

SEGMENTACIÓN DE LUGARES DISPONIBLES EN ESTACIONAMIENTOS HACIENDO USO DE REDES NEURONALES PULSO-ACOPLADAS

PARKING SLOTS SEGMENTATION USING PULSE-COUPLED NEURAL NETWORKS

Víctor Romero Bautista

Benemérita Universidad Autónoma de Puebla, México
victor.romerobau@alumno.buap.mx

Aldrin Barreto Flores

Benemérita Universidad Autónoma de Puebla, México
aldrin.barreto@correo.buap.mx

Salvador Eugenio Ayala Raggi

Benemérita Universidad Autónoma de Puebla, México
salvador.raggi@correo.buap.mx

Verónica Edith Bautista López

Benemérita Universidad Autónoma de Puebla, México
veronica.bautistalo@correo.buap.mx

José Francisco Portillo Robledo

Benemérita Universidad Autónoma de Puebla, México
francisco.portillo@correo.buap.mx

Recepción: 12/mayo/2021

Aceptación: 4/noviembre/2021

Resumen

Algunos de los principales retos en los sistemas de asistencia a estacionamientos basados en visión artificial que están dedicados a la segmentación de lugares disponibles, son las diferentes afectaciones que se pueden presentar, como por ejemplo las variaciones de luz, generación de sombras, así como las diferentes tonalidades de color que presentan los automóviles; los cuales pueden afectar la detección. En este trabajo se propone un algoritmo de identificación basado en el análisis y procesamiento de imágenes en el espacio de color HSV, haciendo uso de un algoritmo de redes neuronales pulso-acopladas (PCNN) en su forma simplificada a través del modelo de intersección cortical (ICM). El algoritmo propuesto está

dividido en tres partes, análisis de la imagen en HSV, segmentación y detección, el cual se evaluó haciendo uso de diferentes imágenes capturadas en un estacionamiento. Se obtuvieron los valores de los parámetros de la red ICM para el proceso de segmentación. Los resultados obtenidos muestran que el algoritmo propuesto permite reducir la susceptibilidad a los efectos de tonalidad que presentan los automóviles, así como los cambios ligeros de iluminación, consiguiendo así la detección de automóviles con diferentes colores bajo las condiciones del día.

Palabras Clave: Estacionamiento, reconocimiento, redes neuronales pulso-acopladas, segmentación.

Abstract

The main challenges in parking lots assistant systems based on artificial vision, which are dedicated to the segmentation of available places into parking lots, are the different effects that can occur such as, changes in luminosity, shadows produced by cars, as well as different color hues that can affect detection. In this work, an identification algorithm based on the analysis and processing of images in the HSV color space is proposed, using pulse-coupled neural networks (PCNN) algorithm in its simplified form, the intersection cortical model (ICM). The proposed algorithm is divided in three parts, HSV image analysis, segmentation, and detection, which was evaluated using different images captured in parking lot. The ICM network parameter values were obtained for the segmentation process. The results show that proposed algorithm allows to reduce the susceptibility presented by cars, as well as slight changes in lighting, thus achieving the detection of cars with different colors under daytime conditions.

Keywords: *Parking lot, pulse-coupled neural networks, survey, segmentation.*

1. Introducción

El proceso de segmentación es una etapa de gran relevancia dentro de un sistema de reconocimiento basado en visión artificial. Este consiste en aislar los objetos de interés del fondo de una imagen, asignando el valor de intensidad de 1 a los objetos, mientras que al fondo se le asigna el valor 0, generando así una

imagen binaria. El resultado obtenido durante la segmentación afecta directamente al reconocimiento de los objetos en una imagen, de hecho, se puede ver al proceso de segmentación como un proceso de reconocimiento de objetos dentro de una imagen. Sin embargo, no hay una técnica definida que permita llevar a cabo este proceso para todo tipo de imágenes [Rodríguez, 2011], es decir que de acuerdo con el tipo de imagen que se esté procesando dependerá el método de segmentación a seguir. En imágenes de estacionamientos, las cuales son empleadas para identificar los espacios disponibles, presentan diferentes factores que afectan este proceso, siendo algunos de éstos, las distintas variaciones de luz, efectos de sombra, oclusión, así como los distintos colores que pueden presentar los automóviles. Para reducir estos inconvenientes, se han propuesto diferentes métodos, como son los mapeos del estacionamiento [Huang, 2013] y [Tatulea, 2019]; detección de líneas y esquinas, las cuales corresponden a los delimitadores de los espacios de estacionamiento [Suhr 2012]; métodos basados en aprendizaje profundo para el reconocimiento y detección de espacios disponibles, donde se suele emplear una red neuronal convolucional [Cai, 2019]. En este trabajo se presenta un método de segmentación basado en las redes neuronales pulso-acopladas (PCNN) en su forma simplificada, el modelo de intersección cortical (ICM), en donde se obtuvo el valor de sus parámetros para emplearla en el proceso de segmentación de lugares disponibles. Así mismo, se propone un algoritmo para la detección de automóviles en un estacionamiento, el cual consiste en tres partes principales, las cuales son, el análisis de la imagen en HSV, segmentación y detección; el algoritmo fue evaluado con imágenes de un estacionamiento capturadas durante el día, donde de acuerdo con los resultados obtenidos, se logró alcanzar una efectividad entre el 80% en imágenes con alta variación de iluminación y 100% para imágenes con iluminación homogénea.

