



Universidad Nacional Autónoma de México  
Posgrado en Ciencia e Ingeniería de la Computación  
Facultad de Estudios Superiores Cuautitlán

# **Segmentación de imágenes digitales sobre la base de la información integral del color**

## **T E S I S**

**Qué para optar por el grado de:**

**Doctor en Ciencias  
(Computación)**

**Presenta:**

**M. en C. Rodolfo Alvarado Cervantes**

**Tutores:**

**Dr. Edgardo M. Felipe Riverón**  
Centro de Investigación en Computación  
Instituto Politécnico Nacional

**Dr. Vladislav Khartchenko**  
Facultad de Estudios Superiores Cuautitlán

Cuautitlán Izcalli, Estado de México, febrero de 2017



Universidad Nacional  
Autónoma de México



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

## **Dedicatoria**

**A mi Papá con infinito amor y cariño, a quien le debo absolutamente todo, que es y siempre ha sido mi verdadero y único héroe... de quien, aún ahora, aprendo con su ejemplo lo verdaderamente importante en la vida: el amor, la familia y el conocimiento de la verdad... fomentó en mí la búsqueda por el conocimiento, lanzándome a una aventura sin igual; su incondicional amor y sabiduría alimentan mi alma desde que tengo memoria... que arde como flama inextinguible en lo más hondo de mi ser, hasta el final de todos los tiempos...**

A mi mamá con infinito amor...

A mi queridísima Tía Chole (Ma Soledad Alvarado Martínez), quien me mostró además de su inmenso cariño, su gran valor y gallardía durante los peores momentos de mi vida...

A mis hermanas Susana Carolina Alvarado Cervantes, Adriana Alvarado Cervantes, Gabriela Alvarado Martínez y Olivia Alvarado (Caro, Ady, Gaby y Oli), a quienes quiero por sobre todas las cosas...

A mi ahijada Ximena Castellero Alvarado y a mi ahijado Yulian Omar Cervantes Bernal; y a mis queridísimas sobrinas y sobrinos:

Daniella Soizic y Audrey Megan Rubalcava Alvarado

Evan y Gohan Sotres Alvarado

Jaime Emilio Hernández Alvarado y Andrés Hernández Alvarado

... a quienes les dedico mi obra y mis mejores esfuerzos por toda la vida.

A mi querida tía Juana Cervantes Macías, por el enorme cariño que siempre me ha tenido y que recordaré por siempre...yo nunca te hago de menos, al contrario... siempre estuviste... estás y estarás al frente conmigo...

A mis cuñados: Jesús Sotres Vélis, Leonardo Rubalcava Torres y Jaime Salvador Hernández Hurtado... por aceptarme y formar tan bellas familias con mis amadísimas hermanas.

A mis sobrinos y sobrinas: Iván Ramos, Giovanni Ramos, Bryan Alexis Espinoza Cervantes, JR Noel Francisco Ramos Manríquez, Leonardo Javier Ramos Manríquez,

Josefina Hernández Bernal, Daniel Cervantes Franco, Moisés Cervantes Franco, Josué Cervantes Franco, Maira Trinidad Cervantes Franco (Trina), Karina Magdaleno Cervantes, Aarón Osorio Cervantes, Enrique Cervantes Amador (Quiques), Luis y Alan Chávez, Horus Israel Villegas de Toro y Elsa Esther Felipe Güitrón (Tanita).

A mi querida tía Roma (Romelia Victoria Cervantes Macías), por haberme querido y cuidado mucho, tanto a mi como a mi Mamaciria, y por ser un verdadero ejemplo de abnegación, fidelidad y de fortaleza frente a la adversidad...

A mis sobrinos-primos Diego José Espinoza Cervantes y Alejandro José Cervantes Bernal, de los que me siento y siempre me he sentido muy orgulloso: verdaderos campeones en todos los frentes... de nobleza de espíritu y altura de metas... nacidos para luchar y llegar a las más altas cumbres...

A mi sobrino-primo Edgar Leonardo Cervantes Bernal, de quien me siento y siempre me he sentido muy orgulloso... Quien a sus escasos 9 años me dio, en un momento crítico de mi vida, la chispa que me permitió llegar finalmente a esta gran Meta tras una increíble e inenarrable odisea... de nobleza de espíritu y altura de metas... al luchar alcanzarás las más altas cumbres...

A la memoria de mi querido Hermano-Primo: Conrado Cervantes Hernández (Tito) 20 de Agosto 1967 - 12 de Septiembre 2015, que comparte con Dios su Divina Gloria por toda la Eternidad... que en paz descanses mi Querido Hermano y goces de la gracia y gloria de Dios por toda la eternidad... de tu Hermano-Primo Rudy que nunca olvidará todas las maravillosas aventuras que compartimos ni todo lo que vivimos... Amén.

A la memoria de mi Mamaciria (Ciria Macías Ornelas). 1920 – 28 Enero 2013 que comparte con Dios su Divina Gloria por toda la Eternidad... por enseñarme la grandeza oculta en la humildad... por tu gran cariño y continuos cuidados desde que tengo memoria... por todo el tiempo que compartimos...

A la memoria de mi abuelita Amalia Martínez Ortiz. 1901 – 1996 que comparte con Dios su Divina Gloria por toda la Eternidad... por tu gran cariño y continuos cuidados desde que tengo memoria... por todos los momentos gratos que pasamos juntos... por esos tacos de frijoles que tanto extraño...

A la memoria de mi abuelito Antonio Alvarado Carrillo (Mi Papatón). 1902 – 1982 que comparte con Dios su Divina Gloria por toda la Eternidad... por todas sus valiosas enseñanzas que nunca olvidaré... ¿Qué es gramática?...

A la memoria de mi abuelito Salvador Cervantes. 1920– 1951 que comparte con Dios su Divina Gloria por toda la Eternidad... a quien nunca conocí pero que siempre quise....

A la memoria de mis mejores amigos de los que aprendí el verdadero significado de la lealtad y la fidelidad, que me cuidaron y me sirvieron de guía para poder ver la indescriptible magnificencia del mundo natural... a la memoria de mi fiel y leal amigo Bogo.

## **Agradecimientos**

A mi tutor Dr. Edgardo M. Felipe Riverón, por ser el mejor de los guías en esta fantástica aventura llamada investigación; por su infinita paciencia y no perder la fe a pesar de las circunstancias tan adversas... siempre esperando y obteniendo lo mejor de mí... quien por su largo y cuidadoso esfuerzo ejercido con paciencia de Santo le debo el alcanzar tan digna meta...

A mi tutor Dr. Vladislav Khartchenko (Slava), por ser el mejor de los guías en esta aventura fantástica; por compartir conmigo su gran conocimiento, sabiduría y nobleza de espíritu... y por la inmensa confianza que ha depositado en mí y a la cual nunca he de fallar...

A la Dra. Alma Virginia Lara Sagahón (Viqui), por tan generosa y maravillosa amistad desde hace tantos años...

Al Dr. Marco Antonio Moreno Ibarra, por ser uno de mis mejores maestros y enseñarme el valor de la humildad... por considerarme su amigo y ayudarme a regresar...

Al Dr. Rafael San Vicente Cisneros, por compartir sus conocimientos durante tantos años...

Al Dr. Luis A. Pineda Cortés, por guiarme y ayudarme a robustecer los conocimientos adquiridos.

Al Dr. Gibrán Fuentes Pineda, por su ayuda en reforzar la investigación.

Al Dr. Oleksiy Pogrebnyak. Por enriquecer con sus conocimientos este humilde trabajo...

Al Dr. Douglas R. Hofstadter, con quien comparto su fe y esperanzas...

Al Dr. Umberto Eco, con quien comparto su opinión de la fe... y

Al Dr. Carlos Castaneda, por compartir las enseñanzas de su Maestro DJ.

## **RICERCAR**

Centro de Investigaciones Teóricas, Facultad de Estudios Superiores Cuautitlán (FES-C), Universidad Nacional Autónoma de México (UNAM). Proyectos de Investigación PAPIIT IN113316, PAPIIT IN112913 y PIAPIVC06.

Instituto de Investigaciones en Matemáticas y en Sistemas (IIMAS), Universidad Nacional Autónoma de México (UNAM).

Centro de Investigación en Computación, Instituto Politécnico Nacional (CIC-IPN).

Instituto Tecnológico y de Estudios Superiores de Monterrey (ITESM).

Escuela Secundaria Federal No 61 "Simón Bolívar". Generación 1986.

Concejo Nacional de Ciencia y Tecnología (CONACyT)

A (Paty) Patricia Bernal Picazo, por tantas atenciones, hospitalidad y comprensión en los momentos difíciles de mi vida... y por Saber reconocer el valor de la caballerosidad por encima de todas las superficies...

A mi primo Noel Ramos Cervantes (Nin), por saber que puedo contar siempre contigo aun en los momentos más difíciles...

A mi primo Daniel Cervantes (Dany), por tantos y tantos recuerdos felices de la infancia que tanto desearía volver a vivir...

A mi querida tía Logia Murguía de Cervantes, quien con su gran cariño y atención, siempre hacía del más Humilde plato el más maravilloso de los banquetes....

A mis tías Rebeca Hernández y Cruz Cervantes Macías.

A mis primos y primas:

Juan Murguía (Juanito), Roberto Espinoza Martínez (Beto), Maricela Cervantes Hernández (Chelita), Jaime Ramos Cervantes, Tony Ramos, Olga Cervantes Murguía, Gerardo Cervantes Hernández, Fredy Cervantes Murguía, René Cervantes Murguía, Maricruz Chávez Cervantes, Nancy Cervantes Hernández, Fabiola Ramos Cervantes (Faby), Liliana Ramos Cervantes (Lily), Arturo Ramos Cervantes, Ossiirt Felipe Díaz, Luis Chávez Cervantes y Carlos Chávez Cervantes.

A mis tíos Luis Chávez, Salvador Cervantes Macías y Guadalupe Ramos (tío pillo Lupillo).

A mi valedor Orlando Rodríguez Sandoval, que por muchos años ha permanecido a mi lado como el más noble y leal de los amigos...

A mi tocayo Rudolf Himmelbauer (Rudy), que por muchos años ha demostrado ser el más noble y desinteresado de los amigos en los tiempos más difíciles...

A mi amigo Peter Khartchenko, con quien comparto emocionantes aventuras que nunca olvidaré...

A mi buen amigo Israel Villegas Villagómez (Burger) y a su esposa Brenda Elizabeth De Toro Ibarra, por todo su apoyo y comprensión durante tantos años...

A mi amigo Luis Fernando Arreola Magaña (Ix), por todo tu apoyo, ayuda y comprensión durante tantos años...

A mi amigo Patricio Arreola Magaña (Pady), por tantas y tan amenas charlas...

A mi amigo Guillermo Arreola M., con el que alguna vez compartí un mágico viaje de conocimiento...

A la Sra. María Guadalupe Magaña Cancino, por siempre proporcionarnos un lugar seguro donde poder debatir nuestras ideas...

A mi amigo Eric Elier Rodríguez Barragán (Daguer).  
A mi amiga Marcela Verdejo Fernández por toda su confianza durante tantos años...  
A mi amiga Sulay Molina.  
A mi amiga Michael White (Mitch).

A mis amigas y amigos: María de los Ángeles Luciano Castro, Nathali Pérez (Naath), Don Miguel Aguirre (Compa Migue), Ricardo González Gallegos (Chino del Lago), Allan Méndez Islas, José Roberto Martínez Márquez, Sandra Morales Güitrón, Mario Jiménez Augrioles, Ricardo M. Ramos, Alex Yopra, Jorge A. Fonseca (George), Raúl Coronel Dávila (Titi) y Alberto Robledo (Guess).

A Dolores Cuello García (Lolita), por ser un alma noble y compasiva siempre en ayuda de nuestros mejores amigos...

A Amalia J. Arriaga Campos, Ma. del Lourdes González Lora (Lulú) y Cecilia Mandujano Gordillo por ayudarme a llegar al final de la meta...

A Oscar Castellanos R., por su gusto de compartir los buenos momentos con los demás.

A mi amigo Saúl Bustamante Trejo, por su continuo llamado a botar (básquet) a mi Papá y a mi...

A mi amigo Carlos Enrique Quijano Tapia, por su generosa y desinteresada amistad.

A todas las personas de mi tierra... Lagos de Moreno, Jalisco y Cuautitlán, México.

A mi tutor de maestría Dr. Serguei P. Levachkine, por enseñarme a luchar y mostrarme un problema digno...

Quiero agradecer a todas las personas que me han ayudado durante mi vida y que por mi corta visión o memoria no he podido nombrar...

## QUAERENDO INVENIETIS

## Contenido

Dedicatoria .....	2
Agradecimientos .....	4
Summary .....	9
Resumen .....	10
Lista de figuras .....	11
Lista de tablas .....	14
1. Introducción .....	16
1.1 El problema a resolver .....	16
1.2 Justificación.....	17
1.3 Especificidad del problema .....	17
1.4 Hipótesis.....	17
1.5 Objetivo general .....	17
1.6 Objetivos particulares .....	17
1.7 Organización del documento.....	18
2. Marco Teórico.....	20
2.1 Segmentación .....	20
2.1.1 Técnicas basadas en píxeles.....	21
2.1.1.1 Histogramas y umbrales .....	22
2.1.1.2 Agrupamiento .....	22
2.1.2 Técnicas basadas en regiones.....	23
2.1.2.1 Crecimiento de regiones .....	23
2.1.2.2 División y agrupamiento ( <i>Splitting &amp; Merging</i> ).....	24
2.1.3 Técnicas basadas en la detección de bordes de color.....	24
2.2 Espacios de color.....	26
2.2.1 Aspectos básicos de la visión del color .....	26
2.2.2 El modelo de color RGB .....	30
2.2.3 El espacio de color YIQ.....	31
2.2.4 La familia de modelos de color HSI.....	33
3. Estado del arte.....	40
4. Metodología .....	47
4.1 La selección de la muestra de píxeles .....	49
4.2 La zona acromática W.....	50
4.3 Cálculo de la tonalidad promedio .....	52
4.4 Distancia de tonalidad $\Delta_h$ .....	53
4.5 Distancias de saturación $\Delta_s$ y de intensidad $\Delta_i$ .....	53
5. Pruebas y resultados .....	55
5.1 Medios utilizados.....	55
5.2 Resultados en imágenes reales .....	55
5.3 Resultados en imágenes de tonos de gris y de bajo contraste de color.....	62
5.4 Parámetros generales de diseño de imágenes sintéticas .....	64
5.5 Diseño de las imágenes para la caracterización del algoritmo .....	64
5.6 Resultados de la caracterización.....	65
5.7 Diseño del sistema de evaluación de la segmentación.....	68
5.8 Resultados con imágenes de baja saturación.....	71
5.9 Resultados con imágenes de alta saturación .....	79



5.10	Resultados del algoritmo al usar solo la mitad de la información de entrada ...	86
5.10.1	Resultados en imágenes de baja saturación .....	86
5.10.2	Resultados en alta saturación .....	92
6.	Conclusiones .....	99
	Referencias .....	103
	Anexo .....	107
	Apoyos y contribuciones .....	107
	Artículos en revistas .....	107
	Ponencias en congresos .....	107

## Summary

In recent years considerable effort has been devoted to the problem of color segmentation in digital images given its importance and potential. Until recently, most published approaches for color segmentation were based on monochromatic techniques applied to each color component of the image in different color spaces (RGB or other) and in different ways, to produce a composition. These approaches have the inherent problem of a significant loss of color information during the process.

This thesis presents the study of an own semiautomatic color segmentation method for color images using the color information of each pixel as a whole, which prevents loss of color information during processing. The segmentation method rely basically in the calculation of an own similarity function defined in a HSI color space (English acronym Hue-Saturation-Intensity) modified for this purpose, and its subsequent threshold. Results of characterization and evaluation are presented by generating synthetic images with its corresponding Ground Truth (GT). Comparative tests are also presented with other similar segmentation methods using pixel samples of both figure and background, as defined in the CIE  $L^*a^*b^*$  and RGB color spaces.

From the results it is shown that the proposed adaptive color similarity function and the proposed supervised color segmentation method provide a useful and effective alternative for segmenting objects (or regions) with different colors in images of relatively complex color, with good performance in the presence of noise. The proposed method discriminates in a very simple way, any kind of different colored objects regardless of their levels, forms and sizes.

## Resumen

En los últimos años se ha dedicado considerable esfuerzo al problema de la segmentación del color en imágenes digitales dada su importancia y potencial. Hasta hace poco, la mayoría de los enfoques publicados para la segmentación del color se basaba en técnicas monocromáticas aplicadas a cada componente de color de la imagen, en diferentes espacios de color (RGB u otros) y en diferentes formas, para producir una composición. Estos enfoques tienen el problema inherente de una pérdida significativa de la información de color durante el proceso.

En esta tesis se presenta el estudio de un método de segmentación de imágenes semiautomático propio que utiliza la información de color de cada píxel como un todo, que evita la pérdida de información de color durante su procesamiento. El método de segmentación consiste básicamente en el cálculo de una función de similitud propia definida en un espacio de color HSI (sigla del inglés de *Hue-Saturation-Intensity*) modificado para este propósito, y su posterior umbralado. Se presentan resultados de su caracterización y evaluación mediante la generación de imágenes sintéticas con su correspondiente Verdad-Base o *Ground Truth* (GT) en inglés. También se presentan pruebas comparativas con otros métodos de segmentación similares que utilizan muestras de píxeles tanto de la figura como del fondo, definidos en el espacio de color CIE L\*a\*b\* y RGB.

A partir de los resultados se muestra que la función adaptativa de similitud de color y el método supervisado de segmentación de color propuestos, ofrecen una alternativa útil y eficaz para la segmentación de objetos (o regiones) con diferentes colores en imágenes de color relativamente complejas, con un buen rendimiento en presencia de ruido. El método propuesto discrimina de un modo muy sencillo, cualquier tipo de objetos de diferente color, independientemente de sus niveles, formas y tamaños.

## Lista de figuras

1. Imagen particionada y correspondiente *quad-tree*
2. Detección de bordes a través de operadores derivativos
3. Espectro electromagnético
4. Representación del modelo de color CIE XYZ sobre un nivel XY
5. Espacio de color RGB
6. Espacio de color HSI
7. Espacio de color HLS
8. Espacio de color HSV
9. Zona acromática W en el modelo de color HSI
10. Tejido teñido. Muestra compuesta de cuatro píxeles de dos zonas con color azul
11. La imagen de similitud de color (ISC) del color azul de las zonas de color azul segmentadas
12. Muestras de píxeles de cuatro puntos del color rosa
13. ISC de las zonas de color rosa segmentadas
14. Muestra de píxeles para el color blanco. ISC de las zonas de color blanco segmentadas
15. Imagen original e imagen compuesta
16. Muestra de siete píxeles correspondiente a los núcleos azul más oscuro
17. ISC de núcleos azules, núcleos verde oscuros, núcleos azules en pseudocolor, rodeados de zonas azules más claras
18. Babuino. Caballos. Tela
19. Imagen compuesta de cinco colores segmentados con los resultados obtenidos con la zona acromática clásica y con la definición de zona acromática propuesta
20. Imagen compuesta de tres colores segmentados con los resultados obtenidos con la definición clásica de la zona acromática y la propuesta.
21. Imagen compuesta de cinco colores segmentados con los resultados obtenidos con la definición clásica de la zona acromática y la propuesta
22. Imagen infrarroja. ISC de la cara segmentada
23. Hoja fósil en roca. ISC del fósil, umbralada por el método de Otsu
24. Firma, ISC de la firma e ISC umbralada
25. Conjunto de imágenes de prueba donde se disminuye el contraste de color progresivamente: 32, 24, 16, 8 y 4 niveles con ruido aditivo Gaussiano SNR = 2
26. Gráficas ROC para variaciones en el tamaño, la forma y el contraste de color
27. Gráficas de las tasas de verdaderos positivos (izquierda) y las tasas de falsos positivos para diferentes umbrales

28. Gráfica de tasas de verdaderos positivos para el número de muestras y la gráfica ROC para el nivel de ruido  $SNR = 1$
29. Objeto de interés (*Ground Truth*) en forma de flor
30. Pruebas en regiones con baja saturación con Delta en HUE
31. Ejemplo en cuadrante de color a 0 grados con una sombra difuminada de un 10% en cada paso
32. Resultados de la segmentación de color lograda con incremento de 10% de la sombra difuminada en cada paso para imágenes de baja saturación
33. Gráficas de la métrica Euclidiana en  $L^*a^*b^*$  y del enfoque probabilístico sobre  $a^*$  y  $b^*$  para imágenes de baja saturación
34. Gráficas de la métrica Euclidiana de los canales RGB y de la función de similitud de color para imágenes de baja saturación
35. Detalles de verdaderos positivos y falsos positivos de la función de la similitud de color en imágenes de baja saturación
36. Gráfica ROC de la métrica Euclidiana en  $L^*a^*b^*$  y del enfoque probabilístico en  $a^*$  y  $b^*$  para imágenes de baja saturación
37. Gráfica ROC de la métrica Euclidiana de los canales en RGB y de la función de similitud de color para imágenes de baja saturación
38. Pruebas en regiones con alta saturación con Delta en HUE
39. Ejemplo en cuadrante de color a 0 grados con una sombra difuminada un 10% en cada paso
40. Resultados de la segmentación de color lograda para imágenes de alta saturación.
41. Gráfica de la tasa de verdaderos positivos y falsos positivos con métrica Euclidiana para los parámetros  $a^*$  y  $b^*$  en incrementos de 10% de la sombra para imágenes de alta saturación
42. Gráfica de la tasa de verdaderos positivos y falsos positivos con métrica Euclidiana de RGB y de la función de similitud de color para imágenes de alta saturación
43. Detalles de la tasa de verdaderos positivos y falsos positivos de la función de similitud de color en imágenes de alta saturación
44. Gráfica ROC de la métrica Euclidiana de los parámetros  $a^*$  y  $b^*$  y del enfoque probabilístico en  $a^*$  y  $b^*$  para imágenes de alta saturación
45. Gráfica ROC de la distancia Euclidiana de los canales RGB y de la función adaptativa de similitud propuesta
46. Resultados de la segmentación del color en imágenes de baja saturación y con incrementos de sombra de 10% en cada paso
47. Gráficas de verdaderos positivos y falsos positivos de la distancia Euclidiana de los canales  $a^*$   $b^*$  y la métrica Euclidiana de los canales RGB, para imágenes de baja saturación
48. Gráficas de verdaderos positivos y falsos positivos del método que utiliza las dos muestras y clasifica mediante máxima similitud y del método que utiliza solo una

- muestra y que clasifica con el método de umbralado de Otsu en imágenes de baja saturación
49. Detalles de verdaderos positivos y falsos positivos del método que utiliza dos muestras y clasifica por máxima similitud en imágenes de baja saturación
  50. Detalles de verdaderos positivos y falsos positivos del método que utiliza solo una muestra de píxeles y umbralado con el método de Otsu en imágenes de baja saturación
  51. Resultados de la segmentación del color en imágenes de alta saturación y con incrementos de sombra desvanecida de 10% en cada paso
  52. Gráficas de verdaderos positivos VP y falsos positivos FP de la métrica Euclidiana de  $a^*$  y  $b^*$  y la métrica Euclidiana de los canales RGB en imágenes de alta saturación
  53. Gráficas de verdaderos positivos y falsos positivos del método que utiliza las dos muestras y clasifica mediante máxima similitud y del método que utiliza solo una muestra y que clasifica con el método de umbralado de Otsu imágenes de alta saturación
  54. Detalles de verdaderos positivos y falsos positivos del método que utiliza dos muestras y asigna mediante el método de máxima similitud en imágenes de alta saturación
  55. Detalles de verdaderos positivos y falsos positivos del método que utiliza solo una muestra y clasifica mediante el método de umbralado de Otsu en imágenes de alta saturación

## Lista de tablas

1. Colores primarios EBU Tech 3213
2. Resultados globales de la segmentación en imágenes reales
3. Resultados globales de la segmentación en imágenes de bajo contraste de color y monocromáticas
4. Observaciones sobre el comportamiento de las curvas mostradas en las figuras 33 y 34 con las dos métricas de color  $L^*a^*b^*$  y del método propuesto
5. Observaciones sobre el comportamiento de las curvas mostradas en las figuras 41 y 42 al comparar las cuatro métricas siguientes: Euclidiana en el espacio  $L^*a^*b^*$  con rechazo de  $L^*$ , un enfoque probabilístico sobre  $a^*$  y  $b^*$ , la métrica Euclidiana en el espacio RGB y la función de similitud de color propuesta
6. Observaciones sobre el comportamiento de las curvas mostradas en las figuras 47 y 48 que comparan los cuatro métodos bajo estudio para imágenes con baja saturación
7. Observaciones sobre el comportamiento de las curvas mostradas en las figuras 53 y 54 que comparan los cuatro métodos de segmentación bajo estudio para imágenes con alta saturación

# CAPÍTULO 1

## INTRODUCCIÓN



# 1. Introducción

En esta sección se presenta el problema que se trata de resolver de forma general y específica, la justificación de la investigación, la hipótesis de trabajo, el objetivo general y los específicos así como otra información relevante sobre la investigación.

## 1.1 El problema a resolver

En visión artificial, la segmentación de imágenes es el proceso de partición de una imagen digital en múltiples segmentos (conjuntos de píxeles, también conocidos como superpíxeles). El objetivo de la segmentación es simplificar y / o cambiar la representación de una imagen en algo que es más significativo y fácil de analizar. La segmentación de imágenes se utiliza normalmente para localizar objetos y bordes (regiones, líneas, curvas, etc.) en imágenes. Más precisamente, la segmentación de imágenes es el proceso de asignar una etiqueta a cada píxel de una imagen de modo que los píxeles con la misma etiqueta comparten ciertas características comunes [47].

El resultado de la segmentación es un conjunto de segmentos que cubren colectivamente toda la imagen o un conjunto de contornos extraídos de la imagen (ver detección de bordes). Cada uno de los píxeles de una región es similar con respecto a alguna característica o propiedad calculada, como el color, la intensidad o la textura. Las regiones adyacentes son significativamente diferentes con respecto a la misma característica (s) [47].

“La segmentación de una imagen consiste en la partición de dicha imagen en diferentes regiones similares en alguna característica predefinida (...) Los seres humanos usamos nuestro sentido visual para separar nuestro entorno inmediato en objetos distintos sin esfuerzo alguno para reconocerlos, guiar nuestros movimientos y para casi todas las actividades de nuestra vida.” (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 237, traducido).

La segmentación es una característica importante de la percepción visual humana que se manifiesta de forma espontánea y natural; aunque están involucrados procesos complejos como el análisis de color, la forma, el movimiento, la textura, etc. [1][2][3].

El color es una característica visual poderosa y robusta para diferenciar los diferentes objetos en una imagen. Es una importante fuente de información en el proceso de segmentación y puede en muchos casos ser utilizado como única característica y único descriptor para la segmentación de los objetos de interés [1][2][3].

