



**INSTITUTO POLITÉCNICO NACIONAL
CENTRO DE INVESTIGACIÓN EN COMPUTACIÓN**



Selección de los colores esenciales de una imagen digital

T E S I S

Que para obtener el

Grado de Maestro en Ciencias de la Computación

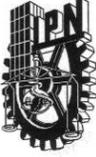
Presenta:

Sergio A. Márquez De Silva

Director de Tesis:

Dr. Edgardo M. Felipe Riverón

**México, D. F.,
Noviembre de 2008**



**INSTITUTO POLITECNICO NACIONAL
SECRETARIA DE INVESTIGACIÓN Y POSGRADO**

ACTA DE REVISIÓN DE TESIS

En la Ciudad de México, D.F. siendo las 18:07 horas del día 6 del mes de Mayo de 2008 se reunieron los miembros de la Comisión Revisora de Tesis designada por el Colegio de Profesores de Estudios de Posgrado e Investigación del:

Centro de Investigación en Computación

para examinar la tesis de grado titulada:

“SELECCIÓN DE LOS COLORES ESENCIALES DE UNA IMAGEN DIGITAL”

MÁRQUEZ

Apellido paterno

DE SILVA

materno

SERGIO ANTONIO

nombre(s)

Con registro:

A	0	6	0	5	2	7
---	---	---	---	---	---	---

aspirante al grado de: **MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN**

Después de intercambiar opiniones los miembros de la Comisión manifestaron **SU APROBACIÓN DE LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA

Presidente

Dr. Juan Humberto Sossa Azuela

Secretario

Dr. Oleksiy Pogrebnyak Boleslavovich

**Primer vocal
(Director de tesis)**

Dr. Edgardo Manuel Felipe Riverón

Segundo vocal

Dr. Jesús Guillermo Figueroa Nazuno

Tercer Vocal

Dra. Hind Taud

EL PRESIDENTE DEL COLEGIO

Dr. Jaime Álvarez Gallegos
DIRECCION



INSTITUTO POLITECNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESION DE DERECHOS

En la Ciudad de México el día 20 del mes Noviembre del año 2008, el (la) que suscribe Sergio Antonio Márquez De Silva alumno (a) del Programa de Maestría en Ciencias de la Computación con número de registro A060527, adscrito al Centro de Investigación en Computación, manifiesta que es autor (a) intelectual del presente trabajo de Tesis bajo la dirección de Edgardo Manuel Felipe Riverón y cede los derechos del trabajo intitulado Selección de los colores esenciales de una imagen digital, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección smarquez@ipn.mx. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

Sergio Antonio Márquez De Silva
Nombre y firma

RESUMEN

En este trabajo se presenta un nuevo algoritmo no supervisado para la cuantificación del color en las imágenes digitales. El propósito principal es que sobre la base de los colores que originalmente están presentes en la imagen, se obtenga una nueva imagen que cuente con un mínimo de los colores que denominamos esenciales que permitan conservar los objetos que componen la imagen original. El método se basa en crear regiones de color homogéneo sobre la base de un nivel de tolerancia que se calcula por la fórmula de la diferencia de color CIE2000 definida para el modelo de color $L^*a^*b^*$. Una consecuencia de los resultados logrados con el algoritmo es que el número final de colores depende de manera muy importante de las características propias del tipo de imagen, esto es, mientras más objetos independientes espacialmente de distinto color tenga la imagen, más colores finalmente arrojará el algoritmo. En este trabajo se demuestra que el método de cuantificación del color propuesto alcanza a definir de forma no supervisada, en dependencia del tipo de la imagen y la distribución de los colores en ella, aquellos colores esenciales que no alteran ostensiblemente las características de color de sus objetos principales. Otros métodos, al ser supervisados, dependen estrechamente del usuario para lograr este objetivo, ya sea mediante la selección manual de los colores esenciales por parte del usuario o mediante el pre-establecimiento de la cantidad de colores que el usuario desea tener en la imagen final.

Palabras clave: Cuantificación del color; Colores esenciales; Espacios de color; CIE2000; Mejoramiento de imágenes.

ABSTRACT

This paper presents a new unsupervised algorithm for the color quantization in digital images. The main goal is to obtain a new image with the essential colors on the base of the colors originally presented in the image, that is, that essential colors permit to preserve the items in the image with (nearly) their own original colors. The method is based on creating color homogeneous regions on the base of a level of tolerance computed by the formula of color difference CIE2000 defined for the color model $L^*a^*b^*$. A consequence of the results achieved by the algorithm is that the final number of colors depends significantly on the proper characteristics of the type of image, that is, the more spatially independent objects of different color in the image, the higher amount of colors produce finally the algorithm. In this thesis are demonstrate that the method of color quantization achieves in a unsupervised way, depending on the type of the image and the distribution of colors in it, results in those essential colors that do not alter ostensibly the most important items in the image. To be supervised, other methods depend very closely on the user to achieve this objective, either through the manual selection of the essential colors by the user or through the pre-setting of the total amount of colors that the user desires the final image to have.

Keywords: Color quantization; Essential colors; Color spaces; CIE2000; Image enhancement.

Dedicatoria

A mis compañeros de maestría Wandha, Iliach, Sergf, Yhabe, Miguel (N²) e Ismael por ser un equipo de éxito.

A mi asesor Edgardo por su gran dedicación a sus alumnos y empeño en su trabajo.

A mi amor, Cris, por empujarme hacia adelante y acompañarme en esta travesía.

A mi mamá Susy por heredarme su gusto por la educación y la enseñanza.

A Keny y Ángel por ser una razón para conseguir mis metas más altas.

A mi Papá por permitirme ser libre y tomar mis propias decisiones.

A mi mamá Nina por inculcarme el gusto a la lectura.

A mi mamá Nono por su infinito amor.

A Rocha por enseñarme a programar.

A Carl Sagan por ser mi inspiración.

A Rosita por cuidar de mi papá.

...Después de todo, cuando estás enamorado, quieres contarlo a todo el mundo. Por eso, la idea de que los científicos no hablen al público de la ciencia me parece aberrante

Carl Sagan

Agradecimientos

DIOS, Por que cumplir mis deberes para con Dios significa nunca olvidarse de Él y tenerlo presente en cada uno de mis actos. Siendo este trabajo un resultado de la salud y la fortaleza que Él me ha dado.

PATRIA, Por abrir los caminos para que pudiera recibir la educación académica a través del Centro de Investigación en Computación del Instituto Politécnico Nacional. Presento este trabajo al servicio de mi patria.

HOGAR, En que otro lugar podría encontrar el amor y la comprensión necesaria para enfrentar las adversidades de la vida y así poder luchar día a día; sino es en mi hogar, con mi familia. La razón de seguir adelante.

Contenido

1	Definición del problema	1
1.1	Introducción	1
1.2	Objetivos	3
1.2.1	Objetivo general	3
1.2.2	Objetivos específicos	3
1.3	Planteamiento del problema	3
1.4	Colores esenciales	4
1.5	Tipos de imágenes	5
1.6	Justificación	9
1.7	Contenido de la tesis	10
2	Conceptos y definiciones	11
2.1	Introducción	11
2.2	Espacios de color	13
2.3	Fundamentos de la visión del color	14
2.4	Modelos de color	15
2.5	Fórmula de diferencia de color CIE2000	19
2.6	Cuantificación del color	20
2.7	Métodos basados en la optimización iterativa	23
2.7.1	Algoritmo K-medias (<i>K-means</i>)	23
2.7.2	Algoritmo K - medias difuso (<i>Fuzzy K-means</i>)	24
2.8	Métodos heurísticos	26
2.8.1	Algoritmo de Popularidad (<i>Popularity</i>)	27
2.8.2	Algoritmo de Corte de Mediana (<i>Median-Cut</i>)	28
2.8.3	Algoritmo <i>Octree</i>	29
2.8.4	Algoritmo de Componentes Principales	30
2.9	Métodos de cuantificación escalar	30
2.9.1	Cuantificación uniforme	31
2.9.2	Cuantificación de mínima varianza	31
2.9.3	Métodos basados en la cuantificación escalar mejorada	32
2.10	Reconstrucción	33
2.10.1	Indexación	33
2.10.2	Difuminado (<i>Dithering</i>)	34
3	Metodología propuesta	37
3.1	Introducción	37
3.2	Descripción	38
3.2.1	Conversión del espacio RGB al espacio $L^*a^*b^*$	38
3.2.2	Generación de regiones de color similares	39
3.2.3	Elección de los colores esenciales	40
3.2.4	Conversión de la paleta de colores del espacio $L^*a^*b^*$ al espacio RGB	40
3.3	Justificación del nivel de tolerancia seleccionado	41
3.4	Interfaz gráfica desarrollada	44

3.5	Descripción de la aplicación	44
3.6	Procedimiento detallado de la metodología propuesta	50
4	<i>Evaluación de los resultados</i>	51
4.1	Introducción	51
4.2	Análisis según los colores obtenidos	58
4.3	Cantidad de colores vs. Cantidad de regiones	70
4.4	Comparación con otros algoritmos.....	76
4.5	Discusión de los resultados	97
4.6	Desempeño de los métodos de cuantificación del color.....	100
5	<i>Conclusiones</i>	105
5.1	Resultado colateral: Segmentación de imágenes	106
5.2	Resultado colateral: Compresión de imágenes.....	108
5.3	Aportes y contribuciones.....	110
5.4	Trabajo futuro	110
5.5	Recomendaciones	111
	<i>Referencias</i>	113

Lista de figuras

Fig. 1 Esquema del proceso de cuantificación.....	2
Fig. 2 Mapa de México.....	2
Fig. 3 Mandril con insectos en la nariz.....	5
Fig. 4 Espectro de luz visible.....	14
Fig. 5 Absorción espectral (normalizada) de los conos.....	14
Fig. 6 Elipses de MacAdam.....	18
Fig. 7 Valores de iluminantes según la fuente de luminancia.....	18
Fig. 8 Energía relativa de los iluminante D65 y F2.....	18
Fig. 9 Energía relativa del iluminante D50.....	18
Fig. 10 Ampliación del ojo izquierdo de la imagen Mandril.....	22
Fig. 11 Cubo de colores RGB.....	27
Fig. 12 Ejemplo de cuantificación uniforme para el plano $R = 0$ del cubo de colores RGB.....	31
Fig. 13 Ejemplo de cuantificación de mínima varianza para el plano $R = 0$ del cubo RGB.....	31
Fig. 14 Imagen reconstruida a la izquierda por indexación y a la derecha por difuminado.....	33
Fig. 15 Espacio CIE $L^*a^*b^*$	39
Fig. 16 Etapas de la metodología propuesta.....	41
Fig. 17 Imagen regionalizada.....	42
Fig. 18 Icono de la aplicación.....	46
Fig. 19 Ventana principal con imagen.....	46
Fig. 20 Ventana de análisis de imagen.....	46
Fig. 21 Ventanas auxiliares de los comandos Flip/Rotate, Stretch y Operations.....	49
Fig. 22 Ventana de ampliación de 25 x 25 pixeles.....	49
Fig. 23 Histogramas generados.....	49
Fig. 24 Ventana auxiliar de la metodología propuesta.....	49
Fig. 25 Bloque 1 "Color".....	53
Fig. 26 Bloque 2 "Otras".....	54
Fig. 27 Bloque 3 "Picasso".....	55
Fig. 28 Bloque 4 "Memorama".....	56
Fig. 29 Bloque 5 "Rayos X".....	57
Fig. 30 Bloque 6 "Rostros".....	57
Fig. 31 Tolerancia vs. Cantidad de colores. Bloque 1: Color.....	59
Fig. 32 Tolerancia vs. Cantidad de colores. Bloque 2: Otras.....	59
Fig. 33 Tolerancia vs. Cantidad de colores. Bloque 3: Picasso.....	60
Fig. 34 Tolerancia vs. Cantidad de colores. Bloque 4: Memorama.....	60
Fig. 35 Tolerancia vs. Cantidad de colores. Bloque 5: Rayos X.....	61
Fig. 36 Tolerancia vs. Cantidad de colores. Bloque 6: Rostros.....	61
Fig. 37 Imágenes ordenadas por su cantidad de colores encontrados (parte 1).....	65

<i>Fig. 38 Imágenes ordenadas por su cantidad de colores encontrados (parte 2).</i>	66
<i>Fig. 39 Imágenes ordenadas por la cantidad de colores final con que quedaron (parte 3)</i>	67
<i>Fig. 40 Imágenes del jitomate con su PC.</i>	68
<i>Fig. 41 Imágenes de la rosa con su PC.</i>	68
<i>Fig. 42 Imágenes de la pera con su PC.</i>	69
<i>Fig. 43 Imagen con las tres cartas del Memorama y su PC.</i>	69
<i>Fig. 44 Colores/Regiones vs. Tolerancia. Bloque 1: Color.</i>	71
<i>Fig. 45 Colores/Regiones vs. Tolerancia. Bloque 2: Otras.</i>	72
<i>Fig. 46 Colores/Regiones vs. Tolerancia. Bloque 3: Picasso.</i>	73
<i>Fig. 47 Colores/Regiones vs. Tolerancia. Bloque 4: Memorama.</i>	74
<i>Fig. 48 Colores/Regiones vs. Tolerancia. Bloque 5: Rayos X.</i>	75
<i>Fig. 49 Colores/Regiones vs. Tolerancia. Bloque 6: Rostros.</i>	75
<i>Fig. 50 Comparación de los resultados con las imágenes del primer bloque "Color".</i>	81
<i>Fig. 51 Comparación de los resultados con las imágenes del segundo bloque "Otras".</i>	86
<i>Fig. 52 Comparación de los resultados con las imágenes del tercer bloque "Memorama".</i>	88
<i>Fig. 53 Comparación de los resultados con las imágenes del cuarto bloque "Picasso".</i>	91
<i>Fig. 54 Comparación de los resultados con las imágenes del quinto bloque "Rayos X".</i>	93
<i>Fig. 55 Comparación de los resultados con las imágenes del sexto bloque "Rostros".</i>	97
<i>Fig. 56 Comparación de los resultados obtenidos por CIESE. Bloque "Color".</i>	100
<i>Fig. 57 Comparación de los resultados obtenidos por CIESE. Bloque "Otras".</i>	101
<i>Fig. 58 Comparación de los resultados obtenidos por CIESE. Bloque "Memorama".</i>	101
<i>Fig. 59 Comparación de los resultados obtenidos por CIESE. Bloque "Picasso".</i>	101
<i>Fig. 60 Comparación de los resultados obtenidos por CIESE. Bloque "Rayos X".</i>	101
<i>Fig. 61 Comparación de los resultados obtenidos por CIESE. Bloque "Rostros".</i>	102
<i>Fig. 62 Segmentaciones de objetos de interés en 4 imágenes, empleando el método propuesto.</i>	107

Lista de tablas

<i>Tabla 1 Categorías y métodos de cuantificación.....</i>	<i>22</i>
<i>Tabla 2 Cantidad de colores originales y obtenidos para los bloques 1 y 2.....</i>	<i>62</i>
<i>Tabla 3 Cantidad de colores originales y obtenidos para los bloques 3, 4, 5 y 6.....</i>	<i>63</i>
<i>Tabla 4 Valores estadísticos de la cantidad de colores obtenidos por bloque.....</i>	<i>64</i>
<i>Tabla 5. Nivel de tolerancia "óptimo" por cada bloque.....</i>	<i>76</i>
<i>Tabla 6 Análisis de los valores CIESE.....</i>	<i>102</i>
<i>Tabla 7 Valores CIESE obtenidos.....</i>	<i>102</i>
<i>Tabla 8 Comparación de la compresión en los bloques de imágenes (ZIP).</i>	<i>109</i>
<i>Tabla 9 Comparación de la compresión en archivos individuales de imágenes (PNG).</i>	<i>109</i>

Glosario de términos

A continuación se definen algunos términos según el uso particular que se le da en el presente trabajo, con el único fin de ayudar a su mejor comprensión. Salvo que se señale explícitamente, no constituyen definiciones académicas.

Número total de colores.

Suma global de los colores que aparecen en la imagen digital, que al menos se diferencian en una de sus componentes RGB.

Paleta de colores (PC).

Conjunto de colores con los que se pretende recrear una imagen. Este conjunto puede ser un subconjunto de los colores originales de la imagen o colores seleccionados por algún algoritmo de cuantificación estático o dinámico.

Color esencial.

Color que al no incluirse en la paleta de colores, se estima que la imagen generada carecerá de información para identificar los objetos que la componen.

Cuantificación Selectiva.

Sistema de cuantificación de colores de imágenes digitales originado con los resultados del presente trabajo, basado en la generación de regiones dentro de la imagen que cumplen el criterio de diferencia de color establecido entre los píxeles. Y un posterior análisis de los colores de las regiones encontradas para generar la paleta de colores final.

Métrica CIE2000.

Formula recomendada por la comisión internacional del color en el año 2000 para diferencia colores dentro del espacio $L^*a^*b^*$.

1 Definición del problema

1.1 Introducción

La cuantificación del color consiste en reducir el número de colores de una imagen digital con un mínimo de alteración visual de la misma. Una imagen de color verdadero, con 24 bits/píxel, tiene $2^{24} = 16\,777\,216$ colores diferentes. Estos colores son representados por un vector con tres componentes independientes con un rango dinámico de 8 bits cada una, lo que brinda $2^8 = 256$ colores diferentes por componente. Este vector describe el espacio de color RGB (Red-Green-Blue) tan frecuentemente utilizado. Se le llama paleta de colores (PC) de una imagen al conjunto de todos los colores que se utilizan para generarla. El objetivo de la cuantificación del color es realizar una transformación entre una imagen de color real y una imagen definida por una paleta de colores (imagen indexada) [Domanski y Bartkowiak, 1998] [Jain y Pratt, 1972]. Esto aparece esquematizado en la Fig. 1. El proceso de la cuantificación del color en una imagen consta básicamente de dos pasos:

- 1) Creación de la paleta de colores.
- 2) Asignación de un color de la paleta a cada píxel de la imagen.

