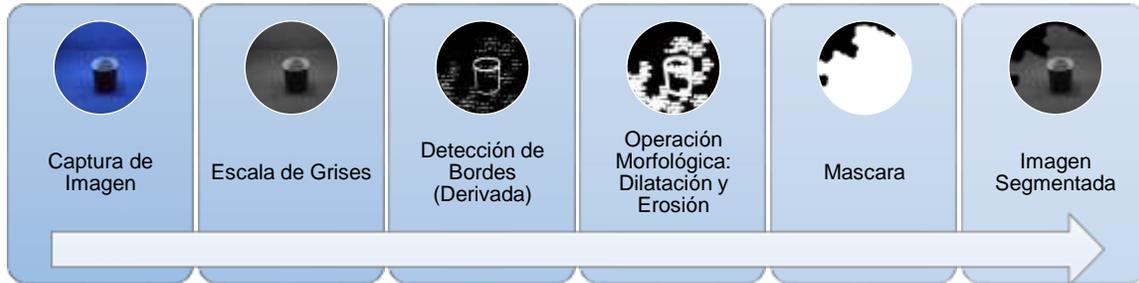


Fig. 2. Segmentación de la imagen.

### **B. Inteligencia artificial para el reconocimiento de objetos**

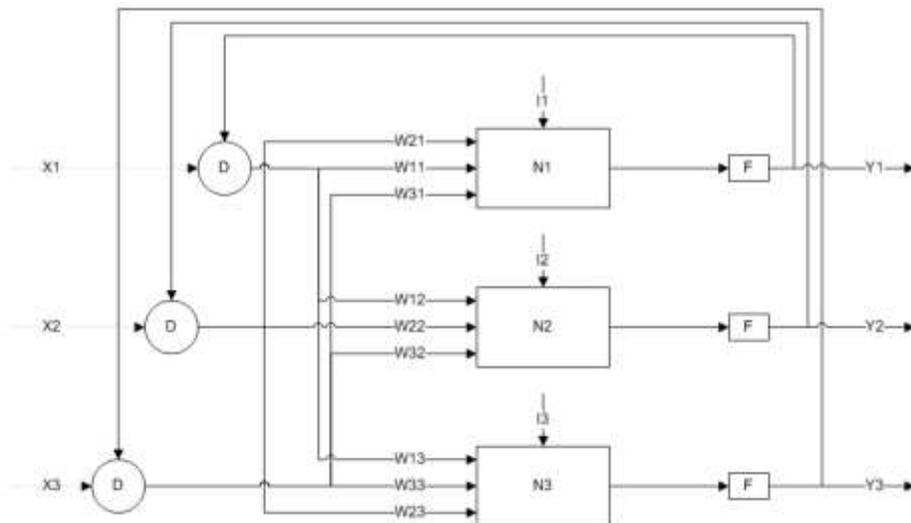
En la segunda etapa se propone reconstruir la imagen utilizando una red neuronal de *Hopfield*, la cual elimina el ruido en la imagen de bordes, mejorando de esta forma la precisión y exactitud del resultado obtenido de la etapa anterior, para concluir en una imagen segmentada apropiadamente.

La inteligencia artificial es conocida como “la ciencia e ingeniería de hacer máquinas inteligentes, especialmente programas de cómputo inteligentes”, esta definición la propuso el profesor John McCarthy, en 1956 [19]. El principal objetivo de la inteligencia artificial es pensar, evaluar o actuar de acuerdo con entradas determinadas para que ejerza alguna función específica; para lograr esto existen diferentes procesos, tales como: *i)* Algoritmos genéticos, *ii)* Redes neuronales artificiales y *iii)* Razonamiento mediante una lógica formal.