En este trabajo de tesis se busca investigar sobre un método propio de segmentación del color en imágenes de color. El método sólo utiliza la información de color para realizar la segmentación, por lo que se considera como un indispensable paso previo al de reconocimiento. En este trabajo no se pretende llegar al reconocimiento de objetos o clases de objetos, sino únicamente a la segmentación de la imagen en regiones homogéneas de color que podrían ser utilizadas para alimentar a tareas subsecuentes.

## 1.2 Justificación

En los últimos años se ha dedicado considerable esfuerzo al problema de la segmentación del color en imágenes digitales dada su importancia y potencial. Hasta hace poco, la mayoría de los enfoques publicados para la segmentación del color se basaba en técnicas monocromáticas aplicadas a cada componente de color de la imagen, en diferentes espacios de color (RGB u otros) y en diferentes formas, para producir una composición. Estos enfoques tienen el problema inherente de una pérdida significativa de la información de color durante el proceso [3][4].

## 1.3 Especificidad del problema

En este trabajo se presenta el estudio de un método de segmentación de imágenes semiautomático propio que utiliza la información de color de cada píxel como un todo, y evita así la pérdida de información durante su procesamiento. El método de segmentación consiste básicamente en el cálculo de una función de similitud definida en un espacio de color HSI (sigla del inglés de *Hue-Saturation-Intensity*) modificado para este propósito, y su posterior umbralado. Se presentan los resultados de su caracterización y evaluación mediante la generación de imágenes sintéticas con su correspondiente Verdad-Base o *Ground Truth* (GT) en inglés.

El método de segmentación del color aquí presentado es la generalización del método propuesto en la tesis de maestría [3] que consistió en la segmentación de patrones lineales topológicamente diferentes en mapas de tramas (*raster*) en colores, y que formó parte del proyecto Automatización de la Digitalización de los Mapas por medio de Reconocimiento de los Patrones Cartográficos, con número de registro 32019-A del CONACyT. Este proyecto tuvo como uno de sus objetivos el desarrollar algoritmos y sistemas capaces de transferir la información contenida en planos cartográficos a su equivalente en representación vectorial, para ser integrados en sistemas de información geográfica.

## 1.4 Hipótesis

Al procesar la información de color como una unidad, mediante la función de similitud y el espacio de color propuestos, se evitará la pérdida de información de color durante la segmentación.

## 1.5 Objetivo general

Lograr la segmentación del color en imágenes digitales mediante el uso de la información del color de forma integral, mediante una función de similitud en el espacio de color propuestos.

## 1.6 Objetivos particulares

- a) Caracterizar el algoritmo de segmentación propuesto;
- b) Evaluar el algoritmo de segmentación del color propuesto;
- c) Obtener resultados cuantificables que permitan ubicarlo en el estado del arte.

## **1.7 Organización del documento**

La tesis está organizada de la siguiente manera: El capítulo 2 ofrece el marco teórico necesario para entender los capítulos siguientes. El capítulo 3 hace un recorrido entre publicaciones recientes que representan el estado del arte en el campo de la segmentación del color en las imágenes digitales. El capítulo 4 presenta la metodología propuesta para la segmentación del color. El capítulo 5 presenta las pruebas y los resultados obtenidos con la metodología, tanto en la caracterización como en las evaluaciones en imágenes reales, de bajo contraste de color, monocromáticas y sintéticas. El capítulo 6 contiene las conclusiones

# CAPÍTULO 2

## MARCO TEÓRICO

## 2. Marco Teórico

En esta sección se presentan los conceptos teóricos necesarios para la comprensión del estado del arte y las posibles contribuciones de la presente tesis al campo de investigación.

### 2.1 Segmentación

En visión artificial, la segmentación de imágenes es el proceso de partición de una imagen digital en múltiples segmentos (conjuntos de píxeles, también conocidos como superpíxeles). El objetivo de la segmentación es simplificar y / o cambiar la representación de la imagen en algo más significativo y fácil de analizar. La segmentación se utiliza normalmente para localizar objetos y bordes (regiones, líneas, curvas, etc.) en dichas imágenes. Más precisamente, la segmentación es el proceso de asignar una etiqueta a cada píxel de la imagen de modo que los píxeles con la misma etiqueta comparten ciertas características comunes. [47]

El resultado de la segmentación es un conjunto de segmentos que cubren colectivamente toda la imagen o un conjunto de contornos extraídos de la imagen (ver detección de bordes). Cada uno de los píxeles de una región es similar con respecto a alguna característica o propiedad calculada, como el color, la intensidad o la textura. Las regiones adyacentes son significativamente diferentes con respecto a la misma característica (s) [47].

*La segmentación de una imagen consiste en la partición de dicha imagen en diferentes regiones, que son similares en alguna característica predefinida. (...) Los seres humanos usamos nuestro sentido visual para separar nuestro entorno inmediato en objetos distintos sin esfuerzo alguno para reconocerlos, guiar nuestros movimientos y para casi todas las actividades de nuestra vida; La segmentación es una característica importante de la percepción visual humana que se manifiesta de forma espontánea y natural; aunque están involucrados procesos complejos, como el análisis de color, forma, movimiento, textura, etc. (...)*

*La segmentación es usualmente el primer paso en el proceso de análisis de una imagen. Las tareas subsecuentes, tales como la extracción de características o reconocimiento de objetos, recaen enormemente en la calidad de la segmentación. Sin un buen algoritmo de segmentación, un objeto puede que nunca sea reconocido. (...) Esta etapa puede determinar el eventual éxito o fracaso del análisis, por lo que se hacen muchos esfuerzos en mejorar la probabilidad de una segmentación exitosa. (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 237, traducido).*

En el presente trabajo de tesis se aborda el problema de la segmentación del color en imágenes digitales sin llegar al etiquetado de los objetos individuales o de las clases de objetos (reconocimiento).

Los resultados de la presente investigación están limitados a separar las imágenes digitales en colores en regiones disjuntas donde a cada región pueda asignársele un color representativo (centroide de color) y un valor de la dispersión de color (desviación estándar

con respecto al centroide de color). Puede verse este enfoque de segmentación del color como una forma de simplificar la descripción del problema original (imagen fuente en colores) conservando la información relevante. A partir de esta representación simplificada pueden obtenerse características útiles en los procesos subsecuentes de reconocimiento de objetos y clases tales como áreas, perímetros, excentricidades, distancias entre regiones, etc.

Si el color es una característica discriminante de los objetos en la imagen, el método propuesto puede segmentar el objeto u objetos presentes en la imagen con gran facilidad y velocidad sin necesidad de algún procesamiento adicional [3].

Dado el auge de nuevas aplicaciones comerciales multimedia, tales como fotografía digital, base de datos de multimedia, teleconferencias, etc., se ha generado un gran interés en la segmentación de imágenes en colores. Debido a esto se ha convertido en un área de estudio, no sólo en la ingeniería y o en las ciencias de la computación, sino de otras disciplinas tales como cartografía, medicina, combate al crimen, aplicaciones militares, entre otras. La segmentación de imágenes ha tomado un lugar central en numerosas aplicaciones que incluyen, aunque no se limitan a, bases de datos multimedia, transmisión de imágenes y video por Internet, transmisiones digitales, televisión interactiva, video sobre demanda, entrenamientos basados en computadoras, educación a distancia, video conferencia y telemedicina y en el desarrollo de hardware e infraestructura de comunicaciones que soportan aplicaciones visuales [3].

La mayoría de la atención sobre la segmentación de imágenes se enfocó durante mucho tiempo en imágenes en escala de grises (imágenes monocromáticas) [1][2][3][4]. Un problema común en la segmentación de una imagen en escala de grises ocurre cuando una imagen tiene un fondo con intensidad que varía gradualmente, o cuando las regiones tienen un amplio rango de valores. El problema es inherente, ya que la intensidad es la única información disponible en imágenes monocromáticas. Es conocido que el ojo humano puede detectar alrededor de 24 niveles de gris en cualquier punto de una imagen compleja dado su adaptación a la brillantez, pero puede diferenciar miles de colores [2].

Los primeros enfoques en segmentación de imágenes están basados en estas tres técnicas [2]:

1. Técnicas basadas en píxeles.
2. Técnicas basadas en regiones.
3. Técnicas basadas en bordes.

### **2.1.1 Técnicas basadas en píxeles**

Las técnicas basadas en píxeles no consideran el espacio contextual todas las decisiones son tomadas únicamente sobre la base de las características de color de los píxeles individuales. Este enfoque tiene como ventaja la sencillez en el diseño de los algoritmos, y como

desventaja, lo susceptible que es al ruido. Otras técnicas las cuales toman en cuenta relaciones espaciales, son usadas para mejorar las técnicas basadas en píxeles [1][2].

### **2.1.1.1 Histogramas y umbrales**

Una de las técnicas más sencillas de segmentación basada en píxeles es el de umbralado a través del histograma, siendo ésta técnica una de las más antiguas y populares. Si una imagen es descompuesta en distintas regiones, el histograma de la imagen usualmente mostrará ciertos picos que suelen estar separados por valles. Siendo estos picos asociados a regiones homogéneas dentro de la imagen.

Por ejemplo, si en una imagen hay un objeto distinguible de un fondo, el histograma tenderá a ser bimodal con un profundo valle. En este caso, el fondo del valle es tomado como el umbral de segmentación; de tal manera que los píxeles pertenecientes a los valores superiores e inferiores a este umbral en el histograma sean agrupados en diferentes regiones: una perteneciente al objeto y otra para el fondo. Para múltiples regiones se tienen varios umbrales. [1][2]

Para imágenes en colores, se propone en [2] un método que utiliza nueve histogramas, tres para cada espacio de color RGB, YIQ y HSI. El pico dominante de los nueve histogramas es utilizado para determinar el intervalo de la subregión. Los píxeles que caen en este intervalo forman una región. Se crea también una lista de 7 prioridades para la selección de picos de intervalo.

Se puede realizar procesamiento adicional tal como la remoción de pequeñas regiones o la adición de nuevas características como textura, densidad de bordes, etc., para mejorar el funcionamiento del método básico.

Resumiendo, el método de segmentación por umbralado de histograma es uno de los más simples para la segmentación de imágenes, por cuya razón se le tiene una gran consideración cuando se necesita una segmentación “gruesa” [1][2].

### **2.1.1.2 Agrupamiento**

El método de agrupamiento está basado en que típicamente una imagen en colores tiende a formar agrupaciones en el histograma, una por cada objeto. Primero se obtiene el histograma a través de los valores de color en todos los píxeles, y después se obtiene la forma de cada grupo. Al final, cada píxel en la imagen es asignado al grupo que esté más cerca del color del píxel [1][2].

Actualmente existen varios métodos de agrupamiento disponibles, dentro de los cuales destacan los algoritmos K-media y Fuzzy K-media (K-media Difuso) que han recibido gran atención. Asimismo, estas técnicas se pueden combinar con las de umbralado a través del histograma para mejorar los resultados.

Es ampliamente reconocido que esta técnica sufre de los dos problemas siguientes: 1. Grupos adyacentes frecuentemente se superponen en el espacio de color, lo que causa clasificaciones incorrectas 2. El agrupamiento es más difícil cuando el número de grupos es desconocido, como es típico en los algoritmos de segmentación [1][2].

## **2.1.2 Técnicas basadas en regiones**

Las técnicas basadas en regiones se enfocan en la continuidad del color en una región de la imagen. A diferencia de las técnicas basadas en píxeles, las técnicas basadas en regiones consideran tanto la distribución en el espacio de color como las restricciones geométricas. Las técnicas estandarizadas incluyen el crecimiento de regiones y las técnicas de división y agrupamiento (*splitting & merging*). [1][2]

El crecimiento de regiones se refiere al agrupamiento a regiones más grandes de píxeles cercanos con propiedades similares. La técnica de *splitting & merging* consiste en subdividir iterativamente una imagen en regiones cada vez más y más pequeñas y probar si regiones adyacentes pueden ser unidas en una sola región. El proceso de unión de regiones está usualmente gobernado por algún criterio de homogeneidad tal como los diferentes tipos de distancias [1][2][4].

### **2.1.2.1 Crecimiento de regiones**

El crecimiento de regiones es un método de segmentación, en el cual píxeles vecinos o una colección de píxeles con características similares se agrupan para formar regiones más grandes. La prueba de similitud de píxeles normalmente se realiza a través de un criterio de homogeneidad del espacio de color [1][2][4].

*Un algoritmo de crecimiento de regiones típico comienza con un cierto número de píxeles semilla en una imagen, y de ahí se hacen crecer regiones al adicionar iterativamente a la región, píxeles vecinos que no han sido asignados. Esto es, un píxel no asignado que rodea una región, que creció a partir de unos píxeles semilla, puede ser asignado a esta región si satisface el criterio de homogeneidad de dicha región. Si el píxel es asignado a la región, la lista de píxeles de dicha región se actualiza para incluir al píxel en cuestión. (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 248, traducido)*

Las diferencias entre las técnicas de crecimiento de regiones difieren en el tipo de criterio de homogeneidad y en la selección de los píxeles semilla. Diferentes criterios de homogeneidad relacionados al color o a las características geométricas, pueden ser utilizados para decidir si un píxel pertenece a una región, o no. Estos criterios pueden ser definidos de manera local, regional o global.

La selección de semillas puede realizarse de manera supervisada o autónoma. En el modo supervisado, los usuarios mismos eligen las semillas, mientras que en la autónoma la elección es hecha automáticamente por un algoritmo creado para ello.



### 2.1.2.2 División y agrupamiento (*Splitting & Merging*)

Esta técnica, en oposición al crecimiento de regiones donde una región crece a partir de píxeles semilla, subdivide inicialmente una imagen en un conjunto arbitrario de regiones disjuntas y después, une o divide las regiones (*split / merge*) en un intento de satisfacer los criterios de homogeneidad [1][2]. El algoritmo es el siguiente:

1. Dividir (*split*) en cuadrantes disjuntos cualquier región  $R_i$  donde  $P(R_i) = \text{Falso}$
2. Juntar (*merge*) cualquier región adyacente  $R_j$  y  $R_k$  para las cuales  $P(R_j \cup R_k) = \text{Verdadero}$
3. Detener cuando no se pueda dividir ni juntar región alguna.

$P()$  es un predicado que representa el criterio de homogeneidad.

La forma de dividir la región  $R_i$  puede variar. Una forma común de particionar es el llamado *quad-tree* que se muestra en la Fig. 1.




Fig. 1 Imagen particionada y su correspondiente *quad-tree*

### 2.1.3 Técnicas basadas en la detección de bordes de color

Una de las tareas más importantes en el procesamiento de imágenes es la detección de los bordes. Tareas de alto nivel tales como segmentación, reconocimiento de objetos, visión por computadora, etc., dependen de la precisión en la detección de los límites de los objetos. Los bordes contienen información esencial de la imagen que no debe de ser despreciada [1][2][4].

La mayoría de este tipo de técnicas está basada en encontrar el valor máximo de la primera derivada de una función de la imagen. Estas ideas se ilustran para el caso de imágenes monocromáticas en la Fig. 2.




Fig. 2 Detección de bordes a través de operadores derivativos

La figura 2 muestra cómo la primera derivada de los niveles de gris es positiva en el borde frontal de una transición, negativa en la transición de blanco al negro, y cero en las áreas homogéneas. La segunda derivada es positiva para aquella parte de la transición asociada al lado oscuro del borde, negativo para la parte asociada al lado claro del borde, y cero en las áreas homogéneas.

En una imagen monocromática, un borde usualmente corresponde a los límites de los objetos o a cambios en propiedades físicas, como la iluminación. En el caso de imágenes en colores o multispectrales, esta definición es más elaborada, ya que se espera información más detallada de la detección de bordes en las imágenes en color.

De acuerdo a ciertos estudios psicológicos del sistema visual humano, el color juega un papel importante en la detección de los límites de los objetos [2]. La detección de los bordes monocromáticos puede no ser suficiente para ciertas aplicaciones, ya que cuando los objetos adyacentes tienen la misma intensidad, pero diferente tonalidad, ningún borde es detectado en las imágenes de niveles de gris.

Como la capacidad de distinguir diferentes objetos es crucial para aplicaciones tales como la segmentación de los objetos o su reconocimiento, la información adicional provista por el color sobre los contornos es de gran importancia.

En una imagen monocromática, un borde es definido como una discontinuidad en la intensidad [1][2][4]. En el caso de las imágenes en colores, la variación del color también necesita tenerse en cuenta. Los primeros enfoques en la detección de bordes, en imágenes en colores, consistieron de extensiones a la detección de bordes monocromáticos. Estas técnicas se aplican a los tres canales independientemente y luego los resultados se combinan con una operación lógica [1][4][9].

La primera derivada en cualquier punto de la imagen puede ser obtenida usando la magnitud del gradiente en dicho punto. Esta tarea puede ser realizada con la convolución de la imagen con ciertas mascarillas.

Un problema común en estas técnicas es que ellas fallan en tomar en cuenta la correlación que existe entre los canales de color y, como resultado, no son capaces de extraer cierta información crucial contenida en el color. Por ejemplo, tienden a perder bordes que tienen la misma intensidad, pero que tienen direcciones opuestas en dos de sus componentes de color [1][4].

## 2.2 Espacios de color

En esta sección se presentan nociones básicas de la visión en color así como varios espacios o modelos de color existentes y transformaciones entre ellos. Esta sección es importante para entender las similitudes y diferencias del espacio de color y la función de similitud propuestos en este trabajo de tesis con respecto al estado del arte y ubicar las posibles contribuciones en el campo.

### 2.2.1 Aspectos básicos de la visión del color

“El color es una sensación creada en nuestro cerebro en respuesta a la excitación de nuestro sistema visual por la excitación electromagnética conocida como luz.” (K.N., Platanotis, y A.N.Venetsanopoulos, 2000, p. 1, traducido). Específicamente, el color es el resultado perceptual de la luz en la región visible del espectro electromagnético de los 400 a los 700 nm que inciden en la retina del ojo humano (Ver la Fig. 3) [1][2].




Fig. 3 Espectro electromagnético

La retina humana tiene tres tipos de células fotorreceptoras de color llamadas conos, las cuales responden a la radiación de diferentes frecuencias. Un cuarto tipo de células fotorreceptoras llamadas bastones también están presentes en la retina, las cuales son efectivas sólo a niveles extremadamente bajos de luz, por ejemplo durante la visión nocturna. Aunque son importantes para la visión, no tienen ninguna función durante la reproducción de las imágenes [1][2].

“La rama de la ciencia del color que concierne a la apropiada descripción y especificación de un color es llamada colorimetría. (...) Debido a que existen tres tipos de células

fotorreceptoras del color llamadas conos, sólo tres componentes numéricos son necesarios y suficientes para describir un color siempre que se utilicen funciones de ponderación espectrales.” (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 1, traducido). Por lo tanto, cualquier color puede ser especificado con un vector de tres componentes. El conjunto de todos los colores forma un espacio vectorial llamado espacio o modelo de color. Los tres componentes de un vector pueden ser definidos de varias maneras diferentes generando diversos espacios de color [2].

Para poder usar la información de color en multimedia, procesamiento de imágenes, aplicaciones de visión por computadora, etc., se necesita un modelo adecuado para representar el color. Se han creado diferentes especificaciones (modelos o espacios) de color para dar solución a distintas necesidades [2][3].

Los espacios de color nos proporcionan un método racional para especificar, ordenar, manipular, analizar, entre otros procedimientos, los colores de algún objeto en cuestión [2].

Escoger una buena representación del espacio de color permite preservar información esencial y provee una visión intuitiva de las necesidades en las operaciones visuales del procesamiento. Por esta razón, es muy importante escoger correctamente un modelo de color que sea adecuado para representar el problema específico y las soluciones [2][6][9].

Actualmente existe extensa literatura técnica sobre los modelos de color en el dominio de la física, ingeniería, inteligencia artificial, ciencias de la computación, psicología y filosofía. De esta literatura, pueden distinguirse cuatro familias básicas de modelos de color [2]:

1. Modelos colorimétricos. Están basados en la medición de valores físicos del reflejo espectral de la luz.
2. Modelos de color psicofísicos. Están basados en la percepción humana del color. Estos modelos son creados, ya sea bajo criterios subjetivos de observación y en referencias comparativas, o están contruidos a través de la experimentación para compaginarse con la percepción humana del color.
3. Modelos de color inspirados en la fisiología. Están basados en los tres colores primarios correspondientes a los tres tipos de conos presentes en la retina. El espacio de color RGB (*Red, Green, Blue*) ampliamente utilizado en las pantallas de las computadoras, es el ejemplo más conocido de un modelo de color inspirado en la fisiología.
4. Modelos de colores oponentes. Están basados en experimentos de percepción. Utilizan principalmente colores primarios opuestos y complementarios, por ejemplo, pares azul-amarillo o rojo-verde.

Los modelos de color se pueden clasificar alternativamente en tres categorías para aplicaciones de procesamiento de imágenes [2]:

1. Modelos de color orientados a los dispositivos. Son modelos que están asociados con la captura, el procesamiento y el despliegue de las imágenes. Estos espacios son de gran importancia en las aplicaciones modernas, donde se debe especificar un color de manera que sea compatible con las herramientas de hardware utilizadas.
2. Modelos de color orientados a los usuarios. Son utilizados como un puente, entre los operadores humanos y el sistema, para manipular la información de color. Estos modelos le permiten al usuario, especificar el color en términos de atributos perceptuales. Pueden ser considerados como una aproximación experimental de la percepción humana del color.
3. Modelos de color independientes del dispositivo. Son utilizados para especificar el color en señales, independientemente de los dispositivos o las aplicaciones. Estos modelos son de importancia donde hay comparaciones de color y se transmite la información visual sobre redes que conectan diferentes plataformas y equipos de cómputo.

“En 1931, la Comisión Internacional de la Iluminación (CIE del francés *Commission Internationale de L'Eclairage*) adoptó curvas de color estandarizadas, diseñadas para un observador hipotético estandarizado” (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 3, traducido). Estas curvas de color especifican cómo una distribución espectral de potencia específica (SPD del inglés *Specific Power Distribution*) de un estímulo externo (luz radiante visible incidiendo en el ojo humano), puede ser transformada en un conjunto de tres números que especifica el color. El sistema de especificación del color está basado en la descripción del color como la componente de luminancia Y y dos componentes adicionales X y Z [2]. Las curvas de ponderación espectral de X y Z fueron estandarizadas por la CIE basadas en valores estadísticos de experimentos que involucraron observadores humanos. Los valores triestímulo CIE XYZ pueden ser usados para describir cualquier color; el espacio de color correspondiente es llamado espacio de color CIE XYZ.

El modelo de color XYZ es un espacio de color independiente de los dispositivos y ha sido útil en aplicaciones donde es importante una representación consistente del color a través de dispositivos de características distintas.

El espacio de color CIE XYZ es perceptualmente no uniforme (ver Fig. 4). Por lo tanto no es apropiado para manipulaciones cuantitativas que se relacionan con la percepción humana del color; raramente es usado en aplicaciones de procesamiento de imágenes. [1][2]

#### Representación típica sobre un nivel XY




Fig. 4 Representación del modelo de color CIE XYZ sobre un nivel XY

“Aunque el modelo de color XYZ es usado solo indirectamente, juega un papel importante en el procesamiento de imágenes, ya que otros espacios de color pueden ser obtenidos a partir de éste a través de transformaciones lineales.” (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 4, traducido). Por ejemplo el espacio lineal de color RGB puede ser transformado a uno obtenido del espacio CIE XYZ mediante solamente una transformación lineal definida en una matriz de  $3 \times 3$ . De la misma manera otros espacios de color tales como el RGB no lineal, el YIQ y el HSI pueden ser transformados a, o desde el espacio CIE XYZ, pero requieren cálculos complejos y no lineales. El CIE también derivó y estandarizó otros espacios de color como perceptualmente uniformes, tales como el CIE  $L^*a^*b^*$  y el CIE  $L^*u^*v^*$ . [2].

La CIE ha patrocinado la investigación en la percepción de color durante muchos años, originando la construcción de varios modelos matemáticos de color ampliamente utilizados en la actualidad. La obtención de dichos modelos se basa en un gran número de experimentos de comparación de colores donde un observador humano promedio juzga la similitud visual entre dos secciones de estímulos visuales de color, y juzga si son aparentemente iguales. [2]

“Ya que los experimentos en colorimetría están basados en procedimientos de comparación, en los cuales un observador humano juzga la similitud entre dos áreas, el modelo teórico sólo predice el resultado de las comparaciones, no los colores percibidos.” (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 4, traducido)

Se descubrió a través de estos experimentos que la luz de casi cualquier composición espectral, puede ser “igualada” por mezclas de sólo tres primarios (luz compuesta de una sola longitud de onda). La CIE, al recopilar resultados de experimentos (con diferentes observadores, con diferentes fuentes de luz, con diferentes potencias y composiciones

espectrales), definió una serie de funciones de comparación de color para observadores estandarizados. [1][2]

Se determinó que los tres colores primarios, utilizados para crear la sensación de color, pueden ser seleccionados con amplio margen cumpliendo sólo que sean independientes. [1][2]

### 2.2.2 El modelo de color RGB

La principal suposición detrás de la teoría colorimétrica moderna (en lo que concierne a tareas de procesamiento de imágenes) es que la base fundamental para la visión en color humana se encuentra en las excitaciones de las tres clases de células fotorreceptoras (llamadas conos) en la retina. Estos fotorreceptores llamados receptores rojo, verde y azul definen un espacio tricromático llamado espacio RGB, cuyos primarios son colores puros en el bajas, medianas y altas frecuencias del espectro electromagnético visible [1][2][6][9].

En el modelo de color RGB, cada color aparece en sus componentes espectrales primarios de rojo, verde y azul (*Red, Green, Blue*) basándose en un sistema de coordenadas cartesianas. El subespacio de color RGB es el cubo mostrado en la (Fig. 5), en el cual las componentes roja, verde y azul están en tres esquinas, el cian, magenta y amarillo en las otras tres esquinas, el negro en el origen  $[0\ 0\ 0]$  y el blanco en la esquina más lejana al origen  $[1\ 1\ 1]$ . Se supone, por conveniencia, que los valores están normalizados al intervalo  $[0,1]$ , dando lugar al cubo mostrado en la figura 5 llamado el cubo unitario. [1]

Las imágenes en el modelo de color RGB consisten en tres planos de imagen independientes; una para cada color primario. Cuando se alimenta a un monitor RGB, estas tres imágenes se combinan en la pantalla fosforescente para producir una imagen compuesta en color. Por lo tanto, el uso del modelo RGB para el procesamiento tiene sentido cuando las imágenes mismas son naturalmente expresadas en términos de estos planos de color [1][2].




Fig. 5 Espacio de color RGB

En procesamiento de imágenes, gráficas computacionales y sistemas de multimedia, la representación RGB es la más utilizada. Una imagen digital en colores es representada como un arreglo bidimensional de vectores de tres variables que representa a los valores del rojo, verde y azul de cada píxel. Estos valores de píxel son relativos a los tres colores primarios que forman el espacio de color [1][2].