El Modelo de Intersección Cortical (ICM)

El ICM es una versión que simplifica el modelo PCNN original [Lindblad, 2013]. Para procesar una imagen con la red PCNN se generan tantas neuronas como píxeles se tengan en la imagen de entrada, también conocida como imagen

estímulo, tal como se presenta en la figura 1, donde partiendo de una imagen S en escala de grises, se construye la red PCNN, la cual generará una imagen de salida Y , que representa características fundamentales de la imagen original, tales como bordes, textura y segmentación [Ma, 2010]. Una neurona de la red ICM (Figura 2), se puede dividir en tres compartimientos: alimentación, potencial interno y generador de pulsos.

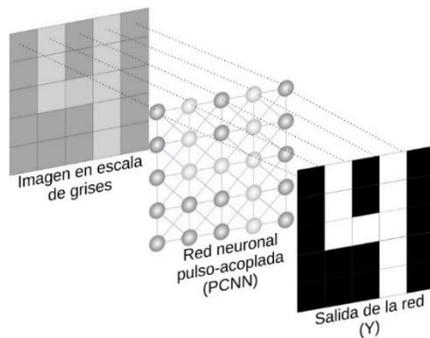


Figura 1 Representación de una red neuronal pulso acoplada.

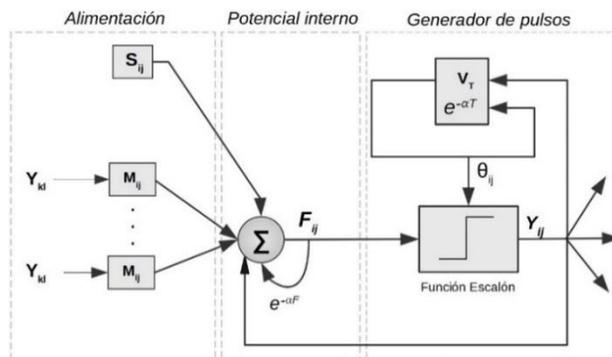


Figura 2 Modelo de neurona ICM.

El compartimiento de alimentación recibe la información de un píxel S_{ij} perteneciente a la imagen estímulo S ; así como la información de sus neuronas vecinas Y_{kl} , las cuales están acotadas por la matriz de pesos sinápticos M mostrada en la ecuación 1, y también recibe la salida de la misma neurona producida en un tiempo anterior $Y[n - 1]$. El potencial interno de la neurona se obtiene por la señal Feeding ($F_{ij}[n]$), en donde se lleva a cabo la sumatoria de las señales de entrada, más una constante de decaimiento α^F multiplicada por la señal Feeding producida

en un tiempo anterior, ecuación 2. El compartimiento de generación de pulsos se encarga de obtener el valor del umbral dinámico representado por θ , ecuación 3, y posteriormente se compara con el potencial interno ($F_{ij}[n]$) para generar la salida de la neurona. Si $F_{ij}[n]$ es mayor que θ , entonces la salida de la neurona es 1, de lo contrario permanece en 0. Para la implementación de la red ICM se hace uso de las ecuaciones 2, 3 y 4, en ese mismo orden, y para la obtener la información de las neuronas vecinas se utiliza el kernel de la ecuación 1.

$$M = \begin{pmatrix} 0.25 & 0.5 & 0.25 \\ 0.5 & 0 & 0.5 \\ 0.25 & 0.5 & 0.25 \end{pmatrix} \quad (1)$$

$$F_{ij}[n] = e^{-\alpha_F} F_{ij}[n-1] + \sum_{kl} M_{ijkl} Y_{kl}[n-1] + S_{ij} \quad (2)$$