Para el problema se utilizarán redes neuronales artificiales, éstas se caracterizan por utilizar elementos procesadores de información de cuyas interacciones locales depende el comportamiento conjunto del sistema [20]. Las redes consisten en un gran número de elementos simples de procesamiento llamados nodos o neuronas que están organizados en capas [21]. Cada neurona está conectada con otras neuronas mediante enlaces de comunicación que tienen asociado un peso, el cual representa la información que será usada por la red neuronal para resolver un

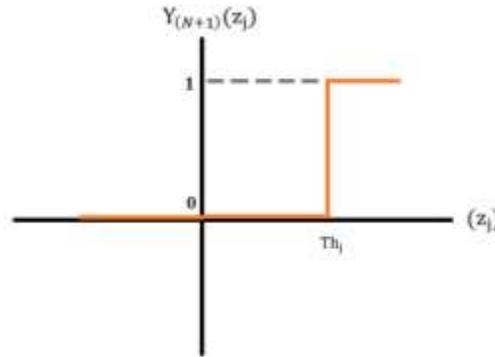
problema determinado [22]. Entonces, dependiendo del tipo de problema a solucionar existen diferentes tipos de redes neuronales: auto-organizativas, recurrentes, entre otras.

Entre las redes neuronales recurrentes se encuentran las Redes de Hopfield, las cuales son de adaptación probabilística, recurrentes y con memoria asociativa, es decir, que aprenden a reconstruir los patrones de entrada que memorizaron durante el entrenamiento [23]; estos patrones pueden presentarse de forma incompleta o con ruido. Además, las redes de Hopfield se caracterizan porque cada neurona puede ser actualizada un número indefinido de veces, independientemente del resto de las neuronas; además, la red se encuentra interconectada en paralelo. En la Fig. 3 se muestra la estructura de la Red de Hopfield en donde  $N1$ ,  $N2$  y  $N3$  corresponden a las neuronas,  $X$  está asociado a las entradas,  $D$  corresponde al nodo de distribución,  $F$  es la función de activación,  $I_i$  es la polarización de entrada,  $W_{ij}$  corresponde a los pesos y, finalmente,  $Y_i$  es la salida.



**Fig. 3.** Estructura de la Red de Hopfield.

El modelo consiste en una red monocapa con  $N$  neuronas, con entradas y salidas analógicas, utilizando neuronas con funciones de activación  $F$  (Fig. 4), el modelo matemático que describe el comportamiento de la red neuronal se representa matemáticamente por las ecuaciones 2 y 3.



**Fig. 4.** Función de activación.

$$z_j = \sum_{i \neq j} w_{ij} y_i(n) + I_j; \quad n = 0, 1, 2, \dots \quad (2)$$

$$y_j(n+1) = \begin{cases} 1 & \forall z_j \geq Th_j \\ 0 & \forall z_j < Th_j \end{cases} \text{ ó: } \begin{cases} 1 & \forall z_j \geq Th_j \\ y_j(n) & \forall z_j < Th_j \\ 0 & \forall z_j < Th_j \end{cases} \quad (3)$$

La Red de Hopfield emplea la estructura básica de las neuronas individuales tipo perceptrón de Adaline; sin embargo, se aleja de los diseños usuales de redes neuronales en su estructura de realimentación. Nótese que una Red de Hopfield binaria de dos neuronas puede ser considerada como un sistema de  $2^n$  estado, es decir,  $2^2$  con salidas que pertenecen al conjunto de cuatro estados {00, 01, 10, 11}. Cuando la red recibe un vector de entrada se estabilizará en uno de los estados anteriores, el estado de salida se determinará por las configuraciones de los pesos de la red.

Para la implementación de la Red de Hopfield es necesario proponer un modelo de pesos basado en la memoria autoasociativa [24], esta se caracteriza porque presupone que la entrada debe aproximarse a un valor almacenado en la memoria de tal forma que:  $\vec{x} = \vec{y}$ . Logrando que para una entrada arbitraria  $\vec{x}_i$  que está más próxima a  $\vec{x}$  en comparación a una entrada  $\vec{x}_j$ , se tendrá la ecuación 4.

$$f(\vec{x}_i) = \vec{x} \quad (4)$$

De esta forma los pesos de la red serán calculados mediante la ecuación 5.

$$W = \sum_{i=1}^L \vec{x}_i \vec{x}_i^T \quad (5)$$

Una entrada parcialmente incorrecta producirá en la red una salida cercana al patrón más parecido almacenado en la memoria, logrando una salida correcta en presencia de una entrada distorsionada. Esta última propiedad hace de la Red de Hopfield sea la más adecuada para la solución esperada (Fig. 5), dado que la entrada es una imagen parcialmente incorrecta debido a las condiciones de ruido, la salida de la red será la imagen corregida.