*Para definir inequívocamente un espacio de color, deben ser especificados la cromaticidad de los colores primarios y un blanco de referencia. De otro modo, los valores asignados a los píxeles en la representación digital de la imagen en colores podrían no corresponder y perder significado. (...)*

*En la práctica, aunque un número de variantes de espacios RGB se han definido y están en uso en la actualidad, las especificaciones exactas generalmente no son accesibles a los usuarios. Los usuarios de multimedia asumen que todas las imágenes digitales están representadas en el mismo espacio RGB y entonces las usan, comparan y manipulan directamente sin importar de donde vinieron dichas imágenes. (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 11, traducido)*

La cromaticidad adecuada de los primarios rojo, verde y azul utilizados está determinada por la tecnología empleada, tales como los sensores de las cámaras, los tipos de fósforo dentro del tubo de rayos catódicos (ya desaparecidos), etc. Así que se han desarrollado diferentes estándares como un intento para cuantificar las prácticas de la industria [1][2].

Se han definido y usado varios estándares de espacios de color en la industria, principalmente en la de la televisión. Entre ellos están los primarios de la Comisión Federal de Comunicaciones de América (FCC del inglés *Federal Communication Commission of America*), 1953, los primarios ‘C’ de la Sociedad de Ingenieros de Cine y Televisión (SMPTE del inglés *Society of Motion Picture and Television Engineers*), los primarios de la Unión de Radiodifusoras Europea (EBU del inglés *European Broadcasting Union* ver tabla 1). La mayoría de estas organizaciones usa un blanco de referencia conocido como CIE D65. [2]

Tabla 1. Colores primarios EBU Tech 3213

<b>Colorimetría</b>	<b>Rojo</b>	<b>Verde</b>	<b>Azul</b>	<b>Blanco D65</b>
x	0.640	0.290	0.150	0.3127
Y	0.330	0.600	0.060	0.3290
Z	0.030	0.110	0.790	0.3582

### 2.2.3 El espacio de color YIQ

El espacio de color YIQ (el cual es usado en los sistemas de transmisión de TV) está basado en un estándar que fue adoptado en los años 1950 por el Comité Nacional de Normas de la Televisión (NTSC del inglés *National Television Standard Committee*). Este estándar buscaba la eficiencia en la transmisión de la señal y la compatibilidad con el estándar de la televisión monocromática. [2]



*El modelo YIQ fue diseñado para tomar ventaja de la mayor sensibilidad del sistema visual humano a cambios en la luminancia, que a cambios en la tonalidad o la saturación. Dadas estas características, es útil en sistemas de video tener una representación donde se tenga la componente de luminancia Y de manera independiente. En el sistema YIQ se tiene adicionalmente la componente in phase I, que es un eje naranja – cian y la componente en cuadratura Q que es un eje magenta – verde. (...)*

*En este modelo de color es posible adecuar la representación del componente de luminancia Y de tal manera que el ruido (o el error de cuantización o de cuantificación) introducido en la transmisión, procesamiento o almacenamiento, sea mínimo. Esto se consiguió al asignar más bits para codificar la luminancia (Y) y menos para codificar la cromaticidad (I y Q) en la transmisión y almacenaje de las imágenes, sin introducir graves errores perceptuales debido a la cuantización. (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 23-24, traducido)*

Otra característica de este modelo es que la componente de luminancia de una imagen puede ser procesada sin afectar su contenido de color. Por ejemplo, se puede aplicar una ecualización de histograma a una imagen en YIQ con simplemente aplicar este proceso a la componente Y, sin afectar a las otras componentes. De esta manera, los colores relativos de la imagen no son afectados durante el procesamiento [1][2][9].

La conversión de RGB a YIQ es definida por la siguiente matriz de transformación:

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ 0.596 & -0.275 & -0.321 \\ 0.212 & -0.523 & 0.311 \end{bmatrix} \begin{bmatrix} R' \\ G' \\ B' \end{bmatrix}$$

Si se introduce una transformación a coordenadas cilíndricas, se pueden calcular los valores correspondientes para la tonalidad (*hue*) y la saturación:

$$\begin{aligned} H_{YIQ} &= \tan^{-1}(Q/I) \\ S_{YIQ} &= (I^2+Q^2)^{1/2} \end{aligned}$$

El modelo YIQ fue desarrollado desde un punto de vista perceptual y provee varias ventajas en la codificación del color en las transmisiones al desacoplar Y, y los componentes de cromaticidad I y Q. Sin embargo, el modelo genera un espacio perceptualmente no uniforme, por lo que no es apropiado para la cuantificación de las diferencias de color percibidas. Por ejemplo, la distancia Euclidiana no es capaz de medir con precisión la distancia perceptual del color en el espacio no uniforme YIQ. Por lo tanto, YIQ no sería el mejor espacio para cálculos cuantitativos en donde intervenga la percepción de color humana. [2]

#### 2.2.4 La familia de modelos de color HSI

La familia de espacios de color HSI es usada principalmente en gráficas computacionales para especificar los colores, al usar las nociones artísticas de tintas, sombras y tonos. Se deriva del espacio de color RGB por transformaciones de coordenadas. En un sistema computacional de procesamiento de imágenes, es necesario transformar las coordenadas de color de HSI a RGB para su despliegue en pantalla, y viceversa para las operaciones del procesamiento. [2]

*La familia de espacios de color HSI usa aproximadamente coordenadas cilíndricas. La saturación (S) es proporcional a la distancia radial y la tonalidad (H) es una función del ángulo del sistema de coordenadas polar. La intensidad (I) o luminancia (L) es la distancia a lo largo del eje perpendicular al plano coordenado polar. El factor dominante al seleccionar un modelo de color HSI particular, es la definición de luminancia, la cual determina las superficies de luminancia constante, y por lo tanto, la forma del sólido que representa el modelo de color. (...)*

*El espacio de color HSI fue desarrollado para especificar numéricamente, los valores de la tonalidad (H), la saturación (S) y la intensidad (I) de un color. La tonalidad (H) es una medida de la composición espectral de un color. Se representa como un ángulo alrededor de un eje vertical, y tiene un rango de valores entre 0 y 360 grados empezando por el rojo en  $0^\circ$ . (K.N., Plataniotis, y A.N.Venetsanopoulos, 2000, p. 25, traducido)*

En este espacio de color, la saturación (S) se extiende desde 0 (en el eje I) radialmente hacia fuera, teniendo un máximo de 1 en la superficie del cono. Este componente se refiere a la proporción de luz pura de la longitud de onda dominante, e indica qué tan lejos está un color de un gris de igual brillantez. La intensidad es una medida de la brillantez relativa; su rango es [0, 1] (ver Fig. 6).

En la parte superior e inferior del cono, donde los valores de I son 1 y 0, respectivamente, la saturación y la tonalidad no tienen sentido y están indefinidas. En cualquier punto a lo largo del eje I, la componente de la saturación es 0 y la tonalidad (H) es indefinida. Esta singularidad ocurre dondequiera que  $R = G = B$ . [2]

El modelo de color HSI debe su utilidad a dos factores principales: 1) de manera similar al modelo YIQ, la componente de intensidad I está desacoplada de la información de cromaticidad. 2) los componentes de Tonalidad (H) y Saturación (S) están íntimamente relacionados a la manera en que nosotros los humanos percibimos la cromaticidad. [2]

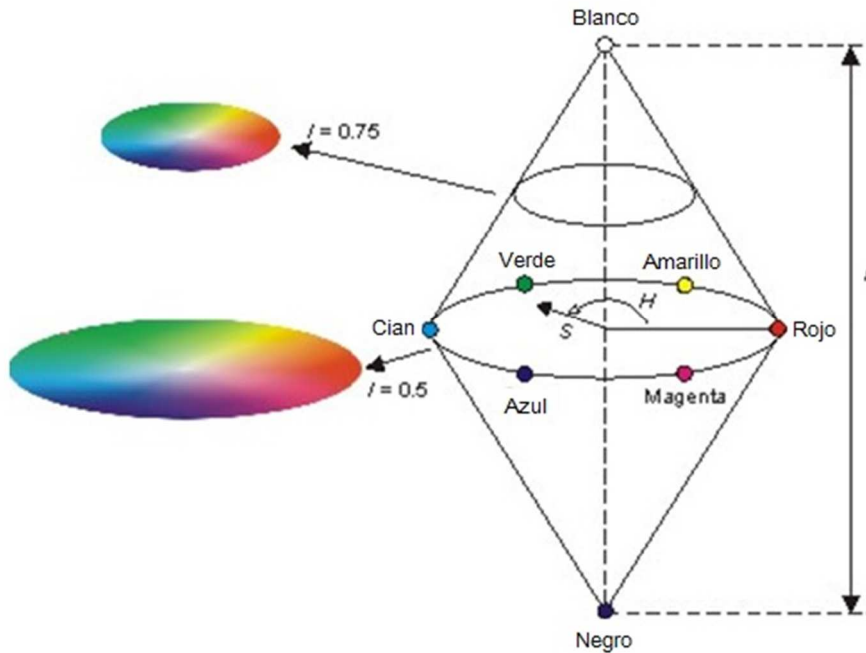


Fig. 6 Espacio de color HSI

La conversión de RGB (rango de [0,1]) a HSI con rango de [0,360] para H y [0,1] para S e I es la siguiente:

$$H = \cos^{-1} \frac{1}{2}[(R-G) + (R-B)]/[(R-G)^2 + (R-B)(G-B)]^{1/2}$$

$$S = 1 - [3/(R+G+B) * \min(R, G, B)]$$

$$I = 1/3 (R+G+B)$$

La conversión de HSI (rango de [0,360] para H y [0,1] para S e I) a RGB con rango de valores en [0,1] es la siguiente:

Si H está en el sector RG ( $0 < H \leq 2\pi / 3$ ):

$$b = 1/3 (1-S)$$

$$r = 1/3 (1 + [S * \cos H / \cos (\pi / 3 - H)])$$

$$g = 1 - (r + b)$$

Si H está en el sector GB ( $2\pi / 2 < H \leq 4\pi / 3$ ):

$$H = H - 2\pi / 3$$

$$r = 1/3 (1-S)$$

$$g = 1/3 (1 + [S * \cos H / \cos (\pi / 3 - H)])$$

$$b = 1 - (r + g)$$

Si H está en el sector BR ( $4\pi/3 < H \leq 2\pi$ ):

$$\begin{aligned}
 H &= H - 4\pi / 3 \\
 g &= 1/3 (1-S) \\
 b &= 1/3 (1+ [S \cos H / \cos (\pi/3 - H)]) \\
 r &= 1 - (g + b)
 \end{aligned}$$

La manera más fácil de seleccionar superficies de luminancia constantes es a través de planos. Una versión simplificada de la luminancia percibida en términos de valores RGB es  $L = (R + G + B)/3$ .

Otros miembros de la familia HSI, como el doble cono hexagonal HLS, pueden ser obtenidos directamente del HSI modificando las superficies de luminancia constante, al definirse  $L = (\text{máximo}(R, G, B) + \text{mínimo}(R, G, B)) / 2$ . Ver Fig. 7.

Si los valores máximos y mínimos coinciden, entonces  $S = 0$  y la tonalidad es indefinida. En caso contrario, la saturación se define como:

$$\begin{aligned}
 \text{Si } L \leq 0.5 \text{ entonces } S &= (\text{Max} - \text{Min}) / (\text{Max} + \text{Min}) \\
 \text{Si } L > 0.5 \text{ entonces } S &= (\text{Max} - \text{Min}) / (2 - \text{Max} - \text{Min})
 \end{aligned}$$

Donde Max = máximo (R, G, B) y Min = mínimo (R, G, B). La tonalidad (Hue) se calcula de la siguiente manera:

1. Si R = Max entonces:  
 $H = (G' - B') / (\text{Max} - \text{Min})$
2. Si G = Max entonces:  
 $H = (B - R) / (\text{Max} - \text{Min})$
3. Si B = Max entonces:  
 $H = 4 + (R - G) / (\text{Max} - \text{Min})$

La transformación inversa, de HLS a HSI, comienza reescalando los ángulos de la tonalidad al rango [0,6]. Se consideran los siguientes casos:

1. Si  $S = 0$ , la tonalidad está indefinida y  $(R, G, B) = (L, L, L)$
2. En caso contrario,  $i = \text{floor}(H)$  siendo el número de sector en y  $f = H - i$  el valor de la tonalidad en dicho sector. Se consideran los siguientes casos:

- a. Si  $L \leq L_{\text{crítico}} (= 255/2)$  entonces:

$$\begin{aligned}
 \text{Max} &= L (1+S) \\
 \text{Mid1} &= L (2fS + S - S)
 \end{aligned}$$

$$\text{Mid2} = L [2(1 - f)S + 1 - S]$$

$$\text{Min} = L (1-S)$$

b. Si  $L > L_{\text{crítico}}$  entonces:

$$\text{Max} = L (1-S) + 255S$$

$$\text{Mid1} = 2[(1-f)S - (0.5 - f) \text{Max}]$$

$$\text{Mid2} = 2[fL - (f - 0.5) \text{Max}]$$

$$\text{Min} = L (1+S) - 255S$$

$L_{\text{crítico}} = 255/2$  para una representación de 8 bits. La función  $\text{floor}(X)$  es una función que regresa el entero más grande que no sea mayor que  $X$ .

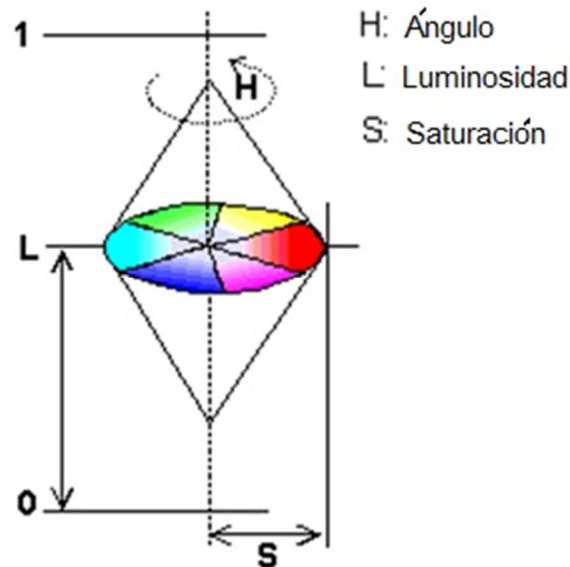


Fig. 7 Espacio de color HLS

El modelo de color HSV también pertenece a este grupo de sistemas de coordenadas de color basados en la tonalidad, que tienen una correspondencia más cercana a la percepción humana. Este espacio orientado al usuario, apela a ideas artísticas intuitivas; como tinte, tono y sombra. El sistema de coordenadas HSV está convenientemente representado en el modelo del cono hexagonal de la Fig. 8.

El conjunto de ecuaciones que transportan un punto de RGB a los valores apropiados de HSV son:

$$H1 = \cos^{-1} [2[(R-G)+(R-B)] / [(R-G)^2 + (R-B)(G-B)]^{1/2}]$$

$$H = H1, \text{ si } B \leq G$$

$$H = 360 - H1, \text{ si } B > G$$

$$S = \max(R, G, B) - \min(R, G, B) / \max(R, G, B)$$

$$V = \max(R, G, B)/255$$

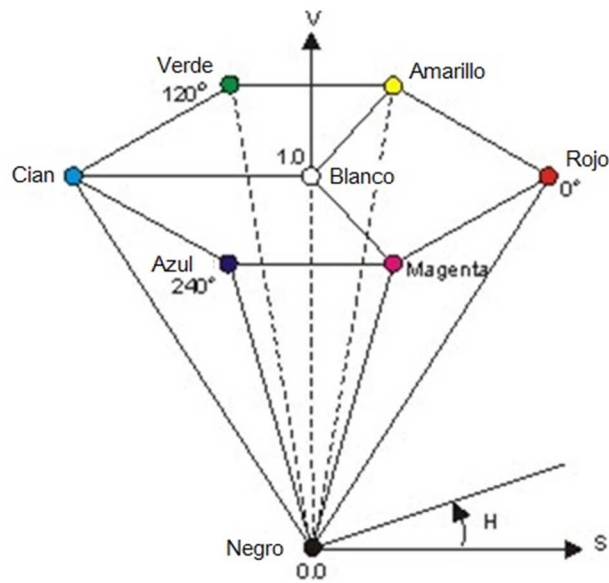


Fig. 8 Espacio de color HSV

Las ventajas de los espacios de la familia de color HSI sobre otros espacios son:

1. Buena compatibilidad con la intuición humana.
2. Separabilidad de los valores cromáticos y acromáticos.
3. Posibilidad de usar una característica de color como tonalidad, con propósitos de segmentación. Se puede usar H, S o I como característica única.

Sin embargo, los espacios de color orientados a la tonalidad tienen algunas importantes desventajas como [1][2][9]:

1. Singularidades en la transformación. Por ejemplo tonalidad indefinida para puntos acromáticos.
2. Sensibilidad a pequeñas variaciones de valores RGB cerca de los puntos de singularidad.
3. Inestabilidad numérica al operar con valores de tonalidad (H) dada la naturaleza angular de esta característica.

En el modelo de representación del color propuesto en esta tesis, se resuelven estas desventajas al dividir el espacio de colores en zonas cromática y acromática y al asignar a cada zona vectores de magnitud 1 o 0 como representación de la tonalidad, en las mejoras

en la definición de la zona acromática  $W$ , en la representación de la tonalidad como un vector normalizado en  $\mathfrak{R}^2$  que elimina la inestabilidad numérica mencionada y en la integración en una función de similitud [3][5][34].

# CAPÍTULO 3

## ESTADO DEL ARTE



### 3. Estado del arte

Actualmente los enfoques y las técnicas disponibles para la segmentación varían ampliamente: los hay basados en morfología matemática [7], en topología computacional [8], basados en optimización de biogeografía [17], en conjuntos neutrosóficos [18], en medidas de rugosidad multiescala [19], en aprendizaje de optimización de enjambre de partículas [20], en cuaterniones [21], en agrupamientos en el espacio de color CIE  $L^*a^*b^*$  [37], basados en técnicas *wavelets* [38] entre otros, pero sigue siendo aún un problema abierto.

Todos estos trabajos tienen en común que la información de color se representa en algún espacio de color (como  $L^*a^*b^*$ ,  $L^*u^*v^*$ , RGB, HSV, etc.) y su homogeneidad y/o discontinuidad se obtienen a partir de una métrica dentro del espacio de color seleccionado. A partir del análisis de los resultados se podrá ver que la función de similitud propuesta así como las modificaciones al espacio HSI propuestos pueden ser una alternativa útil para la integración de la información de color ya sea para la localización de regiones homogéneas y bordes de color así como en la toma de decisiones para la resolución de ambigüedades.

La selección adecuada del espacio de color para el procesamiento de imágenes es un aspecto muy importante a tener en cuenta [2][3][9]. La representación en el espacio de color RGB tiene varias desventajas conocidas, pero es utilizado por Shi y Funt (2007), [21], en una nueva forma mediante el uso de cuaterniones.

En Correa-Tome y otros (2011), [43], se presenta un estudio comparativo entre varios espacios de color perceptualmente uniformes (en concreto:  $L^*a^*b^*$ ,  $L^*u^*v^*$  y  $RLa^*b^*$ ) con el fin de establecer qué espacio de color es mejor para la segmentación de imágenes naturales. Para realizar la comparación se utiliza un método de discrepancia empírica. Este método necesita una Verdad-Base (GT) como modelo 'ideal' de la segmentación y calcula cómo la segmentación se aproxima a este 'ideal'. Estos espacios de color tienen el inconveniente de que cuando manejan la información de saturación y tonalidad de manera conjunta en los canales  $a^* b^*$  (o  $u^* v^*$ ), es difícil predecir si la diferencia en color es debida a alguna de estas variables.

La segmentación 'ideal' utilizada fue hecha por diferentes personas en la base de datos de Berkeley. Sólo se utiliza la información de color para la realización de las pruebas comparativas excluyendo lo demás. En el estándar de comparación (*benchmark*) fueron utilizados dos enfoques: 1. Clasificación supervisada de píxeles y 2. Clasificación no supervisada utilizando *K-media*. También utiliza como referencia el umbralado de la imagen de intensidad en RGB.

Las segmentaciones y evaluaciones hechas por individuos tienen diferencias intrínsecas debido a errores de tipo subjetivo al evaluar la importancia de los objetos en la escena [23]. En cuanto al método de evaluación de resultados podemos observar que los resultados tomados como 'ideales' en el conjunto de datos de Berkeley difieren entre diferentes evaluadores; en este trabajo los autores no mencionan cómo se integraron las diferentes segmentaciones para generar su modelo 'ideal' de segmentación.

Como resultado, concluyen que el espacio de color  $L^*u^*v^*$  obtuvo los mejores resultados en: 1) capacidades medias de discriminación y 2) velocidad de procesamiento.

En Protiere y Shapiro (2007), [41], se presenta un algoritmo de segmentación semiautomático para imágenes naturales. El usuario selecciona primero diferentes regiones de interés mediante sencillos garabatos y a partir de ellos toda la imagen se divide en segmentos de forma automática. Para lograr esta tarea, se calculan distancias ponderadas a partir de los garabatos. La ponderación se obtiene partiendo de una serie de filtros de Gábor para localizar texturas en las imágenes.

En su método se calcula una mínima distancia geodésica tomando en cuenta sólo cambios en la luminosidad como factor de ponderación. La función de similitud de color propuesta en esta tesis podría integrarse en el cálculo de las ponderaciones y de esta manera podría mejorar sus resultados, haciendo que la distancia geodésica sea sensible a la homogeneidad de color y no sólo a la luminancia.

En Bai y Shapiro (2007), [40], los autores presentan un algoritmo semiautomático para la segmentación de imágenes naturales y video. Su técnica se basa en el cálculo de una distancia geodésica ponderada de cada píxel a garabatos generados por el usuario. Los garabatos dados por el usuario son mucho más simplificados en comparación con otros sistemas, ya que el usuario sólo tiene que trazar una línea que cruza la región de interés. Su sistema puede manejar oclusiones parciales. Las ponderaciones para la distancia geodésica se calculan de acuerdo a los cambios en la probabilidad de que el píxel pertenezca al objeto de interés. La probabilidad se calcula a partir de los garabatos dados por el usuario en el espacio de color  $L^*u^*v^*$ . El modelo de color y la función de similitud propuesta en esta tesis también podrían integrarse en su sistema y posiblemente sus resultados; los pesos podrían calcularse según el gradiente de la función de similitud propuesta en el presente trabajo de tesis.

En Rother y otros (2004), [42], los autores presentan un método de segmentación semiautomático de objetos de interés en fondos complejos. El método integra la información de las regiones homogéneas y los bordes. La segmentación se realiza minimizando una función de energía, donde se integra la información de regiones homogéneas y bordes. El trabajo utiliza el espacio de color RGB y modelos de mezcla de Gauss para cada píxel. Como entrada del usuario, el algoritmo sólo necesita el objeto de interés enmarcado. A partir de esta entrada se infiere que el marco está en el fondo y el objeto está contenido en el marco. También se presenta un estudio comparativo del estado del arte a partir de diferentes sistemas comerciales semiautomáticos. Se muestra cómo su método requiere menos esfuerzo por parte del usuario.

En Sivic y Zisserman (2003), [44], se presenta un novedoso enfoque metodológico para la extracción de objetos y escenas en videos en el cual busca y localiza todas las apariciones de un objeto (previamente señalado por un usuario) en un video. El sistema permite recuperar las imágenes (o grupos de imágenes) en donde aparece un objeto particular con la misma facilidad, velocidad y precisión con la que Google encuentra documentos de texto (páginas web) donde aparecen determinadas palabras. Este objeto es representado por un

conjunto de descriptores de regiones (vectores descriptores de 128 dimensiones SIFT) los cuales son invariantes a cambios en perspectiva, por lo que se tienen buenos resultados en el reconocimiento del objeto a pesar de cambios en iluminación, perspectiva y también tolera oclusiones parciales.

Para generar los descriptores se calculan dos tipos de regiones covariantes para cada imagen en el video. El primer tipo (*Shape Adapted, SA*) es construido por adaptación de la forma de una elipse alrededor de un punto de interés. Su forma es determinada al maximizar el gradiente de intensidad isotrópico sobre la región elíptica. El segundo tipo de región (*Maximally Stable, MS*) es construido al seleccionar áreas segmentadas utilizando líneas de cuencas (*watershed lines*) sobre imágenes de intensidad. Se seleccionan las áreas que permanecen constantes al variar el umbral de intensidad.

Ambos tipos de regiones son utilizados porque ellas detectan diferentes áreas de una imagen y por lo tanto proveen representación complementaria de una imagen. SA tiende a describir bordes mientras MS tiende a describir regiones homogéneas sobre fondos. En ese trabajo tanto la detección de regiones como su descripción se calcularon sobre versiones monocromáticas de las imágenes, por lo que la información de color no es utilizada [44]. La función de similitud de color propuesta en este trabajo de tesis podría usarse tanto en la generación de las regiones SA como MS así como en la toma de decisiones para la resolución de ambigüedades; y de esta manera incorporar información de color en el sistema y posiblemente mejorar los resultados.

En Vaitkus y Várady (2013), [16], los autores presentan un algoritmo de segmentación de imágenes basado en herramientas de topología algebraica computacional y la teoría de Morse. Asignan una cantidad llamada persistencia a sus características topológicas, midiendo su tiempo de vida en la construcción. En combinación con los conceptos de la teoría de Morse, construyen y simplifican una segmentación de líneas de cuencas (*watershed*) del complejo. Para imágenes en colores aplican un algoritmo general en la vecindad del grafo de la nube de puntos que representa la imagen en el espacio de color, el que se filtra posteriormente mediante estimación de la densidad Gaussiana.

En Yue y otros (2012), [19], los autores presentan una medida de rugosidad multiescala basada en la simulación de la visión humana. Aplicaron teorías de escala-espacio lineal y conjuntos aproximados para generar la rugosidad jerárquica de la distribución del color en múltiples escalas. El algoritmo de segmentación se basa en medir la rugosidad multiescala en histogramas de color. Los autores proponen la *entropía de rugosidad* para la selección de la escala basada en variación de información.

El trabajo presentado por Huang y otros (2011), [8], aborda el problema de la segmentación de imágenes bajo el paradigma de agrupamiento-entonces-etiquetado. Presentan un algoritmo de agrupamiento mejorado que mantuvo buena coherencia de los datos en el espacio de características y que se utilizó para hacer el agrupamiento en el espacio de características de color usando el espacio de color CIE  $L^*a^*b^*$ . En lugar de calcular las características de cada píxel, se hacen los cálculos a partir de regiones atómicas con características homogéneas de color llamadas superpíxeles. La segmentación de la imagen se obtiene mediante el establecimiento de cada píxel con su grupo correspondiente.

Puranik y otros (2011), [20], presentan un método de segmentación automática basada en conjuntos difusos y aprendizaje global utilizando optimización de enjambre de partículas. Se definen conjuntos difusos en el espacio de color de tono-saturación-luminosidad (HSL). Durante el proceso de búsqueda, un miembro de la población trata de maximizar en cada iteración un criterio de aptitud, que es una alta tasa de clasificación y un pequeño número de reglas. Por último, se selecciona la partícula con el valor más alto de aptitud (*fitness*) como el mejor conjunto de reglas difusas para la segmentación de imágenes.