Dada una imagen en colores cualquiera, se buscará un sub-conjunto de colores de ésta para crear la paleta de colores con los que posteriormente se remplazará el

Capítulo 1 *Definición del problema*

color de cada píxel de la imagen original. La cuantificación del color también se ha utilizado como una operación de compresión de imágenes.

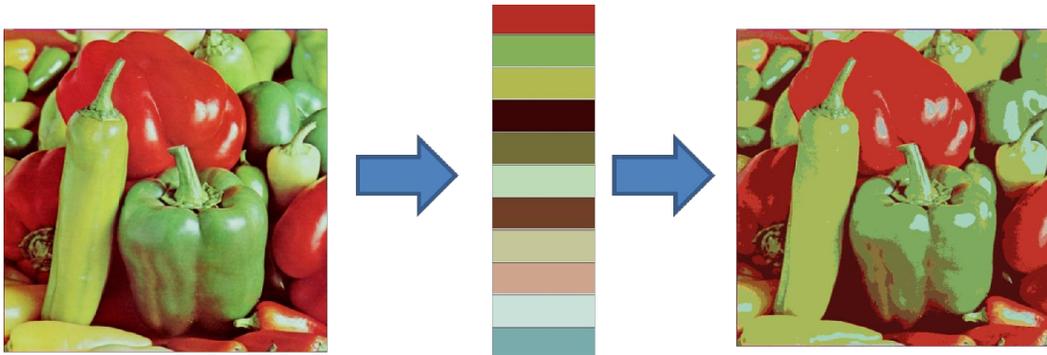


Fig. 1 Esquema del proceso de cuantificación.

Hasta hace poco, la cuantificación del color fue usada para reproducir imágenes de 24 bits en dispositivos de hardware con un número limitado de colores. Aunque los dispositivos de hardware que soportan 24 bits son cada vez más comunes, la cuantificación del color todavía conserva su valor práctico. Con ella se reducen las necesidades de espacio para el almacenamiento de datos de la imagen y los requisitos de ancho de banda en la transmisión de aplicaciones multimedia. Esto se puede considerar como un paso de la etapa de preprocesamiento dentro del análisis de imágenes digitales. En imágenes como la mostrada en la Fig. 2, la que cuenta con una gran cantidad de objetos gráficos, estos pueden ser fácilmente descritos por sus colores esenciales.



Fig. 2 Mapa de México.

Capítulo 1 *Definición del problema*

La tarea de segmentar y/o reconocer los diferentes objetos en la imagen, se facilita drásticamente al regenerarla con una paleta de colores adecuadamente seleccionada.

1.2 Objetivos

El objetivo general y los objetivos específicos que se pretenden lograr en este trabajo son:

1.2.1 Objetivo general

Desarrollar una metodología para la selección de los colores esenciales de una imagen digital en colores, entendiendo como tales aquellos colores que son suficientes para regenerar la imagen sin pérdida del color de los objetos representativos que la componen.

1.2.2 Objetivos específicos

Los objetivos específicos son los siguientes:

- Asimilar la teoría referente al color.
- Asimilar la teoría concerniente a la cuantificación del color.
- Investigar y analizar los distintos algoritmos de cuantificación del color existentes.
- Proponer un algoritmo no supervisado de cuantificación del color.
- Implementar una interfaz gráfica que nos permita trabajar con el algoritmo propuesto y con otros procedimientos de tratamiento de imágenes.
- Validar los resultados.

1.3 Planteamiento del problema

La mayoría de los métodos de cuantificación del color se basan en la distribución estadística de los colores en la imagen (histogramas), donde los colores más predominantes tienden a ser seleccionados y los menos frecuentes a ser descartados. Si bien esto es cierto en la mayoría de los casos, esta consideración en imágenes como la mostrada en la Fig. 2 puede causar pérdida de información, como es el caso del amarillo (color representativo del símbolo plátano) en comparación con el color azul del océano y el café de la tierra. Si por aparecer este color en una cantidad insignificante en la imagen completa éste es descartado,

Capítulo 1 *Definición del problema*

esto conllevaría la omisión de un dato tan importante para el símbolo del plátano en el mapa como es su color. Partiendo de esta necesidad, se ha tratado que el algoritmo propuesto analice las imágenes de tal forma que conserve la mayoría de los colores que tienen una importancia significativa en la descripción de los objetos que aparecen en las mismas.

1.4 Colores esenciales

Para lograr que una paleta de colores cumpla con las características mencionadas, ésta debe estar compuesta por los llamados *colores esenciales* de la imagen. Entendemos en nuestro trabajo como *colores esenciales* de una imagen digital en colores, aquellos colores que poseen matices que de no existir en la misma, darían lugar a que la imagen careciera de algún significado u objeto de importancia que la distingue.

En ocasiones, estos matices se hacen corresponder con términos tales como “colores dominantes” o “colores representativos”. Sin embargo, la equivalencia semántica no es del todo cierta, pues los colores dominantes nos llevan a pensar en los matices de los píxeles más frecuentes, es decir, que ocupan mayores zonas de la imagen, y los colores representativos en los colores que más distinguen a determinados objetos en la misma (y no a la imagen como un todo), según el tipo de imagen, que de no existir la hacen lucir deficiente, algo anormal o poco natural.

En la imagen del mandril (Fig. 3), por ejemplo, los colores esenciales son el de los ojos (anaranjado), el del pelambre (verdoso), el de los pelos de la barbilla (blanco), etc. Los representativos son aquellos colores que, de cambiar, impiden reconocer que la imagen como un todo es la de un mandril (los matices azules del belfo superior o el rojo de la nariz).

Un color esencial puede no estar incluido entre los colores dominantes o entre los colores representativos de una imagen.

Un color esencial no debe alterarse sensiblemente en la imagen, pues con seguridad sufriría cambios en los objetos que la distinguen (objetos que desaparecen, objetos que se fusionen con otros, etc.). Sin embargo, los colores dominantes y representativos pueden variar en alguna medida, sin perder significado la imagen como un todo.

Los colores dominantes pueden estar o no relacionados con los objetos de la imagen o con la representación de la imagen en sí. Los esenciales sí están íntimamente relacionados con los objetos de la imagen, y por lo tanto, con la representación de la imagen en sí.

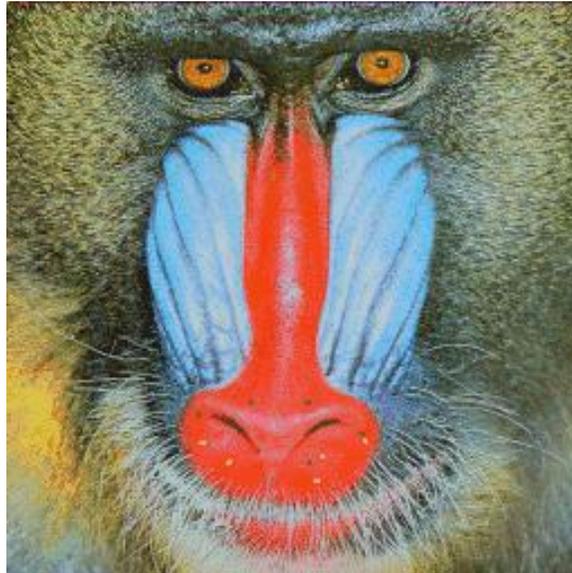


Fig. 3 Mandril con insectos en la nariz.

Es posible que un color esencial sea también representativo, pero puede ser que no sea dominante. Los colores representativos sí pueden considerarse como esenciales (nariz roja del mandril), pero los esenciales puede ser que no sean representativos (como el de los ojos del mandril).

Supongamos que el mandril tuviera como objeto un insecto o una afección (picada de insecto) de color verde en la nariz roja. Si al reducir el número de colores de la imagen estos desaparecen, consideramos que ese color no era esencial. Si se mantiene, sí era esencial. El insecto con su color verde no sería ni dominante (por ser de pequeño tamaño y poco frecuente), ni representativo, pues el mandril no deja de ser mandril o de tener su nariz roja, aunque el insecto haya desaparecido de la imagen. Sin embargo, es muy probable que por su importancia, sea imprescindible en este caso no dejar de ver el insecto o la afección en la nariz del mandril, aunque se reduzca el número de los colores de la imagen.

1.5 Tipos de imágenes

Dado que pretendemos que el algoritmo que se propone sea de carácter general, se ha revisado y analizado su eficiencia y efectividad con diferentes tipos de imágenes, ya que se ha detectado que los algoritmos de cuantificación tienen diferentes comportamientos al aplicarlos a diferentes tipos de imágenes.

Capítulo 1 *Definición del problema*

Todas las imágenes de la siguiente clasificación se considerarán digitales, rectangulares, bidimensionales, de diverso tamaño y diferentes resoluciones espaciales y de niveles, en colores o en blanco y negro e impresas en semitonos o continuas, provenientes de escáner, la Web o cámaras fotográficas digitales. Todas, como es común, vienen acompañados de ruido aditivo en los tres planos de color y son de 24 bit/píxel.

Las imágenes con características distinguibles muy diferentes, detalladas de menor a mayor complejidad, las hemos clasificado en los tipos siguientes:

1. Textos;
2. Caricaturas;
3. Publicitarias;
4. Pinturas;
5. Mapas;
6. Naturales.

Las características particulares de cada tipo de imagen son las siguientes:

1. Textos. Comprende aquellas imágenes con pocos detalles (objetos), pocos niveles de gris y pocas variaciones entre ellos, aunque con buen contraste de los objetos respecto al fondo. Están compuestas fundamentalmente por caracteres y símbolos alfanuméricos, pero pueden tener gráficas, tablas, firmas, figuras. Pueden ser en blanco y negro o en colores y en general los objetos no están solapados. Los caracteres y símbolos pueden provenir de distintas fuentes, ser de diferentes formas y tamaños, de trazos finos o gruesos y tener estilos de letras diferentes (negrillas, versalitas (*italics*) y otras).

Características de los objetos. Normalmente provienen de escáneres y fotografías digitales. Tienen poco ruido, normalmente del tipo aditivo. En determinadas situaciones, los textos pueden ser de distinto color, ordenados en una estructura espacial dada y estar dentro de un fondo más complejo, ya sea en colores o en blanco y negro.

Características principales de la imagen. Pocos detalles, pocos niveles, muchos objetos y dentro de uno o pocos fondos de nivel o color homogéneo.

Mayor dificultad. El número de objetos, el pequeño tamaño de algunos de ellos y la puntuación de algunos símbolos, los que a menudo llevan un punto cuyo tamaño puede ser hasta de un solo píxel.

Capítulo 1 *Definición del problema*

2. Caricaturas. Son imágenes en general compuestas por relativamente pocos colores y niveles, con buen contraste, en colores o en niveles de gris, o simplemente sin color compuestas solo por el contorno de los objetos. Los colores pueden aparecer en semitonos o sólidos, casi siempre sin variaciones de tonalidad. Pueden tener ruido aditivo, aunque imperceptible a primera vista. Los colores contiguos son separados por una línea que los divide, la que puede considerarse como el contorno de las diversas regiones que componen los objetos. Pueden tener un fondo más o menos extenso de un solo matiz o nivel. Si provienen de materiales impresos, están en semitonos; si provienen de computadoras, son de colores sólidos.

Características de los objetos. Tienen pocos objetos independientes, no solapados, con colores diferentes, en general convexos, de poca variabilidad en formas y tamaños y dispuestos en forma aleatoria en la imagen.

Características principales de la imagen. Más detalles y más niveles que en los textos, un menor número de objetos de tamaño y forma variados, de colores sólidos y eventualmente con un fondo de pocos matices diferentes.

Mayor dificultad. Ninguna.

3. Publicitarias. Son imágenes compuestas por gran cantidad de texto y objetos de diversa índole y característica; en ocasiones en presencia de dibujos de personas, rostros u objetos utilitarios (sillas, computadoras, etc.). La mayor parte de las veces están impresas en semitonos en colores. Pueden tener muchos detalles, sombras y reflejos (eventualmente), perspectivas, colores y con un fondo de un matiz constante que puede ocupar la mayor parte de la imagen.

Características de los objetos. Tienen muchos objetos independientes, en ocasiones solapados, con colores diferentes, compuestos de trazos finos, de gran variabilidad en las formas y tamaños y dispuestos aleatoriamente en la imagen según un contexto en particular.

Características principales de la imagen. Impresas en semitonos en colores, cantidad media de detalles y objetos, con un fondo de matiz constante y muy contrastante con los objetos que contiene.

Mayor dificultad. La combinación de caracteres con un gran número de objetos convexos y la impresión en semitonos en colores.

4. Pinturas. Son imágenes generalmente en colores, con muchos detalles (objetos) y con buen contraste en toda su extensión. Pueden tener sombras, con zonas más oscuras y zonas más claras, compuestas siempre de muchos matices y

Capítulo 1 *Definición del problema*

colores con diversas saturaciones, y fondos con niveles poco constantes. Como normalmente las pinturas constituyen obras hechas por el hombre de objetos presentes en la vida real, pueden tener mayor o menor naturalidad y complejidad. Los objetos pueden aparecer algo difusos y poco delimitados.

Características de los objetos. Tienen muchos objetos independientes, en ocasiones solapados, con colores diferentes, cóncavos o convexos, de mucha variabilidad en formas y tamaños y dispuestos en forma aleatoria en la imagen según un contexto en particular.

Características principales de la imagen. Muchos detalles, muchos matices diferentes y colores con diversas saturaciones, con buen contraste y con objetos algo difusos y poco delimitados.

Mayor dificultad. El número de objetos finos y cóncavos, además de la dispersión de los colores.

5. Mapas. Son imágenes artificiales e impresas en semitonos en colores. Pueden estar formadas por una gran diversidad de patrones gráficos, líneas de diversos tipos y caracteres alfanuméricos, sobrepuestos en fondos de diversos colores más o menos constantes.

En principio, deben tener pocos colores, pero por ser impresos en semitonos y en capas sobrepuestas, a veces en número de 7 u 8, un mismo patrón puede aparecer con píxeles de diversos colores producto de la parte del mapa donde fue impreso. Por lo tanto, patrones iguales pueden aparecer con formas y distribuciones de colores muy diferentes. Son imágenes planas, sin sombras y con objetos poco delimitados.

Características de los objetos. Tienen muchos objetos independientes, en ocasiones yuxtapuestos, compuestos de varios colores diferentes, de trazos finos y en general convexos, con líneas de diferentes tipos y colores, de poca variabilidad en formas y tamaños, en fondos de diferentes colores y dispuestos en forma aleatoria en la imagen según un contexto en particular.

Características principales de la imagen. Gran cantidad de colores producto de la forma de impresión (por capas y en semitonos), con objetos poco delimitados, siempre sobre fondos de colores más o menos constantes y pocos matices. Presentan muchos detalles, pero asociados a relativamente pocos objetos. Son imágenes planas por excelencia (sin sombras).

Mayor dificultad. La presencia de pocos colores que corresponden al 80% de los píxeles de la imagen total (océanos, tierra, bordes, etc.), con el 20% de los colores

Capítulo 1 *Definición del problema*

restantes dedicados a la información detallada del mapa, a los diferentes tipos y número de los objetos, además de la impresión en semitonos.

6. Naturales. Son imágenes que pueden ser muy complejas por la diversa cantidad y diversidad de los objetos que pueden estar presentes en ellas, con sombras y brillos, con gran variabilidad de niveles y con diversas gradaciones en las tonalidades de los colores orientadas en todas las direcciones. Tienen muchos detalles, todos de importancia. Los fondos pueden ser variados, casi nunca con matices constantes. Pocas veces presentan textos o caracteres alfanuméricos.

Pueden presentar zonas más claras y zonas menos claras, con contraste variable entre los objetos en dependencia de donde están situados en la imagen. Pueden estar formadas por rostros humanos, animales, paisajes, naturalezas muertas, etc. o combinaciones de ellos. A su vez, eventualmente, pueden incluir pinturas, fotos y material publicitario. Las imágenes pueden tener un gran número de colores con diversos matices y saturaciones.

Características de los objetos. Tienen muchos objetos independientes, en ocasiones yuxtapuestos, con gradación de colores, de trazos finos (cabellos, hojas, hierbas, etc.) y en general convexos, de diferentes tipos y colores, de mucha variabilidad en formas y tamaños, en fondos de diferentes colores y texturas y dispuestos en forma aleatoria en la imagen.

Características principales de la imagen. Gran número de colores con diversos matices y saturaciones, con gradaciones de gran importancia asociadas a su naturalidad, con sombras, reflejos, inmensa cantidad de detalles y objetos de diversas formas, tamaños, perspectivas y disposición relativa de unos objetos respecto a otros. Generalmente tienen relativamente pocas zonas de matices constantes.

Mayor dificultad. Los degradados del color de los innumerables objetos y la diversidad de formas y tamaños de los mismos.

1.6 Justificación

Hoy en día, la creciente incorporación de imágenes a los sistemas de cómputo y de comunicaciones ha propiciado que la capacidad de los medios de almacenamiento y de la transmisión de datos, se incrementen sustancialmente para cubrir los requerimientos implícitos al manejar gran cantidad de imágenes y desde luego videos. Las actividades empresariales e industriales también tienen una alta demanda de análisis de imágenes para reconocer objetos y defectos en los mismos, ya sea por su forma, color, tamaño, etc.