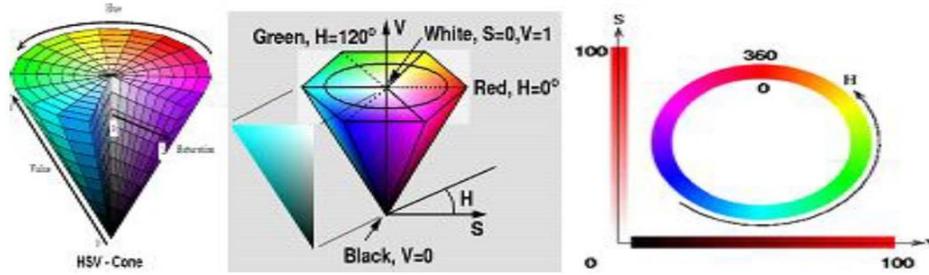
$$\theta_{ij}[n] = \theta_{ij}[n-1]e^{-\alpha_T} + V_T Y_{ij}[n-1] \quad (3)$$

$$Y[n] = \begin{cases} 1, & U_{ij} > \theta_{ij} \\ 0, & \text{en otro caso} \end{cases} \quad (4)$$

Donde n corresponde a una iteración, kl representa la dimensión de la matriz de pesos sinápticos M , $e^{-\alpha_F}$ es la constante de atenuación del canal Feeding, $e^{-\alpha_T}$ es la constante de atenuación del umbral dinámico y V_T es la constante que determina la cantidad de información que se obtendrá de la salida Y en un tiempo anterior.

El espacio de color HSV (Hue, Saturation, Value)

Este modelo representa de mejor manera la forma en cómo los humanos percibimos el color en comparación con el modelo RGB, y lo hace a través de tres componentes, Tonalidad (Hue), Saturación (Saturation) y Valor (Value) [Cuevas, 2013]; estos componentes a su vez representan un sistema coordinado cilíndrico como se muestra en la figura 3. Dónde la tonalidad indica el color, y varía desde 0 a 360 grados, la saturación indica que tan intenso es el color y el valor indica el brillo. Este modelo de color se puede obtener a partir de una imagen RGB mediante las ecuaciones 5, 6 y 7 [Ganesan, 2014].



Fuente: [Ganesan, 2014: 102]

Figura 3 Representación del espacio de color HSV.

$$H = \arccos \frac{\frac{1}{2} 2R - G - B}{\sqrt{(R - G)^2 + (R - B) * (G - B)}} \quad (5)$$

$$S = 1 - 3 \frac{\min(R, G, B)}{R + G + B} \quad (6)$$

$$V = \frac{1}{3} (R + G + B) \quad (7)$$

2. Metodología

El Proceso de segmentación propuesto

El método propuesto para la segmentación y detección de los automóviles consiste de cinco pasos, los cuales están representados en el diagrama de la figura 4; en el primer paso se obtiene la imagen de un estacionamiento en espacio de color RGB, el paso siguiente consiste en el pre-procesamiento de esta imagen, en el tercer paso se aplica la segmentación por la red ICM, seguido de este paso, se lleva a cabo la detección de los automóviles en la imagen del estacionamiento y en el quinto paso se obtiene la imagen de salida en RGB, en la cual se enmarcan los automóviles detectados.

Para la etapa de segmentación, se realizó una comparación con los métodos de segmentación: Manual, Otsu [Otsu, 1979], KNN [Wazarkar, 2018], PCNN e ICM.

En la tabla 1 se presentan las ventajas y desventajas observadas para imágenes de un estacionamiento con las que se cuenta, y de acuerdo a esto se optó por hacer uso del método de segmentación por ICM, puesto que presentó un resultado similar al modelo PCNN original, disminuyendo el costo computacional, así como el número

de parámetros, además se observó que, en comparación con los métodos de Otsu, KNN y Manual, la red ICM genera una serie de imágenes binarias, de las cuales se puede elegir la que tenga mejor información, es decir, se cuenta con una gama de opciones a diferencia de los demás métodos explorados en donde solo se obtiene una imagen.