En el trabajo de Gupta y otros (2011), [17], se propone un enfoque de optimización basado en biogeografía para la segmentación automática del color. Biogeografía es el estudio de la distribución geográfica de los organismos biológicos, que es básicamente un proceso evolutivo que logra el intercambio de información por la migración de las especies. Utilizan agrupamientos en el de espacio de color  $L^*a^*b^*$  (regiones homogéneas) como hábitats que se modifican con el tiempo por las reglas del campo de la biogeografía. El algoritmo de optimización es similar al de aprendizaje por optimización de enjambre de partículas con algunas diferencias en sus normas como la de no crear hijos.

En Sengur y Guo (2011), [18], se presenta un nuevo método de segmentación automática que utiliza conjuntos neutrosóficos para la representación y análisis multiresolución con transformación ondeleta (*wavelet*). Se utiliza tanto la información de color (en el espacio de color CIE  $L^*u^*v^*$ ) como la textura para la segmentación. El análisis de la transformación *wavelet* permite la caracterización de la textura y un valor de la entropía, que se utiliza en la caracterización de la imagen en colores con conjuntos neutrosóficos. Cada píxel de la imagen se representa como un conjunto neutrosófico, con operaciones aplicables definidas en ese campo.

En Celik y Tjahjadi (2010), [22], los autores presentan un algoritmo de segmentación de imágenes en colores no supervisado que utiliza información multiescala de los bordes y contenido espacial de color. La información multiescala de los bordes se extrae utilizando la transformada *wavelet dual tree complex*. Se aplican operadores morfológicos binarios a la información de bordes para detectar regiones semilla. La segmentación de regiones homogéneas se obtiene usando crecimiento de regiones seguido de fusión de regiones en el espacio de color CIE  $L^*a^*b^*$ .

En el trabajo de Harun y otros (2010), [26], los autores presentan una técnica para la segmentación de imágenes de leucemia aguda. La técnica de segmentación segmenta cada imagen de leucemia en dos regiones: objeto y fondo. En su enfoque, la segmentación se basa tanto en el espacio de color HSI como en el RGB. Una comparación de rendimiento entre los algoritmos de segmentación se lleva a cabo para elegir la mejor segmentación de la imagen de color para la detección del estallido. Sus resultados muestran que la segmentación basada en el modelo HSI tiene éxito con las imágenes de leucemia aguda, y además quita el ruido de fondo.

En Kim y otros (2008), [24], los autores proponen un modelo de color en el espacio de color HSI, tomando en cuenta la información de intensidad mediante la adopción del ajuste de la curva *B-spline*, con el fin de hacer un modelo matemático para las características

estadísticas de un color con respecto a la intensidad. Las características estadísticas contienen la desviación media y el estándar de tonalidad y saturación con respecto a la intensidad. El algoritmo propuesto se aplicó con éxito en imágenes en colores bajo diferentes condiciones de iluminación.

En Shi y Funt (2007), [21], los autores presentan un método que utiliza cuaterniones para la representación del color y segmentan la imagen en regiones con color y textura similar. La ventaja de usar la aritmética de los cuaterniones es que el color puede representarse y analizarse como una sola entidad. Cada componente de color de la imagen de entrada RGB se corresponde a cada base imaginaria  $i, j, k$  del cuaternión que representa cada píxel en la imagen. El componente real del cuaternión está relacionado con la textura.

Un primer estudio exhaustivo sobre los métodos de evaluación de segmentación de imágenes, se presenta en Zhang (1996), [12], con una clasificación coherente de los métodos existentes en ese momento. En Zhang (2001), [13], se presentan los progresos realizados en la materia durante los siguientes cinco años después de la primera publicación. Otra actualización se presentó cinco años después abarcando los principales métodos de evaluación de segmentación disponibles hasta 2006, [15].

Chabrier y otros (2006), [45], presentan un estudio comparativo de 14 criterios de evaluación de métodos supervisados de segmentación de imágenes utilizando bordes. El estudio se realizó en dos partes: (1) Evaluación con imágenes sintéticas para caracterizar el comportamiento general del algoritmo que se complementa con (2), que consiste en una evaluación sobre una selección de imágenes reales en colores. Para obtener el GT de segmentaciones de diferentes personas, los autores mencionan que fusionaron los resultados, pero no dan detalles de cómo lo hicieron.

Zhang y otros (2006), [11], presentan un estudio exhaustivo sobre los métodos no supervisados de evaluación de la segmentación publicados hasta ese momento. Los autores proponen una jerarquía de métodos con un compendio de las principales ramas y localizando cada grupo de los métodos no supervisados en él. Ellos mencionan las ventajas, tales como el no necesitar GT para obtener resultados cuantitativos. También proponen las principales líneas de investigación futura para este tipo de métodos en su tiempo.

En Macaire y otros (2006), [37], se presenta un esquema de segmentación de imágenes de color basado en clasificación de píxeles no supervisada. Cuando los puntos de color de diferentes regiones de la imagen producen un solo grupo en el espacio de color, el esquema divide este grupo en subpoblaciones de puntos de color definidos por dominios. Para este propósito, la conectividad y las propiedades de homogeneidad de color en subconjuntos de píxeles son analizadas con el fin de construir clases que correspondan a regiones homogéneas en la imagen.

Martin y otros (2001), [23], presentan una base de datos que contiene el GT de segmentaciones producidas manualmente por un grupo de personas, de una amplia variedad de imágenes de escenarios naturales de color. Los autores definen dos medidas de error relacionadas que cuantifican la coherencia entre las segmentaciones de diferentes granularidades. Estas medidas permiten realizar comparaciones entre las segmentaciones

realizadas por personas y las segmentaciones de la misma escena realizadas por computadora.

En Zhang y Gerbrands (1992), [14], se presenta una forma de diseño de imágenes sintéticas con su GT correspondiente para la evaluación de algoritmos de segmentación. Los autores introducen un marco general y consideraciones generales de diseño. También presentan un sistema para la generación de imágenes sintéticas en tonos de grises tomando en cuenta sus consideraciones de diseño. Se estudia el comportamiento de un método de segmentación en imágenes en tonos de grises que utiliza umbralado y se obtienen algunas observaciones.

Como vimos varios de los trabajos hacen uso de los espacios de color CIE  $L^*a^*b^*$  o CIE  $L^*u^*v^*$ , que tienen algunas supuestas ventajas, tales como la separación de la información de luminosidad ( $L$ ), así como el manejo de la similitud cromática de color como la distancia Euclidiana entre los canales independientes  $a^*b^*$  (o  $u^*v^*$ ).

Como veremos en la sección de pruebas comparativas, la suposición de la independencia de los canales  $a^*$  y  $b^*$  de la luminancia  $L^*$  no fue real [28][29] y la influencia se hizo mayor conforme aumentaba la saturación [28].

# CAPÍTULO 4

## METODOLOGÍA

## 4. Metodología

El método de segmentación propuesto en esta tesis se basa en el cálculo de una función de similitud de color (también propuesta) para cada píxel de la imagen de color (representado en el modelo de color RGB con 24 bits) para formar lo que llamamos una imagen de similitud de color (ISC), la cual es una imagen de escala de grises. Una imagen en colores suele contener millones de colores, y muchos miles de ellos representan el mismo color percibido de un objeto, pero con variaciones debido a la presencia de ruido aditivo, la falta de definición entre las fronteras de color y regiones, sombras en la escena, la resolución espacial del sistema de visión humano, etcétera. La función de similitud de color propuesta permite la agrupación de los muchos miles de colores, en una sola imagen de salida en tonos de grises [3][5][31][32][34][35].

La ISC es entonces umbralada automáticamente y la salida puede ser utilizada como una capa de segmentación, o puede ser modificada posteriormente con operadores morfológicos para introducir características geométricas si éstas son necesarias.

La generación de una ISC sólo requiere del cálculo de la ecuación (1) (más adelante) para cada píxel de la imagen de entrada RGB. Así, la complejidad es lineal con respecto al número de píxeles en la imagen de origen y por esa razón el algoritmo es computacionalmente económico.

En primer lugar, se calcula el centroide de color y la desviación estándar de color de una pequeña muestra que consiste en unos pocos píxeles (menos de 10 píxeles por color) del color que se desea segmentar. El centroide calculado representa el color deseado a ser segmentado mediante la técnica propuesta para tal fin. Entonces, la función de similitud de color utiliza la desviación estándar de color calculada a partir de la muestra de píxeles para adaptar el nivel de dispersión del color en las comparaciones [3][5][31][32][34][35].

El resultado del cálculo particular de la función de similitud para cada píxel y el centroide de color (es decir, la medida de similitud entre el píxel y el valor representativo del color) genera la ISC. La generación de esta imagen es la base del método propuesto en esta tesis, la cual conserva la información del color seleccionado de la imagen en colores original. La ISC es una representación discreta en el rango 0-255 de una función continua, cuyos valores están en el rango normalizado [0-1]. La ISC puede ser umbralada con cualquier método de umbralado automático. Para obtener los resultados presentados en esta investigación se utiliza el método de umbralado de Otsu [25][27].

Para generar una ISC se necesita como entrada: 1) Una imagen en colores representada en el modelo de color RGB de 24 bits (formato de color verdadero) y 2) Una muestra de píxeles seleccionados arbitrariamente que forman la muestra del color que se desea segmentar. De esta muestra de píxeles se calculan los indicadores estadísticos de acuerdo al modelo modificado de color HSI mediante los métodos propuestos.



Esta información es necesaria para adaptar la función de similitud de color con el fin de obtener mejores resultados. Para obtener una ISC se calcula para cada píxel de la imagen la siguiente función de similitud de color propuesta, Ec. (1):

$$S_{(p,q)} = e^{\left(\frac{-\Delta_h^2}{2\sigma_h^2}\right)} * e^{\left(\frac{-\Delta_s^2}{2\sigma_s^2}\right)} * e^{\left(\frac{-\Delta_i^2}{2\sigma_i^2}\right)} \quad (1)$$

Donde  $\Delta_h$  es la distancia entre la tonalidad ( $p$ ) y la tonalidad promedio( $q$ );  $\Delta_s$  es la distancia de saturación entre la saturación( $p$ ) y la saturación promedio( $q$ );  $\Delta_i$  es la distancia de intensidad entre la intensidad( $p$ ) y la intensidad promedio( $q$ );  $\sigma_h$  es la desviación estándar de tonalidad de la muestra de píxeles;  $\sigma_s$  es la desviación estándar de saturación de la muestra de píxeles;  $\sigma_i$  es la desviación estándar de intensidad de la muestra. En la Ec. (1) la información de color se integra dando gran importancia a los pequeños cambios de percepción en el tono, así como una tolerancia ancha o estrecha para los valores de intensidad y saturación en función de la muestra inicial, que es representativa del color que se desea segmentar [3][5][31][32][34][35].

Los valores estadísticos necesarios se calculan como sigue Ec. (2):

$$\begin{aligned} \text{Saturation\_average} &= S_c = \frac{1}{n} \sum_{i=1}^n \text{saturation}(i) . \\ \text{Intensity\_average} &= I_c = \frac{1}{n} \sum_{i=0}^n \text{intensity}(i) . \\ \text{Hue\_standard\_deviation} &= \sigma_h = \sqrt{\frac{\sum_{i=1}^n \Delta_h^2(i)}{n}} . \\ \text{Saturation\_standard\_deviation} &= \sigma_s = \sqrt{\frac{\sum_{i=1}^n \Delta_s^2(i)}{n}} . \\ \text{Intensity\_standard\_deviation} &= \sigma_i = \sqrt{\frac{\sum_{i=1}^n \Delta_i^2(i)}{n}} . \end{aligned} \quad (2)$$

Donde  $n$  es el número de píxeles en la muestra.

Las desventajas comunes atribuidas al espacio de color HSI, tales como las singularidades inamovibles de tonalidad en saturaciones muy bajas o la naturaleza periódica del matiz (*hue*), que se pierde en su representación estándar como un ángulo en el rango  $[0^\circ -360^\circ]$ , son superadas en la técnica propuesta en este trabajo al utilizar una representación vectorial en  $\mathbb{R}^2$  en la separación de las regiones cromáticas y acromáticas y en la definición de las distancias  $\Delta_h, \Delta_s$ .

Dos modificaciones en el espacio de color HSI estándar son propuestas con el fin de crear un modelo consistente para representar los colores y centroides de color:

1. Representación de la tonalidad. En lugar de la representación estándar de la tonalidad como un ángulo en el rango  $[0^\circ -360^\circ]$ , la tonalidad está representada como un vector normalizado con magnitud 1 o 0. Esta representación tiene al menos tres ventajas en comparación con un ángulo en el rango  $[0^\circ -360^\circ]$ : a) la discontinuidad existente en 360 grados y 0 grados se elimina; b) la tonalidad promedio de un grupo de píxeles puede ser entendido como el ángulo resultante de una adición vectorial de los píxeles de color en la región cromática de la muestra, lo que significa una manera sencilla para calcular la tonalidad media; c) el valor de la amplitud de 0 o 1 sirve como bandera destinada a la distinción entre regiones cromáticas o acromáticas.

2. Separación de las regiones cromáticas y acromáticas. La separación de las regiones (como se describe más adelante) se utiliza para calcular la tonalidad promedio. Una vez que se ha calculado esta distinción, ya no es necesaria, porque en la formulación de la Ec. (1) todos los casos de comparación de color entre zonas mantienen coherencia. El uso de Gaussianas en la definición de la Ec. (1) refleja la opinión de que con las modificaciones propuestas en este trabajo se permiten distribuciones normales de las características de color en el espacio HSI modificado, en concordancia con la experiencia visual de la similitud de color [31][32][34][35].

#### **4.1 La selección de la muestra de píxeles**

La muestra de píxeles es la representación del color deseado ( $s$ ) a ser segmentado en una imagen en colores. La selección de la muestra de píxeles es el único paso del proceso en manos del usuario. De esta muestra de píxeles se calculan dos valores para alimentar el algoritmo de segmentación: el centroide del color y una medida de la dispersión del color de este centroide, que en nuestro caso es la desviación estándar. Estos dos valores se representan de acuerdo con el modelo HSI modificado propuesto [3][31][32][34][35].

Si se toma un único píxel como muestra, su color representaría el centroide de color, y produciría una dispersión igual a cero, lo que da una delta de Dirac en el cálculo de la ecuación (1). Esto significa que la función de similitud sería estrictamente discriminativa para el color del píxel. Esta no es la intención en general de la segmentación de imágenes en colores que usualmente contienen millones de colores, muchos miles de los cuales son debidos a la presencia del ruido aditivo y ruido de cuantificación. Por lo tanto, se utiliza en el caso de un píxel por muestra un valor pequeño para la dispersión, tentativamente 0.001.

Si se toma adicionalmente otro píxel, se obtiene entonces el centroide de ambos y su correspondiente desviación estándar para alimentar el algoritmo. Así que cuando se selecciona un píxel adicional, debe tomarse de una región que no estaba segmentada o que estaba mal segmentada cuando se utilizó el primer píxel. Eso significa que para obtener mejores resultados, los píxeles de la muestra deben tomarse de las regiones de color en una forma tal que deben constituir una buena representación de las variaciones de color en la región [31][32][34][35].

Si se añaden más y más píxeles a la muestra el centroide correspondiente a la zona a ser segmentada aumenta en precisión. Aquí podemos cumplir con una relativamente pequeña

muestra representativa de la zona de color a ser segmentada. Más allá de un número dado de píxeles bien seleccionados en la muestra, el aumento de su número no afecta sensiblemente la calidad de la segmentación, porque la adición de más píxeles a la muestra de aproximadamente el mismo color percibido no afecta de una manera sensible a los estimadores estadísticos que alimentan el algoritmo. De los resultados obtenidos en la caracterización del algoritmo (sección 6.5) se obtuvo que 5 píxeles es el tamaño de la muestra que obtuvo los mejores resultados y que no mejoraron sensiblemente la segmentación al aumentar su número en la muestra.

## 4.2 La zona acromática W

La zona acromática W es la región en el espacio de color HSI donde ninguna tonalidad es percibida por el ser humano. Esto significa que el color se percibe sólo como un nivel de gris, debido a que la saturación de color es muy baja; o la luminancia es demasiado baja (cercana al negro) o demasiado alta (cercana al blanco) [2][3][33].

Teniendo en cuenta el espacio tridimensional de color HSI, la zona acromática clásica se define como la unión geométrica de los puntos en el interior del cilindro creado por el umbralado de la saturación agregando dos conos donde hay muy baja intensidad y muy alta intensidad [2]. Píxeles dentro de esta región se perciben como píxeles en niveles de gris (figura 1 izquierda).

Para modelar mejor la respuesta visual humana en las zonas de cambios bruscos, cerca de las zonas de unión de los dos conos con el cilindro de la zona de singularidad W, como se presenta en Plataniotis y Venetsanopoulos (2000), [2], y Alvarado-Cervantes (2006), [3], fue conveniente modificar la caracterización del modelo clásico de color HSI para los colores que pertenecen a regiones con muy baja o muy alta luminosidad, como se muestra en la figura 9 (izquierda). [1][3][31][33].

Con el fin de ajustar la región W con un modelo más cercano a la respuesta humana a la brillantez [10], se introdujo una función exponencial con tres parámetros: umbral de saturación ( $st$ ), punto de inflexión ( $ip$ ), e *influencia*, ver Fig. 9 (derecha).

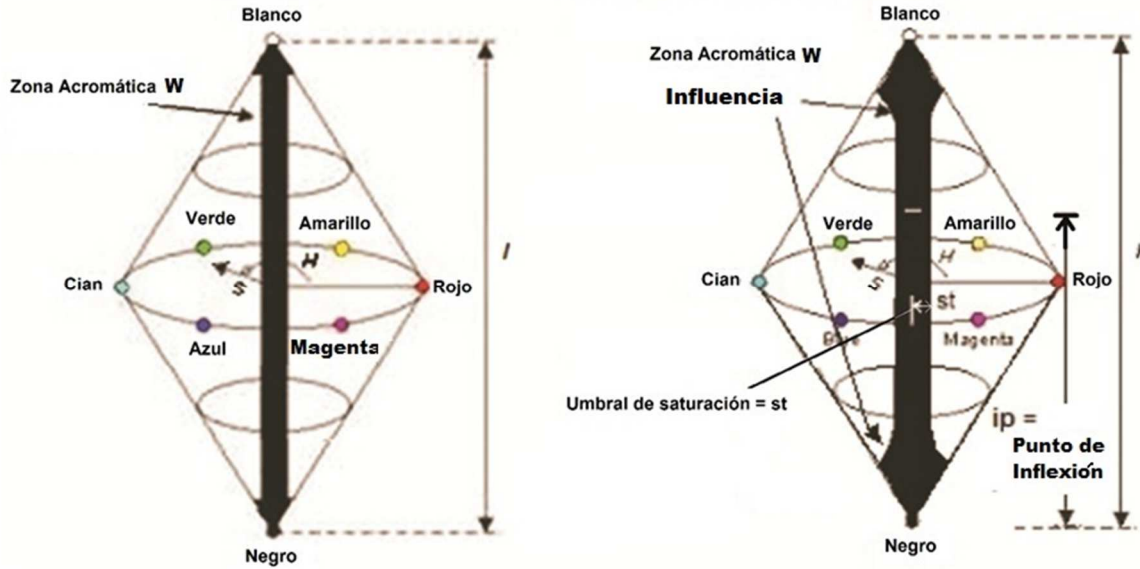


Fig. 9. Zona acromática W en el modelo de color HSI

Entonces, la imagen de saturación se verá ahora afectada por un factor calculado a partir del punto de inflexión ( $ip$ ) y la pendiente *Influencia* para cada píxel ( $P$ ), como se muestra en la Ec. (3):

$$Nueva\_Saturacion\_ (P) = Pos\left(1 - Influencia * (e - 1)^{2 * abs(ip - Intensidad(P))}\right) * Saturacion(P) \quad (3)$$

Donde la pendiente *Influencia* es un parámetro que representa el grado de afectación del factor exponencial al atributo de saturación para cada píxel;  $abs()$  representa la función de valor absoluto,  $Pos()$  es una función que regresa su propio argumento en caso de ser positivo y 0 en otros casos y la intensidad() se define como un promedio de los valores de los píxeles en los canales RGB como se indica en la Ec. (6). Después de calcular los valores Nueva\_Saturacion para la imagen de origen, se umbrala con el valor de saturación ( $st$ ) para obtener los resultados de la zona acromática mejorada W, [31][33].

El punto de inflexión se utiliza para modificar el nivel de afectación de la función exponencial en el nuevo cálculo de la saturación. La hace más o menos sensible a los niveles altos o bajos de iluminación. Por ejemplo, un nivel de 0.5 indica que la influencia de la función exponencial es la misma en las regiones de iluminación alta y baja. Un nivel de 0.6 indica que la función exponencial afecta más a las regiones de baja iluminación [31][33].

Encontramos un rendimiento aceptable con los parámetros determinados empíricamente en los siguientes rangos:  $st \in [0.07 - 0.1]$ ,  $ip \in [0.5 - 0.6]$ , y Pendiente  $\in [1 - 1.5]$ .

### 4.3 Cálculo de la tonalidad promedio

Con el fin de obtener el promedio de la tonalidad ( $H_m$ ) de varios píxeles de una muestra, se aprovecha la representación vectorial en  $\mathfrak{R}^2$ . Los vectores que representan los valores de tonalidad de los píxeles individuales se combinan mediante la suma vectorial. A partir del vector resultante se obtiene el tono promedio correspondiente al ángulo de este vector con respecto al eje rojo. De este modo la tonalidad se calcula de la siguiente manera:

1. Para cada píxel de la muestra se aplica la siguiente transformación propuesta:

$$V_1(P) = \begin{bmatrix} 1 & -\cos(\pi/3) & -\cos(\pi/3) \\ 0 & \sin(\pi/3) & -\sin(\pi/3) \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} = \begin{bmatrix} x \\ y \end{bmatrix} \quad \text{Si } P \notin W \quad (4)$$

$$V(P) = V_1(P) / |V_1(P)|;$$

Y en caso contrario:

$$V(P) = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \quad \text{Si } P \in W$$

Donde  $V(p)$  es la proyección normalizada de las coordenadas RGB del píxel al plano perpendicular al eje de Intensidad del cubo RGB, cuando el eje x es colineal con el eje rojo del círculo cromático. Por otro lado  $W$  representa la zona acromática en el espacio HSI y  $[RGB]^t$  es un vector con los componentes de color del píxel en el espacio de color RGB.

Para llevar a cabo esto, se ejecuta el siguiente código:

```
Vector.x = 0;
Vector.y = 0; // initialize vectors
For (i = 1; i <= n; i++) // for every pixel in the
    sample do
    {Vector.x = Vector.x + V(i).x; // x-component
    of the accumulated vector
    Vector.y = Vector.y + V(i).y;} // y-component of the
    accumulated vector
Vs = [Vector.x Vector.y]; // Accumulated vector
```

En este código tenemos un vector en  $\mathfrak{R}^2$  que acumula las adiciones de vectores al incrementarse el índice. Cada uno de los vectores que se añade corresponde a la transformación anterior de  $\mathfrak{R}^3$  a  $\mathfrak{R}^2$  para cada píxel de la muestra realizada en el paso 1.

2. El ángulo del vector acumulado ( $V_s$ ) con respecto al eje x es la tonalidad promedio:

$$H_m = \text{angle}(V_s, 0) \quad (5)$$

Donde 0 representa el eje del rojo.

#### 4.4 Distancia de tonalidad $\Delta_h$

Aprovechando la representación vectorial de *Hue* obtenida por la transformación  $\mathfrak{R}^3$  a  $\mathfrak{R}^2$  de los puntos en RGB expresada en la ecuación (4), la distancia de tonalidad entre dos píxeles de color o centroides de color  $C_1$  y  $C_2$ , se puede calcular de la siguiente manera:

$$\begin{aligned} \Delta_h(C_1, C_2) &= |V_1 - V_2| && \text{Si } C_1 \text{ y } C_2 \notin W \\ &= 0 && \text{Si } C_1 \text{ o } C_2 \in W \end{aligned} \quad (6)$$

Donde  $W$  es la región acromática y  $V_1$  y  $V_2$  son vectores en  $\mathfrak{R}^2$  calculados con la transformación sobre  $C_1$  y  $C_2$  dada en la ecuación (4).

#### 4.5 Distancias de saturación $\Delta_s$ y de intensidad $\Delta_i$

La distancia de saturación y la distancia de intensidad pueden ser calculadas mediante el uso de las ecuaciones de conversión estándares para la saturación y la intensidad del espacio RGB al espacio HSI [2]. Normalizando  $R$ ,  $G$  y  $B$  en el rango  $[0, 1]$  -Ec. (7):

$$\begin{aligned} saturation(P) &= 1 - \left[ \frac{3}{R+G+B} \min(R, G, B) \right] \\ intensity(P) &= \frac{1}{3}(R+G+B) \end{aligned} \quad (7)$$

En la Ec. (7), se define la saturación igual a cero en el caso del color negro.

Se utilizó la distancia Euclidiana para definir la distancia de saturación y la distancia de intensidad entre dos píxeles o centroides de color. De esa manera la distancia de saturación y la distancia de intensidad entre dos píxeles o centroides de color se definen como:

$$\begin{aligned} \Delta_s &= abs[saturation(C_1) - saturation(C_2)], \text{ y} \\ \Delta_i &= abs[intensity(C_1) - intensity(C_2)], \end{aligned} \quad (8)$$

Donde  $C_1$  y  $C_2$  son píxeles de color o centroides de color, respectivamente, en el espacio de color RGB [5][31][32][34][35].

# CAPÍTULO 5

## PRUEBAS Y RESULTADOS

## 5. Pruebas y resultados

En esta sección se presentan los experimentos y los resultados de la aplicación del método de segmentación propuesto a varios tipos de imágenes: reales, de tonos de gris y de bajo contraste de color y sintéticas. También se hace una caracterización y evaluación del algoritmo de segmentación.

### 5.1 Medios utilizados

Para el desarrollo de la presente investigación se desarrolló una interfaz y el software de procesamiento necesario en Matlab ver 2010. Con este ambiente y la interfaz se crearon las gráficas ROC que permiten visualizar los resultados de forma cuantitativa.

Además del uso de bases de datos de imágenes reales en colores y de bajo contraste de color, se desarrolló una base de datos de imágenes sintéticas que permitió la caracterización del algoritmo y así determinar que es invariante a cambios en tamaño, forma, contraste de color, nivel de umbralado, así como que el número adecuado de muestras de píxeles.

### 5.2 Resultados en imágenes reales

En esta sección se presentan los resultados del método de segmentación aplicado a imágenes reales difíciles de segmentar. Estos experimentos consistieron en la segmentación de regiones de color siguiendo los tres pasos generales siguientes:

- 1) Selección de la muestra de píxeles. Con el fin de tener una guía útil para esta tarea, las siguientes consideraciones pueden ser útiles para seleccionar el número de píxeles de la muestra: Si el color de la zona que se desea segmentar es sólido (sin ruido aditivo) sólo es necesario tener un píxel como muestra de la zona deseada. Sin embargo, si queremos tener en cuenta la falta de definición de color en las fronteras, tenemos que tomar una muestra de los nuevos colores que aparecen en esa zona debido a la condición anterior. Los píxeles de las muestras se pueden seleccionar arbitrariamente, es decir, en cualquier orden, en cualquier número y ubicados físicamente adyacentes o no.
- 2) Cálculo de la ISC. Este paso es automático; su salida es una imagen de niveles de gris que muestra la similitud de cada píxel de la imagen de color verdadero RGB al centroide de color formado con la muestra de píxeles tomados de la región de interés a ser segmentada, siendo blanco para el 100% de similitud y negro para 0%.
- 3) El usuario puede ahora umbralar la ISC. Este paso será necesario para obtener una plantilla para la segmentación final del color deseado en la región de interés; puede ser implementado como paso automático mediante el uso de, por ejemplo, umbrales automáticos no supervisados como el método de Otsu. Esto garantiza que los colores segmentados sean los reales.