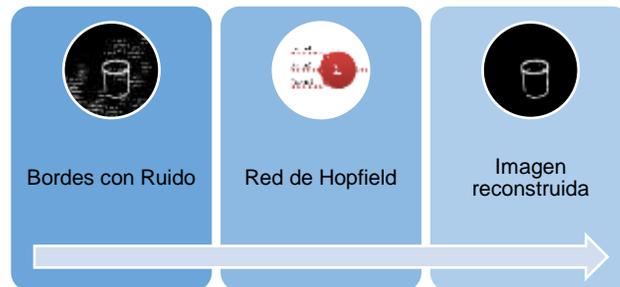


Fig. 5. Procedimiento del sistema de inteligencia artificial.

### C. Extracción de características

La fase de extracción de características consiste en dilatar y erosionar la imagen resultante de la Red de Hopfield para generar una nueva máscara mejorada, que al ser aplicada a la imagen original, el resultado será la segmentación de la imagen extrayendo el objeto a analizar (Fig. 6).

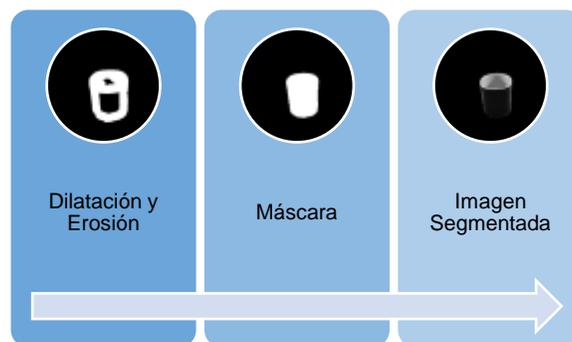


Fig. 6. Estructura de extracción de características.

## III. RESULTADOS

Para validar la metodología propuesta se lleva a cabo un experimento que permite evaluar la efectividad de la metodología propuesta; a continuación se describen los materiales y métodos utilizados; finalmente, se presentan los resultados obtenidos.

### **A. Materiales**

**1) Dispositivo de captura.** Se seleccionó una cámara Handycam® Sony con lente Carl Zeiss®, con zoom óptico de 40x, y referencia DCR-HC52, se seleccionó esta debido a que entrega imágenes de 720x480 píxeles, el cual es el tamaño justo para procesar la imagen rápidamente sin pérdidas de información. Así mismo, la cámara seleccionada cuenta con autocalibración permitiendo de esta forma mejorar el enfoque; adicionalmente, la cámara se fija en un trípode con una inclinación de 33.75°.

**2) Espacio de trabajo.** El espacio de trabajo consiste en cajas cuyas dimensiones son: 47 cm de ancho, 40 cm de alto y 38 cm de profundidad; su interior se forró con papeles de colores básicos rojo, verde y azul (Fig. 7). Se colocaron al interior tres matrices de led: 3x4 de luz blanca, estas matrices fueron situadas en las caras superiores derecha e izquierda, las matrices se ubicaron centradas en cada una de las caras, la luz led se polarizó a diferentes voltajes: 12v, 9v, 7.5v, 6v y 4.5v.



**Fig. 7.** Cajas con tres matrices de leds.

**3) Objetos.** Se seleccionaron dos tipos de objetos pequeños y grandes de la siguiente manera: *i)* Poliedros: prismáticos (Fig. 8), hexaedros, ortoedro y *ii)* No-poliedros (Fig. 9).