Capítulo 1 *Definición del problema*

Aplicaciones cada vez más difundidas en Internet como la de manejo de mapas satelitales, de relieve (curvas de nivel), o simplemente geográficos, han hecho que el procesamiento de imágenes tome un nuevo giro y se enfoque cada vez más en el estudio del color. Un método que ayude a definir de forma no supervisada la cantidad y calidad de los colores fundamentales que conforman los objetos que contiene la imagen de manera general para cualquier tipo de imágenes, será de gran ayuda para las tareas de compresión de imágenes sin pérdida significativa y para el reconocimiento de objetos en las imágenes.

1.7 Contenido de la tesis

Esta tesis ha sido preparada de una manera didáctica. Su contenido general se detalla a continuación.

En el Capítulo 2 se hace una pequeña introducción al mundo del color y de su cuantificación. La primera sección del capítulo está orientada hacia la descripción física del color y a los mecanismos que el sistema visual humano utiliza para su percepción. Se describen, además, los dos principales mecanismos del cerebro utilizados para codificar la información del color de los objetos, junto con las principales características de la percepción del color. Posteriormente, se exponen varios conceptos relacionados con el trabajo, tales como los espacios de color, donde hacemos énfasis en el modelo $L^*a^*b^*$ por ser el espacio de color elegido para demostrar la efectividad del algoritmo, así como por la métrica de diferenciación del color que se emplea. Este capítulo lo concluimos con una descripción de los algoritmos comúnmente utilizados en la actualidad para la cuantificación del color, de los cuales algunos de ellos fueron elegidos para hacer comparaciones con respecto al algoritmo propuesto. En el Capítulo 3 se explica la metodología propuesta, primeramente mediante el diagrama de bloques general del que se detalla cada una de las etapas y su justificación. Al final del capítulo se muestra la herramienta gráfica (interfaz) que se ha desarrollado en *Borland C++ Builder*, Versión 7 y con la cual se hicieron todos los experimentos. El Capítulo 4 fue dedicado exclusivamente a la evaluación de los resultados logrados con el algoritmo propuesto, comparándolo a su vez con algunos de los algoritmos ya presentados en el capítulo 2. Siempre se trató de evaluar los resultados con todos los tipos de imágenes posibles según la clasificación expuesta en el capítulo anterior (1.5). Para esto consideramos determinados criterios que analizan la imagen desde el punto de vista de su calidad perceptual, junto con comentarios puntuales acerca de lo observado en los resultados logrados. Finalmente, se muestra un apartado donde se explica la utilidad de la herramienta creada para los propósitos de compresión de imágenes, reconocimiento de objetos y de su segmentación. El último capítulo está dedicado a las conclusiones y a los trabajos futuros relacionados con el desarrollo hecho.

2 Conceptos y definiciones

Resumen. En este capítulo se expone un breve estado del arte y las definiciones y conceptos en los que está basado el algoritmo desarrollado en esta tesis.

2.1 Introducción

El primer paso crucial en el análisis de imágenes consiste generalmente en segmentar la imagen. La segmentación subdivide la imagen en sus partes constituyentes, que se denominan regiones o segmentos. El nivel al que se lleva a cabo esta subdivisión depende del problema a resolver. Esto es, la segmentación deberá detenerse cuando los objetos de interés de una aplicación hayan sido completamente aislados.

En general, la segmentación autónoma es una de las tareas más difíciles del procesamiento de imágenes, y a su vez, determina el éxito o el fracaso del análisis. Por tanto, habrá que intentar obtener resultados satisfactorios en esta etapa [González y Woods, 2008].

Capítulo 2 *Conceptos y definiciones*

La segmentación de las imágenes es un proceso muy importante de la percepción visual humana. Las personas utilizan su sentido de la visión para particionar (segmentar) su entorno en diferentes objetos. Es un proceso complicado que implica un análisis del color, la forma, el movimiento, la textura, etc. de los objetos en la imagen. Sin embargo, para el sistema visual humano este proceso es espontáneo y natural. Desafortunadamente, no es fácil crear algoritmos cuyas prestaciones sean comparables a las del sistema visual humano.

El mayor obstáculo para el éxito de dichos algoritmos está en que realmente el sistema visual humano utiliza métodos subconscientes para segmentar [Plataniotis y Venetsanopoulos, 2000].

Idealmente los investigadores intentan encontrar la técnica universal para la segmentación que sirva para cualquier tipo de imágenes. Esto, si no imposible, puede ser, al menos, un trabajo de toda una vida. En general, los investigadores se suelen centrar en un número limitado de aplicaciones que comparten una serie de características, de forma que los métodos que desarrollan suelen funcionar bien sólo para dichas aplicaciones.

En la etapa de la segmentación de imágenes, es común llevar a escala de grises o a una imagen binaria las imágenes a tratar para su procesamiento posterior. Sin embargo, con las nuevas aplicaciones como las bases de datos multimedia, fotografías digitales y procesamiento de datos visuales de Internet, el proceso de la segmentación normalmente trata de preservar la información contextual que brinda el color en las imágenes.

En la literatura ha sido reportado un gran número de algoritmos de segmentación del color distintos y cada día aparecen nuevos. Los diferentes métodos de segmentación utilizan técnicas básicas de procesamiento de imágenes, tales como el filtrado y la cuantificación del color.

Los primeros trabajos de investigación sobre imágenes digitales en colores se remontan a principios de los años 80 y fueron debidos a [Tenenbaum, 1975], [Kender, 1976] y [Sangwine y Horne, 1998]. Entonces, se disponía de muy poca memoria de computador y los avances eran lentos. En los últimos años se ha experimentado un gran avance en los equipos de cómputo, lo que ha permitido el procesamiento de imágenes de color de forma rápida y sencilla.

En las secciones siguientes se presentan los conceptos básicos de colorimetría y las transformaciones de espacios de color más significativas para facilitar el análisis del color en nuestra aplicación específica.

2.2 Espacios de color

Con el fin de utilizar el color en el procesamiento de imágenes, se necesita contar con un método apropiado para su representación. Se han desarrollado diferentes sistemas o espacios de color para cubrir esta necesidad. Los espacios de color proporcionan un método racional para especificar el orden, manipular y visualizar de manera efectiva los colores de los objetos tomados en consideración.

La elección del espacio del color depende de un conocimiento previo de la información que nos es útil del color para la aplicación a desarrollar, con el fin de discriminar los colores, agruparlos, indexarlos, compararlos, etc.

Los espacios de color son normalmente espacios tridimensionales por el hecho de que nuestra percepción del color es tricromática. Los diferentes espacios se diferencian en la elección del sistema de coordenadas. En la literatura clásica, pueden distinguirse cuatro familias de modelos de color [Plataniotis y Venetsanopoulos, 2000]:

- a) Modelos colorimétricos. Basados en medidas físicas de la reflectancia espectral. Suelen trabajar con tres filtros de colores primarios y un fotómetro, dando lugar a un diagrama de cromaticidad CIE¹.
- b) Modelos psicofísicos. Fundamentados en la percepción humana del color. Estos modelos se basan en criterios subjetivos de observación y modelos de referencia, como por ejemplo, el modelo de color Munsell [Munsell, 1905], o bien se construyen a partir de experimentos que cumplan con la percepción humana del color, como la familia HSL (*Hue*-Tono, *Saturation*-Saturación y *Luminosity*-Luminosidad); HSV (*Hue*-Tono, *Saturation*-Saturación y *Value*-Valor); HSI (*Hue*-Tono, *Saturation*-Saturación e *Intensity*-Intensidad), L*a*b* (*Luminosity*-Luminosidad y dos canales de cromaticidad), etc.
- c) Modelos fisiológicos. Basados en los tres colores primarios (los tres tipos de conos de la retina humana). El más conocido es el espacio de color RGB (*Red*-Rojo, *Green*-Verde, *Blue*-Azul) utilizado en el hardware de las computadoras y en la televisión en colores.
- d) Modelos de colores contrapuestos. Hacen uso de parejas de colores primarios opuestos entre sí, como el amarillo-azul o el rojo- verde.

¹ CIE: *Commission Internationale de L'Eclairage* - Comisión Internacional de la Iluminación.

2.3 Fundamentos de la visión del color

El color es una sensación creada en respuesta a la excitación del sistema visual humano por las radiaciones electromagnéticas conocidas como luz [González y Woods, 2008]. Específicamente, el color es el resultado perceptivo de la luz en la región visible del espectro electromagnético, con longitudes de onda que van de los 380nm a los 780nm², al incidir sobre la retina del ojo humano. La potencia o radiación de la luz incidente se representa en una distribución espectral de potencia, a menudo dividida aproximadamente en 31 componentes, cada una representativa de una banda de 10nm (Fig. 4) [Sharma y Trussel, 1997].

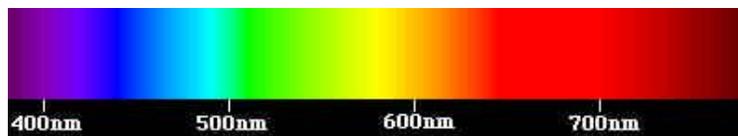


Fig. 4 Espectro de luz visible.

La retina humana posee tres tipos diferentes de células fotorreceptoras del color denominadas conos, que responden a la radiación según distintas curvas espectrales [Wyszecky y Stiles, 1982]. Existe un cuarto tipo de células receptoras, llamadas bastones, que son efectivas en condiciones de muy poca luz. Como son importantes solamente para la visión nocturna, los bastones no se utilizan a la hora de reproducir una imagen en colores en un dispositivo de representación [Plataniotis y Venetsanopoulos, 2000]. La colorimetría se ocupa de la descripción y especificación adecuada del color. Dado que existen tres tipos de conos fotorreceptores, parece adecuado representar al color con tres componentes numéricas. La sensibilidad “probable” normalizada de los receptores, de acuerdo con Hunt [Hunt, 1995], se muestra en la Fig. 5.

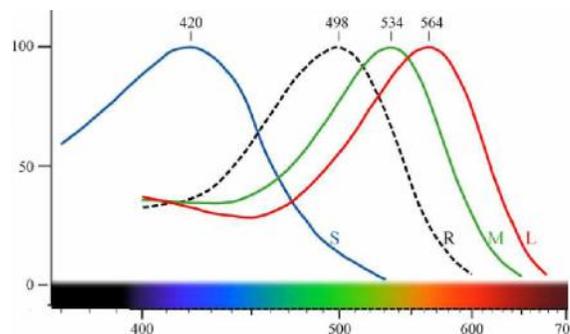


Fig. 5 Absorción espectral (normalizada) de los conos.

² Un nanómetro (nm) es igual a 10^{-9} metros.

De esta forma se obtiene el espacio de color, que puede definirse como el conjunto de todos los colores, cada uno de ellos especificado mediante un vector tridimensional [Wyszecky y Stiles, 1982]. Según la definición de cada una de las componentes se derivarán distintos espacios de color.

En el tratamiento del color existen algunos parámetros básicos cuyas definiciones se presentan a continuación [Plataniotis y Venetsanopoulos, 2000] [Poynton, 1999]:

- a) Intensidad (I). Es una medida, sobre una parte del espectro electromagnético, del flujo de potencia radiado desde una superficie, o incidente en ella, y se expresa en unidades de vatios por metro cuadrado.
- b) Brillo (Br). Es un atributo relacionado con la sensación visual de que un área parezca que emite más o menos luz.
- c) Luminancia (Y). Es la potencia radiada ponderada por una función de sensibilidad espectral característica de la visión humana.
- d) Luminosidad (L^*). Es la respuesta perceptiva no lineal a la luminancia que tiene la visión humana. La no linealidad es prácticamente logarítmica.
- e) Tono o matiz (H). Es una propiedad del color asociada con la longitud de onda dominante en una mezcla de ondas de luz; por lo tanto, representa el color dominante tal y como es percibido por un observador. Así, cuando se dice que un objeto es rojo, verde, amarillo, o de otro color, es su tono lo que se especifica.
- f) Saturación (S). Se refiere a la pureza relativa o a la cantidad de luz blanca mezclada con un tono dado. Los colores puros del espectro están completamente saturados y no contienen luz blanca. El grado de saturación disminuye a medida que se añade más luz blanca.
- g) El tono y la saturación describen la crominancia. Se puede interpretar el color basándose en su luminosidad (L^*), el tono (H) y la saturación (S) [González y Woods, 2008].

2.4 Modelos de color

Para realizar el tratamiento de imágenes en colores es necesario establecer un modelo de representación de dicho color. Dependiendo de la aplicación concreta a implementar, se elegirá una representación u otra. El proceso de elección depende de cómo se generen las señales de color y qué información se necesita extraer de ellas.

En 1931, a raíz de que ningún conjunto finito de fuentes luminosas de color pudiera combinarse para desplegar todos los colores posibles, la Comisión

Internacional sobre Iluminación, conocida como CIE (del francés *Commission Internationale de L'Eclairage*), adoptó unas curvas estándares para un hipotético Observador Estándar. Estas curvas especifican cómo puede ser transformada una determinada distribución espectral de potencia de un estímulo externo (luz radiante visible incidente en el ojo), en un conjunto de tres números que especifican un color sobre la base de tres colores primarios estándar. Los tres primarios estándar son colores imaginarios positivos y se definen matemáticamente con funciones que especifican la cantidad de cada color primario necesaria para describir cualquier color del espectro. Por lo general, el conjunto de primarios de la CIE se integran en el modelo de color XYZ, donde X , Y y Z representan vectores en un espacio tridimensional de color, es decir, X , Y y Z designan las cantidades de colores primarios estándar que se requieren para igualar un color.

El modelo XYZ se obtiene mediante la siguiente transformación general a partir del modelo RGB:

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.341427 & 0.188273 & 0.390202 \\ 0.138972 & 0.837182 & 0.073588 \\ 0 & 0.037515 & 2.038878 \end{pmatrix} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (1)$$

Esta matriz de transformación fue definida por la CIE para el observador patrón [CIE Proc, 1964]. A los observadores se les impone observar los colores con un ángulo del campo visual dado; en el caso del definido por la CIE-1964 el ángulo visual es de 10° . Además, este modelo nos es útil para comparar mediciones del color con las mediciones de los telecolorímetros que trabajan en coordenadas X , Y , Z normalizadas.

Para muchas aplicaciones el tratar con imágenes RGB, implica la obtención de resultados sub-óptimos. La razón es la no uniformidad de dicho espacio de color y la no separación de la información de luminancia y crominancia. Dependiendo de la aplicación, por tanto, será necesario utilizar representaciones de color distintas.

El modelo XYZ hace de puente entre el modelo RGB y el modelo CIELAB que queremos obtener, con el fin de tener una apreciación de diferencias del color más acorde con el Sistema Visual Humano (SVH). El modelo XYZ es la base para todos los modelos, incluso para el RGB, es decir, es el modelo a partir del cuál se pueden describir todos los modelos que existen hoy en día (RGB, CIELUV, CIELAB, YIQ, CMY, etc.).

El modelo CIELAB o $L^*a^*b^*$ lo calculamos a partir del modelo XYZ, para lo que utilizamos las siguientes fórmulas [Braun, Fairchild et al., 1998]:

$$L^* = 116 f\left(\frac{Y}{Y_n}\right) - 16; a^* = 500 \left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right]; b^* = 200 \left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right] \quad (2)$$

Tomando en cuenta que:

$$f(I) = \begin{cases} I^{\frac{1}{3}}; & I > 0.008856 \\ 7.787I + \frac{16}{116}; & I \leq 0.008856 \end{cases} \quad (3)$$

Donde X, Y, Z son los valores triestímulo del modelo XYZ, y $X_n, Y_n,$ y Z_n son los valores normalizados para el blanco de referencia elegido. El blanco de referencia viene dado por las condiciones de la luz, en nuestro caso, por el iluminante elegido. El modelo CIELAB consta también de tres componentes: L^* , que hace referencia a la luminosidad, es decir, a la cantidad de luz blanca relacionada con las otras dos componentes, que son las componentes a^* y b^* de cromaticidad o de color. Es decir, tenemos la información de color en a^* y b^* .

El sistema CIELAB guarda la característica de XYZ en lo referente a que en ambos sistemas se pueden representar todos los colores del espectro en base a la adición de sus tres componentes o colores primarios. Pero, a diferencia del resto de los sistemas, CIELAB es un sistema (aproximadamente) *perceptualmente uniforme*. El modelo XYZ no es perceptualmente uniforme, lo que ya fue demostrado haciendo uso de las elipses de MacAdam [MacAdam, 1942], Fig. 6.

Un sistema perceptualmente uniforme es un sistema en el que la diferencia entre un color y otro dentro del mismo sistema, guarda la misma proporción que la diferencia que se aprecia a través del ojo humano. Nosotros sabemos que el color de un objeto es la percepción que tenemos del mismo, la cual es transmitida por el nervio óptico desde los ojos al cerebro, y que está influenciada por la fuente de luz o iluminante con que se ilumine el objeto en ese momento. El mismo objeto, sin que cambien sus propiedades, puede aparecer al ojo humano de un color distinto bajo distintas condiciones de luz. Este es el fenómeno de *metamerismo*. Existe una gran cantidad de iluminantes definidos por la CIE. Estos representan diversos fenómenos físicos como puede observarse en la Fig. 7.

La energía relativa de estos iluminantes es diferente, es decir, la cantidad de energía emitida a lo largo del espectro, es distinta Fig. 8. Por ejemplo, iluminantes extremos: el iluminante D65 equivale a la luz del día, mientras que el iluminante F2 equivale a la luz fluorescente.

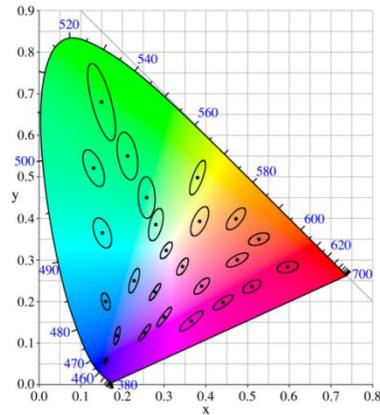


Fig. 6 Elipses de MacAdam.