Durante el umbralado de la ISC alguna información se puede perder, lo que podría ser un inconveniente. Si la propia ISC se utiliza como plantilla, entonces tenemos áreas mejor



segmentadas (sin pérdida de píxeles), una para cada color seleccionado, pero luego se alteran en cierta medida debido a los niveles intrínsecamente grises que forman la ISC. La Fig. 10 (izquierda) muestra una imagen en colores RGB (de tamaño 301 x 226 píxeles y 27146 colores diferentes) de tejido teñido con hematoxilina y eosina (H & E) [39], que es un método de tinción muy popular en histología y el más ampliamente utilizado en el diagnóstico médico. Este método de tinción ayuda a los patólogos a distinguir diferentes tipos de tejido.




Fig. 10 Tejido teñido (izquierda). Muestra compuesta de cuatro píxeles de dos zonas con color azul (derecha)

En esta imagen podemos ver tres tonos principales de color a pesar de los miles (más de 27000 colores) de valores RGB reales para representarlos: azul, rosa y blanco. Las diferentes tonalidades de los píxeles en la imagen dependen de su saturación particular y de la presencia inevitable de ruido. El método de segmentación de color propuesto es prácticamente inmune a estas condiciones, aunque obviamente algunas soluciones podrían utilizarse para mejorar la calidad de las regiones segmentadas, tales como, por ejemplo, procesamiento previo de la imagen para suavizar los ruidos de diferentes tipos, la aplicación de algún método morfológico para reducir los objetos con características dadas y así sucesivamente.

En este experimento se tomó una muestra compuesta de cuatro píxeles situados en dos zonas con color azul. Se seleccionaron de una región de 21 x 21 píxeles ampliada como se muestra en la figura 10 (derecha). A partir de esta muestra se calcularon el centroide de color y la desviación estándar en el espacio de color HSI modificado; con estos dos valores usamos la ecuación. (1) para calcular para cada píxel los valores de píxel de la ISC que se muestra en la figura 11 (izquierda). Después de aplicar el método de umbralado de Otsu (para conseguir una plantilla), se obtuvo la segmentación de color mostrada en la Fig. 11 (derecha).




Fig. 11 La imagen de similitud de color (ISC) del color azul (izquierda). Las zonas de color azul segmentadas (derecha)

Para el área de color rosa se repitió el mismo proceso. La Fig. 12 muestra la muestra de píxeles (de cuatro píxeles). Su correspondiente ISC se muestra en la figura 13 (izquierda), y la segmentación final de la zona rosa en la Fig. 13 (derecha).

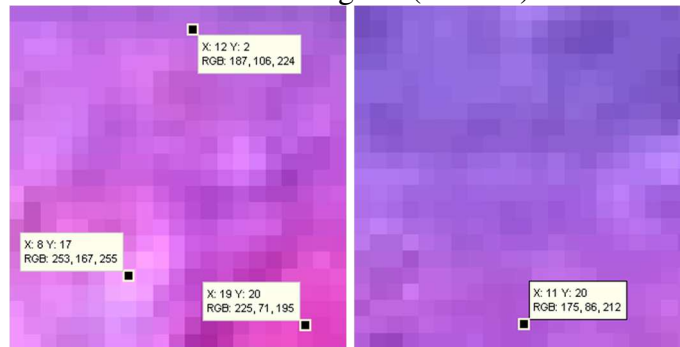


Fig. 12 Muestras de píxeles de cuatro puntos del color rosa




Fig. 13 ISC del color rosa (izquierda). Zonas de color rosa segmentado (derecha)

Repitiendo el proceso anterior, la figura 14 (izquierda) presenta la muestra de píxeles para el color blanco. La figura 14 (centro) muestra la ISC. La segmentación final de las zonas de color blanco se muestra en la Fig. 14 (derecha).




Fig. 14 Muestra de píxeles para el color blanco (izquierda). ISC del color blanco (en el centro). Zonas de color blanco segmentado (derecha)




Fig. 15 Imagen original (izquierda) e imagen compuesta (derecha)

La Fig. 15 (izquierda) muestra la imagen original [39], y la figura 15 (derecha) una imagen compuesta obtenida a partir de la figura 11 (derecha), la figura 13 (derecha) y la figura 14 (derecha) utilizando consecutivamente la operación lógica XOR. Utilizamos esta operación en lugar de la OR para garantizar que en la imagen compuesta un píxel dado aparece sólo una vez en las zonas de color segmentadas, como se espera en toda tarea de segmentación. Los píxeles negros representan los colores que no fueron segmentados por cualquiera de las tres opciones de color o, por el contrario, cuando el píxel apareció con el mismo valor (1 o 0) en dos imágenes binarias (que se hicieron negro por la operación XOR consecutiva). En este ejemplo, hubo 4546 píxeles no segmentados de un total de 68026 píxeles, que es sólo el 6,6% ( $[4546/68026] \times 100$ ) del número total de píxeles de la imagen original. Se puede observar en la figura 15 (derecha) que una gran cantidad de los píxeles negros pertenece a las fronteras entre regiones de diferentes colores en los que son claramente definidos.

La comparación de las dos imágenes de la figura 15 demuestra la calidad de las zonas segmentadas azul, rosa y blanco obtenidas por el método propuesto, no sólo desde el punto de vista del número de píxeles segmentados, sino también desde el punto de vista de la calidad de las tonalidades y niveles de los colores que aparecen en la imagen original. Estos resultados se obtuvieron con tan sólo 12 píxeles que pertenecen a sólo tres muestras, una asociada a cada color azul, rosa y blanco de la imagen original. La imagen compuesta mostrada en la figura 15 (derecha) se ha creado a través de la selección de muestras con un máximo de cuatro píxeles para cada color considerado en el proceso de segmentación. El tamaño y / o forma de las regiones segmentadas de diferentes colores dependen del número,

distribución y cantidad de píxeles que componen cada muestra. Con muestras bien seleccionadas el método da buenos resultados.

Es posible con el método de segmentación de color propuesto dividir una región que tiene un color particular (por ejemplo la región azul en la figura 11) en dos o más subregiones que tienen el mismo color básico (azul), pero dos niveles de saturación diferentes (núcleos oscuros con zonas más claras que las rodean). La Fig. 16 muestra la muestra de siete píxeles seleccionados a partir de dos zonas diferentes que pertenecen a los núcleos azules más oscuros.




Fig. 16 Muestra de siete píxeles correspondientes a los núcleos azules más oscuros

La Fig. 17 (izquierda) muestra la ISC de los núcleos de color azul oscuro, y la figura 17 (centro) muestra la imagen segmentada final. La figura 17 (derecha) muestra el núcleo bien diferenciado (de color verde), rodeado de zonas azules más claras. Las posibilidades del método son varias, ya que sólo requiere unas pocas muestras bien seleccionadas de zonas bien distribuidas de un número adecuado de píxeles.




Fig. 17 ISC de núcleos azules (izquierda). Núcleos azules segmentados (centro). Núcleos azules en pseudocolor (verdes) bien diferenciados rodeados de zonas azules más claras (derecha)

Mostramos ahora los resultados de la segmentación teniendo en cuenta la definición de la zona acromática W propuesta cuando se aplica a tres imágenes en colores clásicas en RGB de 24 bits formato de color verdadero.

La figura 18 (izquierda) muestra una imagen de color RGB (de tamaño de 200 por 200 píxeles y con 33753 colores diferentes) de la imagen popular de un babuino [49]; La figura 18 (centro) muestra una imagen de los caballos [48] y la Fig. 18 (derecha) muestra una imagen de una tela de color [39].

Es posible separar el área acromática para obtener una mejor segmentación. Esta zona acromática se puede subdividir más tarde utilizando sólo la intensidad como característica discriminante. Los resultados obtenidos con la definición propuesta para la zona acromática como se define en la ecuación. (2) con respecto a los resultados obtenidos con la definición clásica de esa zona [2][3] se muestran en las Figuras 19, 20, 21 y en la tabla 2.



Fig. 18 Babuino (izquierda). Caballos (centro). Tela (derecha)

Se utilizó la función XOR para generar todas las imágenes compuestas y así evitar la posibilidad de que un píxel pudiera simultáneamente pertenecer a dos o más regiones segmentadas. A continuación, se demuestra la eficacia del método de segmentación de color propuesto en algunas imágenes en color relativamente complejas.

Con el fin de evaluar la eficacia del método de segmentación de color y debido a la dificultad de obtener un GT para cada imagen compleja a la que el método se aplicó, así como para poder comparar los resultados, la evaluación se basó en el número de píxeles no segmentados con respecto al número total de píxeles segmentados en la imagen resultante correspondiente. Esta relación combina los píxeles que no pertenecen a cualquier grupo de color y los seleccionados por dos o más grupos (obtenidos por medio de la operación XOR) con respecto al número total de píxeles de la imagen. Nos da una medida de la eficiencia de la segmentación. El número máximo de píxeles seleccionados dentro de cada muestra de color era siempre diez o menos. En general, el número de píxeles seleccionados para las muestras depende de la complejidad de la imagen (textura de los objetos), de la diversidad de colores y de su distribución espacial en la imagen. En nuestros experimentos no utilizamos ningún procesamiento previo.

La figura 19 (izquierda) muestra la imagen compuesta del babuino con los píxeles que no fueron segmentados en pseudocolor verde (sólo se seleccionaron cuatro colores en el proceso). La figura 19 (centro) muestra el resultado de la segmentación de la región acromática clásica y la figura 19 (derecha) muestra el resultado de la segmentación de la región acromática propuesta en este trabajo. La mejora en la calidad es significativa. Se obtuvo un 95,5% de píxeles segmentados adecuadamente (Ver la tabla 2).



Fig. 19 Imagen compuesta de cinco colores segmentados (izquierda), y los resultados obtenidos con la zona acromática clásica (centro) y con la definición de zona acromática propuesta (derecha)

Como otro ejemplo, consideremos la imagen de dos caballos con sombras mostrada en la figura 20 (izquierda). Los píxeles no segmentados se muestran en pseudocolor rojo. La figura 20 muestra la segmentación de la zona acromática en la forma clásica (centro) y con la definición propuesta (derecha). La mejora de la calidad es apreciable. Se obtuvo el 97,1% de los píxeles segmentados (Ver la tabla 2).

La figura 21 (izquierda) muestra una imagen compuesta de cinco colores segmentados (con los píxeles no segmentados en pseudocolor blanco) de una tela de color; que contiene una región acromática con alta saturación, pero con bajo brillo, que es muy difícil de separar con la definición clásica (figura 21 centro), pero fácilmente separados con la definición propuesta como se muestra en la figura 21 (derecha). Se obtuvo el 95,3% de los píxeles segmentados (Ver la tabla 2).



Fig. 20 Imagen compuesta de tres colores segmentados (izquierda) y los resultados obtenidos con la definición clásica (centro) y la zona acromática propuesta (derecha)



Fig. 21 Imagen compuesta de cinco colores segmentados (izquierda) y los resultados obtenidos con la definición clásica (centro) y la zona acromática propuesta (derecha)

La tabla 2 resume los resultados obtenidos en la segmentación. La última columna de la tabla 2 muestra el porcentaje de píxeles segmentados obtenido en estas imágenes. En todos los casos, la posibilidad de que un píxel pudiera pertenecer a dos zonas o regiones de color diferentes se ha evitado por medio de la aplicación de la función lógica XOR (de dos o más segmentaciones parciales). Un resultado con muchos píxeles negros indica que se ha producido una coincidencia en píxeles segmentados de dos o más segmentaciones parciales considerados en la operación XOR.

Cuando los resultados de la definición propuesta para la región acromática  $W$  se comparan con los de la definición clásica, la diferencia es notoria; mientras que la zona acromática propuesta parece segmentar correctamente, la definición clásica segmenta sólo un par de píxeles. Como se puede observar de la tabla 2, la exactitud promedio de la segmentación de color en las tres imágenes complejas, sin una exhaustiva selección de colores y un pequeño número de píxeles (4-5 en promedio) por muestra de color, es 95,91%.

**Tabla 2** Resultados globales de la segmentación en imágenes reales

No.	Imagen	Número de píxeles de la imagen	Número de colores	Número de colores seleccionados	Número total de píxeles usados como muestras	Número de píxeles no segmentados	% píxeles segmentados
1	Tejido teñido	68026	27146	3	11	1171	98.3
2	Babuino	40000	33753	5	31	1803	95.5
3	Caballos	154401	71727	3	14	4619	97.1
4	Tela	9900	9349	5	23	465	95.3

### 5.3 Resultados en imágenes de tonos de gris y de bajo contraste de color

En los tres ejemplos siguientes se muestran los resultados obtenidos por el método de segmentación del color propuesto cuando se aplica a imágenes en niveles de gris y en imágenes de bajo contraste de color. La Fig. 22 (izquierda) muestra una imagen en niveles de gris obtenida con una cámara infrarroja; tomamos una pequeña muestra de píxeles (de cuatro píxeles) de la zona de la cara y obtuvimos su correspondiente ISC como se muestra en la figura 22 (centro). La cara segmentada aparece en la figura 22 (derecha) después de la aplicación del método de umbralado de Otsu.

La Fig. 23 (izquierda) muestra la imagen muy compleja de un fósil en una roca [48]. Tomamos una muestra pequeña de píxeles de la zona del fósil, de la que posteriormente obtuvimos la ISC correspondiente (Figura 23, centro). La figura 23 (derecha) muestra la imagen resultante después de umbralar con el método de Otsu.

La Fig. 24 (izquierda) muestra la imagen en tonos de gris de una firma. Tomamos una muestra pequeña de 4 píxeles de la zona de la firma, de la que posteriormente obtuvimos la ISC correspondiente (Figura 24, centro). La figura 24 (derecha) muestra la imagen resultante después de umbralar con el método de Otsu.



Fig. 22 Imagen infrarroja (izquierda). ISC de la cara (centro). Cara segmentada (derecha)




Fig. 23 Hoja fósil incrustada en una roca (izquierda). ISC del fósil (centro). Imagen umbralada por el método de Otsu (derecha)




Fig. 24 Firma (izquierda). ISC de la firma (centro) e ISC umbralada (derecha)

La tabla 3 resume los resultados de la segmentación de las 3 imágenes



**Tabla 3** Resultados globales de la segmentación en imágenes de bajo contraste de color y monocromáticas

No.	Imagen	Número de píxeles de la imagen	Número de colores(niveles)	Número de colores (niveles) seleccionados	Número total de píxeles usados como muestras	Número de píxeles no segmentados	% píxeles segmentados
1	Infrarroja	76800	255	5	5	-	-
2	Fósil	121128	40756	7	15	95 262	-
3	Firma	98 532	255	2	4	76	99.92

#### 5.4 Parámetros generales de diseño de imágenes sintéticas

El uso de imágenes sintéticas en colores es el mejor medio para evaluar la eficiencia y la exactitud de los algoritmos de segmentación del color bajo estudio, debido a que el *ground truth* (GT) requerido para la comparación de los resultados puede ser generado de forma explícita. En general, no es posible contar con un GT para evaluar algoritmos de segmentación del color cuando la imagen de color a ser segmentada está llena de ruido acumulativo y tiene otros problemas degenerativos [28][29][30].

En [14] los autores presentan tres importantes consideraciones de diseño para la creación de imágenes sintéticas:

1. Las imágenes sintéticas deben ser apropiadas para un estudio cuantitativo y deben permitir evaluaciones objetivas de sus propiedades.
2. Las imágenes sintéticas deben poder reflejar las principales características de las imágenes reales, es decir, factores de corrupción como el ruido y desenfoque y también la variación de parámetros tales como el tamaño, forma, etc.
3. El sistema debe permitir la generación de imágenes con variaciones progresivas de cada parámetro. De esta manera es posible el estudio de la influencia de cada parámetro individualmente.

#### 5.5 Diseño de las imágenes para la caracterización del algoritmo

En este trabajo se trata de ampliar los conceptos y consideraciones de diseño presentados en [14] para la generación de imágenes sintéticas en tonos de gris, a imágenes en colores que son las que necesitamos [28][29][30]. Se crean imágenes sintéticas con la figura y el fondo en colores deseado y se selecciona el círculo en esta etapa como el objeto de interés para crear nuestra imagen-base [30]. El círculo es adecuado, ya que es un modelo de los objetos de interés en diversos campos tales como la detección de células blancas de la sangre en imágenes microscópicas, imágenes astronómicas entre otros. También es más difícil de extraer que otros objetos hechos de líneas rectas horizontales y verticales por métodos tales como la convolución con máscaras detectoras de bordes, etc. [30].

Existen otras técnicas para la generación de imágenes sintéticas tales como los métodos orientados a los bordes [23] o a través de la introducción de textura en las imágenes [18]. En nuestro caso, el método de segmentación utilizado está orientado a regiones (o píxeles) sin necesidad de utilizar la información de textura; las imágenes sintéticas fueron diseñadas con estas consideraciones.

La tonalidad fue seleccionada como el parámetro de cambio debido a que integra los tres canales de color RGB, haciendo que sea más difícil de ser procesados mediante la extensión de las técnicas monocromáticas para cada canal de color individual, obligando así a los algoritmos de segmentación a utilizar la información de color de manera integral.

Se variaron las características del objeto básico (círculo), como el tamaño, la forma (variando la excentricidad) y la inclinación (cuando se varió a una elipse), el contraste y el color. Un filtro de promediado se aplicó a toda la imagen por canal (antes de la adición de ruido aditivo) para eliminar los bordes afilados, con el fin de producir en cierta medida un desenfoque. Al final se añadió ruido Gaussiano aditivo a cada canal para simular el ruido blanco comúnmente presentes en imágenes reales [14][30].

La cantidad de ruido Gaussiano aplicado a las imágenes está basada en el concepto de relación señal a ruido (SNR- del inglés *Signal-to-Noise Ratio*); una alta SNR significa una señal reconocible con un bajo nivel de ruido con respecto a la misma; respectivamente, una SNR baja significa alto ruido con respecto a la señal. Utilizamos como señal el contraste entre la figura y el fondo:  $\text{Señal} = \text{abs}(\text{RGB}(\text{Figura}) - \text{RGB}(\text{fondo})) / 3$ , extendiendo su uso en [14] para imágenes en colores en el modelo RGB. Acerca de las imágenes que varían el contraste entre los colores, la diferencia de tonalidad se redujo de 32 niveles a 4, donde para un observador humano es difícil de encontrar alguna diferencia de color (ver la figura 25 a la derecha). La Fig. 25 muestra un conjunto de imágenes de prueba que varían el contraste de color añadiendo ruido Gaussiano con una SNR igual a dos para las pruebas de contraste de color.



Fig. 25 Conjunto de imágenes de prueba donde se cambia el contraste de color de 32, 24, 16, 8 y 4 niveles con ruido aditivo Gaussiano de SNR = 2

## 5.6 Resultados de la caracterización

Se utilizaron imágenes sintéticas de color generadas con su correspondiente GT a través del método descrito anteriormente [30]. El método de segmentación del color propuesto requiere de muestras de 1 a 9 píxeles representativas del color deseado que el operador selecciona. Las muestras fueron creadas tratando de seleccionar píxeles tanto de zonas con un color plano, como de los bordes donde el color presenta una zona de transición [3][32][34][35]. La evaluación se llevó a cabo de la siguiente manera:

1. Se generó una base de datos de imágenes sintéticas en colores con su correspondiente GT mediante la modificación gradual en el objeto básico (en nuestro caso un círculo) de los siguientes parámetros: tamaño, forma (cambiando la excentricidad hacia elipses cada vez más alargadas) con ángulos arbitrarios, contraste de color, variando la diferencia de color entre el objeto y el fondo y reduciéndolo a niveles casi imperceptibles (ver figura 25 de la extrema derecha), variando el ruido Gaussiano desde SNR = 32 hasta 1. Durante la generación de las imágenes sintéticas, el sistema de evaluación crea simultáneamente su correspondiente GT.
2. El algoritmo propuesto de segmentación semiautomático del color se aplicó a las imágenes sintéticas tomando muestras de 1 a 9 píxeles. En algunos casos los píxeles fueron tomados al azar y en algunos otros casos en patrones de líneas desde el centro de la imagen, donde el operador no puede ver fácilmente el color a seleccionar debido al ruido aplicado o por el bajo contraste de color.
3. No se le aplicó ningún preprocesamiento a las imágenes de prueba. Como posprocesamiento se aplicó un filtro morfológico de cierre con un disco de radio de 5 píxeles a todas las imágenes para eliminar los grupos de píxeles conectados en número inferior a 30.
4. Graficamos los resultados de la evaluación mediante gráficas ROC debido a su capacidad de visualizar los éxitos y los fracasos y su interrelación [36], así como porque han sido utilizados con éxito para evaluar algoritmos de segmentación [36]. Utilizamos gráficas ROC para graficar la tasa de los verdaderos positivos (VP) vs. La tasa de falsos positivos (FP): tasa de VP =  $VP / P$ ; tasa de FP =  $FP / N$  (donde P representa el número total de elementos de la clase positiva y N corresponde a la clase negativa) utilizando la clasificación de los píxeles de la imagen, ya sea para el objeto o para el fondo [11]. También graficamos las curvas de tasa VP y tasa de FP por separado por conveniencia.

La Fig. 26 muestra la gráfica ROC para los casos de variación del tamaño, la forma y el contraste de color. Como se puede apreciar, la mayoría de los puntos (en rojo) se concentran en la esquina izquierda, que indica un buen comportamiento del algoritmo de segmentación en la mayoría de los casos con tasa de VP alrededor de 95% y la tasa de FP inferior al 0,1% en la mayoría de los casos [30]. Se esperaban resultados invariables a cambios en el tamaño y la forma debido a que el algoritmo es orientado a píxeles. La gráfica ROC para el contraste de color muestra un buen comportamiento del algoritmo, incluso en casos en que el contraste de color era tan bajo que para un observador normal era difícil de encontrar alguna diferencia de color (como en la figura 25 de la extrema derecha).

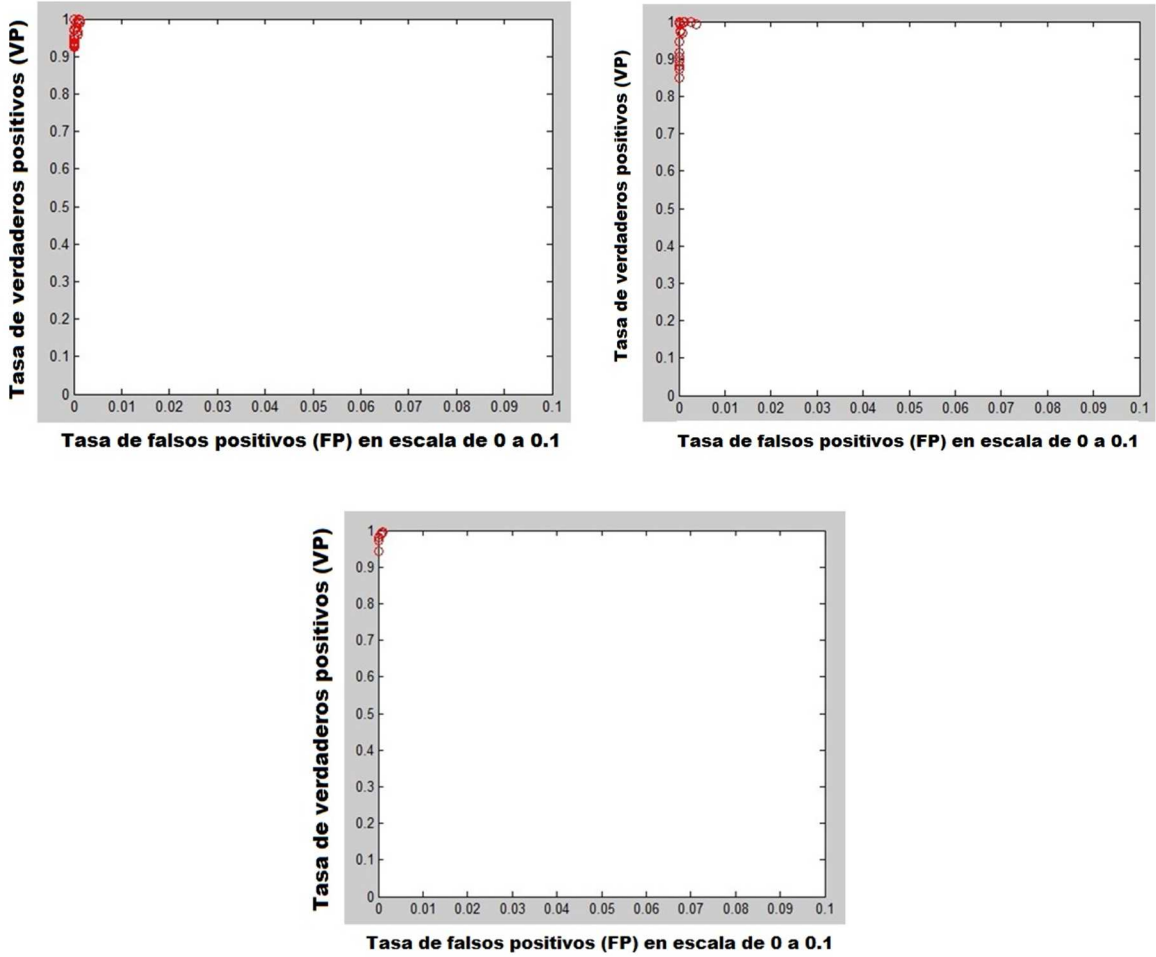


Fig. 26 Gráficas ROC para variaciones en el tamaño (izquierda arriba), la forma (derecha arriba) y el contraste de color (abajo).

La Fig. 27 muestra dos gráficas donde se representa el comportamiento de la segmentación de seis imágenes diferentes que varían en tamaño y forma después de modificar el umbral aplicado al algoritmo. Los umbrales varían, a partir del umbral de Otsu como valor central, 25 niveles de gris por encima y 25 niveles por debajo [25][27]. El valor de la abscisa igual a 1 corresponde a Otsu a -25 niveles de gris; el valor de la abscisa igual a 5 corresponde al valor de Otsu y el valor de la abscisa igual a 10 corresponde al valor de Otsu a +25 niveles de gris por encima. Como se puede observar, la tasa de VP y los valores de la tasa de FP varían sólo alrededor del 2%, demostrándose que el algoritmo de segmentación es apenas sensible al valor del umbral finalmente elegido [30].