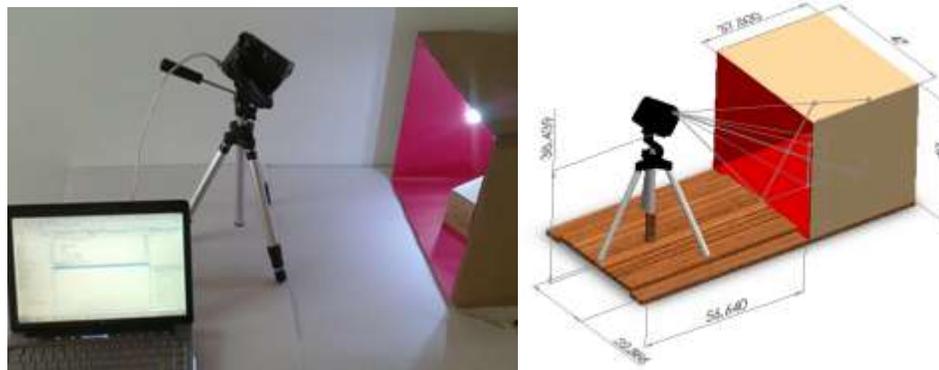
**Fig. 8.** Objetos poliedros.



**Fig. 9.** Objetos no-poliedros.

### ***B. Configuración experimental***

La cámara se ubicó sobre un trípode con un ángulo de inclinación de  $33.75^\circ$ , como se muestra en la Fig. 10, esto debido a la altura del trípode y la distancia desde la cámara hasta el objeto.



**Fig. 10.** Experimento.

### ***C. Muestras***

Para el experimento se tomaron 150 imágenes que corresponden a los objetos prismáticos, hexaedros y ortoedros, cilíndricos y esféricos. Se tomaron cinco fotografías a cada uno de los objetos y para cada fondo de la caja, dependiendo de la intensidad de luz representada en diferentes voltajes. En las imágenes se percibe como a medida que disminuye el voltaje, las imágenes se iban oscureciendo y son

las imágenes que presentan mayor ruido. En la Tabla 1 se presenta una muestra de las fotografías colectadas para el caso de los objetos prismáticos.

**Tabla 1.** Imágenes de objetos prismáticos.

Fondo caja	Objeto	Intensidad de luz				
		12v	9v	7.5v	6v	4.5 v
Azul	Prisma grande					
Verde						
Roja						
Azul	Prisma pequeño					
Verde						
Roja						

## IV. DISCUSIÓN

### A. Segmentación de la imagen

Una vez realizado el procedimiento sobre las 150 imágenes que corresponde a la segmentación, se obtuvo el resultado que se muestra en la Fig. 11. Resultados de la segmentación, en rojo los errores: de las 150 muestras, solamente en cuatro casos no fueron reconocidos, los cuales se encuentran resaltados en rojo, como consecuencia de esto, se presenta una incertidumbre al reconocer imágenes ruidosas, lo que representa el 2.6% de la muestra. Es importante precisar, que los errores, sucedieron bajo las condiciones menos favorables, cuando la intensidad de la luz era baja, considerando así, que el modelo matemático funcionó apropiadamente, ofreciendo una respuesta aceptable frente a condiciones de luz, forma y color variables.



Fig. 11. Resultados de la segmentación, en rojo los errores.

### ***B. Inteligencia artificial***

Dado que el objetivo de la red neuronal es reconstruir un patrón conocido con base en una información almacenada en la memoria, se requiere una red con memoria asociativa. Este concepto es bastante intuitivo, se trata simplemente de asociar dos patrones, el de entrada con uno almacenado en memoria.

Para el caso de las imágenes segmentadas, estas miden 720x480 pixeles, por lo cual los vectores de entrada deberían medir 1x345600, y la matriz de pesos tendría una dimensión de 345600x345600, estos valores son considerablemente altos para ser procesados por un computador convencional. Por esta razón, antes de procesar

la imagen en la red neuronal, la imagen fue dilatada y se le redujo el tamaño a una razón de 10 veces sobre el tamaño original de la imagen, los patrones usados para entrenar la red se muestran en la Fig. 12.



Fig. 12. Patrones entrenados.

