

DISEÑO DE UN ALGORITMO DE SEGMENTACIÓN DE OBJETOS Y CARRETERAS, ENFOCADO A SISTEMAS DE ASISTENCIA VEHICULAR

Juan Luis Burgos Bonilla

Instituto Tecnológico Superior de Misantla
juanluisburgosbonilla14@gmail.com

Luis Alberto Morales Rosales

Instituto Tecnológico Superior de Misantla
lamorales@itsm.edu.mx

Ignacio Algreto Badillo

Universidad Politécnica de Tlaxcala
ignacio.algreto@uptlax.edu.mx

Resumen

Los sistemas avanzados de asistencia al conductor (ADAS) son sistemas encargados de asistir al piloto en el proceso de conducción. Investigaciones recientes han demostrado que estos sistemas pueden prevenir hasta el 42% de los accidentes. Estos sistemas son desarrollados principalmente con visión artificial porque permite emular el comportamiento humano para analizar el entorno. Uno de los principales problemas para utilizar la visión por computadora es la segmentación, debido a que la carretera es un ambiente dinámico en el cual no se pueden aplicar técnicas tradicionales como la segmentación bimodal y obtener excelentes resultados. En este trabajo se presenta un algoritmo de segmentación de objetos en carretera, el cual consta de extracción de todas las regiones de la escena y análisis de muestras de la imagen para separar la carretera de todos los posibles objetos de interés, donde se demuestra que el principal inconveniente para la segmentación son las sombras. El algoritmo propuesto se pone a prueba en diferentes escenarios, donde presenta un 81.89%

de segmentaciones correctas de la carretera en distintas superficies y diferentes situaciones de iluminación.

Palabra(s) Clave(s): Algoritmos de extracción de regiones, segmentación, visión por computadora.

1. Introducción

Los sistemas avanzados de asistencia al conductor (*Advanced Driver Assistance Systems ADAS*) son soluciones tecnológicas aplicadas a automóviles que se encargan de monitorizar el ambiente para detectar riesgos y apoyar en el proceso de conducir, por lo tanto elevan la seguridad del pasajero, vehículo y en general todo el ambiente vial. Gracias a estos avances tecnológicos la sociedad puede contar con herramientas con el potencial de prevenir hasta un 42% de los accidentes de tránsito, además que también pueden ayudar a tener una mayor eficiencia de combustible y reducir contaminantes [14].

Los ADAS han sido desarrollados con una gran variedad de sensores como láser, infrarrojos, sonares, entre muchos otros, pero el sensor sobresaliente es la cámara porque permiten utilizar la visión artificial, misma que intenta emular la vista humana, la cual, le da una ventaja a los ADAS, porque la mayor parte de la información requerida para la toma de decisiones mientras se conduce es visual.

El potencial de la visión artificial es significativo en los ADAS pero la dificultad de su desarrollo la coloca dentro de las tareas más complejas de la computación. Su complejidad es lo que limita el tiempo de análisis, manteniendo un límite de velocidad de 40 km/h para que los sistemas funcionen adecuadamente. Por lo tanto el desarrollo de nuevos algoritmos más rápidos y el disminuir la complejidad de los existentes son los objetivos de las ciencias computacionales.

Uno de los componentes principales de la visión artificial es el procesamiento de imágenes, el cual es un conjunto de técnicas que se aplican a las imágenes digitales para mejorar o facilitar la búsqueda de información. El tratamiento de imágenes se divide en tres partes: pre-procesamiento, procesamiento y post-procesamiento.

El pre-procesamiento se basa en la aplicación de distintas técnicas como filtrado, transformación a escala de grises, ecualización, convolución, realce de bordes, etc. La meta fundamental es mejorar ciertas características que favorezcan las futuras operaciones sobre la imagen. En la carretera la luz, vibración y la temperatura pueden generar ruido en la captura de la imagen, por lo cual los objetos pueden estar sujetos a irregularidades que deben ser tratadas.

En la etapa de procesamiento se estudian las formas, texturas y colores que se encuentran en la imagen. Las técnicas empleadas para analizar y extraer las características se basan en la segmentación, que es la descomposición de la imagen. La segmentación es un paso muy importante porque en esta etapa es donde se selecciona la información de interés, pero el descomponer la imagen puede ser una tarea muy complicada porque en muchos casos las técnicas básicas como la segmentación bimodal no generan buenos resultados y son necesarios grandes cálculos y recursos computacionales para realizar la tarea.

