

**Identificación y Clasificación de Imágenes Farmacéuticas  
mediante Técnicas de Visión e Inteligencia Artificial: Un  
Enfoque en Máquinas de Vectores de Soporte (SVM)**

**Support Vector Machines (SVM) based identification and  
classification of pharmaceutical images**

Jesus Alfonso Medrano Hermosillo<sup>1\*</sup>

[jesus.mh@chihuahua.tecnm.mx](mailto:jesus.mh@chihuahua.tecnm.mx)

Dr. Rodriguez Mata<sup>1</sup>

Dr. Djilali<sup>1</sup>

Dr. Edgar Macias<sup>2</sup>

Dr. Oscar Suárez

Raul Vazquez

<sup>1</sup>Tecnológico Nacional de México

<sup>2</sup> INTEL

## RESUMEN

Este estudio se enfoca en la identificación y clasificación de imágenes con fármacos para facilitar su selección y administración adecuada a pacientes postrados. La implementación del algoritmo se lleva a cabo mediante la combinación de metodologías convencionales de visión e inteligencia artificial. Por el lado de visión artificial, se emplea preprocesamiento de imágenes para el proceso de segmentación, donde la técnica utilizada es la llamada umbralización. Una vez completado dicho proceso, se procede a la clasificación de los fármacos mediante aprendizaje de máquina, conocido en inglés como *machine learning*. En este estudio específico, se eligen las máquinas de vectores de soporte (SVM por sus siglas en inglés), que han demostrado una notable eficacia en la clasificación de datos linealmente separables. Luego de la clasificación de las imágenes, se genera una representación visual (mediante una imagen) que exhibe los medicamentos ordenados y situados en un plano cartesiano, listos para ser dispensados a cualquier paciente.

**Palabras clave:** Aprendizaje de Máquina, Inteligencia Artificial, Visión artificial.

## ABSTRACT

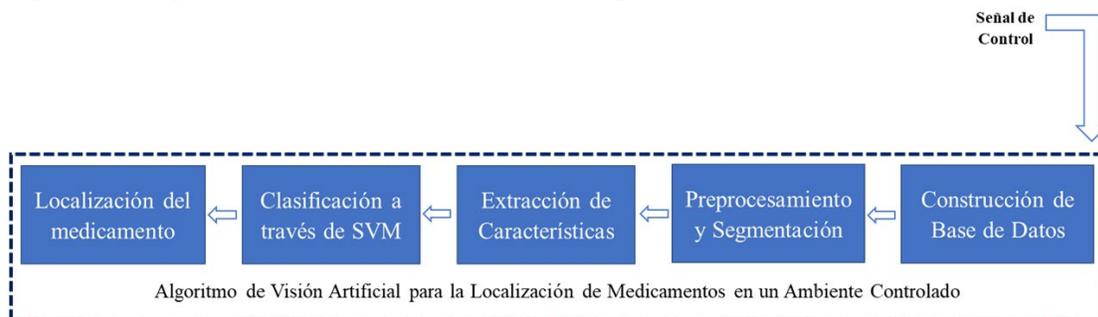
The present study focuses on the identification and classification of images that contain drugs, with the purpose of facilitating their selection and/or appropriate administration. The implementation of the algorithm is carried out by combining conventional techniques and machine learning methods. Preprocessing is used to carry out image segmentation, using the thresholding technique. Once the segmentation is completed, the pills are classified using machine learning techniques. In the specific context of this work, the use of support vector machines (SVM) is chosen, which demonstrate notable effectiveness in the classification of linearly separable data.

**Keywords:** Machine Learning, Artificial Intelligence, Artificial vision.

## 1. Introducción

Según la OMS (Organización Mundial de la Salud), al menos 500,000 personas sufren lesiones medulares cada año, lo cual se traduce a cambios en el estilo y calidad de vida de los afectados (Organization, W. H., & Society, I. S. C., 2013). Las personas que padecen diferentes cuadros de paraplejía, esclerosis múltiple, esclerosis lateral amiotrofia, entre otras, permanecen postrados por la degeneración de la capacidad motriz de su cuerpo, lo cual, implica la utilización permanente de equipos de asistencia médica e incrementa la dependencia hacia terceros para llevar a cabo sus actividades cotidianas. Se han propuesto avances tecnológicos para ayudar a estas personas con distintos tipos de parálisis, como paraplejía, esclerosis múltiple y esclerosis lateral amiotrófica. Estos abarcan dispositivos de autoayuda (Orejuela-Zapata 2019), rehabilitación robótica (Mekki 2018), exoesqueletos para extremidades inferiores (Guntara 2021, Kapula 2021), desde sillas de ruedas (García & Páez, 2021), exoesqueletos (Medrano et. al, 2014), interfaces hombre-máquina (Macías-Macías et. al, 2021), entre otros trabajos (McGibbon et. al, 2021; Pascuas-Rengifo et. al, 2015) y exoesqueletos para extremidades superiores (Sanngoen 2020). Estas tecnologías tienen el objetivo de mejorar la movilidad, minimizar la fatiga muscular y mejorar la calidad de vida en general. No obstante, esta rama de la ciencia sigue siendo ciencia abierta es necesario seguir investigando para satisfacer las necesidades específicas de las personas con lesiones de la neurona motora superior.