Los patrones mostrados tienen dimensiones de 72x48 píxeles, de esta forma la matriz de pesos  $W$  tiene una dimensión de 3456x3456, por lo cual es posible procesar la red en un computador convencional.

### C. Resultados

Al realizar las pruebas de efectividad sobre la red neuronal, se evidenció que la red reconstruyó el patrón esperado. La Fig. 13 muestra la matriz de confusión de la red neuronal que evidencia la capacidad de clasificación de la red. Consecuentemente, se considera que el único error de reconocimiento de un objeto proviene de la incertidumbre de 2.6% encontrada en la etapa de segmentación. Por lo cual la metodología completa contemplaría una eficiencia de total 97.4 %.

Output Class	1	243 24.3%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	2	0 0.0%	247 24.7%	0 0.0%	0 0.0%	100% 0.0%
	3	0 0.0%	0 0.0%	233 23.3%	0 0.0%	100% 0.0%
	4	0 0.0%	0 0.0%	0 0.0%	277 27.7%	100% 0.0%
		100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%
		1	2	3	4	Target Class

Fig. 13. Matriz de confusión.

## V. CONCLUSIONES

Se propuso metodología efectiva para el procesamiento digital de imágenes para identificar formas básicas de objetos a partir de imágenes, esta metodología puede ser extrapolada a diferentes aplicaciones como el agarre de objetos mediante el uso de brazos robóticos, dispositivos de ayuda a personas con limitaciones visuales, entre otras. Por otra parte, el uso de metodologías híbridas, de técnicas de procesamiento de imágenes combinada con técnicas de inteligencia artificial constituye un importante aporte en el área de la visión artificial, específicamente, en el caso del uso de redes neuronales tipo Hopfield.

## CONTRIBUCIÓN DE LOS AUTORES

Ramírez y Rubiano desarrollaron la metodología, recolección de patrones, la experimentación y los resultados obtenidos. Jiménez contribuyó en el desarrollo del sistema de inteligencia artificial y el análisis de los resultados.

## REFERENCIAS

- [1] S. Todorovic, and N. Ahuja, "Unsupervised Category Modeling, Recognition, and Segmentation in Images," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 30, pp. 2158-2174, 2008. <https://doi.org/10.1109/TPAMI.2008.24>
- [2] S. Chartier, and R. Lepage, "Learning and extracting edges from images by a modified Hopfield neural network," *Object recognition supported by user interaction for service robots*, Quebec, Canada, 2002.
- [3] R. Sammouda, and B. B. Youssef, "A comparison of cluster distance metrics for the segmentation of sputum color image using unsupervised hopfield neural network classifier," in *Global Summit on Computer & Information Technology*, Sousse, Tunes, 2014. <https://doi.org/10.1109/GSCIT.2014.6970130>
- [4] X. Zhao, Y. Li, and Q. Zhao, "A Fuzzy Clustering Approach for Complex Color Image Segmentation Based on Gaussian Model with Interactions between Color Planes and Mixture Gaussian Model," *International Journal of Fuzzy Systems*, vol. 20, pp. 309-317, 2017. <https://doi.org/10.1007/s40815-017-0411-1>
- [5] K. Mutter, M. Jafri, and A. Aziz, "Real time object detection using Hopfield neural network for Arabic printed letter recognition," in *10th International Conference on Information Science, Signal Processing and their Applications (ISSPA)*, 2010. <https://doi.org/10.1109/isspa.2010.5605416>
- [6] C. M. Bishop, *Pattern recognition and machine learning*, New York: Springer, 2006.
- [7] S. S. Young, P. D. Scott, and N. M. Nasrabadi, "Object recognition using multilayer Hopfield neural network," *IEEE Transactions on Image Processing*, vol. 6 (3), pp. 357-372, 1997. <https://doi.org/10.1109/83.557336>
- [8] Z. Hongbin, N. Hideki, and N. Tadashi, "Recognizing 3D objects by using a Hopfield-style optimization algorithm for matching patch-based descriptions," *Pattern Recognition*, Pergamon, vol. 31, pp. 727-741,