Existen otras técnicas actuales que se han generado en investigación para obtener la segmentación como los algoritmos basados en vecinos, los cuales ofrecen mejores resultados para segmentar en distintos niveles, cuya función principal es hacer crecer las regiones de píxeles iterativamente utilizando comparaciones entre píxeles con una medida de similitud.

Pese al potencial de los algoritmos de segmentación por vecindario, tienen una gran cantidad de desventajas al aplicarlos a la carretera. Debido a los entornos dinámicos, iluminación variante y vibración, los algoritmos tienen desventaja porque son muy sensibles al ruido, dependen del punto de inicialización para generar una buena o mala segmentación y al ser iterativos tienden a consumir mucho recurso computacional.

Una de las tendencias en las ciencias computacionales es el desarrollar algoritmos de segmentación que faciliten la información para su interpretación en el post-procesamiento, ya que si se generan algoritmos más eficientes es posible aumentar la precisión y disminuir la complejidad computacional. Éste es el objetivo principal del trabajo presente, ya que se deben proporcionar algoritmos primitivos

para la realización de procesos cuyo resultado tiene una implicación importante en los procesos de la visión artificial.

El post-procesamiento se utiliza para interpretar y analizar los resultados. En esta etapa se emplean técnicas de reconocimiento de patrones para la representación numérica de los resultados de la segmentación. Esta etapa depende completamente de la calidad de la segmentación de la información, por lo tanto si la segmentación no es buena, la precisión de la interpretación de los resultados será nula. Y ésta es una de las grandes necesidades que resuelve el trabajo propuesto, generando resultados esenciales para el reconocimiento de objetos en la carretera.

Debido al gran problema que representa el segmentar la carretera para extraer las áreas y objetos de interés se han implementado soluciones existentes que de manera estratégica buscan adecuarse a las condiciones de la carretera. Dentro de los métodos de mayor popularidad se encuentran los que se basan en representar la carretera con una función que describa los píxeles que la conforman [1] [6] [11], esto permite extraer todos los objetos que se puedan encontrar dentro de ella. Uno de los inconvenientes son las sombras porque pueden afectar significativamente la segmentación. Existen cálculos estadísticos para reducir sombras [12] que pueden mejorar la detección de la carretera pero con el riesgo de pérdida de información al procesar la imagen.

Otro método para segmentar la carretera es analizar muestras, las cuales pueden ser valores obtenidos directamente de la imagen o del análisis de la textura en pequeñas áreas [7] [8], esto permite diferenciar la carretera de los objetos y pueden eliminarse algunas sombras.

Debido a la complejidad de eliminar sombras y determinar el área de interés se ha incrementado el desarrollo de sistemas basados en análisis de líneas para seleccionar el carril [2] [3] [5] [6] [9] [10] [11], que: a) utilizan información proporcionada por operadores como Sobel [2] [3] y Canny [10] [11] para extraer bordes y b) utilizan la transformada de Hough [2] [3] [6] para seleccionar y discriminar las líneas. Una de las opciones para mantener un seguimiento en las

líneas y proporcionar una perspectiva continua del área de interés es utilizar técnicas de seguimiento como el filtro Kalman [2].

Por otro lado se encuentra la búsqueda basada en conocimiento [4] [5] [9] [11], la cual utiliza la información proveniente de las líneas en la carretera y/o de sensores láser [4] para reducir el área de búsqueda. La búsqueda consiste en analizar la forma de los objetos empleando extracción de características como HOG (*Histogram of Oriented Gradients*) [4] [5] y clasificadores como SVM (*Support Vector Machines*) [5] [9] [11]. Éste método es robusto para detectar y discriminar objetos, pero el inconveniente es el alto costo computacional que se requiere para realizar la detección.

Todos los trabajos previos muestran que la segmentación de la carretera es un problema con una tasa de detección muy baja, donde las condiciones del medio son impredecibles y no es posible aplicar una técnica a todos los escenarios, por ello algunos buscan una solución estudiando bordes y colores, mientras que otros buscan una solución reconociendo cada objeto.

Independientemente de la técnica a emplear, la segmentación es primordial, por ello en este trabajo se presenta un algoritmo para la segmentación de todos los objetos en carretera basada en extracción de regiones y análisis de muestras para separar la carretera de todos los objetos presentes en la escena.

2. Desarrollo

La metodología propuesta consta de una cámara y una computadora a bordo del automóvil, la cámara es posicionada de manera estratégica en el interior junto al espejo retrovisor, lo que permite tener una perspectiva adecuada del frente del automóvil y estar protegida del viento que puede causar vibración. La figura 1 muestra de manera general los bloques que conforman al sistema.