Fig. 7 Valores de iluminantes según la fuente de luminancia.

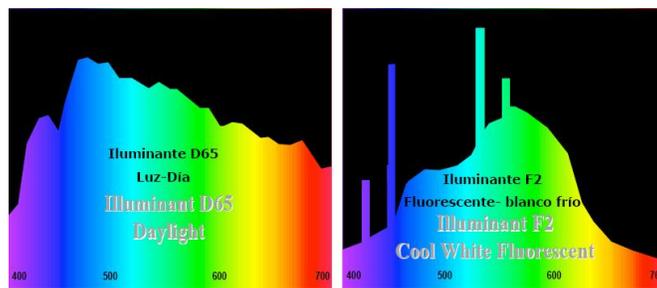


Fig. 8 Energía relativa de los iluminante D65 y F2.



Fig. 9 Energía relativa del iluminante D50.

Dado estos fenómenos y la necesidad de una fuente de luz estándar para una correcta observación del color, la CIE definió el iluminante D50 como la luz de día estándar que corresponde a la luz solar directa. Este iluminante es obviamente muy parecido al D65 que representa la luz del día con cielo totalmente cubierto. El D50 es el estándar utilizado en nuestro método, (Fig. 9).

Tal y como se apuntó anteriormente, para pasar al modelo CIELAB desde XYZ se necesita saber el iluminante utilizado para disponer de un blanco de referencia. Este blanco de referencia son los valores X_n , Y_n , y Z_n estandarizados para el iluminante patrón usado D50, calculados a partir de la distribución espectral relativa de energía y considerando el observador patrón.

2.5 Fórmula de diferencia de color CIE2000

Como ya sabemos, el espacio CIELAB es un sistema (aproximadamente) perceptualmente uniforme, por lo que son necesarias diferentes ponderaciones de la diferencia en claridad, tono y saturación. Han surgido diversas fórmulas de diferencia de color avanzadas a partir de este hecho. La más reciente recomendada por la CIE en el año 2000 es la fórmula CIE2000 denotada ΔE_{00} [Luo, Cui et al., 2001].

Como otras fórmulas de diferencia de color avanzadas, CIE2000 está basada en CIELAB, por lo que a partir del cálculo de parámetros CIELAB se pueden obtener los valores de tono (“C”) y saturación (“h”):

$$C^*_{ab} = \sqrt{a^{*2} + b^{*2}}; \quad h_{ab} = \arctg\left(\frac{b^*}{a^*}\right) \quad (4)$$

Seguidamente, la coordenada a^* de CIELAB se transforma en a' , sin que esto suponga que se propone una redefinición de CIELAB; es decir, esta transformación se propone solamente a efectos del cálculo posterior de diferencias de color. En definitiva, se hacen las transformaciones siguientes, que conducen a variables ‘con primas’:

$$L' = L^*; \quad b' = b^*; \quad h' = \arctg\left(\frac{b'}{a'}\right); \quad C' = \sqrt{a'^2 + b'^2}; \quad a' = (1 + G)a^* \quad (5)$$

Donde G es un parámetro que tiende a la unidad fuera de la zona de estímulos acromáticos y cuyo valor viene dado por la expresión:

$$G = 0.5 \left(1 - \sqrt{\frac{C_{ab}^{*7}}{C_{ab}^{*7} + 25^7}} \right) \quad (6)$$

A continuación, se hallan las componentes de la diferencia de color entre las 2 muestras, designadas con subíndices 'b' (*batch*) y 's' (*standard*), con las expresiones siguientes:

$$\Delta L' = L'_b - L'_s; \Delta C' = C'_b - C'_s; \Delta h' = h'_b - h'_s; \Delta H' = 2\sqrt{C'_b C'_s} \text{sen} \left(\frac{\Delta h'}{2} \right) \quad (7)$$

Finalmente, la fórmula CIE2000 viene dada por la expresión:

$$\Delta E_{00} = \sqrt{\left(\frac{\Delta L'}{K_L S_L} \right)^2 + \left(\frac{\Delta C'}{K_C S_C} \right)^2 + \left(\frac{\Delta H'}{K_H S_H} \right)^2 + R_T \left(\frac{\Delta C'}{K_C S_C} \right) \left(\frac{\Delta H'}{K_H S_H} \right)} \quad (8)$$

donde los factores de peso S_C , S_H y S_L de la función (*weighting factors*) son los siguientes:

$$S_C = 1 + 0.045 \bar{C}'; \quad S_H = 1 + 0.015 \bar{C}' T; \quad S_L = 1 + \frac{0.015 (\bar{L}' - 50)^2}{\sqrt{20 + (\bar{L}' - 50)^2}} \quad (9)$$

y donde T es un factor que implica una dependencia de la tolerancia en tono con el ángulo de tono, dada por la expresión:

$$T = 1 - 0.17 \cos(\bar{h}' - 30^\circ) + 0.24 \cos(2\bar{h}') + 0.32 \cos(3\bar{h}' + 6^\circ) - 0.20 \cos(4\bar{h}' - 63^\circ) \quad (10)$$

Los factores paramétricos K_L , K_C , K_H se toman como la unidad bajo las mismas condiciones de referencia estándares definidas por la CIE.

2.6 Cuantificación del color

Formalmente, la cuantificación del color se refiere a que dada una imagen I , encontrar las particiones óptimas del conjunto de N colores de I en K subconjuntos, donde $K \leq N$, de acuerdo a un criterio de error de cuantificación dado. Los centroides de las agrupaciones definirán, por tanto, las palabras de código que son óptimas en el sentido de mínimo error de cuantificación.

Normalmente, en los métodos de cuantificación del color, el tamaño de la paleta de colores es un parámetro dado por el usuario, lo que conlleva pérdida de

automatización o de fiabilidad debido que la cantidad de colores escogido puede ser que no sea el óptimo para la imagen en cuestión. En el método de cuantificación que proponemos, el tamaño de la paleta de colores es calculado dinámicamente de forma no supervisada, buscando el máximo en la relación dada por número de detalles en la imagen (regiones) contra la menor cantidad de colores. La mayoría de los métodos para el diseño de la paleta de colores se basan en la *cuantificación vectorial*. De este modo se puede interpretar cada color de la paleta como una *palabra de código* y al proceso que le asigna a cada píxel un color, como la *codificación*.

La tarea de encontrar un conjunto óptimo de colores representativos puede ser vista como un problema de *búsqueda de agrupaciones* (*clustering* en inglés) a gran escala [Orchard y Bouman, 1991].

Como error de cuantificación se suele escoger el error cuadrático medio. Dado un píxel \mathbf{x} con tres componentes, el error cuadrático medio de cuantificación de dicho píxel viene dado por:

$$d(\mathbf{x}, \hat{\mathbf{x}}) = \sum_{i=1}^3 (x_i - \hat{x}_i)^2 \quad (11)$$

donde los x_i ($i = 1, 2, 3$) representan las componentes del centroide al que se asocia el píxel \mathbf{x} en la imagen original y se les resta su equivalente en la imagen cuantificada. Para la imagen completa, el error de cuantificación se calcula promediando los errores individuales de cada píxel de la imagen.

La cuantificación de colores reduce significativamente el número de colores de la imagen, lo cual es muy deseable para evitar que los métodos de búsqueda de agrupaciones lleven mucho tiempo de cálculo. Es decir, la cuantificación es un paso dentro del preprocesamiento de la imagen (preparación de la imagen) para su posterior segmentación basada en la búsqueda de agrupaciones o en otras estrategias. En la Fig. 10 podemos apreciar la gran cantidad de colores que están presentes en una imagen digital y que el ojo humano, al integrarlos, según la mezcla aditiva de los colores, llega a definir que el objeto (en este caso el ojo del mandril) es de color anaranjado. La tarea de la cuantificación del color es encontrar el mínimo número de colores que puede tener cada objeto, sin que en conjunto se reduzca apreciablemente la información de los objetos presentes en la imagen. La calidad del método de cuantificación del color está dada, intrínsecamente, por la permanencia de aquellos colores en la imagen que mantienen perceptualmente ante el usuario las mismas propiedades del color de los diversos objetos que la componen.

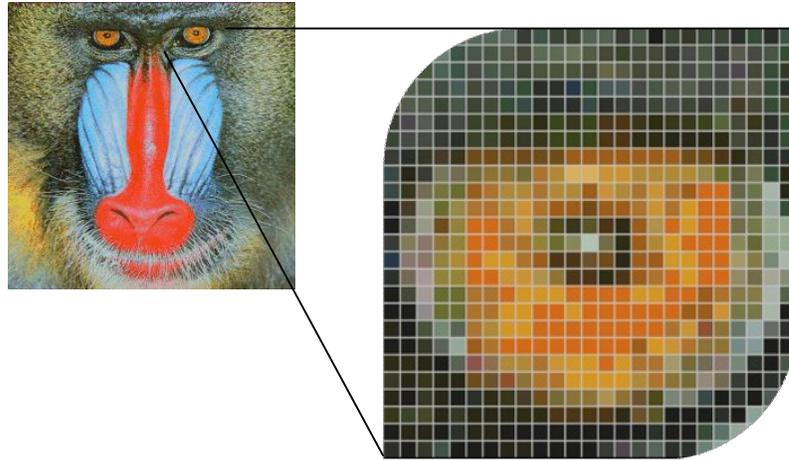


Fig. 10 Ampliación del ojo izquierdo de la imagen Mandril.

En general, los algoritmos de cuantificación del color pueden ser clasificados en dos categorías: Métodos independientes de la imagen y Métodos dependientes de la imagen. Los métodos independientes de la imagen pueden ser vistos como de cuantificación uniforme, dado que el espacio de color es dividido en k regiones del mismo tamaño, mientras que en los métodos dependientes de la imagen las regiones tienen tamaños distintos. En la mayoría de los métodos que entran en esta categoría, el espacio de color es dividido de acuerdo a la distribución estadística de los colores presentes en la imagen. Los algoritmos de cuantificación uniforme son, en general, simples, y sus resultados no son buenos. Por este hecho, son más comunes los métodos de cuantificación basados en la imagen. Estos algoritmos de cuantificación pueden ser subdivididos según la metodología empleada para encontrar las agrupaciones de colores adecuadas. Los métodos de diseño de paletas de colores se pueden dividir en tres categorías [Piñero, 2002], (Tabla 1):

Tabla 1 Categorías y métodos de cuantificación.

Optimización iterativa	Heurísticos	Cuantificación Escalar
<ul style="list-style-type: none"> • K-medias • Difuso k-medias • Genético k-medias • Redes neuronales 	<ul style="list-style-type: none"> • Divisores y Acumulativos • Popularidad • Corte mediana • <i>Octree</i> • Componentes Principales 	<ul style="list-style-type: none"> • Uniforme • Mínima varianza

2.7 Métodos basados en la optimización iterativa

Estos métodos, dado un conjunto de colores iniciales, tratan de ajustar la paleta de colores de acuerdo a un criterio de error de cuantificación global. Entre los más conocidos están los siguientes:

- a) Algoritmo LBG (*Linde-Buzo-Gray*) [Linde, Buzo et al., 1980], también llamado Algoritmo de K-medias (*K-means*) o Algoritmo generalizado de Lloyd. El algoritmo se propuso para hallar un diccionario sub-óptimo para aplicaciones de cuantificación vectorial. Representa uno de los algoritmos clásicos más utilizados para la búsqueda de agrupaciones.
- b) Algoritmo K-medias difuso (*Fuzzy K-means*) [Bezdek, 1981]. Es una extensión difusa del anterior, consistente en la relajación de la estricta regla de clasificación dentro del paso de re-cálculo de centroides del algoritmo anterior.
- c) Algoritmo K-media genético [Sheunders, 1996]. Es una aproximación híbrida que combina el algoritmo de K-medias con un algoritmo genético para evitar la convergencia a un mínimo local.
- d) Algoritmos basados en redes neuronales [Domanski y Bartkowiak, 1998]. Parten de una paleta dada, que es una versión sub-muestreada de la imagen de color original, con la que se va entrenando iterativamente la red de forma que se produzca un ajuste en las neuronas ganadoras, representantes de un color de la paleta. Son métodos que llevan mucho tiempo de computación.

2.7.1 Algoritmo K-medias (*K-means*)

Este método de búsqueda de agrupaciones en n dimensiones produce K vectores de medias que representan K clases de datos [Linde, Buzo et al., 1980]. Se basa en una medida de distorsión $d(\mathbf{x}, \mathbf{y})$ entre puntos de \mathcal{R}^n .

Sea el conjunto de datos de entrenamiento $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$. Dado un *centroide* (representante de una agrupación) \mathbf{y}_i , el conjunto de puntos de X que esté más cercano a \mathbf{y}_i que a cualquier otro centroide, según la medida de distorsión $d(\mathbf{x}, \mathbf{y})$, se denomina *región de Voronoi* de \mathbf{y}_i , la que se denota por

$$V_i = \{ \mathbf{x} \in X : d(\mathbf{x}, \mathbf{y}_i) < d(\mathbf{x}, \mathbf{y}_j), i \neq j \} \quad (12)$$

El número de vectores en una región de Voronoi se representa por $|V_i|$. El centroide de los vectores de una región de Voronoi viene dado por:

$$\frac{1}{|V_i|} \sum_{x \in V_i} x \quad (13)$$

Sea $\mathcal{Y}(x)$ el centroide y_i más cercano a x . La distorsión promedio para todo el conjunto de datos X es:

$$d(X) = \frac{1}{|X|} \sum_{x \in X} d(x, \mathcal{Y}(x)) \quad (14)$$

Con esta notación, el algoritmo *K-media* se resume en los siguientes pasos:

- 1) Elegir un conjunto inicial de centroides y_1, y_2, \dots, y_K .
- 2) Determinar la región de Voronoi para cada y_i .
- 3) Calcular el centroide de cada región de Voronoi.
- 4) Si el algoritmo no ha convergido, ir al paso 2; en cualquier otro caso, parar.

Un posible criterio para saber si el algoritmo ha convergido es que la distorsión promedio sea lo suficientemente pequeña. Otro criterio consiste en calcular el cambio en la distorsión de una iteración a otra y parar si ese cambio es suficientemente pequeño.

La determinación de los centroides iniciales juega un papel crucial debido a que cuanto mejor sea la partición inicial, más rápido convergerá el algoritmo. Es más, aunque se asegura la convergencia, ésta no tiene por qué ser a un mínimo global.

Una forma de llevar esta elección a cabo consiste en calcular el histograma N -dimensional de la imagen y determinar los picos dominantes del mismo. Los K picos dominantes se corresponderán con los K centroides iniciales [Plataniotis y Venetsanopoulos, 2000]. En otros algoritmos, las agrupaciones iniciales se escogen aleatoriamente [Weeks y Hague, 1997], con lo que disminuye la dificultad, pero aumenta el tiempo de convergencia del algoritmo.

2.7.2 Algoritmo K - medias difuso (*Fuzzy K-means*)

El algoritmo K-media (*K-means*) explicado en el apartado anterior puede extenderse para incluir reglas de inferencia difusa, formando lo que se denomina

el algoritmo *Fuzzy K-means* [Bezdek, 1981]. En el algoritmo K-media un vector x puede pertenecer solamente a una región descrita por el centroide y_i . No existe la posibilidad de pertenecer parcialmente a una agrupación y parcialmente a otra, y sin embargo, en muchos problemas de clasificación de patrones sería deseable que el sistema tuviera esto en cuenta. Para ello, se puede utilizar una función de pertenencia que indique el grado en el que un vector pertenece a una agrupación o a otra. El hecho de que el grado de pertenencia a un conjunto determinado sea explícitamente representado, es lo que lleva al uso de la palabra *borroso o difuso* (en inglés, *fuzzy*) para describir este tipo de agrupaciones.

Sea u_{ij} un indicador de la pertenencia de un vector de datos x_j a la agrupación i . Para el algoritmo K-media, $u_{ij} \in \{0, 1\}$, es decir, sólo toma dos posibles valores.

$$u_{ij} = \begin{cases} 1, & \text{si } X_j \in \text{agrupación } i \\ 0, & \text{en otro caso.} \end{cases} \quad (15)$$

Como todo elemento tiene que pertenecer a una agrupación, se cumple que:

$$\begin{aligned} \sum_{i=1}^K u_{ij} &= 1, \quad j=1, 2, \dots, N, \\ \sum_{i=1}^K \sum_{j=1}^N u_{ij} &= N \end{aligned} \quad (16)$$

Para el algoritmo K-media difuso (*Fuzzy K-means*) se puede generalizar el concepto del indicador u_{ij} a que tome un valor comprendido en el rango $[0, 1]$. Bajo esta especificación, u_{ij} indica el grado en el que x_j pertenece a la agrupación i , y se dice que es una *función de pertenencia al conjunto*.

Para describir el algoritmo de búsqueda de agrupaciones basado en esta generalización, se define una *función objetivo* basada en una medida ponderada de similitud entre los píxeles de la imagen y cada uno de los K centroides. Un extremo local de dicha función objetivo indica una agrupación óptima de los datos de entrada. La función objetivo a minimizar viene dada por:

$$J(U, Y) = \sum_{j=1}^N \sum_{i=1}^K (u_{ij})^m d^2(x_j, y_i) \quad (17)$$

donde $U = [u_{ij}]$ es la matriz de las funciones de pertenencia; $Y = [y_1, y_2, \dots, y_K]$ es el conjunto de centroides; y m ($1 \leq m \leq \infty$) varía la naturaleza de la agrupación (para $m = 1$ se tiene una agrupación “dura” y para valores altos de m se tienen

agrupaciones con la borrosidad en aumento). La medida de la distancia se toma, por razones analíticas, como

$$d^2(x_j, y_i) = (x_j - y_i)^T (x_j - y_i) \quad (18)$$

La función $J(U, Y)$ mide el error al representar K agrupaciones borrosas indicadas por U con centroides representados por Y . El objetivo es minimizarla, sujeto a la restricción:

$$\begin{aligned} \sum_{i=1}^K u_{ij} &= 1, \quad j = 1, 2, \dots, N \\ u_{ij} &\geq 0, \quad i = 1, 2, \dots, K \quad j = 1, 2, \dots, N \end{aligned} \quad (19)$$

Cuando $m = 1$, el algoritmo se reduce al de K-media. Si $m > 1$, hay que resolver un problema de optimización con restricciones. Es decir, el problema de búsqueda de agrupaciones por el algoritmo K-media difuso se resuelve eligiendo un conjunto inicial de K centroides o medias e iterando las dos ecuaciones hasta que converjan.