Sin embargo, uno de los casos más severos de deficiencia motriz es la cuadriplejía, la cual impide el movimiento de los miembros de la persona (Mogahed & Ibrahim, 2023). Esta situación impide que la persona pueda realizar la toma de cualquier objeto, como puede ser el caso de sus medicamentos (English, 2023). Es por tal motivo, que el propósito del presente trabajo es el desarrollo de un algoritmo para la detección, clasificación y localización de medicamentos en un ambiente controlado. Para como trabajo a futuro, cualquier sistema mecatrónico robótico pueda obtener el medicamento adecuado y suministrarlo al paciente con discapacidad de movimiento. El diagrama del algoritmo completo se puede ver en la Figura 1.



**Figura 1.** Diagrama a bloques del algoritmo implementado.

El presente trabajo está organizado de la siguiente manera: en la Sección 2 se ilustran los trabajos relacionados, en la Sección 3 se muestran los fundamentos matemáticos del algoritmo propuesto. Por otro lado, los resultados del trabajo se observan en la Sección 4. Finalmente, en la Sección 5 se comentan las conclusiones y el trabajo a futuro.

## 2. Antecedentes

Con base al diagrama a bloques observado anteriormente, son necesarias diversas técnicas para el desarrollo del algoritmo propuesto. Los trabajos relacionados con técnicas de visión y clasificación se muestran a continuación. (Andhare & Rawat, 2016) desarrollaron un sistema de visión capaz de identificar las coordenadas de un objeto dentro del espacio de trabajo de un brazo robótico de seis grados de libertad, a partir de las coordenadas de píxeles que obtiene el sensor de visión de dicho objeto. En (Huiling et. al, 2019) se desarrolla un sistema de reconocimiento de medicamentos para máquinas expendedoras. El sistema emplea SVM (*Support Vector Machines*) y componentes conectados para identificar la región de texto del medicamento.

Luego, realiza la segmentación del texto mediante el método *fragment link*. Finalmente, utiliza el *software* de reconocimiento óptico de caracteres (OCR, por sus siglas en inglés) para reconocer con precisión el nombre del medicamento.

En (Hnoohom et. al, 2018) los autores presentan el diseño de una aplicación de teléfono inteligente capaz de identificar de manera automática distintos fármacos utilizando la arquitectura de aprendizaje profundo Inception-V3, obteniendo un 92.75% de precisión. Las pruebas de uso real demostraron que el modelo de red neuronal propuesto podía identificar correctamente el medicamento indicado en los datos de entrenamiento. En (Shinde et. al, 2020) se presenta un trabajo de investigación enfocado en la detección de medicamentos falsificados a través de sus firmas hiperespectrales. El sistema implementado utiliza las firmas hiperespectrales de los medicamentos originales y falsificados para entrenar un modelo de aprendizaje automático basado en una red neuronal para reconocerla autenticidad del medicamento. El modelo propuesto logra una media superior al 90% de precisión en la clasificación de los medicamentos. En (Ou, & Lin, 2018), los autores proponen el uso de redes neuronales convolucionales para la detección de píldoras, donde el trabajo obtuvo un rendimiento de más del 80% en la clasificación de los medicamentos. Cabe resaltar, que se utilizó una base de datos de 1,680 imágenes para el entrenamiento de la red neuronal. Es posible observar que existe una vasta literatura sobre la detección de objetos, sin embargo, algunos de ellos suelen ser complejos para su aplicación en la vida real, es por lo que el algoritmo propuesto, para el presente trabajo, es el uso de máquinas de vector se soporte, por su simpleza y eficiencia (Gidudu et. al, 2007).

### 3. Fundamentos matemáticos

#### 3.1 Análisis por medio de visión artificial

Precedentemente de iniciar el procesamiento de imágenes y la implementación de clasificadores para el entrenamiento del SVM, es esencial contar con muestras representativas. Con este propósito, se capturaron imágenes de diversas medicinas en un entorno controlado. Estas imágenes exhiben pastillas, cápsulas y tabletas dispuestas en posiciones y orientaciones aleatorias. La Figura 2 ilustra un ejemplo visual de estas imágenes obtenidas.