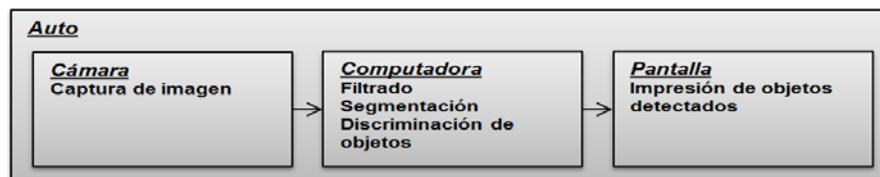


Figura 1 Diagrama general del sistema.

La carretera es un ambiente en constante cambio y en cada fotograma se encuentran variaciones en los objetos, además de cambios de iluminación, por lo tanto es necesario segmentar cada imagen, para extraer las regiones y eliminar todas aquellas regiones que conformen la carretera. La figura 2 muestra el proceso de segmentación, el cual se aplica a cada imagen.

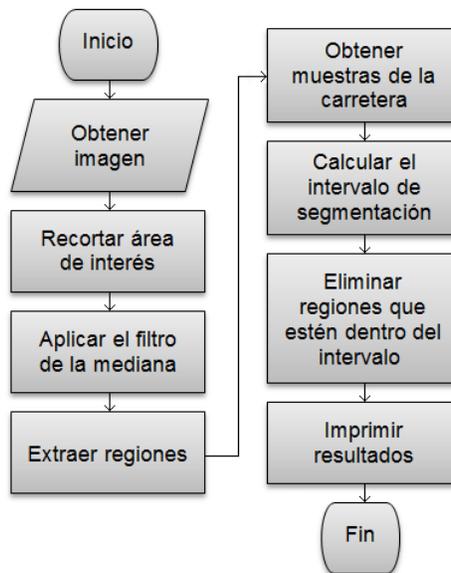


Figura 2 Diagrama de flujo del proceso de segmentación.

Después de obtener la imagen original como se muestra en la figura 3, se recortan los bordes innecesarios de la imagen original como muestra la figura 4a y se selecciona el área de interés, que se puede describir con un trapecio, debido a que es la forma como se puede apreciar la carretera. Utilizando un trapecio como se ve en figura 4b, se pueden eliminar los laterales y la mayor parte del cielo, de esta manera el número de datos a procesar se reduce un 30%.



Figura 3 Imagen original.



Figura 4 Determinación del área de interés.

Uno de los principales inconvenientes al obtener imágenes en carretera es que están expuestas al ruido, por eso se propone utilizar el filtro de la mediana porque permite remarcar bordes mientras se suaviza la imagen.

Para extraer las regiones, se crea una matriz acumuladora para guardar la etiqueta de la región de cada pixel y debe tener el mismo tamaño que la matriz de los datos, donde sólo el pixel (2,2) tiene el valor uno y el resto en ceros. Se menciona que al final del proceso, esta matriz contendrá valores que van del 1 a k , donde k representa el número de regiones encontradas en la imagen.

El proceso para asignar cada pixel a una región requiere realizar una comparación de cada pixel con sus 6 vecinos como muestra la figura 5. El realizar la clasificación de esta manera asegura que la segmentación siempre sea la misma al aplicarla varias veces en la misma imagen, esto permite tener una menor variación de resultados cuando se trabaja en secuencia de imágenes.

225	225	225	91	91	91	91
225	225	225	91	91	91	91
225	91	91	91	91	91	91
225	225	225	91	91	155	155
122	122	122	91	91	155	155
122	122	122	91	91	155	155
122	122	122	91	91	155	155

Figura 5 Matriz de datos con selección de vecinos del pixel (2,2).

Se debe comparar la similitud del pixel actual con cada uno de los pixeles vecinos y guardar el parentesco con verdadero "T" o falso "F" como muestra la figura 6.

T	T	T
T	255	T
T	F	F

Figura 6 Matriz de parentesco.

De la matriz acumuladora se toma el número de región de los vecinos similares y del pixel actual, para posteriormente extraer la moda. La figura 7 ejemplifica la selección de vecinos en la matriz de regiones en base al parentesco.

0	0	0	0	0	0	0	0
0	1	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

Figura 7 Selección de los valores de los vecinos y del pixel actual.