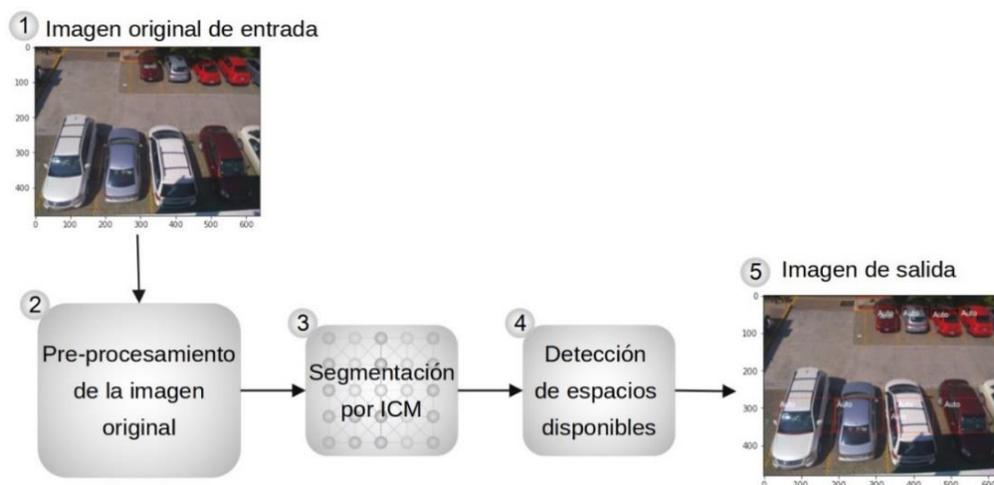


Figura 4 Método propuesto para detección de espacios disponibles en estacionamientos.

Tabla 1 Comparación de métodos de segmentación explorados.

Método	Ventajas	Desventajas
Manual	No demanda una programación compleja para la programación.	Requiere de un análisis de las imágenes a segmentar, y los parámetros no se ajustan para todas las imágenes.
Otsu	Presenta una buena respuesta en la mayoría de las imágenes en espacio de color HSV.	El algoritmo de implementación es complejo, además presentó un bajo rendimiento para imágenes en espacio RGB.
KNN	Buena respuesta en imágenes en espacios de color HSV y RGB.	Demanda un tiempo elevado de procesamiento y memoria para almacenar los datos de aprendizaje. Se requiere de un análisis de los datos de aprendizaje para mejorar el resultado de segmentación.
PCNN	Buena respuesta para imágenes en espacio de color RGB y HSV.	Demanda un costo computacional elevado para su implementación. Se requiere de la elección adecuada de sus parámetros.
ICM	Buena respuesta en imágenes con espacio de color HSV y RGB, reduce el costo computacional que demanda el modelo original, reduce la cantidad de parámetros para sintonizar.	Es necesario sintonizar correctamente sus parámetros para obtener una buena segmentación.

Fuente: Elaboración propia.

Una vez elegido el método de segmentación se diseñó un algoritmo que permitiera realizar el proceso de detección de automóviles con base a la segmentación generada por la red ICM, el cual se muestra en la figura 5. La primera parte del algoritmo consiste en recibir una imagen I , en espacio de color RGB y convertirla al espacio de color HSV generando I_{hsv} , la imagen resultante es dividida en dos regiones de interés, que corresponden a las zonas donde se encuentran los espacios del estacionamiento, obteniendo así, las sub-imágenes I_a e I_b ; en la figura 6 se presenta este proceso.

- 1 Adquirir una imagen a color RGB $\rightarrow I$;
- 2 Convertir la imagen I al espacio de color HSV $\rightarrow I_{hsv}$;
- 3 Seleccionar las dos regiones de interés de la imagen $I_{hsv} \rightarrow I_a, I_b$;
- 4 Usar el espectro hue para cada I_a, I_b , y aplicar operación de dilatación $\rightarrow I_{ha}, I_{hb}$;
- 5 Limitar colores de I_{ha} y I_{hb} menores a 90 de intensidad $\rightarrow I_{al}, I_{bl}$;
- 6 Normalizar las imágenes $I_{al}, I_{bl} \rightarrow I_{an}, I_{bn}$;
- 7 Aplicar segmentación por ICM con $e^{-\alpha F} = 0,4$; $e^{-\alpha T} = 0,5$ y $V_T = 21 \rightarrow I_{sa}, I_{sb}$;
- 8 Aplicar operación de apertura y cierre a las imágenes I_{sa}, I_{sb} ;
- 9 Etiquetar los objetos contenidos en las imágenes $I_{sa}, I_{sb} \rightarrow I_{Ea}, I_{Eb}$;
- 10 **for** Cada etiqueta en las sub-imágenes I_{Ea}, I_{Eb} **do**
- 11 | almacenar coordenadas x,y del objeto;
- 12 | Dibujar las coordenadas del objeto en la imagen original $I \rightarrow I_d$
- 13 **end**
- 14 **return** Imagen con detección de los automóviles $\rightarrow I_d$

Figura 5 Algoritmo para detección de automóviles por segmentación propuesto.