**Figura 2.** Imagen de la base de datos propuesta.

El factor de calibración (FC) juega un papel fundamental en la localización de objetos en una imagen, ya que facilita la determinación de la relación entre píxeles y distancia. En el entorno controlado propuesto, el campo visual abarca un espacio de 42.19 cm x 56.25 cm, mientras que las superficies de las imágenes capturadas son 1200 píxeles x 1600 píxeles. Así, el FC se establece de la siguiente manera:

$$FC = \frac{\text{Dimensiones de la imagen en centímetros}}{\text{Dimensiones de la imagen en píxeles}} \quad (1)$$

En relación con imágenes de la base de datos, el resultado del factor de calibración se establece en  $0.0352 \frac{cm}{pixel}$ . Además, al considerar la distancia entre el centro óptico de la cámara y la superficie del entorno controlado, se determina el campo visual total de la cámara en las direcciones vertical ( $\theta_{vertical}$ ) y horizontal ( $\theta_{horizontal}$ ):

$$\theta_{vertical} = 2 \tan^{-1} \left( \frac{21.04 \text{ cm}}{45 \text{ cm}} \right) = 50.23^\circ \quad (2)$$

$$\theta_{horizontal} = 2 \tan^{-1} \left( \frac{28.125 \text{ cm}}{45 \text{ cm}} \right) = 64.01^\circ \quad (3)$$

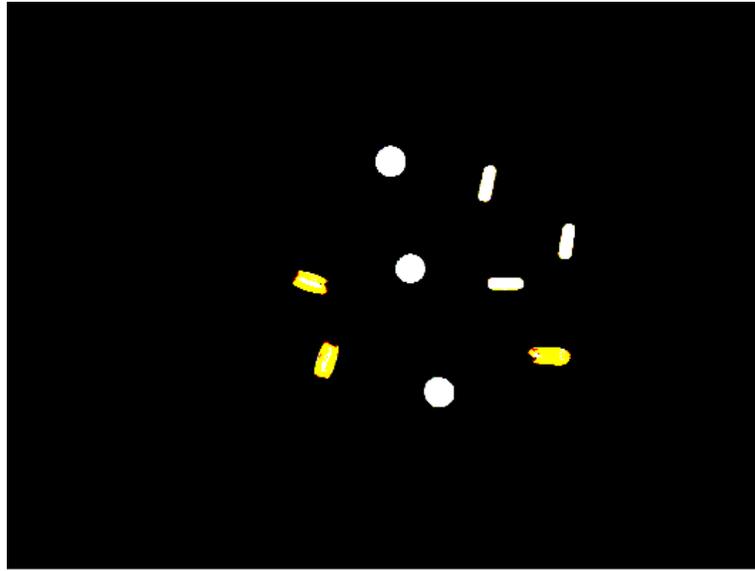
Con lo anterior, es posible detectar la posición de los diferentes objetos. Para más información respecto al procedimiento anterior, consultar (González & Woods, 2006).

### **Preprocesamiento y segmentación**

Diversos métodos se emplean en la segmentación de imágenes (González, 2002), siendo la media de intensidad de píxeles una herramienta eficaz comúnmente utilizada con este propósito. En otras palabras, al calcular el valor medio de la intensidad de los píxeles, se aplica la umbralización local para lograr la segmentación de la imagen respectiva (Chacón, 2007). En el marco del algoritmo propuesto, esta técnica se implementa para obtener las imágenes binarias deseadas, y la ecuación que rige dicha segmentación se presenta en (4).

$$g(x, y) = \begin{cases} 1 & \text{si } f(x, y) > T \\ 0 & \text{si } f(x, y) \leq T \end{cases} \quad (4)$$

Donde  $g(x, y)$  es valor del píxel en la nueva imagen segmentada,  $f(x, y)$  es el valor del píxel de la imagen a segmentar y  $T$  representa el umbral global. Considerando las imágenes en un estado binario, se continúa con la exclusión de todos los componentes conectados que posean  $2000 \leq T$  ya que esta cantidad representa el mínimo de píxeles conectados que contienen los medicamentos en las imágenes. Es crucial destacar que este proceso se aplica exclusivamente al canal R del espacio de color RGB (Red, Green, Blue; por sus siglas en inglés) de las imágenes originales. Esto se realiza con el propósito de facilitar el procesamiento de las imágenes en las siguientes fases del algoritmo. La Figura 3 exhibe el resultado de una imagen segmentada correctamente, donde se visualizan fácilmente los objetos a clasificar.



**Figura 3.** Segmentación de los objetos de interés  
**Extracción de características**

En la fase de extracción de características, se procede a identificar las partes más significativas de un objeto en la imagen, como señalan en (Shah et al., 2016). En el algoritmo propuesto, se destacan el área, redondez y solidez como características clave para la clasificación de los fármacos. El cálculo de estas propiedades se lleva a cabo mediante las ecuaciones (5), (6) y (7), respectivamente. Una vez obtenidas estas características, se forma un vector compuesto por tres elementos, proporcionando así la base para el desarrollo de un clasificador adecuado.