Se calcula la moda para obtener la región más sobresaliente del vecindario, el nuevo valor a asignar al pixel actual y a sus vecinos como muestra la figura 8.

1	1	1	0	0	0	0	0
1	1	1	0	0	0	0	0
1	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0

Figura 8 Actualización del número de región del pixel actual y de sus vecinos.

El utilizar la moda para actualizar las regiones previamente asignadas ayuda a reacomodar cada pixel a la región que tenga un número mayor de vecinos, lo cual obliga a separar las regiones colindantes que tengan bordes parecidos. La figura 9 muestra el resultado de realizar la asignación de región para todos los pixeles.

1	1	1	2	2	2	2
1	1	1	2	2	2	2
1	2	2	2	2	2	2
1	1	1	2	2	3	3
4	4	4	2	2	3	3
4	4	4	2	2	3	3
4	4	4	2	2	3	3

Figura 9 Asignación final de regiones.

El proceso anterior esquematizado con las matrices muestra el funcionamiento del algoritmo de extracción de regiones, el cual está definido en el Pseudocódigo 1:

```

funcion Extraer_Regiones(datos)
  establecer filas, columnas = tamaño(datos)
  establecer regiones(filas, columnas) = 0
  establecer region = 1
  establecer matriz(1,1) = region

  establecer umbral = n
  hacer j = 2 hasta columnas-1
    hacer i = 2 hasta filas-1
      asignar varvecinos = vecinos(|matriz(i,j)-vecino|<umbral)
      asignar varregiones = regiones(varvecinos)
      si varregiones = 0
        asigna varmoda = region
        asigna region = region + 1
      si no
        asigna varmoda = calcularmoda(varregiones)
      fin si
      asigna regiones(varvecinos) = varmoda
    fin hacer
  fin hacer
  salida regiones
fin de funcion
    
```

Para seleccionar el intervalo de umbralización se obtienen muestras de distintas coordenadas de la imagen. Se emplea una máscara en forma de trapecio como muestra la figura 10. El trapecio obliga a seleccionar en su mayoría pixeles que están dentro de la carretera, esto se debe a que se ajusta a la forma de la carretera desde la perspectiva de la cámara.

116	115	114	25	25	24	25	25	11	9	11
114	116	23	25	26	23	26	26	25	10	11
115	23	26	23	201	202	103	25	26	23	9
24	25	26	23	202	203	200	24	23	24	23
24	26	26	201	205	203	204	203	25	23	26
23	23	25	26	24	24	24	26	24	25	24
24	24	24	26	25	24	26	26	26	25	24
24	25	25	25	23	26	23	25	23	23	26

Figura 10 Selección de muestras en la matriz de datos.

En la figura 11 se observa que las muestras obtenidas se ordenan de manera ascendente y se separan en segmentos de datos parecidos.

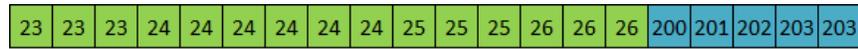


Figura 11 Muestras ordenadas.

La asignación de segmentos se realiza mediante la diferencia de un valor actual y el anterior. Si su diferencia es menor que el umbral N entonces quiere decir que pertenecen al mismo segmento. Este método permite incrementar el intervalo de segmentación y por lo tanto describir mejor la carretera. Esta forma de ordenar datos y clasificar segmentos es una de las aportaciones de este trabajo que mejora la segmentación debido a que busca un conjunto de valores similares dependiendo de N . En la figura 11 se tienen dos intervalos de umbralización de acuerdo a los valores obtenidos de la muestra.

La condición para seleccionar el segmento que describe la carretera, es que debe cumplir que sus valores comiencen en el origen inferior de la imagen y se encuentren dispersos, además de que sea el primero o el segundo segmento de mayor tamaño.

Para eliminar la carretera de la imagen se combina la extracción de regiones con el intervalo de segmentación. En este proceso se extraen las regiones donde sus valores tengan intersección con el intervalo umbral. La figura 12.a muestra la selección de regiones que pertenecen a la carretera.

Las regiones seleccionadas como pertenecientes a la carretera son eliminadas y de esta manera sólo quedan las regiones sobresalientes como se muestra en la figura 12.b.

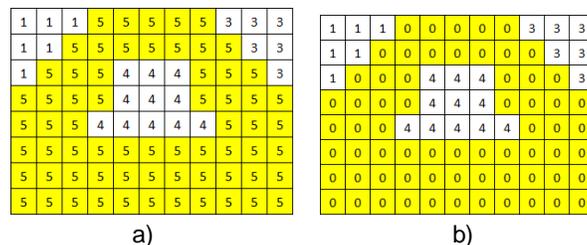


Figura 12 Selección de regiones con el intervalo de segmentación (a) y eliminación (b).