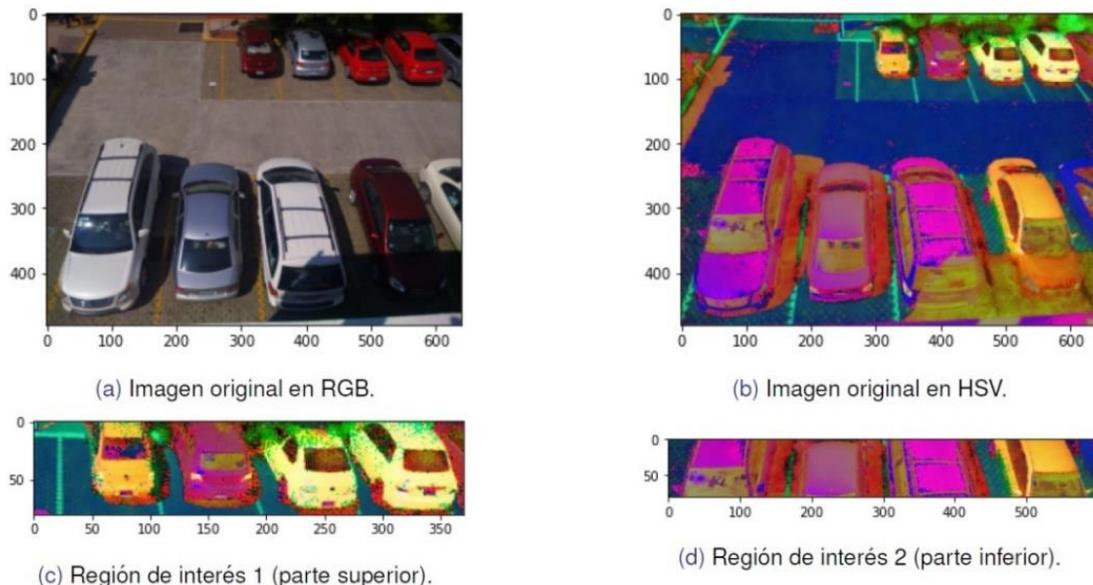


Figura 6 Resultados de la primera fase del algoritmo propuesto.

Posteriormente, de las imágenes I_a e I_b se extrae el espectro Hue y se aplica la operación de dilatación, seguido de una restricción de intensidad, donde los niveles menores a 90 son despreciados, obteniendo I_{al} e I_{bl} , que a su vez son normalizadas con valores de intensidad entre 0 y 1; las imágenes resultantes introducen a la red ICM, la cual se configura para generar 10 pulsos, con los siguientes valores de sus parámetros: $e^{\alpha_F} = 0.4$, $e^{\alpha_T} = 0.5$ y $V_T = 21$, obteniendo así 10 imágenes binarias por cada imagen introducida, de las cuales se elige la imagen con mayor entropía utilizando la ecuación 8 [Ma, 2010], donde p_1 , corresponde a la cantidad de valores de intensidad igual a 1 en la imagen binaria y p_0 , corresponden a los valores de intensidad igual a 0; con esto se obtienen las imágenes segmentadas I_{sa} e I_{sb} , este proceso se muestra en la figura 7, para una zona de interés.