$$\text{Área} = \text{Número de píxeles de la región} \quad (5)$$

$$\text{Redondez} = \frac{4 * \text{Área} * \pi}{\text{Perímetro}^2} \quad (6)$$

$$\text{Solidez} = \frac{\text{Área}}{\text{Área Convexa}} \quad (7)$$

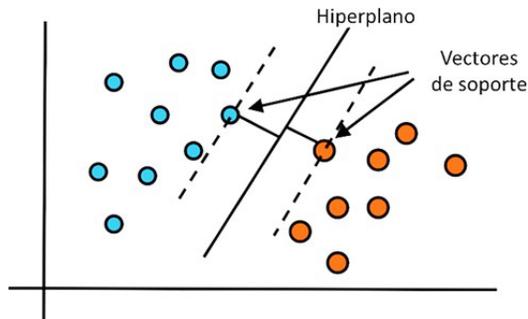
Con el propósito de evaluar el potencial de las características extraídas para la clasificación de medicamentos en pastillas, cápsulas o tabletas, se procede al cálculo de la matriz de correlación de estas características. La Tabla 1 presenta la matriz de correlación correspondiente, destacando que el área y la solidez exhiben el menor grado de correlación entre ellas (0.3970), mientras que la redondez y la solidez muestran un mayor grado de correlación (0.7917). Con base en este análisis, se avanza hacia la implementación de un clasificador binario basado en SVM utilizando estas propiedades descriptivas.

**Tabla 1.** Correlación de los medicamentos a clasificar

Características	Área	Redondez	Solidez
Área	1	0.7613	0.3970
Redondez	0.7613	1	0.7917
Solidez	0.3970	0.7917	1

### 3.2 Clasificador utilizando máquinas de vector de soporte

Una técnica ampliamente reconocida para la clasificación de objetos es el algoritmo SVM. Estas máquinas emplean datos, también denominados vectores de soporte, para establecer un umbral distintivo entre diferentes clases (Suthaharan et al., 2016).



**Figura 4.** Descripción del hiperplano creado por el algoritmo SVM

En la Figura 4, se observan dos clases claramente divididas por un hiperplano, el cual es definido por el algoritmo de máquinas de vectores de soporte. En el escenario específico de una aplicación como clasificador binario lineal, el hiperplano se expresa mediante:

$$g(x) = w^T X + b \leftrightarrow g(x) = 0 \quad (8)$$

En la ecuación anterior,  $X$  representa los patrones de entrada,  $w$  los pesos del sistema y  $b$  es el bias. La determinación de los pesos se logra al minimizar la función de costo definida en la ecuación (9) con respecto a los pesos del sistema.

$$J(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^N \lambda_i [d_i(w^T x_i + b) - 1] \quad (9)$$

Donde  $\lambda_i$  son los multiplicadores de Lagrange. La clasificación de los distintos fármacos en el presente trabajo se realiza utilizando SVM, el cual es un clasificador supervisado binario descrito por una función discriminante lineal (LDA, por sus siglas en inglés) descrita anteriormente.

Considerando que las clases son linealmente separables, es necesario definir los pesos  $\omega = (\omega_1, \omega_2, \dots, \omega_l)$  a través de la ecuación dada por (Pisner et al., 2020):

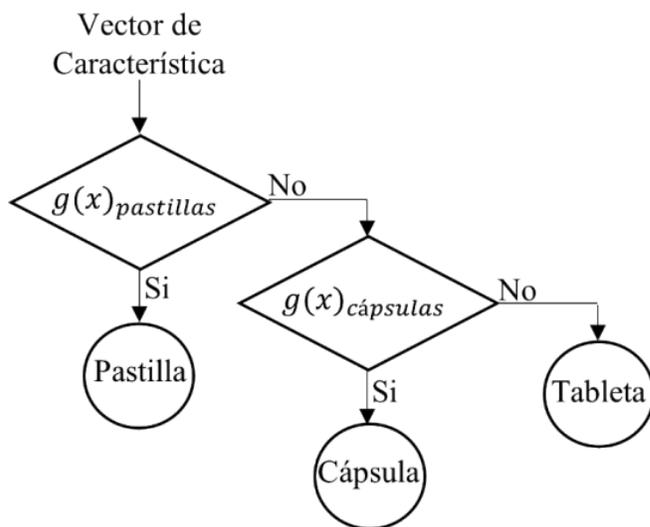
$$\omega = \sum_{i=1}^q \lambda_i y_i x_i \quad (10)$$

Aquí,  $y_i$  son las etiquetas,  $x_i$  el vector de características y  $q$  la cantidad de vectores de soporte. Para tomar la decisión de a que clase ( $W_1$  o  $W_2$ ) pertenece el vector  $X = \{x_1, x_2, \dots, x_n\}$ , el clasificador toma las decisiones de la siguiente manera:

$$\omega^T X > 0 \rightarrow X \in W_1 \quad (11)$$

$$\omega^T X \leq 0 \rightarrow X \in W_2 \quad (12)$$

No obstante, en la aplicación de fármacos propuesta, el clasificador debe tener la capacidad de identificar los tres tipos de medicamentos. Por consiguiente, se requiere diseñar dos SVM de clasificación binaria: uno para reconocer pastillas ( $g(x)_{pastillas}$ ) y otro para las cápsulas ( $g(x)_{capsulas}$ ). De esta manera, se propone un flujo de trabajo que se describe en la Figura 5.