El proceso anterior esquematizado con las matrices muestra el funcionamiento del algoritmo de selección de muestras y eliminación de regiones, mismo que se explica en el Pseudocódigo 2:

```
funcion Eliminar_Regiones(datos, regiones)¶
¶
establecer muestras = obtener_muestras(datos)¶
establecer muestras_ordenadas = ordenar(muestras)¶
establecer filas = tamaño(muestras_ordenadas)¶
establecer acumulador(filas, 2) = 0¶
establecer segmento = 0¶
establecer umbral = N¶
asignar acumulador((1-filas), 1) = muestras_ordenadas¶
¶
hacer i = 2 hasta tamaño(muestras_ordenadas)¶
si (acumulador(i, 1) - acumulador(i-1, 1)) > umbral¶
asignar segmento = segmento + 1¶
fin si¶
asignar acumulador(i, 3) = segmento¶
fin hacer¶
¶
establecer segmentos = valores_unicos(acumulador((1-filas), 3))¶
hacer i = 1 hasta tamaño(segmentos)¶
asignar dispersos = revisar_posiciones_en_acumulador(segmentos(i))¶
si dispersos = verdadero¶
asignar carretera = segmentos(i)¶
fin si¶
fin hacer¶
¶
establecer valores_carretera = buscar_valores(acumulador, carretera)¶
establecer coordenadas = datos(valores_carretera)¶
establecer regiones_carretera = buscar_regiones(regiones, coordenadas)¶
asignar regiones_carretera = 0, ¶
establecer mascara = (regiones > 0) = 1¶
establecer segmentacion = datos + mascara¶
salida segmentacion¶
fin funcion¶
```

El algoritmo propuesto extrae todas las regiones existentes en la escena. El analizar el intervalo de valores que conforman a la carretera y combinarlo con las regiones detectadas, permite eliminar la carretera resaltando todos los objetos que pueden ser de interés, facilitando su análisis, lo que da pauta para la implementación de distintos algoritmos para interpretar o reconocer los objetos.

Por la generalización del método propuesto, es posible aplicarlo a carretera de cualquier color e incluso a carreteras rurales. El algoritmo de segmentación es importante en la detección de objetos en carretera, especialmente en situaciones donde hay sombra, no hay líneas pintadas o existen baches, que es algo recurrente en las carreteras de México. Así, el diseño e implementación del algoritmo es primordial para sistemas automatizados o inteligentes que permitan a un vehículo proporcionar seguridad o auto-guiarse.

3. Resultados

Los algoritmos fueron evaluados en dos conjuntos de imágenes:

- El primer conjunto de pruebas es denominado KITTI [14], proporcionado por el Instituto Tecnológico de Karlsruhe y el Instituto Tecnológico de Toyota, como un conjunto de pruebas enfocadas a la visión artificial aplicada a la detección de objetos en carretera.
- El segundo conjunto de pruebas fue obtenido de una cámara a bordo del automóvil en carreteras de la ciudad de México, Puebla y Tlaxcala. Este conjunto de imágenes contiene carretera de asfalto, pavimento y ladrillos, además de una gran diversidad en sombras y cambios de color en la carretera.

Base de datos KITTI

Consta de distintos conjuntos de imágenes enfocados a la segmentación de la carretera, seguimiento de objetos y reconocimiento de objetos. Todos los conjuntos tienen gran diversidad de situaciones como imágenes con sombras, cambios de luz, tráfico, entre otras, lo que hace a KITTI un test completo para evaluar fortalezas y debilidades de los algoritmos.

La base de datos para evaluar la segmentación de la carretera se conforma de 290 imágenes clasificadas en tres tipos:

- UU – calles sin líneas
- UM – calles con líneas
- UMM – calles con múltiples líneas

La figura 13 muestra un ejemplo de la aplicación de la metodología propuesta en una imagen del conjunto KITTI.

La mayor parte de las imágenes no contienen automóviles, por lo tanto sólo se evalúa la segmentación de la carretera. La tabla 1 muestra los resultados de la segmentación de carretera en las imágenes de KITTI.

En este conjunto se evaluó únicamente la calidad de la segmentación de la carretera. Observándose que la mejor segmentación se encontró en las carreteras de multicarril.