Los algoritmos de agrupaciones de pixeles encuentran problemas en las situaciones siguientes:

- 1) A menudo las agrupaciones adyacentes se superponen en el espacio de color.
- 2) La segmentación es más difícil cuando el número de agrupaciones es desconocido, lo que ocurre con frecuencia.
- 3) Al ser técnicas de segmentación basadas en el píxel, no tienen en cuenta las restricciones espaciales, lo cual las hace susceptibles al ruido.

2.8 Métodos heurísticos

Estos algoritmos, en lugar de encontrar los mínimos locales llevando a cabo numerosas iteraciones, intentan obtener una solución aceptable en mucho menos tiempo. La mayoría de los algoritmos se basan en un análisis estadístico de la distribución de los colores de los pixeles. Se clasifican en *métodos divisorios* y *métodos acumulativos*. Los primeros subdividen el espacio de color tridimensional en celdas siguiendo distintos criterios, mientras que los segundos aplican un algoritmo de agrupación jerárquico uniendo iterativamente los centroides según ciertas reglas.

El cubo de colores es una matriz tridimensional de todos los posibles colores que se definen para un tipo de datos determinado de la imagen. Si se escoge un tipo de datos de la imagen de ocho bits por cada componente de color, el cubo de color representará 2^{24} colores posibles. A esta distribución de los colores se le llama cubo de colores RGB (Fig. 11)

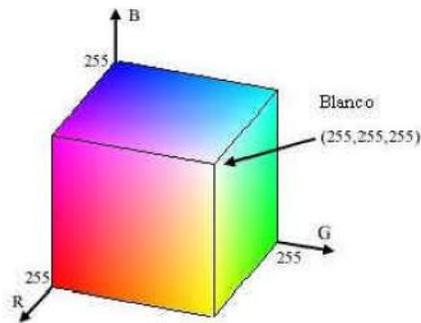


Fig. 11 Cubo de colores RGB.

La cuantificación implica dividir el cubo de colores RGB en un número pequeño de regiones y después asignar todos los colores que caen dentro de una misma región al valor del color central de la misma. La diferencia entre los métodos radica en la aproximación utilizada para dividir el cubo de colores RGB.

Otros algoritmos heurísticos que se pueden encontrar en la literatura son el Algoritmo de Popularidad (*Popularity algorithm*) [Heckbert, 1982], que utiliza el histograma de la imagen para seleccionar los K colores más frecuentes en la misma; el Algoritmo del Corte de Mediana (*Median-Cut algorithm*) [Heckbert, 1982]; el Algoritmo de División Binaria [Orchard y Bouman, 1991]; el Algoritmo de Wu [Wu, 1992] basado en las componentes Principales, y el Algoritmo de Mejoramiento Selectivo Condicionado [Ramos y Felipe, 2002].

2.8.1 Algoritmo de Popularidad (*Popularity*)

El Algoritmo de Popularidad [Heckbert, 1982] fue inventado por Tom Boyle y Andy Lippman en el MIT en el verano de 1978, cuando Tom Boyle escribió su software llamado *Color Maker*. Subsecuentemente, Paul Heckbert reescribió aquel software con el nombre *IMAGE* y publicó el algoritmo.

Este algoritmo es una simple y rápida manera de crear una paleta de color, así como también es uno de los primeros algoritmos desarrollados en el campo de la cuantificación del color.

La idea principal es contar las ocurrencias de cada color en la imagen y entonces seleccionar los M colores más frecuentes para conformar la paleta de color. El algoritmo trabaja en un tiempo con una complejidad $O(N \log N)$, para escoger los M colores más frecuentes que pueden ser detectados para crear un primer ordenamiento de los valores de los píxeles y entonces después escanear la lista ordenada. Algunos valores de píxel son entradas consecutivas en la lista ordenada, así que escanearlos tomará solo el tiempo $O(N)$. El principio detrás del algoritmo de Popularidad es que los picos del histograma corresponden a los centroides de los *clusters*. Desafortunadamente este principio no se mantiene en la práctica.

En algunos casos la interacción humana es necesaria. Cuando hay partes importantes de la imagen, pero con colores con poca frecuencia de ocurrencia, el algoritmo por sí solo las descartaría y las reemplazaría, como por ejemplo, los ojos de una persona en una fotografía de su rostro. El remedio para esto es usar un método para que el usuario manualmente elija las zonas que se quieren enfatizar. Estos puntos serán multiplicados en el conteo para la tabla de frecuencias garantizando una mejor representación en la paleta de colores.

2.8.2 Algoritmo de Corte de Mediana (*Median-Cut*)

Este algoritmo fue el primero propuesto por Heckbert en su trabajo relacionado con la cuantificación del color clásica [Heckbert, 1982]. Su idea consiste en dividir recurrentemente el espacio de color en particiones rectangulares, esto es, subdividir en varias ocasiones el cubo de colores en cajas rectangulares cada vez más pequeñas. Primero, el algoritmo proyecta todos los vectores a los ejes coordenados. El punto medio de los valores proyectados es el punto de corte de esa partición. Esto conduce a igualar el número de colores S_1 y S_2 en ambas nuevas particiones.

El proceso continúa recurrentemente hasta que se crea el número de M particiones. Entonces los centroides de las particiones forman la paleta de colores. El algoritmo original es recursivo, pero la variante iterativa es más fácil de definir. A continuación se presenta la variante iterativa.

S_1	←	Cubo RGB más pequeño que cubre todos los vectores
M	←	1
Repetir		
S_i	←	Selecciona el que maximice $(\text{Max}(X_i) - \text{Min}(X_i))$
X_j	←	Encuentra el eje de S_i que maximice.
X_j	←	Encuentra la mediana de X_i
S_{2i}, S_{2i+1}	←	Particiona S_i de la ortogonal X_j a X_j
Se calculan los covectores C_{2i} y C_{2i+1}		
M	←	$M + 1$

Hasta ($M = |C|$)

Existen muchas variaciones del algoritmo, por ejemplo, el de corte en el centro (*Center-Cut*) que divide por el centro las particiones en vez de por la mediana.

2.8.3 Algoritmo *Octree*

El algoritmo de cuantificación *Octree* [Gervautz y Purgathofer, 1988] subdivide repetidamente el cubo en ocho cubos más pequeños con una estructura arborescente de grado ocho. Entonces los cubos adyacentes con el menor número de píxeles se combinan. Se repite esto hasta que se obtiene el número requerido de colores. *Octree* produce resultados similares al algoritmo de *Median-Cut*, pero con una velocidad más alta y con menos exigencias para la memoria.

El algoritmo de cuantificación *Octree* es rápido y produce paletas de colores de calidad. La publicación original fue reimpressa más adelante en *Graphics Gems I*, lo que dio lugar a la adopción amplia del algoritmo en diversas implementaciones. Muchos paquetes comerciales del procesamiento de imágenes todavía están utilizando el algoritmo *Octree*.

Este se basa en una estructura de datos consistente en un árbol donde cada nodo contiene indicadores a ocho nodos hijos. Los colores se almacenan en los nodos de la hoja correspondiente. Este produce la paleta de colores en un solo paso y no utiliza ningún tipo de pre-cuantificación de los vectores de la entrada. La idea es que la imagen es procesada píxel por píxel. Se recorre el árbol hasta que se alcanza un nodo de la hoja y si el nodo de la hoja está vacío, entonces el color del píxel se inserta en la estructura de datos del *octree*; si no, la cuenta de la frecuencia de ese color se aumenta.

Los colores del modelo de color RGB tienen 8 bits por componente, así que podemos separar el color RGB en 8 planos de tres bits. Por ejemplo, supongamos que en la posición del bit i R tiene su bit con valor 1, G en 0 y B en 1. Esto conduce al número binario $101_2 = 5_{10}$. Está claro que con 3 bits podemos representar los números del cero al siete. Este número se utiliza como índice del nodo hijo. Primero tomamos el plano más significativo y utilizamos el índice para atravesar a uno de los ocho nodos hijos. Entonces tomamos el siguiente plano y lo utilizamos otra vez como índice de un nodo hijo. Esto continúa hasta que hemos recorrido todo el árbol. Cuando se han procesado todos los píxeles, entonces comienza el proceso de reducir las hojas del árbol.

El algoritmo busca un nodo para el cual la suma de las frecuencias es mínima. Calcula el vector medio de todos los nodos de la hoja situados bajo este nodo.

Quita todos los nodos de la hoja y almacena el nuevo vector medio con las frecuencias sumadas. El proceso continúa hasta que solamente queden M hojas.

El operador de la reducción divide el espacio de color en diversos tamaños. El tamaño del cubo depende del nivel en el cual la reducción del *octree* fue realizada.

2.8.4 Algoritmo de Componentes Principales

Wu [Wu, 1992] propuso un algoritmo que primero proyecta todos los vectores por su grado de luminosidad y entonces clasifica los vectores según sus proyecciones cromáticas.

Ahora bien, si consideramos los valores de la proyección, tenemos una lista de los valores escalares que representan el espacio de colores entero. El algoritmo de cuantificación por componentes Principales (*Optimal Principal Quantizer*) utiliza el cuantificador escalar óptimo en los valores de la proyección para repartir el sistema de proyecciones en los intervalos k , donde $k < M$.

La función de distorsión usada en la cuantificación escalar de los valores de la proyección es la distorsión que tiene lugar al cuantificar los vectores en esa partición. De esa manera, el cuantificador principal óptimo se puede considerar como método híbrido de dos métodos existentes: la cuantificación escalar y la cuantificación vectorial.

El valor de k se determina dinámicamente a medida que el proceso dinámico continúa. Si después de que el cuantificador principal es encontrado, con $k < M$, entonces todavía necesitan ser formadas M/k particiones. El algoritmo entonces usa un esquema de partición local óptima para dividir las particiones creadas en pasos anteriores.

2.9 Métodos de cuantificación escalar

Un paso fundamental para la posterior segmentación del color mediante la ubicación de agrupaciones, consiste en convertir los datos de la imagen en el formato más adecuado para su representación, es decir, se tendrán que encontrar los descriptores o las transformaciones de los espacios de color que den mayores diferencias entre las agrupaciones y mayor correlación brinden con el sistema visual humano a la hora de distinguir los diferentes colores. A continuación explicaremos los métodos de cuantificación escalar del color de uso más común.

2.9.1 Cuantificación uniforme

Para llevar a cabo la cuantificación uniforme de los colores, se divide el cubo de colores RGB en pequeñas cajas de igual tamaño (pequeños cubos), asignándosele el color del píxel del centro de cada caja a todos los píxeles con los colores que caigan dentro de la misma. Una vez que el cubo de colores RGB se ha dividido y se hayan hecho las correspondientes asignaciones, todas las cajas vacías (sin píxeles con colores dentro de ellas) se eliminan (Fig. 12).

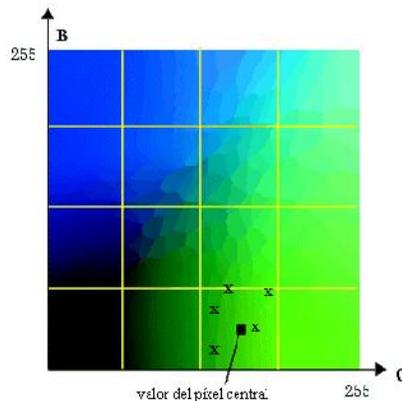


Fig. 12 Ejemplo de cuantificación uniforme para el plano $R = 0$ del cubo de colores RGB.

2.9.2 Cuantificación de mínima varianza

En este tipo de cuantificación, el conjunto de colores *RGB* se divide en cajas, no necesariamente con forma de cubo, sino pueden ser esféricas o de alguna otra forma, y pueden ser de distintos tamaños. Las dimensiones de las cajas dependen de cómo estén distribuidos los colores en la imagen y no tienen por qué cubrir el cubo de color completamente. Si en algunas áreas de la imagen no existen píxeles con colores diferentes a los ya asignados, no habrá cajas asociadas a ellos.

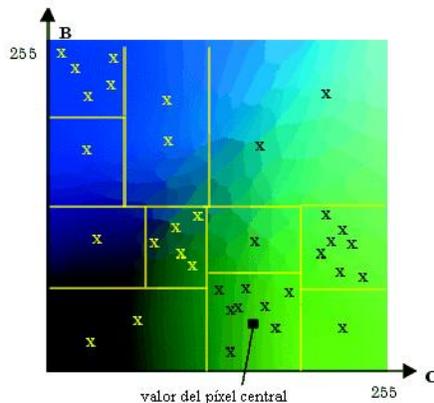


Fig. 13 Ejemplo de cuantificación de mínima varianza para el plano $R = 0$ del cubo RGB.

El cuantificador de mínima varianza trabaja asignando los píxeles a distintos grupos, según las varianzas entre sus valores de color. Se establecerán más agrupaciones en las regiones con mayores errores de cuantificación, es decir, donde los datos (colores de los píxeles) tengan mayor varianza [Domanski y Bartkowiak, 1998] [Heckbert, 1982] [Wan, Wong et al., 1988].

Tras indicar el número de colores a los que se quiere cuantificar la imagen, el algoritmo determina el emplazamiento de las cajas analizando los datos de color de la imagen. Una vez dividida la imagen, a los píxeles con colores que caen dentro de una misma caja se les asigna el valor del color del píxel central, como ocurría con la cuantificación uniforme (Fig. 13).

Para un número de colores dado, la cuantificación de mínima varianza produce mejores resultados que la cuantificación uniforme, debido a que tiene en cuenta los datos reales. La cuantificación de mínima varianza asigna más entradas del mapa de colores a los colores que aparecen frecuentemente en la imagen original, y menos a los que aparecen con menor frecuencia. Como resultado, la precisión de los colores es mayor que en el caso de la cuantificación uniforme. El tiempo de computación en la cuantificación de mínima varianza es mayor que en la uniforme. Estas técnicas calculan primero el histograma a partir de los colores de los píxeles que componen la imagen y posteriormente se halla cada agrupación. Entonces, cada píxel de la imagen se asocia a la agrupación más cercana en color. Por tanto, los algoritmos de agrupaciones proveen un método para representar un conjunto de datos de N puntos a través de un conjunto de K puntos, donde $K < N$. El nuevo conjunto de datos es, de alguna forma, representativo del conjunto completo.

La mayoría de los algoritmos de agrupaciones son iterativos, donde se parte de un conjunto inicial de puntos y por división, fusión o promediado, van ajustándose hasta obtener el conjunto óptimo de puntos representativos de los colores de toda la imagen.

2.9.3 **Métodos basados en la cuantificación escalar mejorada**

Estos métodos explotan la dependencia estadística de la imagen. Entre otros, cabe destacar la *cuantificación escalar secuencial* [Balasubramanian, Bouman et al., 1995], donde se calculan y analizan las distribuciones marginales de los colores. Cada componente de color se cuantifica individualmente teniendo en cuenta condicionalmente la información de la cuantificación de la componente anterior.

Para eliminar posibles cambios y desplazamientos en los colores, la cuantificación se debe llevar a cabo en los planos RGB, en lugar de aplicarla a otros sistemas de

representación. [Jain y Pratt, 1972], [Lucchese y Mitra, 2001] y [Pratt, 2001] han investigado la asignación óptima de los niveles de decisión del cuantificador para imágenes en colores, de forma que se minimicen las distancias entre el color original y los centroides de los grupos que los representan. Los autores de dichos trabajos encontraron que la cuantificación de las coordenadas RGB daban los mejores resultados en comparación con otros sistemas de representación del color. La principal razón es que en el sistema RGB se utiliza la mayor parte de los niveles de cuantificación, mientras que para otros espacios de color muchos de estos niveles no se utilizan.

También se han encontrado estudios que mantienen el criterio de que existen espacios de color más adecuados para cuantificar los colores que el RGB, según la aplicación [Domanski y Bartkowiak, 1998] [Kolpatzik y Bouman, 1995].

2.10 Reconstrucción

Una vez obtenida la Paleta de Colores se procede a la reconstrucción de la imagen, donde el método a usar varía según la aplicación. Para esto hay dos métodos fundamentales: por indexado y por difuminado (Fig. 14)

Si lo que se desea es segmentar, es muy conveniente que los bordes entre los objetos estén muy bien definidos y que se reduzcan los degradados que pueda tener la imagen. Pero si la aplicación requiere que la imagen conserve sus propiedades perceptuales se requiere otra técnica.



Fig. 14 Imagen reconstruida a la izquierda por indexación y a la derecha por difuminado.

2.10.1 Indexación

Para el primer caso, es común emplear el método de indexación por similitud, donde simplemente se reemplaza el color original con el color que tenga más

parecido en la PC. Esta similitud es calculada por algún tipo de distancia en un espacio de representación del color. En nuestro caso empleamos la fórmula CIE2000 para calcular las diferencias del color [Luo, Cui et al., 2001].