1998. [https://doi.org/10.1016/s0031-3203\(97\)00105-2](https://doi.org/10.1016/s0031-3203(97)00105-2)
- [9] H. Zha, H. Nanamegi, and T. Nagata, "3-D object recognition from range images by using a model-based Hopfield-style matching algorithm," in *13th International Conference on Pattern Recognition*, Vienna, Austria, 1996. <https://doi.org/10.1109/ICPR.1996.547244>
- [10] N. M. Nasrabadi, and W. Li, "Object recognition by a Hopfield neural network," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 21 (6), pp. 1523-1535, 1991. <https://doi.org/10.1109/21.135694>
- [11] E. García, "Detección y clasificación de objetos dentro de un salón de clases empleando técnicas de procesamiento digital de imágenes," México, 2008. [http://newton.azc.uam.mx/mcc/01\\_esp/11\\_tesis/tesis/terminada/080513\\_garcia\\_santillan\\_elias.pdf](http://newton.azc.uam.mx/mcc/01_esp/11_tesis/tesis/terminada/080513_garcia_santillan_elias.pdf)
- [12] P. Fiorentin, and A. Scroccaro, "Comparison of luminance measurement based on illuminance and luminance detectors," in *Conference IEEE Instrumentation and Measurement Technology*, Singapore, 2009. <https://doi.org/10.1109/IMTC.2009.5168561>
- [13] B. Escalante, "Procesamiento digital de imágenes," *Apuntes de curso*, Distrito Federal, México, 2006. [http://lapi.fi-p.unam.mx/wp-content/uploads/PDI\\_Cap1\\_Introduccion.pdf](http://lapi.fi-p.unam.mx/wp-content/uploads/PDI_Cap1_Introduccion.pdf)
- [14] E. Lucer, and H. Saldana, "Utilización de técnicas de visión artificial para la detección automática de defectos externos del mango," Grade Thesis, Universidad Señor de Sipán, Chiclayo, Perú, 2016.
- [15] A. Martínez, "Técnicas de segmentación de imágenes, reconstrucción y descomposición de mallas enfocadas y aplicaciones médicas," Doctoral Thesis, Universidad de Jaén, Spain, 2013. <http://ruja.ujaen.es/bitstream/10953/524/1/9788484390398.pdf>
- [16] E. R. Davies, *Machine Vision, Theory, Algorithms, Practicalities*, Elsevier, 2004.
- [17] Mathworks, "MathWorks-Makers of MATLAB and Simulink," 2020. <https://www.mathworks.com/>
- [18] S. Ortiz, and C. Lemus, "Diseño de un modelo basado en técnicas de inteligencia artificial para el desarrollo de un sistema inteligente orientado al aprendizaje," Grade Thesis, Escuela Especializada en Ingeniería ITCA, Santa Tecla, El Salvador, 2011. <https://www.itca.edu.sv/wp-content/themes/elaniin-itca/docs/2011-Diseno-de-un-modelo-basado-en-tecnicas-de-inteligencia.pdf>
- [19] J. R. Hiler, and V. J. Martínez, *Redes neuronales artificiales: Fundamentos, modelos y aplicaciones*, RA-MA, 2009.
- [20] D. J. Matich, *Redes Neuronales: Conceptos Básicos y Aplicaciones*, Universidad Tecnológica Nacional, Argentina, 2001.
- [21] M. J. Palmer, and J. J. Montaña, "¿Qué son las redes neuronales artificiales? Aplicaciones realizadas en el ámbito de las adicciones," *Adicciones*, vol. 11, pp. 243-255, 1999.
- [22] Electronica.com.mx, "Hopfield", 2020. <http://electronica.com.mx/neural/informacion/hopfield.html>
- [23] L. Wang, "Effects of noise in training patterns on the memory capacity of the fully connected binary Hopfield neural network: mean-field theory and simulations," *IEEE Transactions on Neural Networks*, vol. 9 (4), pp. 697-704, 1998. <https://doi.org/10.1109/72.701182>