Figura 13 Ejemplo de aplicación del algoritmo a una imagen del conjunto KITTI.

Tabla 1 Resultados de eliminación de carretera en KITTI.

Clase	Segmentación
UU	50%
UM	74%
UMM	90%

Base de datos de la cámara abordo

Con una cámara a bordo de un automóvil se recolectaron muestras de distintas situaciones en distintas horas del día, las cuales son:

- Carreteras con líneas y sin líneas
- Carreteras uniformes y con cambios de color
- Carreteras oscuras y claras
- Carreteras con sombras
- Automóviles en movimiento frente al automóvil y a los costados

Este conjunto se divide en dos tipos de carreteras:

- Carreteras de pavimento o asfalto.
- Carreteras de ladrillos.

Resultados de imágenes de carretera de pavimento y asfalto

El conjunto de imágenes de carreteras con pavimento y asfalto consta de una colección de 1846 imágenes que contienen al menos uno o más automóviles. Las imágenes son clasificadas en 4 tipos:

- CU - carretera uniforme sin sombras
- CUS - carretera uniforme con sombras
- CC - carretera con cambios de color sin sombras

- CCS - carretera con cambios de color con sombras

La figura 14 muestra un ejemplo de la aplicación de los algoritmos operando sobre una imagen recolectada con la cámara instalada en el automóvil.

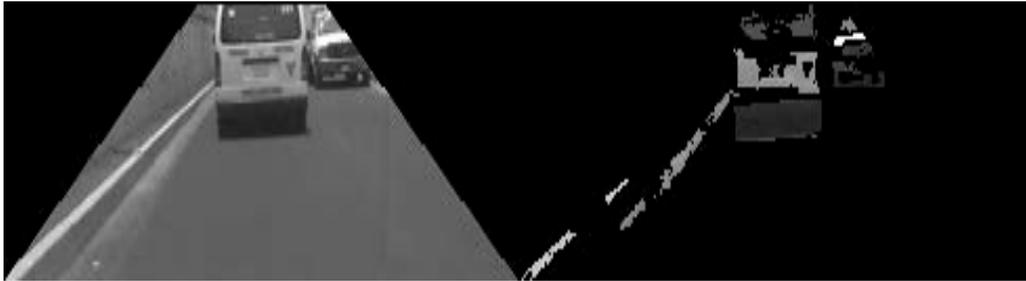


Figura 14 Ejemplo de segmentación a una imagen con asfalto.

En este conjunto se evalúa el número de veces que se segmenta correctamente un objeto en el número de imágenes donde aparece, por lo tanto se evalúan en secuencias de imágenes. La tabla 2 muestra los resultados obtenidos de las dos clases:

- Automóviles en el frente
- Automóviles siendo rebasados

Tabla 2 Resultados de la segmentación continua de objetos en carretera.

Clase	Frente	Rebase
CU	90.99%	92.65%
CUS	57.14%	98.15%
CC	90.06%	97.00%
CCS	76.19%	72.73%

Este conjunto se encuentra mejor distribuido y en él se pueden apreciar de una manera clara, que las sombras son la principal debilidad de la segmentación.

Resultados de imágenes de carretera de ladrillos

El conjunto de imágenes de carreteras de ladrillos consta de una colección de 740 imágenes. La figura 15 muestra un ejemplo de segmentación.



Figura 15 Ejemplo de segmentación a una imagen con ladrillos.

La mayor parte de las imágenes no contienen automóviles pero sí sombras. Para el conjunto se obtuvo el 86.49% de segmentaciones correctas de la carretera.

4. Discusión

Los resultados descritos en la sección anterior muestran una mala segmentación en las imágenes que contienen sombra, principalmente todas aquellas donde las sombras cubren gran parte de la carretera, al tener un cambio significativo en el color, provoca que el algoritmo lo considere como un objeto ajeno a la carretera.

La tabla 1 muestra que las imágenes *UU* tienen una precisión del 50%, la mala detección no es a causa de no tener líneas de carril, esta se debe a que son carreteras de dos carriles y en su mayoría están rodeadas de árboles y edificios, los cuales generan sombras de gran tamaño.

En el caso de las *UMM* el alto índice se debe a que la mayor parte de carreteras tienen cuatro o más carriles, y por ser muy grandes, son menos afectada por la sombras.