$$H(s) = -p_1 \ln(p_1) - p_0 \ln(p_0) \quad (8)$$

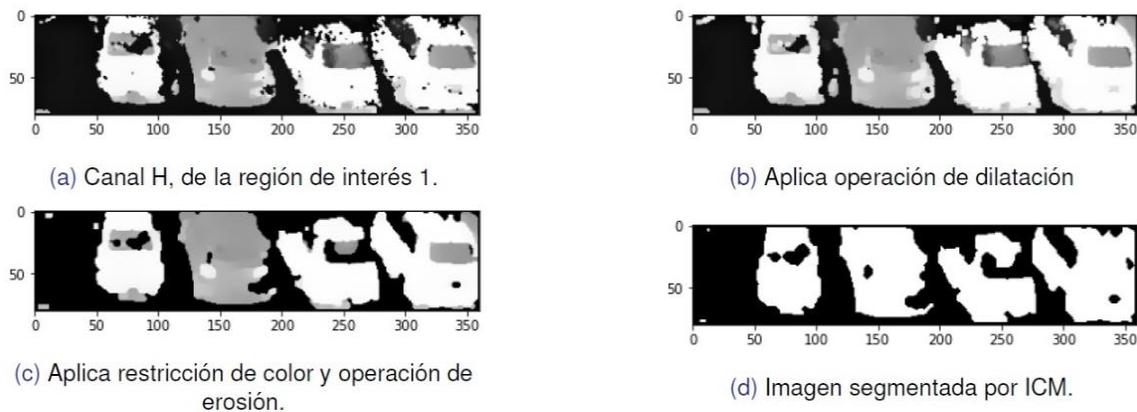


Figura 7 Etapa de pre-procesamiento y segmentación para la región de interés de la parte superior del estacionamiento

Obtenidas las imágenes segmentadas por la red ICM I_{sa} e I_{sb} , se les aplica el proceso de etiquetado para extraer los objetos contenidos en cada imagen, el resultado de esta operación aplicado a la sub-imagen presentada en la figura 7 inciso (d), se muestra en la figura 8, que corresponde a los cuatro objetos extraídos de la imagen, los cuales representan la información de cada automóvil.

Por último, se obtienen las coordenadas de cada objeto extraído de las imágenes I_{sa} e I_{sb} , para posteriormente colocarlas en la imagen original, con lo cual se indica

la detección de un espacio de estacionamiento ocupado, tal como se muestra en la figura 9.

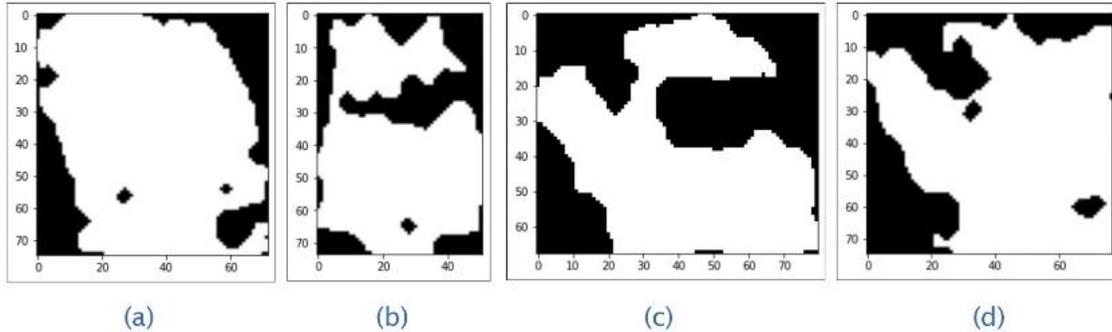


Figura 8 Extracción de objetos de una región de interés mediante proceso de etiquetado.

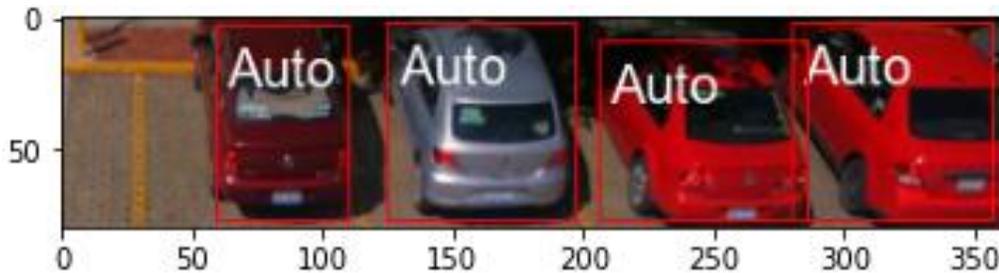


Figura 9 Detección de espacios de estacionamiento ocupados.

3. Resultados

Se llevaron a cabo pruebas del algoritmo propuesto (figura 9), con 82 imágenes de un estacionamiento, el cual está compuesto de cuatro tomas diferentes: centro, derecha, izquierda y lateral. En la tabla 2 presenta el porcentaje de efectividad promedio obtenido de las pruebas realizadas para las diferentes tomas del estacionamiento.

Tabla 2 Resultados obtenidos con la implementación del algoritmo propuesto.

Toma del estacionamiento	Imágenes de prueba	Efectividad clima nublado	Efectividad con clima soleado
Derecha	31	100%	80%
Centro	30	80%	75%
Izquierda	7	75%	80%
Lateral	4	60%	N/A

Fuente: Elaboración propia.