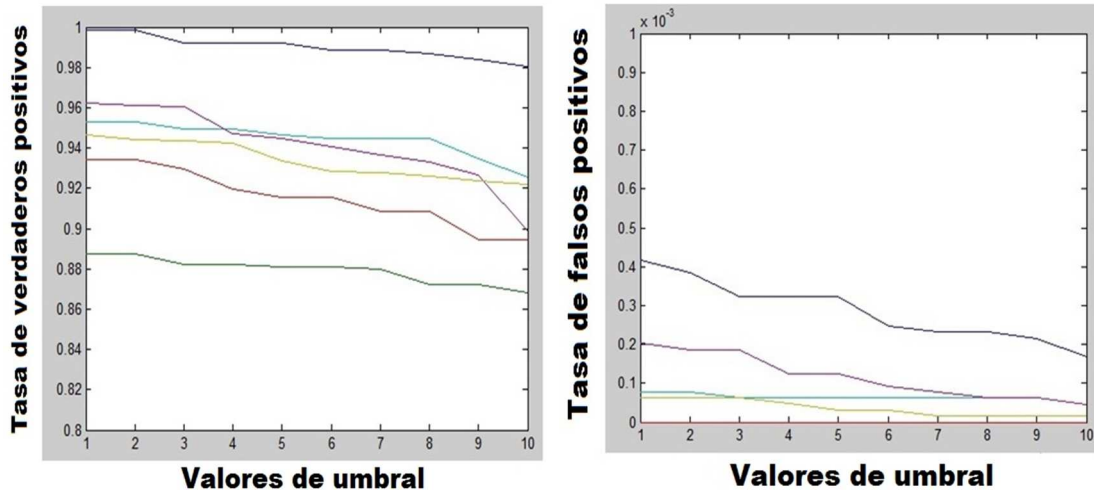


Fig. 27 Gráficas de las tasas de VP (izquierda) y las tasas de FP (derecha) para diferentes umbrales.

La Fig. 28 (izquierda) muestra otra gráfica donde las tasas de VP (tres curvas sin marcador) y las tasas de FP (tres curvas con marcador) se representan gráficamente frente al número de píxeles por muestra tomada para la muestra inicial de color. La primera línea de la parte superior (de color azul) corresponde a la segmentación de los diferentes tipos de objetos en imágenes sin ruido, la segunda línea (roja) corresponde al ruido con  $SNR = 2$  y la tercera línea (verde) al ruido con  $SNR = 1$ . La línea magenta corresponde a la tasa de FP con  $SNR = 2$  que se sobrepone con la de tasa de FP de imágenes sin ruido, mostrando tasas de error bajas (cercanas a cero) en ambos casos. La línea cian corresponde a la tasa de FP de imágenes con ruido de  $SNR = 1$ . Ésta fluctúa mostrando los valores más bajos cerca de cero para 1, 3, 5 y 10 muestras [30].

A partir del análisis de la gráfica podemos señalar que 5 píxeles por muestra es una buena opción para la mayoría de los casos, teniendo una alta tasa de VP y baja tasa de FP a pesar del ruido. También podemos observar que en los casos sin ruido, sólo es necesario un píxel por cada muestra teniendo una tasa VP de cerca de 90% y una tasa FP cercana a cero. La figura 28 (derecha) muestra la gráfica ROC correspondiente a los casos más ruidosos donde los puntos más cercanos a la esquina superior izquierda corresponden a los casos con 3, 5 y 10 píxeles por muestra. Entonces, podemos concluir que con la elección de las muestras con 5 píxeles como máximo, el algoritmo ya es capaz de presentar un buen rendimiento [30].

## 5.7 Diseño del sistema de evaluación de la segmentación

Se realizaron pruebas comparativas en un conjunto de imágenes de baja y alta saturación con la función adaptativa de similitud del color propuesta en este trabajo [3][5][31][32][33][34][35], la distancia mínima Euclidiana de los canales RGB (usado como referencia en las comparaciones) y dos métodos diferentes de clasificación implementados en el espacio de color CIE  $L^*a^*b^*$ , a saber: 1) Usando la distancia mínima Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$  (de la manera en que se implementa en Matlab [39]), y 2) el uso de un enfoque probabilístico en los canales  $a^*$  y  $b^*$ . El valor  $L^*$  es excluido de los cálculos con la intención de hacerlos inmunes a los cambios de iluminación. Si  $L^*$  se usara en los cálculos

de las distancias, los errores debido a las sombras se incrementarían, ya que las sombras representan cambios de luminancia, no de color.

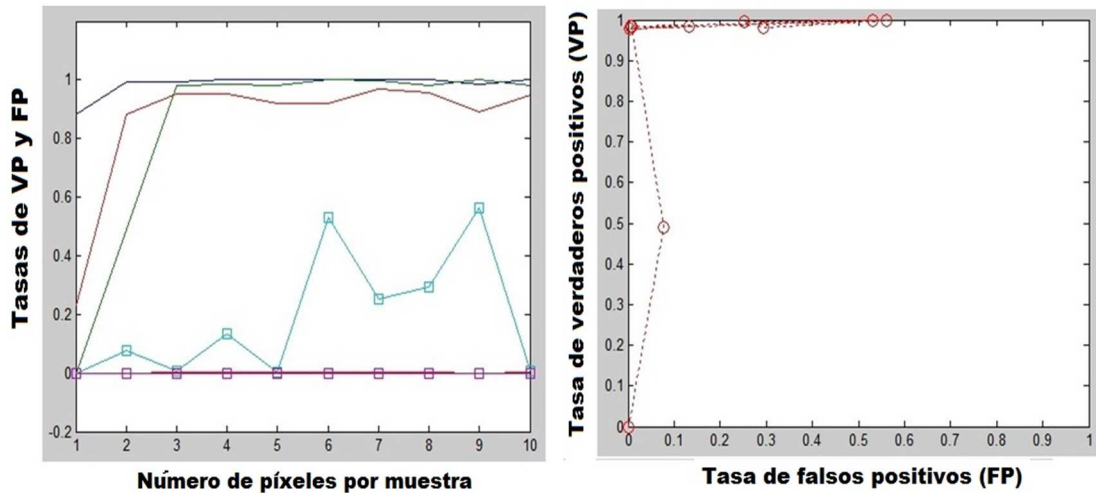


Fig. 28 Gráfica de tasas de VP para el número de muestras (izquierda) y la gráfica ROC para el nivel de ruido con SNR = 1 (derecha)

La forma en que se llevaron a cabo las pruebas es la siguiente: en el caso de la mínima distancia Euclidiana de los canales  $a^*$  y  $b^*$ , la imagen RGB y las muestras de píxeles (de figura y fondo) se transforman al espacio de color  $L^*a^*b^*$ , descartando en todos los casos la luminancia  $L^*$ , a fin de calcular la distancia Euclidiana en los canales  $a^*$  y  $b^*$  (información de color) de forma independiente de la iluminación.

A continuación, se calcularon para cada muestra los centroides (promedio de los valores  $a^*$  y  $b^*$  de las muestras de píxeles) que representan los colores de la figura y el fondo en el espacio de color  $L^*a^*b^*$ . Después se calcula la distancia Euclidiana desde el centroide de cada clase a cada píxel de la imagen para clasificar los píxeles como figura o fondo de acuerdo con la distancia mínima. Los detalles acerca de este procedimiento se pueden consultar en [39].

Mediante un enfoque probabilístico, se transformaron la imagen y las muestras de píxeles (de figura y fondo) al espacio de color  $L^*a^*b^*$  descartando en todos los casos la luminancia  $L^*$ . Entonces se calcularon la media y la desviación estándar de los valores  $a^*$  y  $b^*$  de las muestras de píxeles. A partir de esta información, se aproximaron funciones de densidad de probabilidad normal (PDF del inglés *Probability Density Function*) para decidir que cada píxel pertenezca a las clases de objeto y del fondo utilizando funciones Gaussianas para cada canal  $a^*$  y  $b^*$ . A partir de esta probabilidad -Ec. (9)- se calcula la función de similitud:

$$P_{1/2}^i(x) = \frac{p^i_1(F_i)}{p^i_1(F_i) + p^i_2(F_i)} \quad (9)$$

donde  $P_{1/2}^i(x)$  representa la probabilidad [41] de que el píxel  $x$  pertenezca a la región 1 con respecto a las probabilidades  $p^i_1$  (figura) y  $p^i_2$  (fondo) para cada canal dado  $F_i$ , que puede ser  $a^*$  o  $b^*$  en este caso. Del mismo modo se calcula  $P_{2/1}^i(x)$ . Para integrar la información de

probabilidad de los dos canales  $a^*$  y  $b^*$ , multiplicamos la función de probabilidad de ambos canales:

$$P_{1/2}(x) = P^1_{1/2}(x) * P^2_{1/2}(x) \quad (10)$$

De manera similar, se calcula  $P_{2/1}(x)$ . La clasificación se produce después de la obtención del valor máximo entre ellos y de asignar en consecuencia.

Para la función adaptativa de similitud propuesta se llevaron a cabo los siguientes pasos:

1. Se tomaron muestras de píxeles de la figura y del fondo de las cuales se calcularon los centroides y la dispersión estándar de color.
2. La imagen RGB de 24 bits se transformó al espacio de color HSI modificado.
3. Para cada píxel se calculó la función de similitud con los centroides de la figura y el fondo y se crearon dos imágenes de similitud de color (ISC).
4. Se clasificó cada píxel de la imagen RGB calculando el valor máximo para cada posición del píxel entre las ISC de la figura y del fondo.

La forma base de las imágenes sintéticas de prueba en este caso fue creada con las siguientes características:

1. Con secciones cóncavas y convexas con el fin de que sea más representativa de las imágenes reales, como las flores naturales.
2. Con curvatura extrema omnidireccional en toda la imagen para dificultar la obtención de bordes mediante la aplicación de máscaras detectoras de bordes.
3. Con el objeto ubicado en el centro de la imagen.

El objeto resultante en forma de flor se considera como el objeto de interés y *Ground Truth* (GT) en todas las pruebas posteriores (Fig. 29).



Fig. 29 Objeto de interés (*Ground Truth*) en forma de flor

Además de la forma de este objeto de interés, se impusieron otras características con el fin de dificultar aún más su segmentación basada en el color:

1. Bajo contraste. El contraste entre el objeto y el fondo en todas las imágenes apareció muy bajo para el observador, incluyendo algunas imágenes en las que a primera vista el usuario no puede ver la diferencia (por ejemplo, la flor de 5 en la figura 25). La diferencia entre el color del objeto de interés y el fondo le llamamos Delta y se produce en diferentes direcciones del espacio HSI. Las pruebas se realizaron en los cuadrantes de color  $0^\circ$ ,  $60^\circ$ ,  $120^\circ$ ,  $180^\circ$ ,  $240^\circ$  y  $300^\circ$ .
2. Bordes difuminados. Los bordes fueron difuminados con un filtro de promediado con máscara cuadrada de tamaño  $3 \times 3$  píxeles aplicado a toda la imagen, con el fin de difuminar las esquinas y hacer la detección del objeto más difícil; esto se hizo antes de la introducción del ruido aditivo Gaussiano.

Los colores básicos tanto para la figura como para el fondo fueron seleccionados manteniendo la intensidad normalizada -Ec. (7)- constante a 0.5 y la saturación normalizada -Ec. (7)- a 0.3 y sólo variando la tonalidad. La tonalidad fue seleccionada como el parámetro Delta -Ec. (1)- debido a que en su cambio se integran los tres canales de color RGB en conjunto, haciendo que sea más difícil el ser extraídos mediante extensiones de técnicas en escala de grises aplicadas para cada canal de color, obligando así a los algoritmos de segmentación evaluados a utilizar la información de color de manera integral [5].

Las muestras de los píxeles correspondientes a la figura se obtuvieron de dos cuadrados de  $2 \times 2$  píxeles que empiezan en los píxeles (84, 84) y (150, 150). Las muestras para los píxeles del fondo se obtuvieron de dos cuadrados de  $2 \times 2$  píxeles a partir de los píxeles (15, 15) y (150, 180).

## 5.8 Resultados con imágenes de baja saturación

Las imágenes se generaron en los sectores 0, 60, 120, 180, 240 y 300 grados correspondientes a las imágenes flor\_0, flor\_1, ..., flor\_5 (Fig. 30).



Fig. 30 Pruebas en regiones con baja saturación con Delta en HUE

Seguidamente se aplicó una sombra difuminada a cada una de las imágenes ruidosas y borrosas de  $256 \times 256$  píxeles con el centro de luz en las coordenadas fijas en (150, 150). Esta sombra se aplicó gradualmente con incrementos del 10% en cada paso. La Fig. 31 muestra esto para la flor\_0.




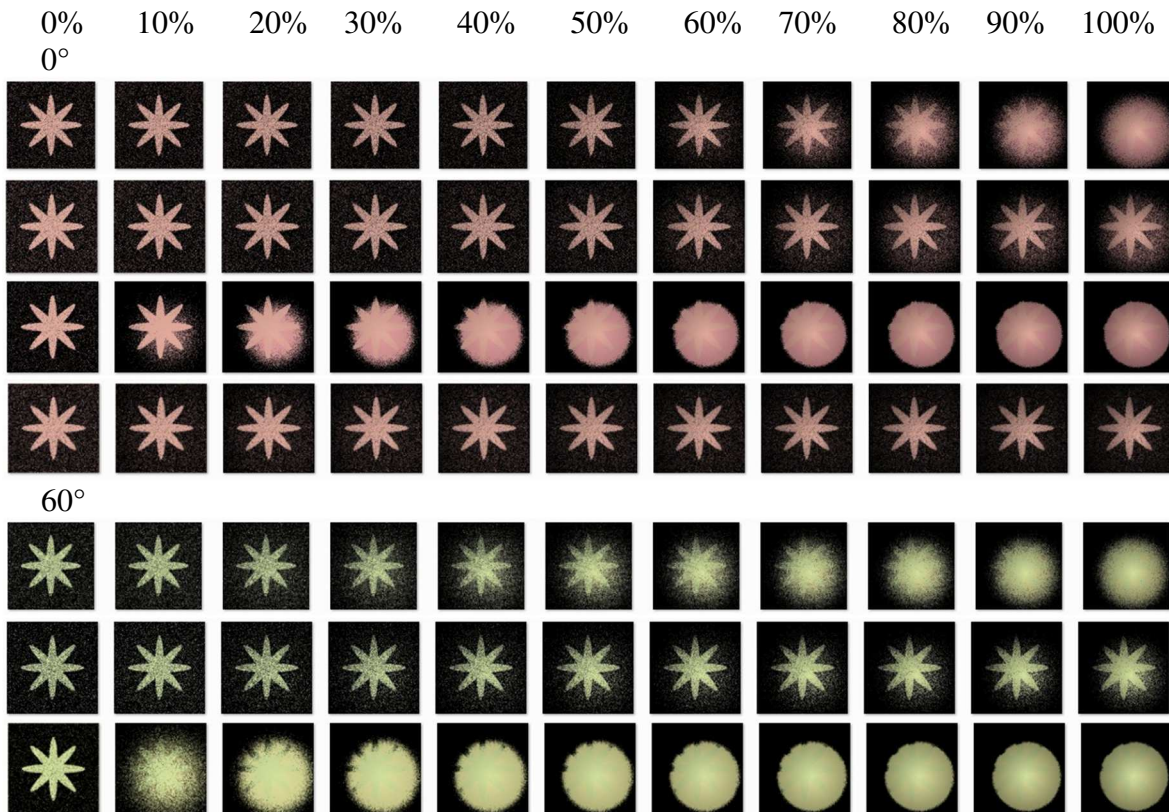




Fig. 31 Ejemplo en cuadrante de color a 0 grados aplicando una sombra difuminada de un 10% en cada paso

En esta sección se muestran los resultados de los experimentos aplicados a imágenes de baja saturación. Los resultados se muestran en función de VP (verdaderos positivos) y FP (falsos positivos) graficados contra el nivel de sombra difuminada, representando en cada paso un 10% de incremento. La primera posición significa que no hay sombra y la posición 11 significa la aplicación al 100% de la sombra difuminada. Todas las imágenes tienen el mismo posprocesamiento: eliminación de las áreas más pequeñas que 30 píxeles y después un cierre morfológico con un elemento de estructura circular de radio igual a 5 píxeles [29]. En la Fig. 32 se muestran los resultados con el método propuesto de la segmentación de imágenes en colores con niveles diferentes de sombra difuminada (mostrada en el cuarto renglón de cada color) en comparación con los obtenidos con la métrica Euclidiana en el espacio de color CIE  $L^*a^*b^*$  sin considerar  $L^*$  como lo hace Matlab (mostrada en el primer renglón de cada color), un enfoque probabilístico en  $a^*$  y  $b^*$  (segundo renglón de cada color) y la distancia mínima Euclidiana (tercer renglón de cada color) para cada cuadrante de color ( $0^\circ$ ,  $60^\circ$ ,  $120^\circ$ ,  $180^\circ$ ,  $240^\circ$  y  $300^\circ$ ) y con incrementos de 10% de la sombra difuminada en cada paso.







120°



180°



240°






Fig. 32. Resultados de la segmentación de color lograda con la métrica Euclidiana de  $a^*$  y  $b^*$  en el espacio de color CIE  $L^*a^*b^*$  (filas superiores de cada color, impares) y la función adaptativa de similitud de color propuesta (filas inferiores de cada color, pares), para cada cuadrante de color ( $0^\circ$ ,  $60^\circ$ ,  $120^\circ$ ,  $180^\circ$ ,  $240^\circ$  y  $300^\circ$  respectivamente) y con incremento de 10% de la sombra difuminada en cada paso para imágenes de baja saturación

Como se muestra en las gráficas de la Fig. 33 y en coincidencia con el análisis visual de la flor correspondiente (Figura 32), las fallas de la segmentación en el espacio de color  $L^*a^*b^*$  comenzaron en diferentes niveles de la sombra desvanecida y en todos los casos de estudio, mientras que la segmentación con la función adaptativa de similitud de color propuesta es prácticamente inmune a la aplicación de sombra difuminada (izquierda) [29].

Podemos ver tres tendencias generales en el comportamiento de los falsos positivos (FP) en la figura 33 izquierda (Ver la tabla 4): 1. Aumento en un ángulo de aproximadamente  $45^\circ$  en los casos de la flor\_0 y la flor\_3 (con marcador de diamante); 2. Aumento lento y progresivo como en casos de la flor\_1 y la flor\_4 (con marcador cuadrado); y 3. Aumento brusco como en los casos de la flor\_2 y la flor\_5 (con marcador circular). El comportamiento se repite cada 180 grados y coincide con las posiciones de color oponente (amarillo-azul, por ejemplo).

Como se puede ver a partir de las imágenes correspondientes a los resultados de la segmentación de las imágenes de prueba con baja saturación (Figura 32 cuarta fila de cada color) y los gráficos correspondientes (Fig. 34 derecha), la función de similitud propuesta se comportó correctamente en todos los casos, siempre segmentando el objeto de interés con una alta tasa de éxito de verdaderos positivos (VP) de aproximadamente el 95% con una baja tasa de error de alrededor del 2% en promedio.

No podemos decir lo mismo de ambas implementaciones en el espacio de color  $L^*a^*b^*$ : ni en la distancia Euclidiana ni en el enfoque probabilístico. En la figura 32 la primera fila de cada color muestra los resultados del clasificador utilizando la mínima distancia Euclidiana de los canales  $a^*$  y  $b^*$ . La segunda línea de cada color muestra los resultados utilizando el

clasificador probabilístico. Se rechazó  $L^*$  en todos los casos para tratar de hacerlos independientes de la luminancia.

Como se puede ver en los resultados mostrados en la figura 32, el enfoque probabilístico mejoró la segmentación en todos los casos, permitiendo en algún momento segmentar la mayor parte del objeto de interés en todos los niveles de sombra aplicados (como en los casos del Rojo  $0^\circ$ , amarillo  $60^\circ$ , cian  $180^\circ$  y azul  $240^\circ$ ), donde falló la distancia Euclidiana. En otros casos, no se pudo separar el objeto del fondo en altos niveles de sombreado, pero hay una mejora en la calidad de la segmentación del objeto a un nivel específico de sombra (como el caso de la figura 32 verde  $120^\circ$  en 50% de nivel de sombra), donde se extrae el objeto de interés en el caso de enfoque probabilístico, pero no en el caso de la distancia mínima Euclidiana de  $a^*$  y  $b^*$  (segundas y primeras filas respectivamente, figura 32 verde  $120^\circ$  en 50% de nivel de sombra).




Fig. 33 Gráficas de la métrica Euclidiana en  $L^*a^*b^*$ , al rechazar  $L^*$  (izquierda) y el enfoque probabilístico sobre  $a^*$  y  $b^*$  (derecha) en incrementos de 10% de la sombra difuminada en cada paso sobre imágenes de baja saturación




Fig. 34 Gráficas de la métrica Euclidiana de los canales RGB (izquierda) y de la función de similitud de color (derecha) en incrementos de 10% de la sombra difuminada en cada paso sobre imágenes de baja saturación

Como se muestra en los gráficos de la figura 33 y en coincidencia con el análisis visual de la flor correspondiente (Figura 32), los errores de segmentación en el caso de la distancia Euclidiana de  $a^*$  y  $b^*$  (ver la figura 33 a la izquierda) y en el caso del enfoque probabilístico en el espacio de color  $L^*a^*b^*$  (véase la figura 33 derecha) comienzan a diferentes niveles de la sombra difuminada, mientras que nuestro método es prácticamente inmune a la sombra desvanecida (ver la figura 34 a la derecha).

En la gráfica de los resultados para la distancia Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$  (Figura 33 izquierda), se pueden observar tres tendencias generales en el comportamiento de los falsos positivos (FP), a saber: 1) Aumento tardío en un ángulo de aproximadamente  $45^\circ$  en los casos de flor\_0 y flor\_3 (con marcador de diamante); 2) Aumenta lenta y progresivamente en los casos de la flor\_1 y la flor\_4 (con marcador cuadrado) y 3) Aumenta bruscamente en los casos de la flor\_2 y la flor\_5 (con marcador circular). El comportamiento se repite cada 180 grados y coincide con las posiciones de color oponente (amarillo-azul, por ejemplo).

Para el enfoque probabilístico en el espacio  $L^*a^*b^*$ , en la figura 33 (derecha) se pueden observar dos tendencias generales diferentes en el comportamiento de FP: 1) Incremento abrupto, como en los casos de flor\_2 y flor\_5; 2) Aumento lento en todos los demás casos.

Las mejoras observadas visualmente en la calidad de la segmentación por el enfoque probabilístico en comparación con la métrica Euclidiana en  $a^*$  y  $b^*$ , no se reflejan correctamente en los gráficos finales porque el posprocesamiento final es el mismo en todas las pruebas: la eliminación de píxeles conectados de tamaño inferior a 30 píxeles, seguido de un cierre morfológico con un elemento de estructura circular de radio 2 píxeles. Con diferente posprocesamiento de esas imágenes se pueden hacer destacar estas mejoras.

En el caso de la distancia Euclidiana de los canales RGB se pueden observar dos tendencias generales distintas: 1) Un incremento de los falsos positivos de manera relativamente suave para los casos de las flores 0, 2 y 4 (líneas azul, roja y púrpura, figura 26 izquierda), y 2) Un incremento notoriamente más brusco en el índice de falsos positivos para los casos de las flores 1, 3 y 5 que corresponden a las líneas verde, cian y amarillo.

La Fig. 34, derecha, muestra los resultados del método propuesto; se puede apreciar en las curvas correspondientes a los VP y FP que el método propuesto es prácticamente inmune a la aplicación de la sombra difuminada en todos los casos de estudio.

La Fig. 35 muestra los detalles de las curvas relacionadas con VP y FP de nuestro método en imágenes de baja saturación con el siguiente código de colores: flor\_0 (azul), flor\_1 (verde), flor\_2 (rojo), flor\_3 (cian), flor\_4 (púrpura) y flor\_5 (amarillo). Se puede apreciar que el índice de verdaderos positivos (VP) es superior al 96% y el de falsos positivos (FP) es inferior al 2%; las variaciones en las curvas son inferiores al 1%.

La tabla 4 muestra una síntesis de los diferentes casos mostrando el nivel cuando se produce un fallo notorio en la calidad del color durante la segmentación.

**Tabla 4** Observaciones sobre el comportamiento de las curvas de las figuras 33 y 34 con las dos métricas de color en  $L^*a^*b^*$  y el método propuesto

Flor	Color de la línea	Métrica Euclidiana en $L^*a^*b^*$ , descartando $L^*$	Enfoque probabilístico en $a^*$ y $b^*$ , descartando $L^*$	Métrica Euclidiana en RGB	Función de similitud de color
0	Azul	60% (posición 7). Incrementa a 45°	70% (posición 8). Incrementa lentamente	0% (posición 1). Incrementa lentamente. Máxima falla en 100%	Inmune
1	Verde	30% (posición 4). Incrementa lenta y progresivamente	80% (posición 9). Incrementa lentamente	0% (posición 1). Máxima falla en 20%. Disminuye poco lentamente	Inmune
2	Rojo	40% (posición 5). Incrementa abruptamente	30% (posición 4). Incrementa rápidamente	0% (posición 1). Incrementa lentamente. Máxima falla en 100%	Inmune
3	Cian	70% (posición 8). Incrementa a 45°	80% (posición 9). Incrementa lentamente	0% (posición 1). Máxima falla en 20%. Disminuye poco lentamente	Inmune
4	Púrpura	20% (posición 3). Incrementa lenta y progresivamente	70% (posición 8). Incrementa lentamente	0% (posición 1). Incrementa lentamente. Máxima falla en 100%	Inmune
5	Amarillo	50% (posición 6). Incrementa abruptamente	20% (posición 3). Incrementa rápidamente	0% (posición 1). Máxima falla en 20%. Disminuye poco lentamente	Inmune




Fig. 35 Detalles de verdaderos positivos (izquierda) y falsos positivos (derecha) de la función de similitud de color en imágenes de baja saturación

La Fig. 35 muestra los detalles de las curvas relacionadas con VP y FP de la función de similitud de color propuesta, con el siguiente código de color: flor\_0 (azul), flor\_1 (verde), flor\_2 (rojo), flor\_3 (cian), flor\_4 (púrpura) y flor\_5 (amarillo). Las variaciones en las curvas son inferiores al 1% [29].

Para obtener gráficas ROC representativas y que ilustren el comportamiento de la función de similitud de color propuesta con la métrica Euclidiana en el espacio de color  $L^*a^*b^*$  (rechazando  $L^*$ ), el enfoque probabilístico en  $a^*$  y  $b^*$ , la métrica Euclidiana de los canales R, G, y B en todos los sectores de color bajo estudio se calculó el VP promedio y FP para todas las flores de color, obteniéndose los resultados mostrados en las Figs. 36 y 37.

En la gráfica ROC correspondiente a la media de VP y FP de todas las flores, se puede observar que los resultados de la función de similitud se mantienen en la zona de alta eficiencia (coordenada 0, 1), mientras que en todos los demás casos se aleja progresivamente de la zona de alta eficiencia.