La tabla 2 en su apartado *CUS – Frente* reporta que la tasa de detección es muy baja debido a que los objetos que se desplazan frente al automóvil pueden ser afectados por las sombras al moverse, por lo tanto, el objeto cambia su color constantemente. Si se compara toda la columna uno y dos de la tabla 2 es evidente que existe una mejor segmentación para los automóviles que están siendo rebasados, y esto es ocasionado por el acercamiento a los automóviles mientras se rebasan.

Para comparar resultados con investigaciones relacionadas se tomaron dos trabajos: el primero basado en conocimiento [4] y el segundo basado en valores de pixeles [6].

La figura 16 muestra la comparación del trabajo [4] con el presentado. En esta figura se compara la tasa de detección de los automóviles.

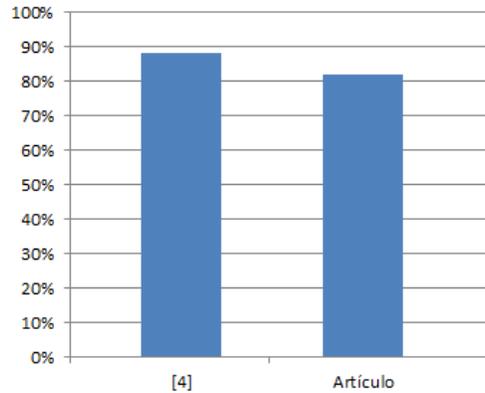


Figura 16 Comparación de resultados en detección de vehículos.

Los resultados del trabajo [4] sobresalen en comparación al algoritmo propuesto debido a que analiza el objeto con sensor láser y cámara, teniendo la ventaja de que el láser no es afectado por las sombras como es en el caso del trabajo presente, aunque [4] tiene un alto costo computacional por el descriptor de HOG y Haar-like.

La figura 17 muestra la comparación del trabajo [6] con el presentado. En esta figura se compara la tasa de segmentación de la carretera.

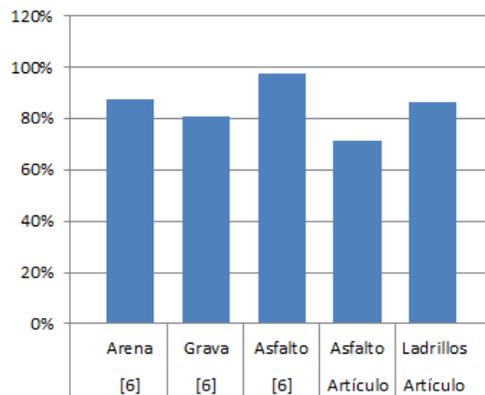


Figura 17 Comparación en resultados de segmentación de carretera.

Los resultados del trabajo [6] son superiores en comparación del algoritmo propuesto, esto puede deberse a que la colección de resultados reportados del trabajo [6] no demuestra tener segmentación con presencia de automóviles, mientras que el trabajo presente, se reporta en su mayoría imágenes con vehículos.

El que existan automóviles en la carretera dificulta la segmentación porque la información de la carretera se reduce en función al área que ocupe el vehículo dentro de ella. El área que puede ocupar un vehículo dependerá de la distancia de observación de la cámara.

5. Conclusiones

Uno de los principales problemas para realizar una segmentación de la carretera son las sombras, porque ellas afectan significativamente al sistema. Son un problema difícil de solucionar porque dependiendo el tipo de carretera (obscura, clara) es como se pueden percibir. Las sombras claras son hasta cierto punto fácil de tratar pero las oscuras son muy difíciles porque la similitud con la carretera es nula, por lo tanto se puede interpretar como un objeto ajeno a la carretera. Por otro lado, la carretera muy clara, se comporta de forma similar a las sombras. Al ser la superficie muy clara, la luz que se refleja puede cambiar la percepción del color de la carretera a una gran distancia y el sistema puede confundirse de manera similar al caso de las sombras.

El utilizar formas para delimitar áreas de interés, por ejemplo trapecios para el caso de intentar ajustar el área de la carretera, pueden reducir estratégicamente el área de búsqueda, principalmente porque permite descartar información de manera rápida y evitar cálculos y análisis en zonas que no contienen información de importancia.

6. Bibliografía y Referencias

- [1] Y. Xia, M. Huang, W. Cui, F. Wang, X. Chen, "A Novel On-Road Object Detection Approach Based on Vision". 2009 International Conference on Measuring Technology and Mechatronics Automation. Abril 2009. Pp. 440 – 443.