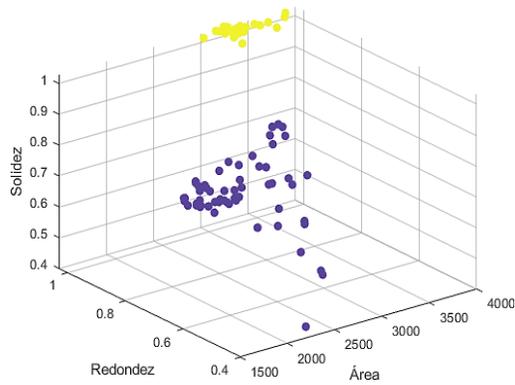
**Figura 5.** Descripción del algoritmo de clasificación implementado

El algoritmo recibe como entrada el vector de características de un medicamento que se va a clasificar. Primero, pasa por  $g(x)_{pastillas}$  para evaluar si es una pastilla o cualquier otro tipo de medicamento. Luego, se somete a  $g(x)_{cápsulas}$  para determinar si es una cápsula o si se clasifica como una tableta. El análisis del conjunto de entrenamiento y prueba para ambos clasificadores arroja las siguientes funciones discriminantes lineales, que definen los respectivos hiperplanos:

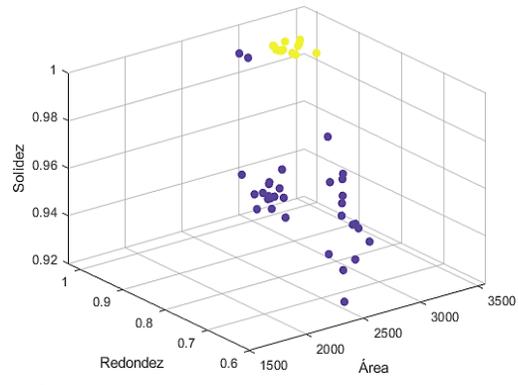
$$g(x)_{pastillas} = 0.0095x_1 + 1.2332x_2 + 0.0878x_3 - 30.8028 \quad (13)$$

$$g(x)_{capsulas} = -0.0158x_1 + 0.4259x_2 + 0.1659x_3 + 36.4810 \quad (14)$$

En la Figura 6, se presentan los resultados del entrenamiento y la prueba del clasificador de pastillas. En esta representación, los puntos amarillos indican los elementos clasificados como pastillas, mientras que los puntos azules representan los elementos clasificados como otro tipo de medicamento. De manera análoga, la Figura 7 muestra los resultados correspondientes al clasificador de cápsulas, donde los puntos amarillos indican los elementos clasificados como cápsulas y los puntos azules representan los elementos clasificados como otro tipo de medicamento. Estas visualizaciones reflejan la efectividad de los clasificadores en la diferenciación de pastillas y cápsulas de otros tipos de medicamentos.

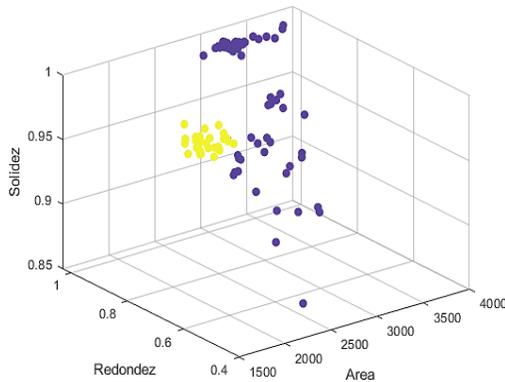


a) Resultados del entrenamiento

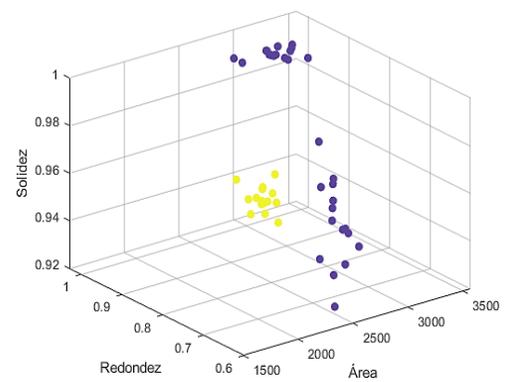


b) Resultado de la prueba

**Figura 6.** Resultados del clasificador de pastillas



a) Resultados del entrenamiento



b) Resultado de la prueba

**Figura 7.** Resultados del clasificador de cápsulas

A partir de los resultados obtenidos en las pruebas de los clasificadores de pastillas y cápsulas, se generan las correspondientes matrices de confusión, presentadas en la Tabla 2 y Tabla 3, respectivamente. Estas matrices ofrecen una visión detallada de la eficacia de los clasificadores al evaluar la precisión de las predicciones para cada clase.