Fig. 36 Gráfica ROC de la métrica Euclidiana en  $L^*a^*b^*$  descartando  $L^*$  (izquierda) y del enfoque probabilístico en  $a^*$  y  $b^*$  (derecha) para imágenes de baja saturación




Fig. 37 Gráfica ROC de la métrica Euclidiana de los canales en RGB (izquierda) y de la función de similitud de color (derecha) para imágenes de baja saturación

Los resultados en el espacio  $L^*a^*b^*$  se mantienen estables inicialmente y más tarde lenta y progresivamente se desplazan a la zona superior derecha de la gráfica ROC, la que se puede considerar como el lado "liberal" (coordenada 1, 1), ya que hacen clasificaciones positivas, con evidencia débil, haciendo que casi todos los verdaderos positivos fueran clasificados correctamente, pero manteniendo una alta tasa de falsos positivos [29].

### 5.9 Resultados con imágenes de alta saturación

Los colores básicos de alta saturación tanto para la figura como para el fondo fueron seleccionados manteniendo la intensidad constante a 0.9 y la saturación a 0.9 y como en el caso de los experimentos de baja saturación sólo se varió la tonalidad [29].

Las muestras de los píxeles correspondientes a la figura, se obtuvieron como en el caso de baja saturación de dos cuadrados de 2 x 2 píxeles que empiezan en los píxeles (84, 84) y (150, 150). Las muestras para los píxeles del fondo se obtuvieron de dos cuadrados de 2 x 2 píxeles a partir de los píxeles (15, 15) y (150, 180).

Las imágenes se generaron en los sectores 0, 60, 120, 180, 240 y 300 grados correspondientes a las imágenes flor\_0h, flor\_1h, ..., flor\_5h (Fig. 38).



Fig. 38 Pruebas en regiones con alta saturación con Delta en HUE

Seguidamente se aplicó una sombra difuminada a cada una de las imágenes ruidosas y borrosas de 256 x 256 píxeles con el centro de luz en las coordenadas fijas en (150, 150). Esta sombra se aplicó gradualmente con incrementos del 10% en cada paso. La Fig. 39 muestra esto para la flor\_0h.







Fig. 39 Ejemplo en cuadrante de color a 0 grados aplicando una sombra difuminada que se incrementa en un 10% en cada paso

En la Fig. 40 se muestran los resultados con la solución propuesta en este trabajo para la segmentación de imágenes en colores con un nivel diferente de la sombra difuminada (cuarto renglón de cada color) en comparación con los obtenidos con la métrica Euclidiana en el espacio de color CIE  $L^*a^*b^*$  sin considerar  $L^*$  como lo hace Matlab (primer renglón de cada color), un enfoque probabilístico en  $a^*$  y  $b^*$  (segundo renglón de cada color) y la



métrica Euclidiana en el espacio de color RGB (tercer renglón de cada color) para cada cuadrante de color ( $0^\circ$ ,  $60^\circ$ ,  $120^\circ$ ,  $180^\circ$ ,  $240^\circ$  y  $300^\circ$ ) y con incrementos de 10% de la sombra difuminada en cada paso.






Fig. 40 Resultados de la segmentación de color lograda entre la métrica Euclidiana de los parámetros  $a^*$  y  $b^*$  en el espacio de color  $L^*a^*b^*$  (filas superiores de cada color), la métrica Euclidiana de los canales de color RGB (filas de en medio de cada color) y la función adaptativa de similitud de color propuesta (filas inferiores)

de cada color), para cada cuadrante de color (0°, 60°, 120°, 180°, 240° y 300°) y en incrementos de 10% de la sombra difuminada en cada paso para imágenes de alta saturación

En la Fig. 41 se grafican los resultados de VP y FP al aplicar la sombra difuminada con un 10% en cada paso, con el paso 1 correspondiente a 0% y el 11 al 100%. Se pueden notar tres tendencias diferentes en sectores con 120 grados de diferencia: 1) Subida de la curva bruscamente (flores 0h, 2h y 4h, que corresponde a los canales del modelo de color RGB) con alta sensibilidad a la sombra difuminada (con más sensibilidad que en el caso de RGB, como se puede observar en la figura 40); 2) Subida lenta (flores 1h y 5h) inferior a RGB, y 3) Incremento insensible (flor 3h) en cerca de 90%. La tabla 5 resume las observaciones sobre el comportamiento de las curvas que comparan la métrica Euclidiana en el espacio de color  $L^*a^*b^*$ , la métrica Euclidiana en RGB, y la función adaptativa de similitud de color propuesta [28][46].




Fig. 41 Gráfica de la tasa de VP y FP utilizando métrica Euclidiana para los parámetros  $a^*$  y  $b^*$  en el espacio de color  $L^*a^*b^*$  en incrementos de 10% de la sombra difuminada en cada paso para imágenes de alta saturación

En la Fig. 42 se grafican los resultados de VP y FP al aplicar la sombra difuminada con un 10% de aumento en cada paso, con el paso 1 correspondiente al 0% y el 11 al 100%. Se pueden notar dos tendencias principales y una intermedia: 1) Subida gradual iniciando aproximadamente con un 20% de la sombra difuminada que corresponden a los canales RGB y a las flores 0h, 2h y 4h que tienen 120 grados de diferencia entre ellos. 2) Subida abrupta iniciando con un 10 % de sombra difuminada y teniendo ya malos resultados con solo 20% de la sombra en flor 1h y flor 5h. 3) Comportamiento intermedio a las tendencias anteriormente mostradas para la flor 3h.

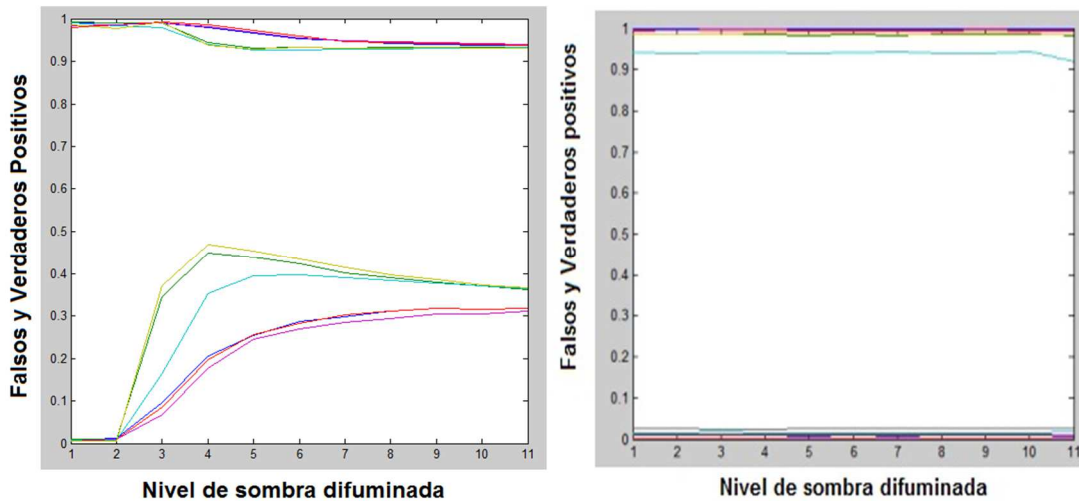


Fig. 42 Gráfica de la tasa de VP y FP utilizando métrica Euclidiana de RGB (izquierda) y de la función de similitud de color (derecha) en incrementos de 10% de la sombra difuminada en cada paso para imágenes de alta saturación

En la Fig. 42 (derecha) se grafican los resultados para la función de similitud propuesta de la misma manera que en las gráficas anteriores. Como puede observarse, tiene un comportamiento muy regular para todos los colores siempre manteniendo alta eficiencia y prácticamente inmune a la aplicación de la sombra difuminada. La tabla 5 resume las observaciones de los comportamientos de las gráficas anteriores.




Fig. 43 Detalles de la tasa de VP y FP usando la función de similitud de color en imágenes de alta saturación

Para la métrica Euclidiana de los canales  $a^*$  y  $b^*$ , se pueden notar tres tipos de tendencias en sectores con 120 grados de diferencia (Figura 41 izquierda): 1) Subida de la curva bruscamente (flores 0h, 2h y 4h que corresponden a los canales de color RGB) con alta sensibilidad a la sombra difuminada; 2) Subida lenta (flores 1h y 5h), y 3) Incremento insensible (flor 3h) a cerca de 90% de la aplicación de la sombra. En la tabla 5 se resumen las observaciones sobre el comportamiento de las curvas que comparan la métrica Euclidiana en el espacio de color  $L^*a^*b^*$  del enfoque probabilístico sobre  $a^*$  y  $b^*$ , y la función de similitud del color propuesta en esta tesis.

Nuestro sistema se comportó correctamente en todos los casos de estudio segmentando siempre el objeto de interés con una alta tasa de éxito mayor que el 95% de VP (excepto para el cian que tuvo una tasa de VP de alrededor del 94%) y con una baja tasa de error menor al 3% en promedio (Figura 43). El enfoque probabilístico mejoró en algunos casos la métrica Euclidiana en  $a^*$  y  $b^*$  como en las flores 1h y 3h. En otros casos, no se pudo segmentar el objeto de interés, incluso, sin aplicarle sombra, como sucedió en azul 240° (Figura 40).

**Tabla 5** Observaciones sobre el comportamiento de las curvas comparando las métrica Euclidiana en el espacio  $L^*a^*b^*$  rechazando  $L^*$ , un enfoque probabilístico sobre  $a^*$  y  $b^*$ , la métrica Euclidiana en el espacio RGB, y la función de similitud de color propuesta

Flor Alta Saturación	Color de la línea	Métrica Euclidiana en $L^*a^*b^*$ , descartando $L^*$	Enfoque probabilístico en $a^*$ y $b^*$ , descartando $L^*$	Métrica Euclidiana en RGB	Función de similitud de color
0h	Azul	0% (posición 1) Peor caso	0% (posición 1) Incrementa rápidamente	20% (posición 3). Incrementa lentamente. Máxima falla en 100%	Inmune
1h	Verde	30% (posición 4). Incrementa lenta y progresivamente	30% (posición 4). Incrementa muy lentamente	10% (posición 2). Incrementa rápidamente. Máxima falla en 30%. Disminuye poco lentamente	Inmune
2h	Rojo	10% (posición 2). Incrementa rápidamente	10% (posición 2). Incrementa rápidamente	20% (posición 3). Incrementa lentamente. Máxima falla en 100%	Inmune
3h	Cian	80% (posición 9). Incrementa a 45°	Inmune	10% (posición 2). Incrementa rápidamente. Máxima falla en 40%. Disminuye poco lentamente	Inmune
4h	Púrpura	10% (posición 2). Incrementa rápidamente	0% (posición 1). Incrementa rápidamente	20% (posición 3). Incrementa lentamente. Máxima falla en 100%	Inmune
5h	Amarillo	30% (posición 4). Incrementa rápidamente	30% (posición 4). Incrementa rápidamente	10% (posición 2). Incrementa rápidamente. Máxima falla en 30%. Disminuye poco lentamente	Inmune

Para obtener las gráficas ROC representativas que ilustren el comportamiento de la métrica Euclidiana en  $L^*a^*b^*$  sin tomar en cuenta  $L^*$ , la métrica Euclidiana de RGB y la función adaptativa de similitud de color, en todos los sectores de color bajo estudio, se calculó el promedio de los índices VP y FP para todas las flores de color, obteniendo los resultados que se muestran en las figuras 44 y 45, respectivamente.

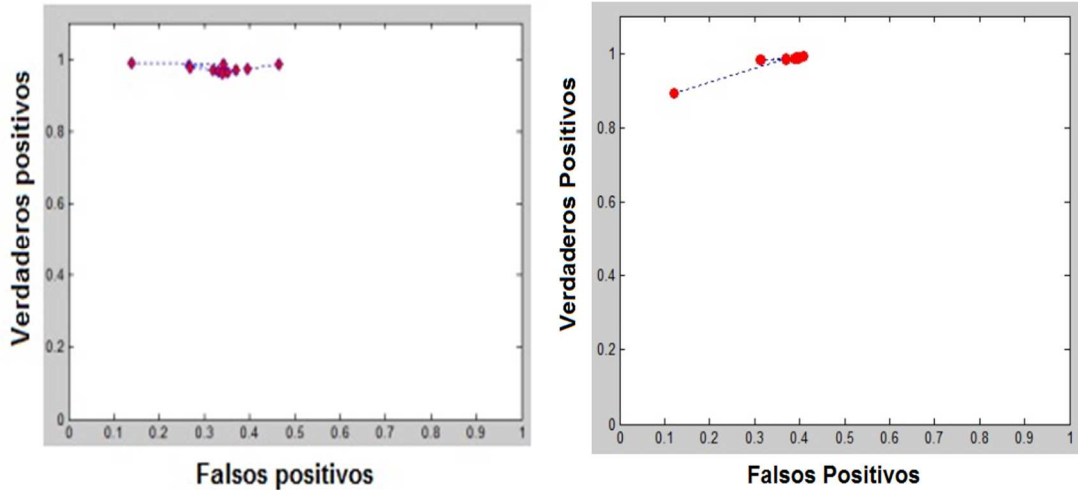


Fig. 44 Gráficas ROC de la métrica Euclidiana de los parámetros  $a^*$  y  $b^*$  en el espacio de color  $L^*a^*b^*$  (izquierda) y del enfoque probabilístico en  $a^*$  y  $b^*$  para todas las flores de alta saturación

En la gráfica ROC correspondiente a la media de VP y FP de todas las flores, puede verse que los resultados en el espacio de color CIE  $L^*a^*b^*$  (Figura 44 izquierda) son pobres desde el principio, peor que los resultados RGB (Figura 45 izquierda), pues la curva continuamente se mueve a la zona superior derecha de la gráfica ROC que se puede considerar como el lado "liberal" (coordenada 1, 1); en ella se ve que se hacen clasificaciones positivas con evidencia débil y aunque casi todos los verdaderos positivos fueron clasificados correctamente, se tiene una alta tasa de errores (falsos positivos) [28].




Fig. 45 Gráficas ROC de la distancia Euclidiana de los canales RGB (izquierda) y de la función adaptativa de similitud propuesta (derecha)

Los resultados RGB se mantienen estables sólo en los dos primeros pasos y rápidamente se mueven a la zona superior derecha de la gráfica ROC hacia el lado "liberal" (coordenada 1, 1).

De la gráfica ROC correspondiente (Figura 45 derecha) se puede observar que la función adaptativa de similitud de color propuesta se mantiene en la zona de alta eficiencia (coordenada 0, 1), mientras que la segmentación de color en el espacio CIE  $L^*a^*b^*$  y la


métrica Euclidiana de los canales de color RGB progresivamente se alejan de la zona de alta eficiencia con cambios relativamente pequeños en la luminancia  $L^*$  [28][46].

## **5.10 Resultados del algoritmo al usar solo la mitad de la información de entrada**

En esta sección se muestran gráfica y numéricamente los resultados, tanto en la región de baja saturación (ver la figura 46) como en la región de alta saturación (ver la figura 51) incrementando el nivel de sombra difuminada en un 10% en cada paso. La primera posición significa que no hay sombra y la posición 11 significa la aplicación del 100% de sombra difuminada. A todas las imágenes se les aplica el mismo procesamiento antes de obtener los gráficos ROC: eliminación de las áreas inferiores a 30 píxeles y un cierre morfológico con un elemento de estructura circular de radio igual a dos píxeles.

### **5.10.1 Resultados en imágenes de baja saturación**

A continuación se presentan los resultados en imágenes de baja saturación aplicando diferentes niveles de sombra difuminada. Se comparan la métrica Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$  en el espacio de color CIE  $L^*a^*b^*$  (primera fila de cada color), la métrica Euclidiana de los canales RGB (segunda fila de cada color), el método propuesto que utiliza muestras de píxeles de la figura y el fondo y clasifica por máxima similitud (tercera fila de cada color) y el método propuesto que utiliza una sola muestra de píxeles de la figura y clasifica por umbralado automático usando la función de similitud propuesta (cuarta fila de cada color). Se muestran los resultados en la figura 46 para cada cuadrante de color ( $0^\circ$ ,  $60^\circ$ ,  $120^\circ$ ,  $180^\circ$ ,  $240^\circ$  y  $300^\circ$ ) y 10% de incrementos de la sombra desvanecida.








Fig. 46. Resultados de la segmentación de color en imágenes de baja saturación con la métrica Euclidiana de los parámetros  $a^*$  y  $b^*$  rechazando  $L^*$  en el espacio de color CIE  $L^*a^*b^*$  (primera fila de cada color), la métrica Euclidiana de los canales RGB (segunda fila de cada color), el método propuesto que utiliza muestras de píxeles de la figura y el fondo y que clasifica por máxima similitud (tercera fila de cada color) y el método que solo utiliza muestras de píxeles de la figura y que clasifica por umbralado automático utilizando la función de similitud adaptativa propuesta (cuarta fila de cada color) para cada cuadrante de color ( $0^\circ$ ,  $60^\circ$ ,  $120^\circ$ ,  $180^\circ$ ,  $240^\circ$  y  $300^\circ$ ) y con incrementos de sombra de 10% en cada paso

Como se puede ver en las imágenes correspondientes a los resultados de la segmentación de las imágenes de prueba con baja saturación (Fig. 46, filas tercera y cuarta de cada color) y los gráficos correspondientes (en la Fig. 48 izquierda y derecha y en la Fig. 49 izquierda y derecha), donde ambos métodos utilizaron la función adaptativa de similitud de color propuesta, se comportaron correctamente en todos los casos de estudio, siempre segmentando el objeto de interés con una alta tasa de éxito de verdaderos positivos (VP) superior al 95% y con una tasa de error inferior al 2% (Figuras 49 y 50, izquierda y derecha).

La Fig. 49 muestra los detalles de las curvas relacionadas con VP y FP del método que utiliza muestras de píxeles de la figura y fondo y que clasifica por máxima similitud. La figura 50 muestra los detalles de los resultados del método que utiliza solo muestras de píxeles de la figura y que clasifica mediante umbralado automático de la función de similitud de color en imágenes de baja saturación con el siguiente código de colores: flor\_0 (azul), flor\_1 (verde), flor\_2 (rojo), flor\_3 (cian), flor\_4 (púrpura) y flor\_5 (amarillo); las variaciones en las curvas son inferiores al 2%. La tabla 6 muestra este caso y todos los demás casos, y el nivel cuando se produce una falla notoria en la calidad de la segmentación.




Fig. 47. Gráficas que muestran los verdaderos positivos (VP) y falsos positivos (FP) de la distancia Euclidiana de los canales  $a * b$  rechazando  $L^*$  (izquierda) y la métrica Euclidiana de los canales RGB (derecha), con incrementos de sombra difuminada de 10% en cada paso para imágenes de baja saturación




Fig. 48. Gráficas de VP y FP del método que utiliza dos muestras de píxeles y que clasifica mediante máxima similitud (izquierda) y el método que utiliza solo una muestra y umbrala con el método de Otsu (derecha), con incrementos del 10% de la sombra difuminada en cada paso para imágenes de baja saturación




Fig. 49. Detalles de los verdaderos positivos VP (izquierda) y falsos positivos FP (derecha) del método que utiliza dos muestras y clasifica por máxima similitud en imágenes de baja saturación




Fig. 50. Detalles de los verdaderos positivos VP (izquierda) y falsos positivos FP (derecha) del método que utiliza solo una muestra de píxeles y umbralado con el método de Otsu en imágenes de baja saturación

Como se muestra en los gráficos de la figura 47 (izquierda) y en coincidencia con el análisis visual de la flor correspondiente (Figura 46, primera fila de cada color), las fallas en la segmentación para el caso de la distancia Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$  en el espacio de color CIE  $L^*a^*b^*$  (ver Fig. 47 izquierda) empiezan en diferentes niveles de aplicación de la sombra difuminada en todos los sectores en estudio.

Se pueden observar tres tendencias generales en el comportamiento de los falsos positivos (FP) en la figura 47 izquierda, a saber: 1) Aumento tardío en un ángulo de aproximadamente  $45^\circ$  en los casos de flor\_0 y flor\_3 (con marcador de diamante); 2) Aumento lento y progresivo en casos de flor\_1 y flor\_4 (con marcador cuadrado) y 3) Aumento brusco en los casos de flor\_2 y flor\_5 (con marcador circular). El comportamiento se repite cada 180 grados y coincide con las posiciones de color oponente (amarillo-azul, por ejemplo).

La segmentación utilizando la métrica Euclidiana de los canales de color RGB falló de una manera más regular, pues empezó a tener problemas en la baja saturación con menos de 10% a 20% de la sombra aplicada.




En la tabla 6 se resumen las observaciones sobre el comportamiento de las curvas que comparan la métrica Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$  en el espacio de color CIE  $L^*a^*b^*$ , la métrica Euclidiana de los canales RGB, el método que utiliza muestras de píxeles tanto de la figura y el fondo y clasifica por máxima similitud y el método que solo utiliza muestras de píxeles de la figura y clasifica mediante umbralado automático utilizando la función de similitud, para las imágenes de baja saturación.

**Tabla 6.** Observaciones sobre el comportamiento de las curvas que comparan los cuatro métodos bajo estudio para las pruebas de imágenes de baja saturación

Flor baja saturación	Color de línea	Métrica Euclidiana de a* y b*	Métrica Euclidiana en RGB	Dos muestras y asigna por máxima similitud	Una muestra y umbralada con Otsu
0	Azul	60% (posición 7). Incrementa a 45°	10% Incrementa lentamente	Inmune	Inmune
1	Verde	30% (posición 4). Incrementa lenta y progresivamente	Menos de 10%. Incrementa rápidamente	Inmune	Inmune
2	Rojo	40% (posición 5). Incrementa rápidamente	10% Incrementa lentamente	Inmune	Inmune
3	Cian	70% (posición 8). Incrementa a 45°	Menos de 10%. Incrementa rápidamente	Inmune	Inmune
4	Púrpura	20% (posición 3). Incrementa lenta y progresivamente	10% Incrementa lentamente	Inmune	Inmune
5	Amarillo	50% (posición 6). Incrementa rápidamente	Menos de 10%. Incrementa rápidamente	Inmune	Inmune

### 5.10.2 Resultados en alta saturación

A continuación se presentan los resultados para las imágenes de alta saturación al aplicar diferentes niveles de sombra difuminada, al comparar la métrica Euclidiana de los canales a\* y b\* rechazando L\* en el espacio de color CIE L\*a\*b\* (primera fila de cada color), la métrica Euclidiana de los canales RGB (segunda fila de cada color), el método que utiliza muestras de píxeles de la figura y el fondo y clasifica por máxima similitud (tercera fila de cada color) y el método que utiliza solo muestras de píxeles de la figura y clasifica mediante umbralado automático usando la función de similitud (cuarta fila de cada color) incluidos en la figura 51 para cada cuadrante de color (0°, 60°, 120°, 180°, 240° y 300°) y con incrementos de 10% de la sombra desvanecida.






Fig. 51. Resultados de la segmentación de color en imágenes de alta saturación por la métrica Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$  en el espacio de color CIE  $L^*a^*b^*$  (primera fila de cada color), la métrica Euclidiana de los canales en el espacio de color RGB (segunda fila de cada color), el método que utiliza muestras de píxeles de la figura y el fondo y que clasifica por máxima similitud (tercera fila de cada color) y el método que utiliza solo muestras de píxeles de la figura y clasifica por umbralado automático mediante la función de similitud (cuarta fila de cada color) para cada cuadrante de color ( $0^\circ$ ,  $60^\circ$ ,  $120^\circ$ ,  $180^\circ$ ,  $240^\circ$  y  $300^\circ$ ) y con incrementos de sombra desvanecida de 10% en cada paso

Como puede verse en los resultados correspondientes de la segmentación de las imágenes de prueba con alta saturación (en la figura 51, tercera y cuarta línea de cada color), y las gráficas correspondientes (Figura 53, izquierda y derecha; Figura 54, izquierda y derecha; Figura 55, izquierda y derecha) ambos métodos que utilizan la función de similitud del color propuesta se comportaron correctamente en todos los casos, siempre segmentando el objeto de interés con una alta tasa de éxito de verdaderos positivos (VP) superior al 95% y con una tasa de error menor que el 2% (Figuras 54 y 55, izquierda y derecha).

La primera fila de cada color en la figura 51 indica los resultados usando la distancia Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$ . Tres tipos de tendencias se pueden notar en sectores de 120 grados de diferencia (véase la figura 52 izquierda): 1) Subida brusca de la curva (flores\_0h, \_2h y \_4h que corresponden a los canales de color RGB) con alta sensibilidad a la sombra difuminada; 2) Subida lenta (flores\_1h y \_5h), y 3) Incremento insensible (flor\_3h) a cerca de 90%.




Fig. 52. Gráficas de verdaderos positivos VP y falsos positivos FP de la métrica Euclidiana de  $a^*$  y  $b^*$  rechazando  $L^*$  (izquierda) y la métrica Euclidiana de los canales RGB (derecha) con incrementos de 10% de sombra desvanecida en cada paso en imágenes de alta saturación






Fig. 53. Gráficas de verdaderos positivos VP y falsos positivos FP del método que utiliza dos muestras de píxeles para fondo y figura y que clasifica mediante máxima similitud (izquierda) y el método que utiliza solo una muestra de la muestra de píxeles y clasifica mediante umbralado automático usando el método de Otsu (derecha) con incrementos de la sombra desvanecida del 10% en cada paso en imágenes de alta saturación




Fig. 54. Detalles de verdaderos positivos VP (izquierda) y falsos positivos FP (derecha) del método que utiliza dos muestras de píxeles para figura y fondo y clasifica mediante el método de máxima similitud en imágenes de alta saturación




Fig. 55. Detalles de verdaderos positivos VP (izquierda) y falsos positivos FP (derecha) del método que utiliza solo una muestra y clasifica mediante umbralado automático con el método de Otsu para imágenes de alta saturación

La segmentación que utiliza la métrica Euclidiana de los canales de color RGB falló de una manera más regular (Figura 52 derecha) empezando a tener problemas en alta saturación en alrededor del 20% al 30% de la aplicación de la sombra difuminada.

La tabla 7 resume las observaciones sobre el comportamiento de las curvas que comparan la métrica Euclidiana de los canales  $a^*$  y  $b^*$  rechazando  $L^*$  en el espacio de color CIE  $L^*a^*b^*$ ; la métrica Euclidiana de los canales RGB; el método que utiliza muestras de píxeles de la figura y el fondo que clasifica por máxima similitud; y el método que sólo utiliza muestras de píxeles de la figura y clasifica mediante umbralado automático utilizando la función de similitud en imágenes de prueba de alta saturación.