2.10.2 Difuminado (*Dithering*)

El difuminado, conocido en inglés como *dithering*, es una técnica usada para crear la ilusión de profundidad de color con una paleta de color limitada. En una imagen reconstruida, los colores no disponibles en la paleta son aproximados por una difusión de los colores disponibles en la paleta. El ojo humano percibe la difusión como una mezcla de colores. Esta técnica es análoga a la técnica de medios tonos o semitonos (*halftone*) usada en la imprenta. Si la intención es conservar la mayor similitud con la imagen original, se emplea algún método de difuminado (*dithering*). Para esto, generalmente se usa el método de difuminado de Floyd-Steinberg [Floyd y Steinberg, 1975], desarrollado en 1975, es uno de los algoritmos más potentes para minimizar los artefactos visuales a través de un proceso de difusión del error. Este algoritmo típicamente produce imágenes cercanas a la original con una simplicidad mayor que otros métodos de difuminación. Es comúnmente empleado por software para la manipulación de imágenes, como por ejemplo, para hacer conversiones en el formato GIF, dado que este formato está restringido a 256 colores. El algoritmo difumina el error de cuantificación de un píxel a sus píxeles vecinos de acuerdo a la siguiente distribución:

$$\frac{1}{16} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 7 \\ 3 & 5 & 1 \end{bmatrix} \quad (20)$$

El algoritmo recorre la imagen de izquierda a derecha y de arriba hacia abajo, cuantificando el valor del error píxel por píxel; en cada píxel su error de cuantificación es transferido a los píxeles vecinos, sin afectar a los píxeles que ya han sido indexados. El método implementa el siguiente programa en pseudocódigo:

```
for each y
  for each x
    oldpixel := pixel[x][y]
    newpixel := find_closest_palette_color(oldpixel)
    pixel[x][y] := newpixel
    quant_error := oldpixel - newpixel
    pixel[x+1][y] := pixel[x+1][y] +  $\frac{6}{16}$  quant_error
    pixel[x-1][y+1] := pixel[x-1][y+1] +  $\frac{2}{16}$  quant_error
    pixel[x][y+1] := pixel[x][y+1] +  $\frac{4}{16}$  quant_error
    pixel[x+1][y+1] := pixel[x+1][y+1] +  $\frac{1}{16}$  quant_error
```

Por tanto, si cierto número de píxeles se han redondeado hacia abajo, es más probable que el próximo píxel se redondee hacia arriba, de modo que en promedio, el error de cuantificación es cercano a cero. Esto puede ocasionar ciertos efectos denominados "fantasmas" en la imagen, que consiste en la aparición de sombras en la imagen. Este problema puede ser resuelto con la elección de los coeficientes de manera que su suma sea menor a la unidad.

3 Metodología propuesta

Resumen. Dados los conceptos expuestos hasta aquí, en este capítulo se presenta la descripción general, la propuesta de solución, el diagrama de bloques, la interfaz gráfica, el algoritmo de cuantificación del color propuesto y el procedimiento detallado de la metodología propuesta.

3.1 Introducción

En este capítulo se muestran hasta el momento se han descrito los algoritmos de cuantificación del color más comunes. Ahora nos enfrentamos al reto de detectar la cantidad de colores de forma no supervisada que han de conformar la paleta de colores. Dado que todos los métodos clásicos de cuantificación del color reciben como parámetro inicial la cantidad de grupos a tener (*clusters*), esto equivale a la cantidad de colores que se desea obtener como resultado final de la cuantificación. Estos algoritmos pueden ser usados eficientemente y sin problemas cuando la aplicación recibe siempre el mismo tipo de imágenes, para las que una cantidad de

colores elegida a priori puede ser determinada manualmente y sobre la base de la experiencia. Pero cuando es de nuestro interés encontrar la cantidad de colores representativos de una imagen sin importar el tipo o características que presente la misma, estos algoritmos no llegan a ser los más adecuados.

Este trabajo presenta un algoritmo que consigue una reducción apreciable en el número de colores de una imagen, sin necesidad de conocer a priori la cantidad de colores que ha de tener la paleta de colores. Por lo tanto, en una imagen que tenga una gran diversidad de colores, la paleta de colores resultante contendrá una mayor cantidad de estos que la de aquella imagen en donde el sistema visual humano identifique pocos colores.

3.2 Descripción

El desarrollar un algoritmo que al contrario de los métodos clásicos no requiere conocer el tamaño de la paleta de colores a generar, nos condujo a un método no supervisado de cuantificación. El algoritmo propuesto es el siguiente:

1. Conversión de la imagen del espacio de color RGB al $L^*a^*b^*$.
2. Creación de regiones de color similar dentro de la imagen.
 - a. Exploración de la imagen píxel a píxel.
 - b. Asignación de cada píxel a una región, según el criterio de agrupamiento (Ver la Sección 3.2.2).
 - c. En caso de que el píxel no pueda asignársele a una región vecina, convertirlo en raíz de una nueva región.
 - d. Por cada píxel nuevo en la región, ajustar el color de la región al promedio del color de los pixeles que la componen.
3. Agrupación de colores entre regiones.
 - a. Ordenamiento por frecuencia de ocurrencia de los colores resultantes hasta el momento.
 - b. Agrupar los colores menos frecuentes con los más frecuentes, siempre y cuando cumplan con el criterio de agrupamiento.
4. Conversión de los colores resultantes del espacio $L^*a^*b^*$ al espacio RGB.

3.2.1 Conversión del espacio RGB al espacio $L^*a^*b^*$

En la primera fase convertimos la imagen que se encuentra en el espacio de color RGB al espacio $L^*a^*b^*$. Este espacio de color fue elegido por su uniformidad perceptual, del cual puede observarse una representación del mismo en la Fig. 15.

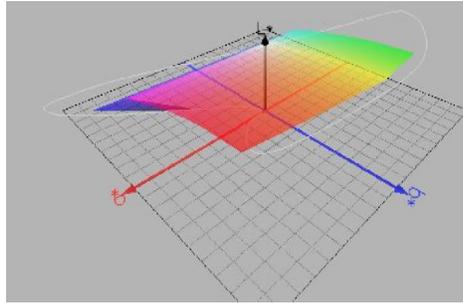


Fig. 15 Espacio CIE L*a*b*.

3.2.2 Generación de regiones de color similares

En la segunda fase los píxeles de la imagen son agrupados para obtener regiones con color homogéneo, lo que se logra con un proceso de crecimiento de regiones donde partiendo de un píxel no procesado, aglomera sucesivamente los píxeles vecinos que cumplen con un criterio de agrupamiento que consiste en la homogeneidad del color. En este trabajo a este criterio lo hemos llamado **nivel de tolerancia**, el cual utilizamos como un límite de la diferencia de color calculado por la expresión de CIE2000. En este proceso se emplea la vecindad 8, ya que los 8 píxeles vecinos de cada píxel son revisados para detectar aquéllos que no han sido asignados a una región. Cuando un píxel no puede ser adherido a una región vecina, entonces éste se convierte en la raíz de una nueva región.

El método propone un nivel de tolerancia con el valor de 8 como una medida general para todos los tipos de imágenes considerados. Más adelante en este trabajo (sección 3.2.2.2) explicaremos las razones tomadas en cuenta para la elección de este valor.

Conforme se van agregando píxeles a una región, éstos van modificando el color de la región. El color de la región es equivalente al del centroide de la agrupación de colores de los píxeles que la conforman en el espacio de color L*a*b*. Este centroide es calculado según la ecuación siguiente:

$$\left(\overline{L^*}, \overline{a^*}, \overline{b^*}\right) = \frac{\sum_{i=1}^n (L_i^*, a_i^*, b_i^*)}{n} \quad (21)$$

donde n es la cantidad de píxeles que conforman la región y L_i^* , a_i^* y b_i^* son las componentes del color de cada uno de estos píxeles. Es el color de la región el que es considerado para ser comparado con el color del resto de los píxeles candidatos

para ingresar. Para generar las regiones es necesario analizar la inclusión o no de cada píxel en las regiones vecinas, o si es el caso, su asignación como raíz de una nueva región. Esto se logra explorando la imagen píxel a píxel.

El algoritmo de generación de regiones empleado permite garantizar una mejor solución en el proceso de cuantificación del color, ya que contribuirá durante el agrupamiento de los píxeles de la imagen en regiones, lograr un mínimo de alteración del color respecto a los presentes en la imagen original. A su vez, nos permite confiar plenamente en que el algoritmo propuesto mantenga los detalles de la imagen con su correspondiente color, forma y orientación.

3.2.3 Elección de los colores esenciales

Después de la fase 2, ya se cuenta con una paleta de colores reducida al número de regiones, donde 2 objetos de la misma clase separados espacialmente entre sí y que visualmente debemos etiquetarlos con el mismo color, podrían tener pequeñas diferencias en sus colores. Para conseguir esto hacemos una reagrupación de los colores siguiendo el algoritmo siguiente:

1. Ordenamos la paleta de colores de mayor a menor frecuencia de aparición de los colores en la imagen.
2. Tomamos el color menos frecuente.
3. Obtenemos una sub-lista de los colores de la paleta que se encuentran dentro del rango de tolerancia preestablecido.
4. Si la sub-lista está vacía, etiquetamos el color como esencial y regresamos al paso 2.
5. Si la sub-lista no está vacía, buscamos el color más cercano según la CIE2000 y los agrupamos.
6. Regresamos al paso 2 hasta haber reagrupado todos los colores.

Al finalizar esta etapa, la imagen ya dividida en regiones con los colores esenciales elegidos para cada una de ellas, puede servir como máscara de segmentación de los objetos presentes en la imagen. Si bien este resultado es colateral al objetivo principal de la tesis, algunos resultados interesantes serán mostrados en el Capítulo 4.

3.2.4 Conversión de la paleta de colores del espacio $L^*a^*b^*$ al espacio RGB

La paleta obtenida al final del paso 3 se encuentra expresada en términos de las componentes $L^*a^*b^*$, por lo que para generar una imagen con los colores de esta

paleta es necesario primeramente convertirla a su equivalente en el espacio RGB, para finalmente elegir el tipo de reconstrucción que se desee, que puede ser indexación, difuminado o bien, mostrar la imagen original dividida en regiones, cada una de ellas de un color esencial particular.

En la Fig. 16 se muestran 4 imágenes donde la imagen original cuenta con 35,121 colores, mientras que las tres imágenes resultado cuentan con solo 33 colores obtenidos mediante la aplicación de la metodología propuesta. Se puede observar la diferencia entre los dos métodos de reconstrucción y la ventaja que tiene la imagen dividida en regiones para ser usada como máscara de segmentación.



Fig. 16 Etapas de la metodología propuesta.

De izquierda a derecha y de arriba hacia abajo: imagen original; imagen reconstruida por indexación; imagen reconstruida por difuminado; imagen dividida en regiones.

3.3 Justificación del nivel de tolerancia seleccionado

Para determinar un aceptable nivel de tolerancia que nos permitiera emplear el método de cuantificación propuesto con el mayor número de imágenes de diferente tipo (Ver Sección 1.5), se realizó un análisis exhaustivo el cual se expone en el capítulo 5. Para alcanzar este objetivo, fue necesario crear y analizar las gráficas de *cantidad de colores final* versus *nivel de tolerancia* de los tipos de imágenes considerados.

Las imágenes de prueba analizadas con nuestro método de cuantificación y sus respectivas gráficas de colores resultantes para distintos valores del nivel de tolerancia, muestran claramente el lugar donde ocurre un cambio brusco de la pendiente, la cual va a constituir nuestra zona de análisis.

Capítulo 3 Metodología propuesta

Para todas las imágenes analizadas se observa que nuestro método de cuantificación reduce de manera (cercanamente) exponencial los colores de la imagen, tomando como asíntota el valor 1 para el número de colores. En todas las gráficas vemos que existe una zona donde hay un cambio apreciable en la pendiente de la misma, el cual tiene lugar para el nivel de tolerancia entre los valores 6 y 10 para todos los tipos de imágenes considerados. Por esto, el nivel de tolerancia global más aceptable se ha establecido en el valor de ocho. Un nivel de tolerancia 0 nos arroja la cantidad de colores originales y en cada imagen hay un nivel de tolerancia que agrupa a un solo color.

No obstante estos resultados, se buscó otro análisis que confirmara que el nivel de tolerancia elegido para una imagen cualquiera fuera el más aceptable.

La imagen resultado de regionalizar todos los píxeles nos da una herramienta para segmentar objetos de la imagen, al utilizarla como una máscara para la segmentación. Mientras más regiones contenga una imagen, es evidente que conservará mayor número de detalles; una pequeña cantidad de regiones significa que la imagen contiene pocos objetos o bien que varios de los objetos se han perdido durante el proceso de cuantificación.

Si bien es cierta que la cantidad de colores de la imagen resultado es obtenida a partir de los colores de las distintas regiones generadas, estos dos conceptos no son necesariamente linealmente dependientes, ya que varias regiones pueden compartir el mismo color. Por ello la calidad de la imagen en términos de apreciación de los detalles puede medirse por la cantidad de regiones que tiene la misma; cada región está formada por píxeles del mismo color que se encuentran conectados por su vecindad. A más regiones en la imagen, mejor apreciación de los detalles en la misma, como se observa en la Fig. 17.

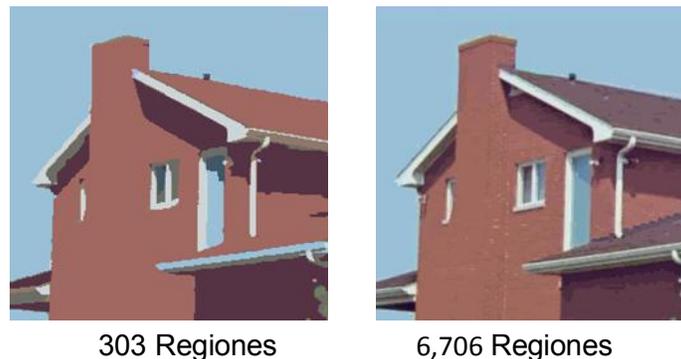


Fig. 17 Imagen regionalizada.
A la izquierda imagen resultado, a la derecha imagen original.

Dado que se encuentra implícita en la cuantificación del color una disminución del número de regiones independientes, siempre existe por lo tanto una pérdida de calidad en la imagen cuantificada. Por lo tanto, podemos plantearnos el objetivo de reducir la mayor cantidad de colores con la menor pérdida de regiones. Esto se puede expresar como:

$$\begin{aligned} \text{Cantidad de colores} &\rightarrow 0 \\ \text{Cantidad de regiones} &\rightarrow \infty \end{aligned}$$

Por lo tanto, cuando la proporción *Número de Colores Esenciales/Número de Regiones* tiende a 0 (cero), pasa a ser la mejor solución para la cuantificación.

De nuestro análisis, se generaron gráficas de este tipo, de donde se puede observar en ellas un punto mínimo el que por lo general es único. Este punto se puede considerar como el nivel de tolerancia que da más regiones con menos colores. Se puede observar claramente cómo el nivel de tolerancia que brindaría mejores resultados con las imágenes de todos los tipos, se encuentra en valores bajos del nivel de tolerancia. Esto corrobora el hecho de que el nivel de tolerancia preestablecido en ocho, conserva su validez como un valor global para cualquiera de los tipos de imágenes considerados.

De aquí se desprende que con este mismo criterio, podríamos optimizar el algoritmo para lograr una mejor calidad de la imagen cuantificada, si el nivel de tolerancia es calculado para cada imagen que se desee cuantificar. En este caso, se trataría de mejorar la velocidad de ejecución del algoritmo, ya que su cómputo implicaría correr el algoritmo para cada imagen con diversos valores del nivel de tolerancia. Como apreciamos en las gráficas mostradas en la sección 4.3, el nivel de tolerancia puede acotarse a los primeros 20 valores, lo que implicaría 20 veces más el tiempo de cómputo requerido.

La situación particular que se presenta con las imágenes de texto en un fondo de color constante, es la inmensa cantidad de objetos independientes (regiones) que puede presentar (número de caracteres y símbolos presentes en el texto), frente a un mínimo de colores “óptimo” en la imagen cuantificada (dos solamente para lograr el mejor contraste). Esto da lugar a que en este caso la gráfica *Número de colores / Número de regiones vs. Nivel de tolerancia*, presente el resultado tan discrepante para el nivel de tolerancia, con respecto al obtenido para el resto de los tipos de imágenes.

3.4 Interfaz gráfica desarrollada

Para la implementación del algoritmo propuesto se generó una herramienta sencilla de usar, la que al adicionársele métodos de procesamiento de imágenes se logró una robusta interfaz para el análisis de imágenes.

La herramienta fue desarrollada en *Borland C++ Builder Versión 7*, en un equipo con 512MB de memoria RAM y un procesador AMD de 1Ghz, con el sistema operativo Windows XP. El archivo ejecutable fue compilado para poder contar con transportabilidad, lo que aseguró que pueda ejecutarse en otros equipos sin necesidad de una instalación previa. El icono de la aplicación se muestra en la Fig. 21.

La interfaz gráfica tiene las siguientes características generales:

- Todos los comandos y menús están escritos en idioma inglés.
- Está centrada en el usuario.
- Es robusta.
- Es amigable con el usuario.
- Los comandos se seleccionan mediante menús.
- Se incorporaron menús contextuales y secuencias de teclas para facilitar su operación.
- Muestra realimentación visual del estado corriente de los procesos.
- Brinda mensajes de errores cortos y concisos.
- Es visualmente agradable a la vista.
- Bloquea las opciones no válidas.
- Los nombres de los comandos y los menús son descriptivos y están organizados de forma lógica y jerárquica.
- De acuerdo a un código preconcebido, se establece automáticamente el nombre de cada imagen que se cree, el cual aparece en la barra de título situada encima de la ventana donde se muestra la imagen.