**Tabla 2.** Matriz de confusión del clasificador de pastillas

		Valor Predicho	
		No Pastilla	Pastilla
ValorReal	No Pastilla	TN=15	FP=0
	Pastilla	FN=2	TP=13

**Tabla 3.** Matriz de confusión del clasificador de cápsulas.

		Valor Predicho	
		No Cápsula	Cápsula
ValorReal	No Cápsula	TN=15	FP=0
	Cápsula	FN=0	TP=15

Considerando las matrices de confusión, se procede al cálculo de las métricas de desempeño del clasificador. La precisión evalúa la calidad del modelo en las tareas de clasificación, mientras que la exhaustividad cuantifica la cantidad que el modelo es capaz de identificar (Campbell et al., 2022). La precisión se calcula mediante la ecuación (15), mientras que la exhaustividad se determina a través de la ecuación (16).

$$precisión = \frac{TP}{TP + FP} \quad (15)$$

$$exhaustividad = \frac{TP}{TP + FN} \quad (16)$$

Al examinar los resultados previos, se destaca que el clasificador de pastillas logra identificar el 86% de las pastillas, mientras que el clasificador de cápsulas alcanza un reconocimiento del 100%. Estos resultados se muestran coherentes y competitivos en relación con los trabajos previamente descritos en el capítulo de antecedentes.

### 3.3 Localizador de medicamentos

En el presente trabajo, la determinación de la posición de los fármacos se lleva a cabo mediante el cálculo del centroide de los objetos en la imagen. Donde el centroide representa el centro de masa de los objetos, detallando sus coordenadas en píxeles en la propia imagen (González, 2002). Dicho centroide se obtiene mediante las siguientes ecuaciones:

$$c_x = \frac{1}{6A} \sum_{i=0}^{N-1} (x_i + x_{i+1})(x_i y_{i+1} - x_{i+1} y_i) \quad (17)$$

$$c_y = \frac{1}{6A} \sum_{i=0}^{N-1} (y_i + y_{i+1})(x_i y_{i+1} - x_{i+1} y_i) \quad (18)$$

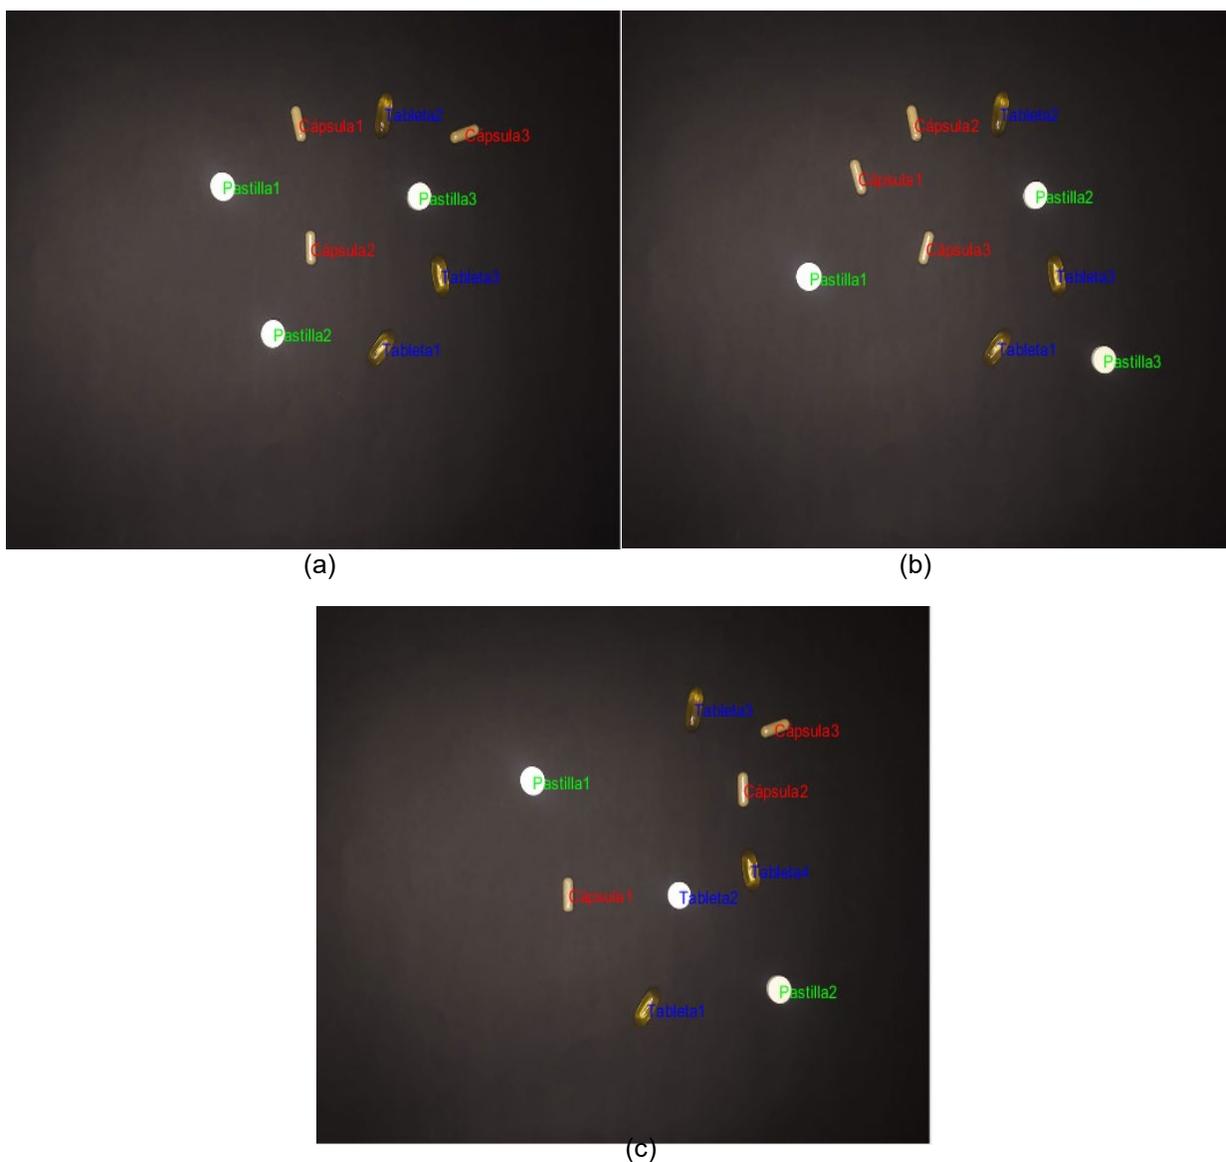
Donde  $A$  es el área de la figura, y  $x_i, y_i$  corresponden a las coordenadas de sus vértices. Una vez encontrado el centroide, se utiliza el factor de calibración calculado en (1) para definir las coordenadas en centímetros de la posición de los medicamentos.