En la figura 10 se presenta el resultado de la implementación del algoritmo para una imagen de la parte centro, indicada en el inciso (a), y derecha, indicada en el inciso (b), del estacionamiento con clima nublado. Así mismo, en la figura 11, se muestran los resultados para una imagen de la parte izquierda, inciso (a), y lateral, inciso (b), del estacionamiento con clima nublado. Mientras que, en la figura 12 se muestra el resultado obtenido para imágenes de la parte izquierda, inciso (a), y centro, inciso (b), del estacionamiento con clima soleado.

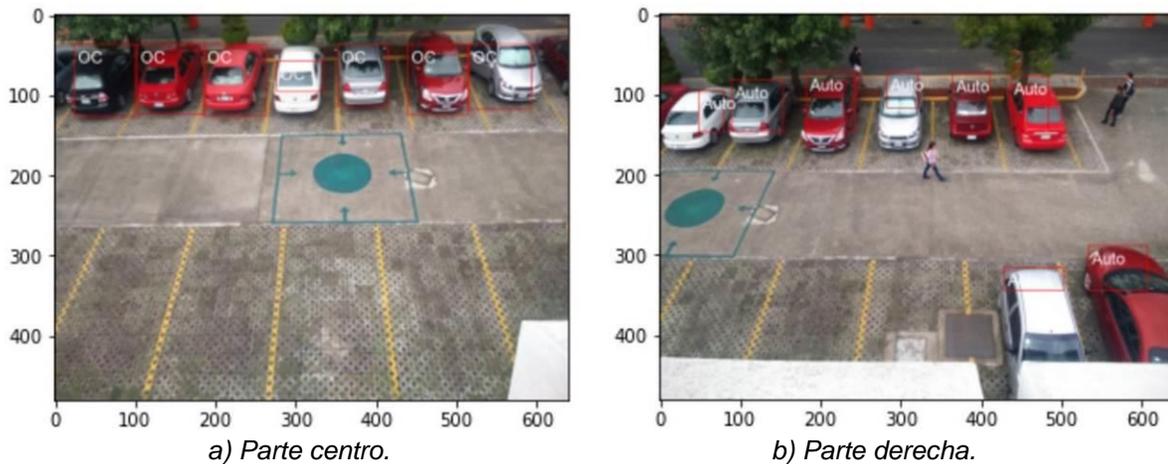


Figura 10 Resultado obtenido de la implementación del algoritmo propuesto para una imagen del estacionamiento con clima nublado.

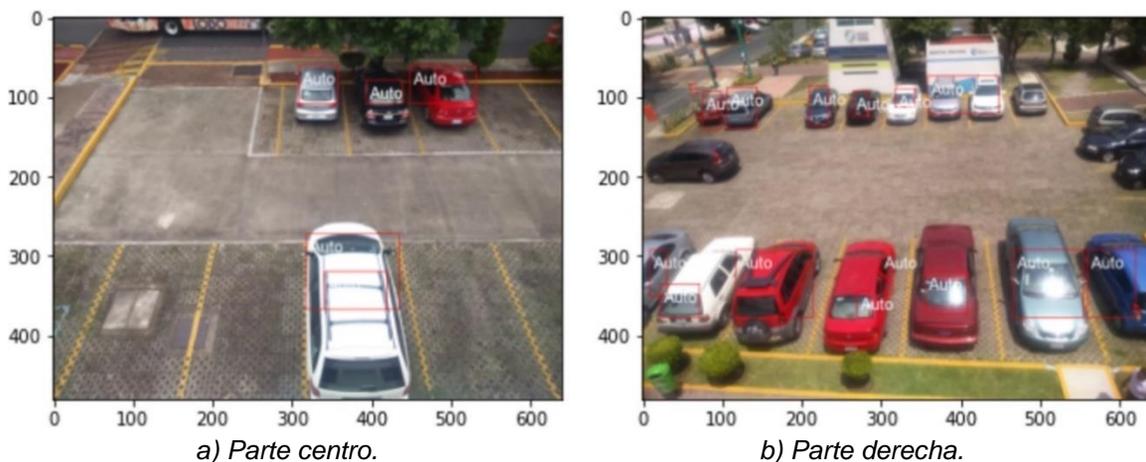


Figura 11 Resultado obtenido de la implementación del algoritmo propuesto para una imagen del estacionamiento con clima nublado.