Tabla 7. Observaciones sobre el comportamiento de las curvas que comparan los cuatro métodos de segmentación en estudio para imágenes de alta saturación

Flor Alta Saturación	Color de la línea	Métrica Euclidiana en $L^*a^*b^*$ rechazando $L^*$	Métrica Euclidiana en RGB	Dos muestras y clasifica por máxima similitud	Una muestra y umbralada con Otsu
0h	Azul	0% (posición 1). Peor caso	10%. Incrementa rápidamente	Inmune	Inmune
1h	Verde	30% (posición 4). Incrementa lenta y progresivamente	20%. Incrementa lentamente	Inmune	Inmune
2h	Rojo	10% (posición 2). Incrementa rápidamente	10%-20%. Incrementa rápidamente	Inmune	Inmune
3h	Cian	80% (posición 9). Incrementa a 45°	20%. Incrementa lentamente	Inmune	Inmune
4h	Púrpura	10% (posición 2). Incrementa rápidamente	10%. Incrementa rápidamente	Inmune	Inmune
5h	Amarillo	30% (posición 4). Incrementa rápidamente	20%. Incrementa lentamente	Inmune	Inmune

# CAPÍTULO 6

## CONCLUSIONES

## 6. Conclusiones

Los resultados obtenidos durante la investigación demostraron que la función adaptativa de similitud de color y el método supervisado de segmentación de los colores propuesto, ofrecen una alternativa útil y eficaz para la segmentación de objetos (o regiones) con diferentes colores en imágenes de color relativamente complejas, con un buen rendimiento en presencia del inevitable ruido aditivo. El método propuesto discrimina de un modo muy sencillo cualquier tipo de objetos de diferente color independientemente de sus formas y tonalidades.

Por otro lado se presentó una evaluación cuantitativa y la caracterización de la función adaptativa de similitud de color propuesta y del algoritmo semiautomático de segmentación de imágenes en colores obtenido directamente a partir de la función de similitud. Se llevó a cabo la caracterización y evaluación mediante la generación de imágenes sintéticas con su correspondiente GT. Se calcularon la tasa de verdaderos positivos (VP) y la tasa de falsos positivos (FP) para cada imagen, con el fin de obtener las gráficas ROC de los resultados. Este sistema es útil en general para evaluar la calidad del uso de la información de color dentro de algoritmos de segmentación.

El comportamiento (caracterización) se evaluó mediante la variación del tamaño, la forma y el contraste de color, la cantidad de ruido aditivo, el umbral y el número de píxeles tomados en la muestra. Después de un análisis de las correspondientes gráficas ROC, el algoritmo mostró buen comportamiento en todos los casos de estudio con tasas de VP mayores que el 95% y tasas de FP inferiores al 2%. Se muestra el buen desempeño del algoritmo, incluso en casos en los que el contraste de color es tan bajo que un observador no encuentra diferencia de color.

También se demuestra que la caracterización de la región acromática presentada en este trabajo de tesis mejora el rendimiento en comparación con los métodos previamente publicados, debido a la afectación de la saturación por un factor exponencial en un esfuerzo para modelar mejor la respuesta visual humana en el caso de muy bajo o muy alto brillo. La mejora en la calidad de los resultados es significativa.

Se presentó un estudio comparativo entre el comportamiento de la técnica propuesta que utiliza una muestra de píxeles y umbralado automático, y dos técnicas de segmentación comparables en imágenes en color: 1) la métrica Euclidiana de los canales de color  $a^*$  y  $b^*$  rechazando  $L^*$  en el espacio de color CIE  $L^*a^*b^*$  y 2) un enfoque probabilístico en  $a^*$  y  $b^*$ .

Los resultados obtenidos en este trabajo muestran que los dos métodos que utilizan la función de similitud de color propuesta obtuvieron buenos resultados en baja y alta saturación en todos los casos de estudio siendo prácticamente inmune a los cambios en el desvanecimiento de sombra, con tasas de éxito superior al 95% de verdaderos positivos (TP) y la tasa de falsos positivos (FP) (errores) menor que el 3%. El rendimiento del método que utiliza una sola muestra de píxeles y que clasifica mediante umbralado

automático es equivalente al método que usa muestras de píxeles tanto de la figura y el fondo y que clasifica por máxima similitud.

Como puede verse por los resultados, los dos métodos implementados que emplean la función de similitud de colores en todos los casos superaron: 1) El método que utiliza la distancia Euclidiana en el espacio de color CIE  $L^*a^*b^*$ , pero descartando  $L^*$ ; 2) El método que usa un enfoque probabilístico en  $a^*$  y en  $b^*$  y 3) La métrica Euclidiana de los canales de color RGB usada como referencia.

En las regiones de alta saturación el algoritmo de segmentación que utiliza la distancia Euclidiana en el espacio de color CIE  $L^*a^*b^*$  descartando  $L^*$ , sufrió errores en todos los casos. Se manifestaron en diferentes grados y en diferentes niveles de sombra difuminada (de menos de 10% al 80%). Se pueden notar tres tipos de tendencias (como se muestra en la figura 33 izquierda) en sectores con 120 grados de diferencia: 1) Subida de la curva bruscamente (flores\_0h, \_2h \_4h y que corresponden a los canales de color RGB) con una alta sensibilidad a la sombra difuminada (superior a la distancia Euclidiana en RGB); 2) Subida lenta (flores\_1h y 5h) inferior al caso de la distancia Euclidiana en RGB y 3) Incremento insensible (flor\_3h) hasta cerca de 90% de sombra.

También en las regiones de baja saturación, la segmentación tuvo errores en todos los casos. Los errores se manifestaron en diferentes grados y en diferentes niveles de sombra desvanecida (del 20% al 80%). Tres tipos de tendencias o simetrías recurrentes se pudieron notar en sectores con 180 grados de diferencia: 1) Subida de la curva gradualmente (flores\_1h y \_4h); 2) Elevación abrupta (flores\_2h y\_5h), y 3) Aumento en un ángulo cercano a los 45° (flores\_0h y \_3h).

El método de segmentación que utiliza un enfoque probabilístico en  $a^*$  y  $b^*$  mejoró en muchos casos los resultados al usar la métrica Euclidiana en  $a^*$  y  $b^*$ , pero en otros casos no se pudieron obtener mejoras debido a la corrupción del mismo espacio  $L^*a^*b^*$ .

La corrupción de los componentes de color  $a^*$  y  $b^*$  debido a los cambios de luminancia ya se nota en algunas regiones de baja saturación, pero aumenta rápidamente en la mayoría de las regiones de alta saturación de forma irregular. En algunas regiones de alta saturación el espacio de color  $L^*a^*b^*$  no es útil para distinguir cambios sutiles en el tono con la mínima cantidad de sombra aplicada.

La mayoría de las regiones de alta saturación son muy sensibles a los cambios de luminancia, ya que los más pequeños cambios provocan fallos durante la segmentación. De estos resultados se puede observar que el CIE  $L^*a^*b^*$  tiene un rendimiento peor que el espacio de color RGB en varias regiones de color de alta saturación. Hemos demostrado que la mejora en la calidad de la técnica de segmentación propuesta con sus rápidos resultados es sustancialmente significativa.

Se puede observar que la no consideración del parámetro de luminancia  $L^*$  en el cálculo de la distancia Euclidiana y en el enfoque probabilístico, no hizo a los métodos inmunes a cambios en la iluminación, de tal modo que una simple sombra podía alterar la calidad de sus resultados. También se pudo notar a partir de los resultados, que los parámetros  $a^*$   $b^*$

del espacio de color  $L^*a^*b^*$  no son independientes del parámetro  $L^*$  como uno podría suponer.

La segmentación usando la métrica Euclidiana de los canales RGB falló en una forma más regular empezando a tener problemas en baja saturación con menos del 10% de difuminado y en alta saturación con menos del 20% de difuminado. Se pueden observar dos tipos de comportamiento: 1) Incremento abrupto de los errores y 2) Incremento progresivo de los errores.

El método propuesto de segmentación también se puede utilizar directamente en imágenes en escala de grises sin realizar ningún cambio, brindando buenos resultados. Por el contrario, los otros métodos de prueba que utilizan el espacio de color CIE  $L^*a^*b^*$  necesitan incluir el valor de la luminancia  $L^*$  para realizar la segmentación en ese tipo de imágenes, ya que los valores  $a^*$  y  $b^*$  se mantienen sin cambios en el centro del plano  $a^*b^*$ . Una tarea adicional por realizar es decidir cuándo el parámetro de luminancia  $L^*$  debe ser considerado en el cálculo de la distancia.

El sistema de pruebas diseñado se puede utilizar ya sea para explorar el comportamiento de una función de similitud en diferentes espacios de color o para explorar diferentes distancias de color (o funciones de similitud) en el mismo espacio de color. En lugar de intercambiar espacios de color en los experimentos, sólo sería necesario un cambio de la métrica (o de la función de similitud) en el mismo espacio.

La corrupción de los componentes de color  $a^*$  y  $b^*$  debido a los cambios de luminancia ya se hace notable en algunas regiones de baja saturación, pero aumenta rápidamente en la mayoría de las regiones de alta saturación de forma irregular. En algunas regiones de alta saturación el espacio de color  $L^*a^*b^*$  no es útil para distinguir cambios sutiles en el tono con la mínima cantidad de sombra aplicada.

La mayoría de las regiones de alta saturación son muy sensibles a los cambios de luminancia, ya que los más pequeños cambios provocan fallos durante la segmentación. De estos resultados se puede observar que el CIE  $L^*a^*b^*$  tiene un rendimiento peor que el espacio de color RGB en varias regiones de color de alta saturación. Hemos demostrado que la mejora en la calidad de la técnica de segmentación propuesta y sus rápidos resultados son sustancialmente significativos.

Como se puede observar directamente a partir de los resultados de la segmentación y de las gráficas generadas, la función adaptativa de similitud de color propuesta superó en todos los casos a la distancia Euclidiana en el espacio de color  $L^*a^*b^*$ , sin tomar en cuenta  $L^*$ . El método de segmentación utilizando la función de similitud se desempeñó bien en todos los casos con tasas superiores al 95% de verdaderos positivos (VP) y tasas menores que el 3% de falsos positivos (FP).

En cuanto a la evaluación del método de segmentación de color con condiciones muy difíciles, podemos notar que la función adaptativa de similitud de color propuesta tuvo un buen desempeño en todas las pruebas y se mantuvo cerca de la zona de alta eficiencia de las

gráficas ROC (coordenadas 0, 1), sin cambios notables, cuando el nivel de sombra difuminada aumentaba.

Durante el curso de la presente investigación se pudieron observar las deficiencias del espacio de color CIE L\*a\*b\* para el proceso de la segmentación del color y se puede ver que los resultados obtenidos son pobres y variables para cada región de color y nivel de saturación. Por lo tanto, todas las aplicaciones que utilizan ese espacio de color tendrán malos e inesperados resultados, en función de las imágenes de entrada y la iluminación.

De los resultados se puede afirmar que algunos sistemas basados en el espacio de color CIE L\*a\*b\* usan imágenes que se adaptan a sus pruebas y a sus resultados, como es el caso de las imágenes con baja saturación. Con este tipo de imágenes, la segmentación en el espacio de color CIE L\*a\*b\* se comporta bien con cambios de luminancia, incluso mejor que en el espacio de color RGB. Sin embargo, con imágenes de alta saturación los sistemas que utilizan el espacio de color CIE L\*a\*b\* se comportan peor que en el espacio de color RGB, por lo que forzosamente producen resultados muy pobres en la segmentación, incluso con la menor variación en la iluminación.

## Referencias

1. Gonzalez RC, Woods RE. *Digital Image Processing*, third Edition, Prentice Hall, Upper Saddle River NJ, USA; 954 p., 2008.
2. Plataniotis KN, Venetsanopoulos AN. *Color Image Processing and Applications*. First Edition, Springer, Berlin Heidelberg Germany; 354 p., 2000.
3. Alvarado-Cervantes R. *Segmentación de patrones lineales topológicamente diferentes, mediante agrupamientos en el espacio de color HSI*, M. Sc. Thesis, Centro de Investigación en Computación, Instituto Politécnico Nacional, México; 2006.
4. Cheng H, Jiang X, Sun Y, and Wang J. *Color Image Segmentation: Advances and prospects*, Pattern Recognition; 34(12): 2259-2281, 2001.
5. Alvarado-Cervantes R., Felipe-Riveron E.M., Khartchenko V., and Pogrebnyak O. *An Adaptive Color Similarity Function Suitable for Image Segmentation and its Numerical Evaluation*. Color Research and Application. Ellen C. Carter (Ed.). 2016 Wiley Periodicals, Inc. Col Res Appl, 00, 000–000, 2016; published Online May 20, 2016 in Wiley Online Library (wileyonlinelibrary.com). DOI 10.1002/col.22059. New Jersey USA, 2016.
6. Angulo J, Serra J. *Modelling and segmentation of colour images in polar representations*, Image and Vision Computing; 25: 475–495. Centre de Morphologie Mathématique – Ecole des Mines de Paris, France, 2007.
7. Angulo J, Serra J. *Mathematical Morphology in Color Spaces applied to The Analysis of Cartographic Images*, GEOPRO 2003 México; 2003.
8. Huang R, Sang N, Luo D, Tang Q. *Image Segmentation via coherent clustering in  $L^*a^*b^*$  Color Space*. Pattern Recognition Letters; 32: 891-902, 2011.
9. Hanbury, A, Serra, J. *A 3D-polar coordinate colour representation suitable for image analysis*, Technical Report PRIP-TR-77, Pattern Recognition and Image Processing Group, Institute of Computer Aided Automation, Vienna University of Technology, Vienna Austria; 2003.
10. Poynton C, "<http://www.poynton.com/PDFs/GammaFAQ.pdf>"; 2016.
11. Zhang Hui A, Fritts Jason E, Goldman Sally A. *Image segmentation evaluation: A survey of unsupervised methods*, Computer Vision and Image Understanding; doi:10.1016/j.cviu.2007.08.003; Elsevier, 2007.
12. Zhang YJ. *A Survey on Evaluation Methods for Image Segmentation*, Pattern Recognition; Vol. 29, No 8 p. 1335-1346, 1996.
13. Zhang, YJ. *A review of recent evaluation methods for image segmentation*. Proceedings of the 6th International Symposium on Signal Processing and Its Applications; p. 148-151, 2001.
14. Zhang YJ, Gerbrands JJ. *On the Design of Test Images for Segmentation Evaluation*. Proceedings EUSIPCO, 1; P. 551-554, 1992.
15. Zhang YJ. *A Summary of Recent Progresses for Segmentation Evaluation*. In: Zhang Y.J. Advances in Image and Video Segmentation. IGI Global Research Collection, Idea Group Inc (IGI), p. 423-439. ISBN 1591407559, 9781591407553, 2006.
16. Vaitkus M, Várady T. *Grayscale and Color Image Segmentation using Computational Topology*. Proceedings of CESC 2013: The 17th Central European Seminar on Computer Graphics; 2013.



17. Gupta S, Bhuchar K and Sandhu PS. *Implementing Color Image Segmentation Using Biogeography Based Optimization*. IPCSIT vol. 9 p. 79-86, IACSIT Press, Singapore. International Conference on Software and Computer Applications, 2011.
18. Sengur A, Guo Y. *Color Texture Image Segmentation Based on Neutrosophic Set and Wavelet Transformation*, Computer Vision and Image Understanding Volume 115, Issue 8, August 2011 p. 1134-1144, Doi: 10.1016/j.cviu.2011.04.001; 2011.
19. Yue XD, Miao DQ, Zhang N, Cao LB, Wu Q. *Multiscale Roughness Measure for Color Image Segmentation*. Information Sciences Vol. 216; p. 93–112, 2012.
20. Puranik P, Bajaj P, Abraham A, Palsodkar P, Deshmukh A. *Human Perception-based Color Image Segmentation Using Comprehensive Learning Particle Swarm Optimization*. Journal of Information Hiding and Multimedia Signal Processing. Vol. 2 Number 3, p. 227-235 2011.
21. Shi L, Funt B. *Quaternion Color Texture Segmentation*, Computer Vision and Image Understanding; 107: 88–96, 2007.
22. Celik T, Tjahjadi T. *Unsupervised Colour Image Segmentation Using Dual-Tree Complex Wavelet Transform*. Computer Vision and Image Understanding. 114: 813–826, 2010.
23. Martin D, Fowlkes C, Tal D, *et al*. *A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics*. Proceedings of the 8th International Conference on Computer Vision 2: 416-423, 2001.
24. Kim C, You BJ, Jeong MH, Kim H. *Color Segmentation Robust To Brightness Variations By Using B-Spline Curve Modeling*, Pattern Recognition 41; p. 22 – 37, 2008.
25. Otsu N. *A Threshold Selection Method from Gray-Level Histograms*, IEEE Transactions on Systems, Man and Cybernetics. 9(1): 62-66, 1979.
26. Harun NH, Mashor MY, Mokhtar NR *et al*. *Comparison of Acute Leukemia Image Segmentation using HSI and RGB Color Space*. 10th International Conference on Information Science, Signal Processing and their Applications (ISSPA 2010) Kuala Lumpur, 10-13, p. 749 – 752. Print ISBN: 978-1-4244-7165-2, 2010.
27. Sezgin M and Sankur B. *Survey over image thresholding techniques and quantitative performance evaluation*. Journal of Electronic Imaging 13 (1): 146–165. Doi: 10.1117/1.1631315, 2003.
28. Alvarado-Cervantes, R, Felipe-Riveron, EM, Khartchenko, V, and Pogrebnyak, O. *Influence of Luminance  $L^*$  in the  $L^*a^*b^*$  Color Space during Color Segmentation in Highly Saturated Color Images*. In: Oscar Herrera Alcántara (Ed.) Research in Computer Science. Vol 102. Advances in Machine Learning and Image Processing pp 21-31. 14th Mexican International Conference on Artificial Intelligence MICAI 2015. Cuernavaca Morelos, Mexico. October 25-31, 2015.
29. Alvarado-Cervantes, R, Felipe-Riveron, EM, Khartchenko, V, and Pogrebnyak, O. *Influence of the Luminance  $L^*$  during Color Segmentation in the  $L^*a^*b^*$  Color Space*. 15<sup>th</sup> International Conference on Computing Science CORE 2015, Research in Computer Science 105: 107-115. CIC IPN, México, 2015.
30. Alvarado-Cervantes, R, Felipe-Riveron, EM y Khartchenko, V. *Characterization and Numerical Evaluation of a Color Image Segmentation Method*. In: Alexander Gelbukh, Félix Castro Espinoza and Sofía N. Galicia-Haro (Eds.) Thirteenth Mexican International Conference on Artificial Intelligence MICAI 2014 pp 48-52. Published by the IEEE Computer Society, Los Alamitos, CA, USA, ISBN 978-1-4799-9900-2, and Library of Congress Number 2015935989. BMS Part Number CFP1434B-PRT, 2015.

31. Alvarado-Cervantes, R y Felipe-Riveron, EM. *Improved HSI Color Space for Color Image Segmentation*. In: Luis Alvarez, Marta Mejail, Luis Gomez, Julio Jacobo (Eds.). Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. LNCS Volume 7441. pp. 348-354. Springer. 17th Iberoamerican Congress, CIARP 2012, Buenos Aires, Argentina. ISBN: 978-3-642-33274-6, 2012.
32. Alvarado-Cervantes, R y Felipe-Riveron, EM. *An Adaptive Color Similarity Function for Color Image Segmentation*. In: C. San Martín and Sang-Woon Kim Jacobo (Eds.). Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. LNCS Volume 7042. pp. 113-124. Springer. 16th Iberoamerican Congress, CIARP 2011, Pucón, Chile, ISBN: 978-3-642-25084-2, 2011.
33. Alvarado-Cervantes, R y Felipe-Riveron, EM. *Refined Achromatic Zone Segmentation in Color Images*. In: Castillo Montiel E., Chimal Eguía J.C., Uriarte Arcia A., and Cabrera Rivera L. (Volume Eds.). Advances in Computer Science Vol. 58 p 79-90. 12th International Conference on Computer Science CORE 2012. CIC IPN, México, 2012.
34. Alvarado-Cervantes, R, Felipe-Riveron, EM and Sanchez-Fernandez, LP. *Color Image Segmentation by means of a Similarity Function*. In: I. Bloch and R.M. Cesar, Jr., Jacobo (Eds.). Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. LNCS Volume 6419. pp. 319-328. Springer. 15th Iberoamerican Congress, CIARP 2010, Sao Paulo, Brasil, ISBN: 978-3-642-16686-0, 2010
35. Alvarado-Cervantes, R y Felipe-Riveron, EM. *Color Image Segmentation Accomplished by an Adaptive Similarity Measure*. In: Grigori Sidorov, Benjamín Cruz, Miguel A. Martínez and Sulema Torres (Eds.) Research in Computing Science. Vol 34, pp. 103-115. 9<sup>th</sup> International Conference on Computing Science CORE 2008, CIC IPN, Mexico. ISSN 1870-4069, 2008
36. Fawcett T. *An introduction to ROC analysis*. Pattern recognition Letters 27: 861-874, 2006.
37. Macaire L, Vandenbroucke N, Postaire JG. *Color Image Segmentation by Analysis of Subset Connectedness and Color Homogeneity Properties*, Computer Vision and Image Understanding 102: 105–116, 2006.
38. Bourbakis N, Yuan P, Makrogiannis S. *Object Recognition Using Wavelets, L-G graphs and Synthesis of Regions*, Pattern Recognition 40: 2077 – 2096, 2007.
39. <http://www.mathworks.com/help/images/examples/color-based-segmentation-using-the-l-a-b-color-space.html> (Revised on April 27, 2015).
40. Bai, X., & Sapiro, G. *A Geodesic Framework for Fast Interactive Image and Video Segmentation and Matting*. In. IEEE 11<sup>th</sup> International Conference on Computer Vision, (2007) (pp. 1-8).
41. Protiere, A., & Sapiro, G. *Interactive Image Segmentation via Adaptive Weighted Distances*. IEEE Transactions on Image Processing, 16(4), (2007) 1046-1057.
42. Rother, C., Kolmogorov, V., & Blake, A. *Grabcut: Interactive Foreground Extraction using Iterated Graph Cuts*. ACM Transactions on Graphics (TOG), 23(3), (2004) 309-314.
43. Correa-Tome F.E., Sanchez-Yanez R.E., and Ayala-Ramirez V. *Comparison of Perceptual Color Spaces for Natural Image Segmentation Tasks*, Opt. Eng. 50(11), 117203 (2011).
44. Sivic J. and Zisserman A., *Video Google: A Text Retrieval Approach to Object Matching in Videos*. Ninth IEEE International Conference on Computer Vision (ICCV 2003). Nice France 2003. pp 1-8

45. Chabrier S, Laurent H, Rosenberg C, Zhang YJ. *Supervised Evaluation of Synthetic and Real Contour Segmentation Results*, 14th European Signal Processing Conference (EUSIPCO 2006), Florence, Italy, September 4-8; 2006.
46. Alvarado-Cervantes R., Felipe-Riveron E.M., Khartchenko V., and Pogrebnyak O. *A Study on the Influence of Luminance  $L^*$  in the  $L^*a^*b^*$  Color Space during Color Segmentation*. Journal of Computer and Communications, 4, 28-34. (2016). Scientific Research Publishing. ISSN Online: 2327-5227. 5th International Conference on Signal and Image Processing CSIP 2016. March 2-4, Beijing, China <http://dx.doi.org/10.4236/jcc.2016.43005>
47. Shapiro L. G. and Stockman G. C. (2001): "Computer Vision", pp 279-325, New Jersey, Prentice-Hall, ISBN 0-13-030796-3.
48. <https://www.microsoft.com/en-us/download/details.aspx?id=52644>. Microsoft Research Cambridge Object Recognition Image Database
49. <https://www.npmjs.com/package/baboon-image>. The baboon test image.

## Anexo

### Apoyos y contribuciones

Se recibió apoyo económico en forma de beca de estudios de Doctorado en los proyectos PAPIIT IN113316 y PAPIIT IN112913 para poder llevar a cabo la presente investigación.

### Artículos en revistas

De la presente investigación se obtuvieron resultados válidos que fueron aceptados para su publicación en la revista **Color Research and Application**, indexada en el Journal on Citation Reports de Thompson Reuters:

- a) Alvarado-Cervantes R., Felipe-Riveron E.M., Khartchenko V., and Pogrebnyak O. *An Adaptive Color Similarity Function Suitable for Image Segmentation and its Numerical Evaluation*. *Color Research and Application*. Ellen C. Carter (Ed.). 2016 Wiley Periodicals, Inc. Col Res Appl, 00, 000–000, 2016; published Online May 20, 2016 in Wiley Online Library (wileyonlinelibrary.com). Online ISSN: 1520-6378. Print ISSN: 0361-2317. DOI 10.1002/col.22059. To be published in paper in April 2017.

También se enviaron dos artículos para su revisión a revistas indexadas:

- a) Alvarado-Cervantes, R., Felipe-Riverón, E. M., Khartchenko, V., Pogrebnyak, O., *A Study on the Behavior of the CIE  $L^*a^*b^*$  Color Space under the Influence of Lightness  $L^*$  during Color Image Segmentation*. *IEEE Transactions on Image Processing*, On review
- b) Alvarado-Cervantes, R., Felipe-Riverón, E. M., Khartchenko, V., Pogrebnyak, O., *A Study of the use of a Robust Color Image Segmentation Method*. *Journal of Real-Time Image Processing*. On review

### Ponencias en congresos

De la presente investigación se obtuvieron resultados que se presentaron en los congresos internacionales siguientes:

- a) Alvarado-Cervantes R., Felipe-Riveron E.M., Khartchenko V., and Pogrebnyak O., *A Study on the Influence of Luminance  $L^*$  in the  $L^*a^*b^*$  Color Space during Color Segmentation*, **Journal of Computer and Communications**, **4**, **28-34**. (2016). Scientific Research Publishing. ISSN Online: 2327-5227. 5th International Conference on Signal and Image Processing CSIP 2016. March 2-4, Beijing, China <http://dx.doi.org/10.4236/jcc.2016.43005>
- b) Alvarado-Cervantes, R, Felipe-Riveron, EM, Khartchenko, V, and Pogrebnyak, O., *Influence of Luminance  $L^*$  in the  $L^*a^*b^*$  Color Space during Color Segmentation in Highly Saturated Color Images*, In: *Research in Computer Science, Advances in Machine Learning and Image Processing*, Oscar Herrera Alcántara (Ed.). Vol 102. pp 21-31. 14th Mexican International Conference on Artificial Intelligence MICAI 2015. Cuernavaca Morelos, Mexico. October 25-31, 2015. ISSN 1870-4069

- c) Alvarado-Cervantes, R, Felipe-Riveron, EM, Khartchenko, V., *Characterization and Numerical Evaluation of a Color Image Segmentation Method*, In: Alexander Gelbukh, Félix Castro Espinoza and Sofia N. Galicia-Haro (Eds.) **Thirteenth Mexican International Conference on Artificial Intelligence MICA I 2014 pp 48-52**. Published by the IEEE Computer Society, Los Alamitos, CA, USA, ISBN 978-1-4799-9900-2, and Library of Congress Number 2015935989. (2015)
- d) Alvarado-Cervantes, R, Felipe-Riveron, EM, Khartchenko, V, and Pogrebnyak, O., *A Comparative Study of the use of a Robust Color Image Segmentation Method*, **Fifteenth Mexican International Conference on Artificial Intelligence MICA I 2016**, Cancun, Mexico October 23-29, 2016, In press
- e) Alvarado-Cervantes, R, Felipe-Riveron, EM, Khartchenko, V, and Pogrebnyak, O., *Influence of the Luminance  $L^*$  during Color Segmentation in the  $L^*a^*b^*$  Color Space*. 15<sup>th</sup> International Conference on Computing Science CORE 2015, **Research in Computer Science Vol. 105 pp 107-115**. CIC IPN, México, 2015. ISSN 1870-4069