3.5 Descripción de la aplicación

Al operar con el sistema, que tiene como icono el mostrado en la Fig. 18, lo primero que aparece es la pantalla principal (Fig. 19). Los menús en esta ventana principal, cuando no se ha abierto ninguna imagen son los siguientes:

Capítulo 3 Metodología propuesta

File / Open Image:

Abre una imagen digital y la muestra (Comando *File/Open*). Se puede elegir entre los formatos gráficos más comunes de imágenes como BMP, JPG, GIF, EMF, WMF.

File / Exit:

Cierra la aplicación.

Análisis de colores / Color Analysis:

Despliega la ventana de la Fig. 20 creada para comparar dos colores mostrados en RGB, se obtiene su valor equivalente en el espacio $L^*a^*b^*$, así como distintas distancias entre ellos, tales como la euclidiana en RGB, la *City block* (o *Manhattan*) en RGB, la Euclidiana en $L^*a^*b^*$ y la CIE2000. El propósito principal de esta ventana fue el análisis de las distintas métricas para medir la diferencia entre los colores, así como el papel que juegan en ellas los espacios RGB y $L^*a^*b^*$.

Window / Horizontal, Vertical, Cascade:

Distribuye en la pantalla las imágenes abiertas en distintas ventanas independientes de manera horizontal, vertical o en cascada. Estas opciones están inhabilitadas mientras no se tenga ninguna imagen abierta.

Al abrir una imagen, en la ventana principal (Fig. 19) se muestra la información siguiente de la misma:

- Muestra las coordenadas relativas (al origen de la imagen) del puntero sobre la imagen y los valores RGB de las componentes del píxel ubicado en esa posición.
- Muestra la cantidad total de colores de la imagen seleccionada.
- Muestra las dimensiones de la imagen seleccionada.

A su vez, en la ventana principal se dispone de los siguientes menús:

File / Save As:

Salva la imagen seleccionada con el nombre predefinido o con alguno que asigne el usuario. En esta opción se puede seleccionar entre los formatos más comunes de imágenes, aunque es recomendable utilizar únicamente BMP para evitar cambios en los colores o en su cantidad, debido a algún tipo de compresión intrínseca con el formato.

File / Close:

Cierra la imagen activa.



Fig. 18 Icono de la aplicación.

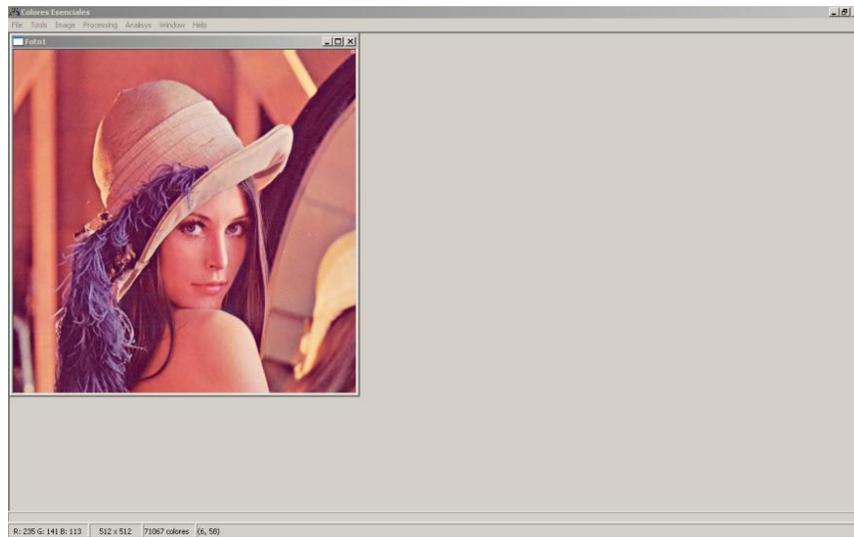


Fig. 19 Ventana principal con imagen.

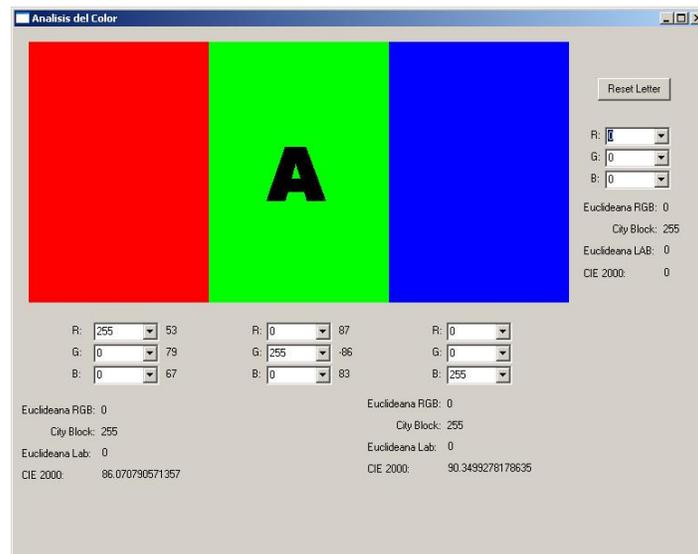


Fig. 20 Ventana de análisis de imagen.

File / Close All:

Cierra todas las imágenes abiertas.

Tools / Flip/Rotate:

Rota 45, 90 o 180 grados la imagen seleccionada, o bien invierte la imagen por su eje horizontal o vertical.

Tools / Stretch:

Cambia el tamaño de la imagen seleccionada.

Tools / Revert colors:

Revierte los colores de la imagen seleccionada, donde para cada píxel RGB aplica la transformación (255-R, 255-G, 255-B).

Tools / Operations:

Ventana donde se pueden elegir ya sea dos imágenes o una imagen y una constante, para seleccionar después alguna operación dada (Fig. 21). Las operaciones disponibles son:

Aritméticas: Suma, resta, multiplicación, división; Lógicas: Y, O, O Exclusivo; Mínimo, Máximo, Promedio, Diferencia, Error cuadrático medio³, Reconstrucción por indexación y Reconstrucción por difuminado⁴.

Tools / View Lens:

En una ventana aparte, se muestra una ampliación (*Zoom*) de la zona de la imagen donde se encuentra el cursor (Fig. 22). Debido a su actualización en tiempo real, se puede observar la imagen original ampliada al mover el cursor sobre ella. Adicionalmente, se cuenta con la opción de fijar la ampliación dando doble clic sobre la ventana, lo que genera una imagen aparte que puede ser posteriormente salvada.

Image / Histogram:

Genera el histograma de la imagen seleccionada, de las tres componentes RGB, así como el histograma en escala de grises calculado mediante el promedio de las 3 componentes RGB (Fig. 23).

Image / Split / RGB, CMY, Lab:

Hace la conversión de la imagen en colores seleccionada al espacio elegido y muestra cada componente en una imagen separada.

³ Medida utilizada para la evaluación de los resultados; su uso es explicado en el Capítulo 4.

⁴ Los colores contenidos en la imagen 2, son tomados como la paleta de colores que ha ser empleada en los métodos de reconstrucción.

Image / LUT (Look-Up-Table) / by Luminance, by Frequency.

Muestra la tabla de colores (LUT) de la imagen seleccionada ordenada por la luminancia (valor L^* en el espacio $L^*a^*b^*$) o por la frecuencia de ocurrencia. Junto con el color aparecen el número de píxeles que tienen ese color y su por ciento respecto al total de píxeles de la imagen.

Image / LUT / Generate image, Generate text.

Una vez que ha sido desplegada la tabla de colores, estas opciones se habilitan para generar, ya sea una imagen contenedora de todos los colores que componen la LUT, o bien un archivo de texto con los códigos de los colores de la LUT.

Processing / Quantization.

Ejecuta la metodología propuesta para la cuantificación del color de la imagen seleccionada; para ello se muestra una ventana auxiliar donde, si así se desea, se puede variar el nivel de tolerancia y seleccionar el método de reconstrucción de la imagen. El valor implícito del nivel de tolerancia es ocho. El método implícito entrega la imagen regionalizada, de la cual se puede obtener la paleta de colores con las opciones de la LUT mostradas anteriormente (Fig. 24).

Processing / Morphology / Dilation, Erosion, Edge detection (LdG).

Ejecuta las operaciones morfológicas de dilatación, erosión y detección de bordes, este último por el método del Laplaciano del Gaussiano. Estas operaciones se realizan con un elemento de estructura plano cuadrado de 3 x 3 píxeles.

Processing / Binary.

Convierte la imagen seleccionada en binaria, tomando el valor RGB en escala de grises (127, 127, 127) como umbral.

Processing / Gray Scale.

Convierte la imagen seleccionada en una imagen en escala de grises mediante el promediado de sus componentes RGB.

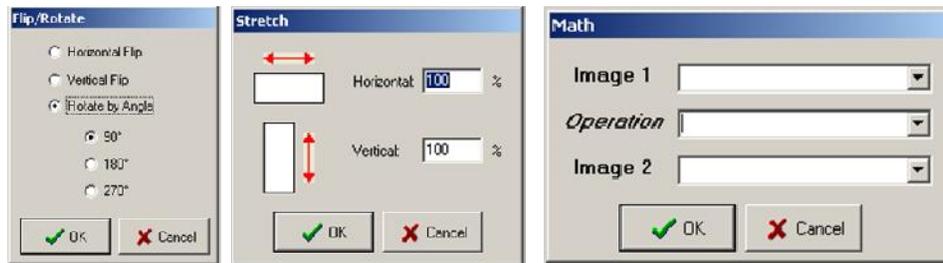


Fig. 21 Ventanas auxiliares de los comandos *Flip/Rotate*, *Stretch* y *Operations*.

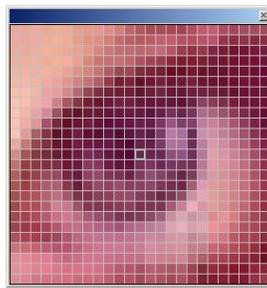


Fig. 22 Ventana de ampliación de 25 x 25 píxeles.

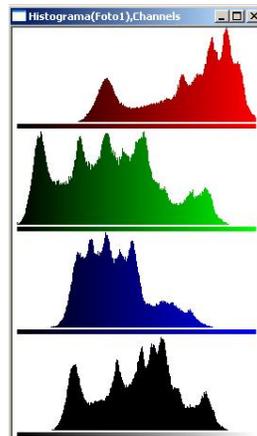


Fig. 23 Histogramas generados.

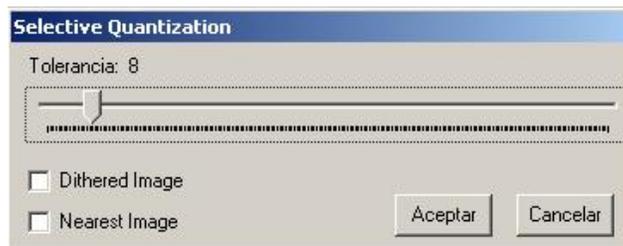


Fig. 24 Ventana auxiliar de la metodología propuesta.

Adicionalmente, se ha programado un menú contextual al cual el usuario tiene acceso dando clic con el botón derecho del ratón (*Mouse*).

Menú contextual / Segmentation / Create Mask

Genera una máscara de segmentación a partir del color del píxel sobre el cual se dio clic. En una imagen regionalizada, el resultado de aplicar la máscara será equivalente a la segmentación de los objetos de ese color en la imagen sobre la cual se aplica la máscara.

Menú contextual / Segmentation / Add to Mask

Suma otra máscara a la máscara previamente generada.

Menú contextual / Segmentation / Apply Mask

Aplica la máscara generada a la imagen seleccionada, de donde se extraen todos los píxeles que cubre la misma.

Menú contextual / CIE2000 / Select color 1, Select color 2

Permite obtener la diferencia mediante la fórmula CIE2000 entre 2 colores seleccionados.

3.6 Procedimiento detallado de la metodología propuesta

La metodología propuesta implementada con la herramienta desarrollada es descrita paso a paso:

1. Se carga del disco la imagen a cuantificar (Comando *File / Open*).
2. Se va al menú *Processing* y se ejecuta la opción *Quantization*.
3. Si se desea obtener una imagen reconstruida por indexación o por difuminado se selecciona la opción deseada. En caso de querer probar con otros niveles de tolerancia diferente al implícito de ocho, se varía éste; se da clic al botón Aceptar.
4. La(s) imagen(es) generada(s) contiene(n) los colores esenciales de la imagen; si se desea tener una lista de los mismos seleccionando cualquiera de estas imágenes se va al menú *Image / LUT* y se genera la lista, ya sea en una imagen o en un archivo de texto.

4 Evaluación de los resultados

Resumen. En este capítulo se presentan los resultados experimentales al aplicar el método de cuantificación desarrollado y descrito en el capítulo anterior. Los resultados demuestran la capacidad del método para obtener los colores esenciales de la imagen. Se muestran los resultados obtenidos con algunas técnicas clásicas y actuales de cuantificación, con las cuales comparamos nuestro método.

4.1 Introducción

En esta sección se muestran las imágenes utilizadas para evaluar el algoritmo de cuantificación desarrollado. Las mismas se han dividido en bloques según la fuente. Se ha procurado incluir en cada bloque imágenes las características detalladas en la sección 1.5 para lograr tener imágenes en las categorías consideradas: caricaturas, naturales, publicitarias, pinturas, mapas y textos. Sin embargo, hay imágenes que han sido difíciles de clasificar en una categoría dada, debido a que tienen características de más de una categoría.

Capítulo 4 *Evaluación de resultados*

Todos los bloques de imágenes presentan las imágenes resultantes al aplicar el algoritmo de Corte de Mediana, el algoritmo de componentes Principales y desde luego el algoritmo propuesto en este trabajo, además de un análisis específico a tratar para el bloque.

Para todos los bloques se muestran los resultados obtenidos para el análisis del nivel de tolerancia explicado en la sección 4.3.

Capítulo 4 *Evaluación de resultados*

Para el primer bloque denominado "Color" las imágenes fueron obtenidas de la base de datos de la Universidad del Sur de California - USC [UCS Universidad del sur de California, 2008]. Estas imágenes se consideran las clásicas para evaluar la eficacia de los algoritmos que se utilizan en el procesamiento y el análisis de imágenes (Fig. 25).

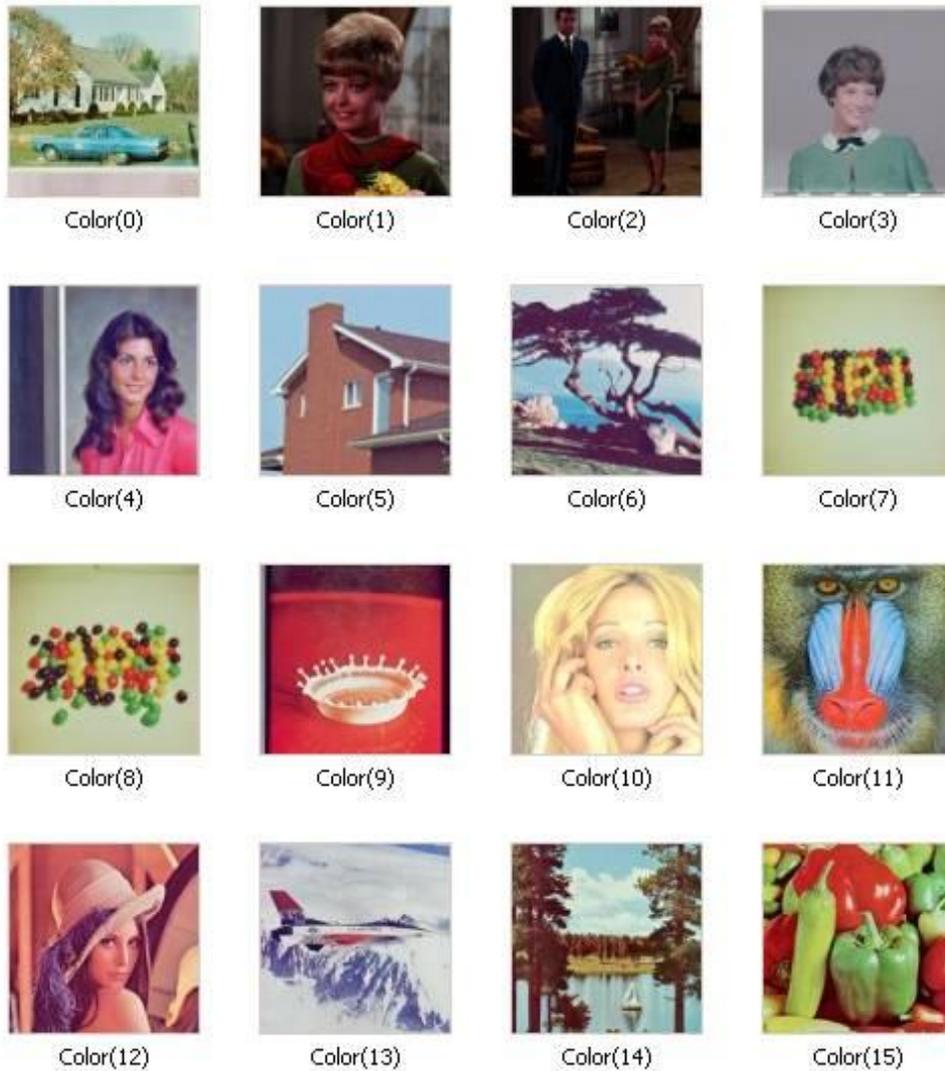


Fig. 25 Bloque 1 "Color".