- [2] Y. Wang, W. Deng, S.Zhang, Y. Zhang, "A lane departure warning system developed under a virtual environment". *Informative and Cybernetics for Computational Social Systems*. Octubre 2014. Pp. 63 – 67.
- [3] M. Hammond, G. Qu, O. A. Rawashdeh, "Deploying and Scheduling Vision Based Advanced Driver Assistance Systems (ADAS) on Heterogeneous Multicore Embedded Platform". *2015 Ninth International Conference on Frontier of Computer Science and Technology*. Agosto 2015. Pp. 172 – 177.
- [4] F. Garcia, A. Ponz, D. Martin, A. de la Escalera, J. M. Armingol, "Computer vision and laser scanner road environment perception". *IWSSIP 2014 Proceedings*. Mayo 2014. Pp. 63 – 66.
- [5] Y. Deng, H. Liang, Z. Wang, J. Huang, "An integrated forward collision warning system based on monocular vision". *Robotics and Biomimetics (ROBIO)*. Diciembre 2014. Pp. 1219 – 1223.
- [6] Z. Wan-zhi, W. Zeng-cai, "Rural Road Detection of Color Image in Complicated Environment". *International Journal of Signal Processing, Image Processing and Pattern Recognition*. Vol. 6. No. 6. 2013. Pp. 161 – 168.
- [7] J. M. Álvarez Álvarez, A. M. López, "Road Detection Based on Illuminant Invariance". *IEEE Transactions on Intelligent Transportation Systems*. Vol. 12. Octubre 2010. Pp. 184 – 193.
- [8] S. Graovac, A. Goma, "Detection of Road Image Borders Based on Texture Classification". *International Journal of Advanced Robotic Systems*. Vol. 9. Octubre 2012. Pp. 242.
- [9] S. Zhou, J. Gong, G. Xiong, H. Chen, K. Iagnemma, "Road detection using support vector machine based on online learning and evaluation". *Intelligent Vehicles Symposium (IV)*. Junio 2010. Pp. 256 – 261.
- [10] R. Chen, H. Xiao, X. Dou, W. Hou, "Research on Recognition Methods of Bus Front Road Condition Based on Video". *Image and Graphics (ICIG), 2013 Seventh International Conference*. Julio 2013. Pp. 439 – 442.
- [11] M. A. Sotelo, J. Nuevo, L. M. Bergasa, M. Ocana, I. Parra, D. Fernandez, "Road Vehicle Recognition in Monocular Images". *Proceedings of the IEEE*

- International Symposium on Industrial Electronics. ISIE 2005. Junio 2005. Pp. 1471 – 1476.
- [12] B. Wang, V. Frémont, “Fast road detection from color images”. Intelligent Vehicles Symposium (IV). Junio 2013. Pp. 1209 – 1214.
- [13] J. Fritsch, T. Kuehnl, A. Geiger, “A New Performance Measure and Evaluation Benchmark for Road Detection Algorithms”. International Conference on Intelligent Transportation Systems (ITSC). 2013.
- [14] Aria Etemad, euroFOT study demonstrates how driver assistance systems can increase safety and fuel efficiency. 2012.

7. Autores

El Ing. Juan Luis Burgos Bonilla es ingeniero en sistemas computacionales egresado y actualmente estúdiante de posgrado del Instituto Tecnológico Superior de Misantla. Su línea de investigación se enfoca en la visión artificial y el procesamiento de imágenes.

El Dr. Luis Alberto Morales Rosales es egresado del INAOE en el área de Ciencias Computacionales. Actualmente, es coordinador del posgrado en sistemas computacionales del Instituto Tecnológico Superior de Misantla. Las líneas de investigación que desarrolla son cómputo móvil y cómputo inteligente. En particular, se enfoca en el desarrollo de algoritmos de orden parcial difuso para la coordinación de eventos en entornos distribuidos, el desarrollo aplicaciones inteligentes para educación especial y explora la minería de datos aplicada a la toma de decisiones.

El Dr. Ignacio Algreto Badillo recibió el grado por el INAOE en el 2008. Se ha desempeñado como profesor-investigador de tiempo desde el 2014 en la Universidad Politécnica de Tlaxcala. Él es miembro del SNI nivel 1 desde el 2011, tiene más de 80 artículos científicos, es revisor en varios comités nacionales e internacionales, es líder de varios proyectos y sus líneas de investigación son enfocadas en el diseño y desarrollo de sistemas digitales, arquitecturas reconfigurables, sistemas criptográficos, aceleración en hardware para aplicaciones específicas, y aplicaciones de robótica.