## 4. Resultados

A continuación, a manera de comprobar el funcionamiento del algoritmo completo se realizaron ciertas tomas de diferentes medicamentos en una superficie. Donde el algoritmo además de poder detectar y posicionar correctamente los diferentes fármacos, fue capaz de clasificarlos de manera correcta. En la Figura 9 se ilustran diversas pruebas para la identificación de las diferentes tablillas, donde fueron elegidas de la siguiente manera:

- Si el fármaco tiene forma circular y su área tiene una cierta dimensión, el medicamento pertenece a la clase de "Pastilla 1".
- Si el fármaco tiene forma de ovalo con una cierta dimensión, el medicamento puede pertenecer a la clase de la "Tableta 2" o la "Pastilla 3". Donde su área, redondez y solidez van a determinar a cuál clase pertenece.

Cabe resaltar que lo mencionado anteriormente es una descripción muy general, ya que las características que se observaron en la Sección 3 fueron sometidas al algoritmo SVM para su clasificación de acuerdo con los hiperplanos nombrados en (13) y (14). Donde en los resultados observados en la Figura 9, se aprecia que el algoritmo hizo una correcta clasificación e identificación de los medicamentos en la imagen. Es así, que el algoritmo puede ser utilizado para futuras aplicaciones, cabe resaltar que la programación es sumamente sencilla, ya que sólo es necesario implementar los hiperplanos mencionados anteriormente, no es necesario volver a entrenar el algoritmo nuevamente, a menos de que se deseen aplicar más fármacos u otra aplicación.



**Figura 8.** Pruebas de funcionamiento del algoritmo de visión para la detección de fármaco

## Conclusiones y trabajo a futuro

Este estudio resalta la eficacia del algoritmo SVM en la detección de fármacos en un entorno controlado, proporcionando una clasificación y localización precisa de los diferentes medicamentos. La utilidad de SVM no solo radica en su eficacia, sino también en su facilidad de programación, lo que permite su implementación en cualquier sistema embebido y facilita su acceso a regiones con limitaciones tecnológicas.

En cuanto a futuras investigaciones, se contempla el diseño de un sistema mecatrónico dedicado a la selección y suministro automatizado de los medicamentos identificados en el presente trabajo. Esta perspectiva no solo constituye una mejora práctica en la administración de medicamentos, sino que también promete elevar la calidad de vida de aquellos pacientes con restricciones en el movimiento corporal y/o de miembros superiores. Este trabajo sienta las bases para avanzar hacia soluciones más integrales en el ámbito de la atención médica, orientadas a mejorar la accesibilidad y el bienestar de los pacientes con discapacidades físicas.

## 5. REFERENCIAS BIBLIOGRÁFICAS

Andhare, P., & Rawat, S. (2016). Pick and place industrial robot controller with computer vision. 2016 International Conference on Computing Communication Control and Automation (ICCUBEA), 1-4.

Campbell, C., & Ying, Y. (2022). Learning with support vector machines. Springer Nature.