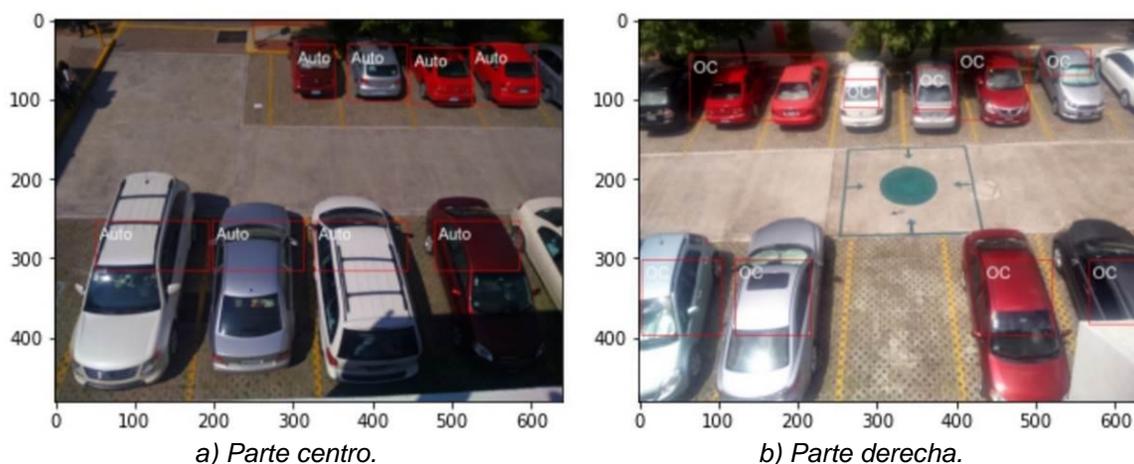


Figura 12 Resultado obtenido de la implementación del algoritmo propuesto para una imagen del estacionamiento con clima soleado.

4. Discusión

De acuerdo con los resultados obtenidos durante la implementación del algoritmo con las imágenes de prueba, se observó que en imágenes con iluminación homogénea se logró alcanzar un 100% de efectividad, mientras que con imágenes que presentan variaciones de luz, se obtuvo una efectividad máxima del 80%.

Los puntos detectados que pueden afectar el reconocimiento son: una mala ubicación de las zonas de interés, que ocasiona pérdida de información de los automóviles; efectos de sombra, que provoca la unión de dos objetos durante el proceso de segmentación; fondo de color distinto al piso del estacionamiento, que de igual forma, ocasiona la unión de dos o más objetos durante la segmentación y oclusión entre automóviles.

5. Bibliografía y Referencias

- [1] Cai, Y. B., Alvarez, R., Sit, M., Duarte, F. y Ratti, C. (2019). Deep learning-based video system for accurate and real-time parking measurement. *IEEE Internet of Things Journal*, 6(5):7693-7701.
- [2] Cuevas E., Zaldivar, D., y Pérez, M. (2013). *Procesamiento digital de imágenes con MATLAB y Simulink*. México: Alfaomega.
- [3] Ganesan, P., Rajini, V., Sathish, B.S. y Shaik, K. B. (2014). HSV Color Space Based Segmentation of Region of Interest in Satellite Images. *IEEE*

- International Conference on Control, Instrumentation, Communication and Computational Technologies, 101-105.
- [4] Huang, C., Tai, Y. y Wang, S. (2013). Vacant parking space detection based on plane-based hierarchical framework. *IEEE Transactions on Circuits and Systems for Video Technology*, 23(9):1598-1610.
- [5] Lindblad, T., Kinser, J. y Taylor, JG. (2013). *Image processing using pulse-coupled neural networks*. Springer.
- [6] Ma, Y., Zhan, K. y Wang, Z. (2010). *Applications of pulse coupled neural networks*. Springer: Berlin.
- [7] Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*. 9(1): 62-66.
- [8] Rodríguez, M. R. y Sossa, A. J. H. (2011). *Procesamiento y análisis digital de imágenes*. México: Alfaomega.
- [9] Suhr, J. K., y Ho, G. J. (2012). Fully-automatic recognition of various parking slot markings in around view monitor (avm) image sequences. *International IEEE Conference on Intelligent Transportation Systems*, 1294-1299.
- [10] Tatulea, P., Calin, F., Brad, R., Brâncovean, L. y Greavu, M. (2019). An image feature method for parking lot occupancy. *Future Internet*, 11(8):169.
- [11] Wazarkar, S. Keshavamurthy, B. N. y Hussian, A. (2018). Region-based segmentation of social images using soft knn algorithm. 125:93-98.