García, W., & Páez, E. (2021). Diseño de un sistema de conducción autónoma adaptado a una silla de ruedas eléctrica.

Gidudu, A., Hulley, G., & Tshilidzi, M. (2007). Classification of images using support vector machines.

Gonzalez, R. C., & Woods, R. E. (2002). Digital image processing (2nd ed.). Prentice Hall.

Xia, H., Wang, C., Yan, L., Dong, X., & Wang, Y. (2019). Machine Learning Based Medicine Distribution System. 2019 10th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS), 912-915.

Macías-Macías, J. M., Quintana, J. A. R., Aguirre, J. S. A. M., Murguía, M. I. C., & Sáenz, A. D. C. (2021). Procesamiento embebido de p300 basado en red neuronal convolucional para interfaz cerebro-computadora ubicua. RECIBE.

Chacón, M. I. (2007). Procesamiento digital de imágenes. Editorial Trillas.

McGibbon, C. A., Sexton, A., Gryfe, P., Dutta, T., Jayaraman, A., Deems-Dluhy, S., Novak, A. C., Fabara, E., Adans-Dester, C., & Bonato, P. (2021). Effect of using of a lower-extremity exoskeleton on disability of people with multiple sclerosis. *Disability and Rehabilitation: Assistive Technology*, 18(5), 475–482.

Medrano, J. A., Zendejas-Hernandez, I., & Sandoval-Rodríguez, R. (2014). Diseño de un Exoesqueleto de Miembros Inferiores para la Movilidad de Personas con Paraplejía.

Mogahed, H. S., & Ibrahim, M. M. (2023). Development of a motion controller for the electric wheelchair of quadriplegic patients using head movements recognition. *IEEE Embedded Systems Letters*, 1.

Hnoohom, N., Yuenyong, S., & Chotivatunyu, P. (2018). MEDiDEN: Automatic Medicine Identification Using a Deep Convolutional Neural Network. 2018 International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP), 1-5.

World Health Organization, & International Spinal Cord Society. (2013). International perspectives on Spinal cord Injury. World Health Organization.

Ou, Y., Tsai, A., Wang, J., & Lin, J. (2018). Automatic Drug Pills Detection based on Convolution Neural Network. 2018 International Conference on Orange Technologies (ICOT), 1-4.

Pascuas-Rengifo, Y., Vargas-Jara, E. O., & Sáenz-Núñez, M. (2015). Tecnologías de la información y las comunicaciones para personas con necesidades educativas especiales. *Entramado*, 11(2), 240–248.

Pisner, D. A., & Schnyer, D. M. (2020). Support vector machine. In *Machine learning* (pp. 101-121). Academic Press.

González, R. C., & Woods, R. E. (2006). *Digital Image Processing* (3rd ed.). Prentice-Hall, Inc., USA.

Shinde, S. R., Bhavsar, K., Kimbahune, S., Khandelwal, S., Ghose, A., & Pal, A. (2020). Detection of Counterfeit Medicines Using Hyperspectral Sensing. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC).

Shah, F. P., & Patel, V. (2016, March). A review on feature selection and feature extraction for text classification. In 2016 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET) (pp. 2264-2268). IEEE.

Suthaharan, S. (2016). Support vector machine. In *Machine learning models and algorithms for big data classification: Thinking with examples for effective learning* (pp. 207-235).

Jacob, S. (2017). A review of technology advances for assisting paralyzed people [leading edge]. *IEEE Technology and Society Magazine*, 36(2), 36-37.

Orejuela-Zapata, J. F., Rodríguez, S., & Ramírez, G. L. (2019). Self-help devices for quadriplegic population: A systematic literature review. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 27(4), 692-701.

Mekki, M., Delgado, A. D., Fry, A., Putrino, D., & Huang, V. (2018). Robotic rehabilitation and spinal cord injury: a narrative review. *Neurotherapeutics*, 15(3), 604-617.

Guntara, A., & Rahyussalim, A. J. (2021, March). The uses of lower limb exoskeleton, functional electrical stimulation, and future improvements for leg paralysis management—A systematic review. In *AIP Conference Proceedings* (Vol. 2344, No. 1). AIP Publishing.

Kapula, P. R., Pasha, I. A., Kumar, B. A., & Sowmya, V. (2021, November). Wearable Lower Limb Exoskeletons for paraplegia: A Review. In 2021 International Conference on Technological Advancements and Innovations (ICTAI) (pp. 441-445). IEEE.

Krakowska, N., Szmelcer, B. P., Zaborna, D., Fortuna, A., Wszelaki, P., Florczak, A., & Kędziora-Kornatowska, K. (2019). Rehabilitation of patients with paraplegia—a review of the diversity of forms. *Journal of Education, Health and Sport*, 9(5), 534-546.

Sirawattanakul, S., & Sanngoen, W. (2020). Review of upper limb exoskeleton for rehabilitation and assistive application. *International Journal of Mechanical Engineering and Robotics Research*, 9(5), 752-758.



Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-CompartirIgual 2.5 México.