Capítulo 4 *Evaluación de resultados*

El segundo bloque denominado “Otras” fueron imágenes diversas obtenidas de fuentes y medios heterogéneos como escáner, imágenes Web, etc. Estas pretenden demostrar las ventajas del algoritmo para tareas específicas, así como su universalidad. (Fig. 26)

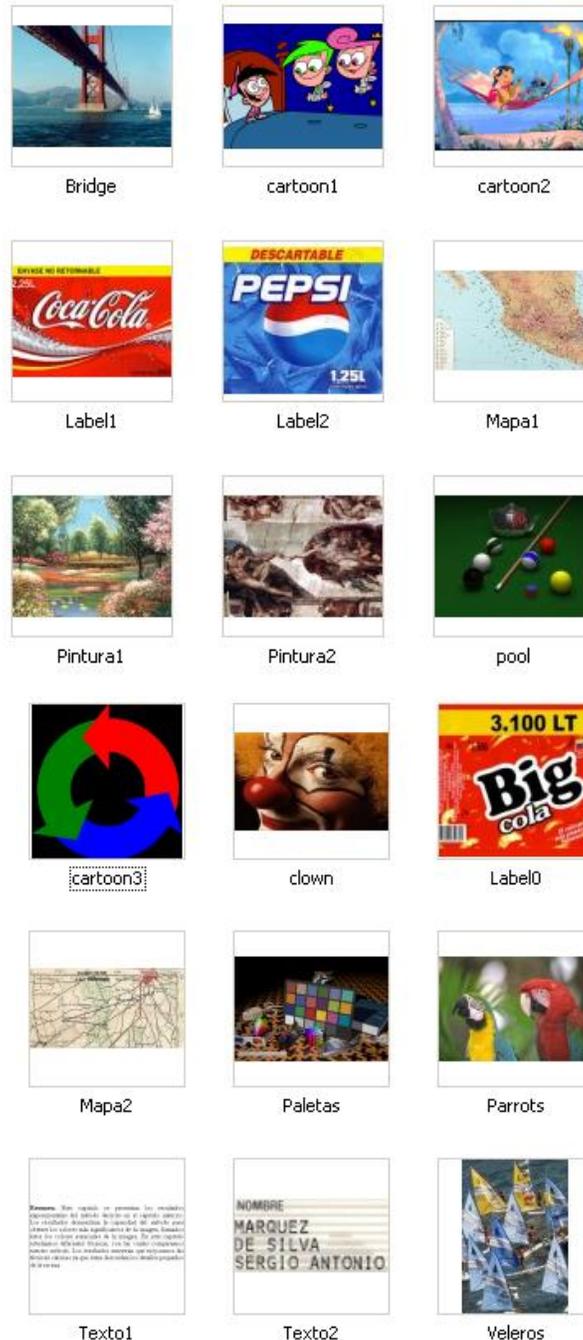
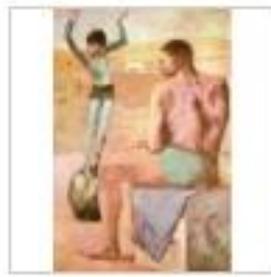


Fig. 26 Bloque 2 "Otras" .

Capítulo 4 *Evaluación de resultados*

El tercer bloque “Picasso”, como su nombre lo indica, son imágenes digitalizadas de algunas pinturas de Pablo Picasso, debido a que el manejo de los colores presentes en ellas crea un gran reto para cualquier algoritmo de cuantificación para lograr una correcta selección de los colores esenciales (Fig. 27).



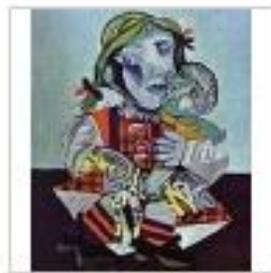
Picasso(0)



Picasso(1)



Picasso(2)



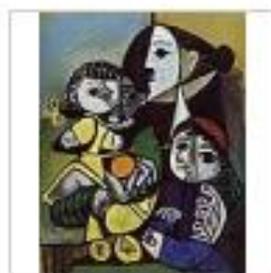
Picasso(3)



Picasso(4)



Picasso(5)



Picasso(6)



Picasso(7)



Picasso(8)

Fig. 27 Bloque 3 "Picasso".

Capítulo 4 *Evaluación de resultados*

El cuarto bloque “Memorama”, son imágenes de tres tarjetas de un juego de memorama, en la que encontramos una manzana, una rosa y una pera; digitalizadas 2 veces para cada tarjeta en diferente posición y una vez más todas juntas. Se pretende hacer un análisis de la varianza de los resultados para cada uno de los tipos de objetos (Fig. 28).



Fig. 28 Bloque 4 "Memorama".

Capítulo 4 *Evaluación de resultados*

El quinto bloque llamado "Rayos X", contiene 5 imágenes de radiografías en niveles de gris (Fig. 29).



Fig. 29 Bloque 5 "Rayos X".

Y por último, el sexto bloque llamado "Rostros", con las imágenes de la cara de 12 personas tomadas a partir de fotografías tamaño infantil (Fig. 30).



Fig. 30 Bloque 6 "Rostros".

En total, el algoritmo se trabajó con un total de 67 imágenes.

Para comparar los resultados obtenidos con los otros métodos elegidos de cuantificación del color, se siguió el siguiente procedimiento:

- 1.- Cuantificar con nuestro método los colores de una imagen de cada tipo con el nivel de tolerancia ocho y anotar la cantidad de colores que resultó de la cuantificación.
- 2.- Ajustar los otros algoritmos de cuantificación a la cantidad de colores que se obtuvieron con el método propuesto.
- 3.- Mostrar la paleta de colores construida con cada método y regenerar la imagen mediante el algoritmo de difuminado de *Floyd-Steinberg*, o por el del color más cercano, según el caso.

4.2 Análisis según los colores obtenidos

En las figuras 31, 32, 33, 34, 35 y 36 se muestran las gráficas con el total de colores obtenidos para las imágenes de cada bloque para los distintos niveles de tolerancia; esta prueba fue parte del análisis realizado para elegir como valor global el nivel de tolerancia ocho. Como puede observarse en las gráficas, la cantidad de colores se reduce siempre drásticamente con niveles de tolerancia menores que 10. Las gráficas son mostradas a partir del nivel de tolerancia 2, dado que con los niveles de tolerancia 1 y 0 (la cantidad original de colores), las gráficas exigirían una escala tal que sería difícil apreciar los resultados.

Las tablas 2 y 3 resumen la cantidad de colores que tenían originalmente las imágenes de cada bloque y la cantidad de colores final que se obtuvo al aplicar el algoritmo de cuantificación propuesto, siempre con el nivel de tolerancia ocho.

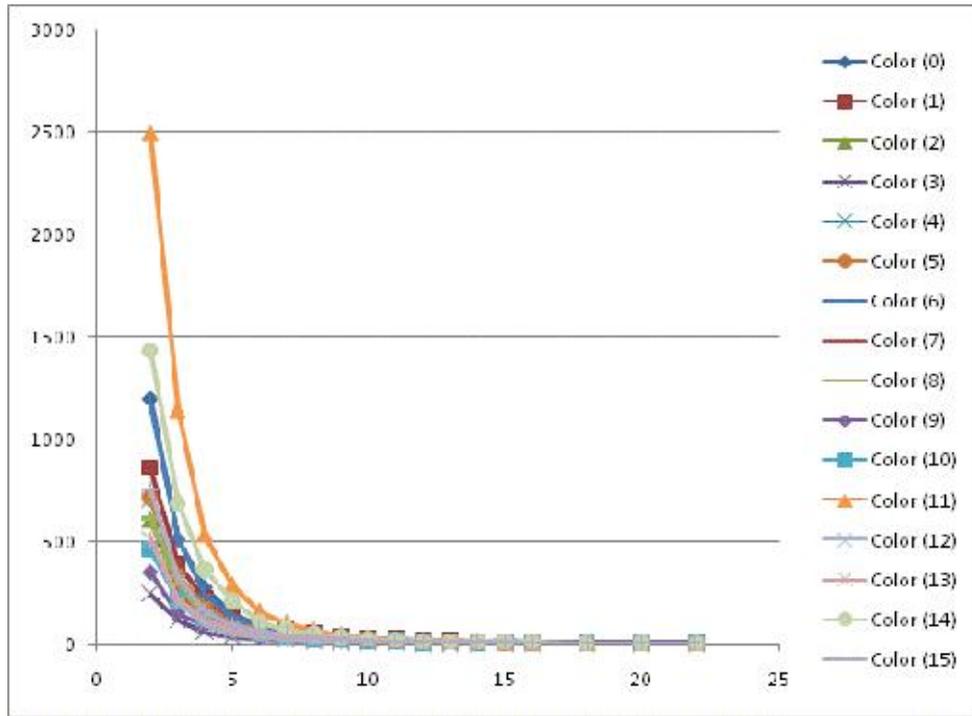


Fig. 31 Tolerancia vs. Cantidad de colores. Bloque 1: Color.

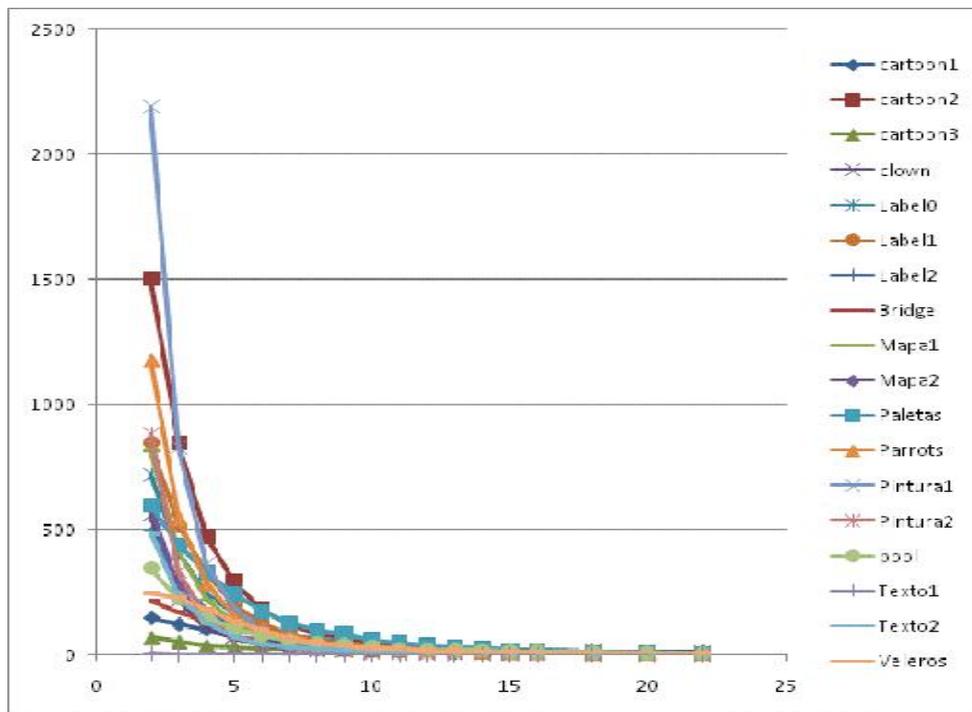


Fig. 32 Tolerancia vs. Cantidad de colores. Bloque 2: Otras.

Capítulo 4 *Evaluación de resultados*

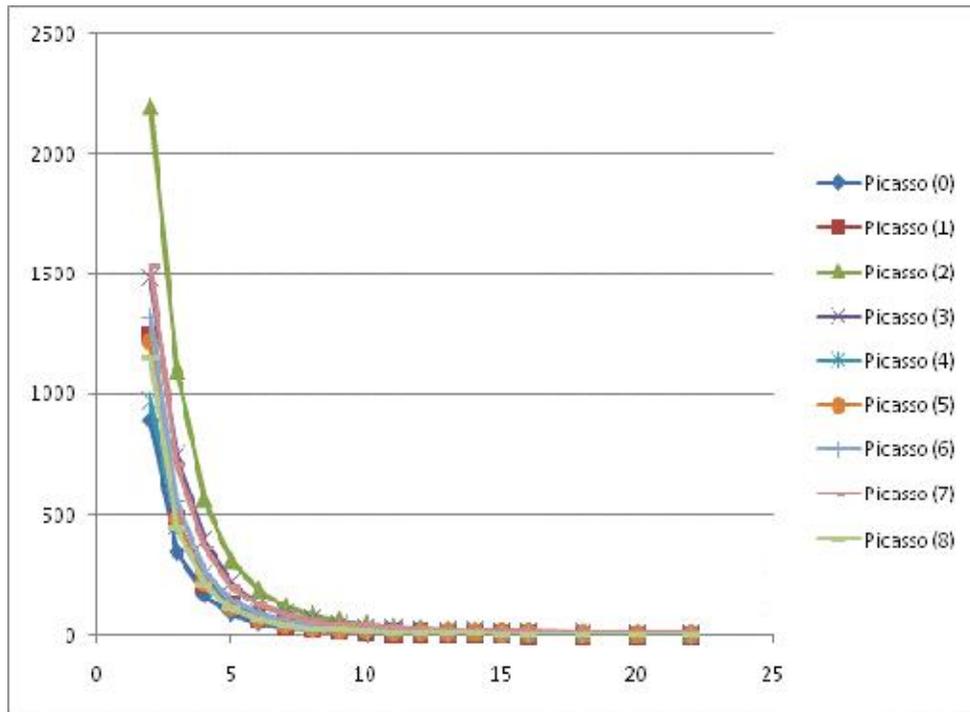


Fig. 33 Tolerancia vs. Cantidad de colores. Bloque 3: Picasso.

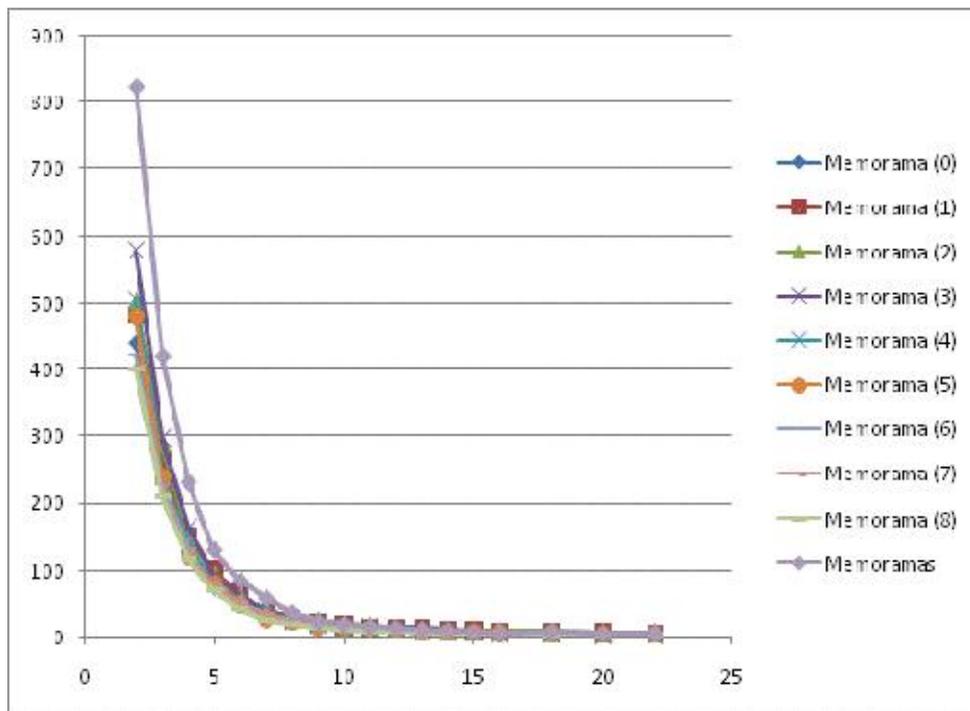


Fig. 34 Tolerancia vs. Cantidad de colores. Bloque 4: Memorama.

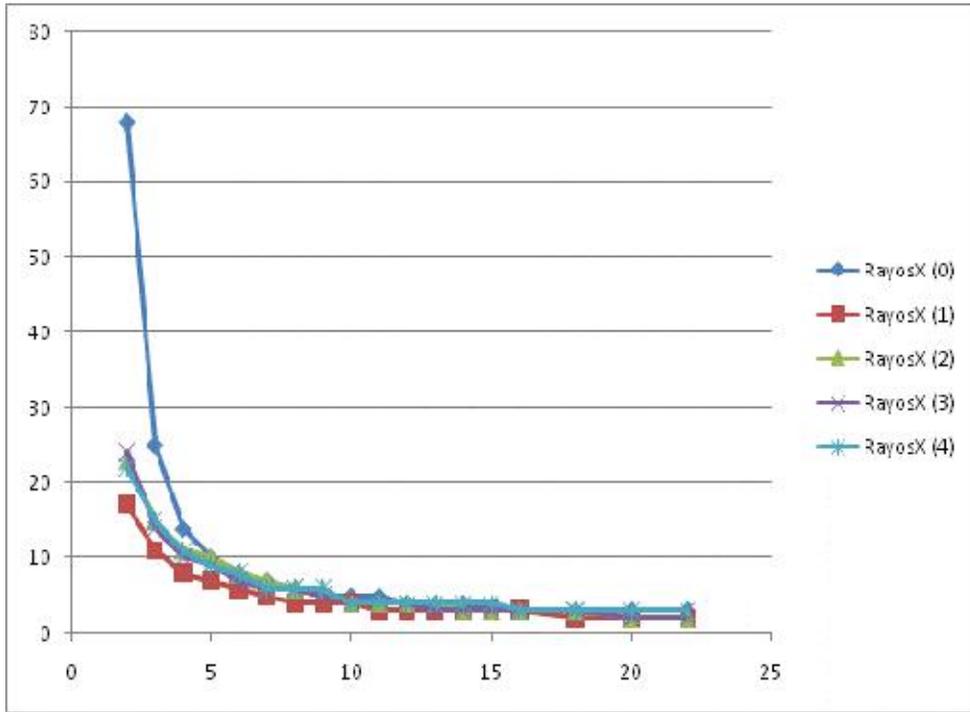


Fig. 35 Tolerancia vs. Cantidad de colores. Bloque 5: Rayos X.

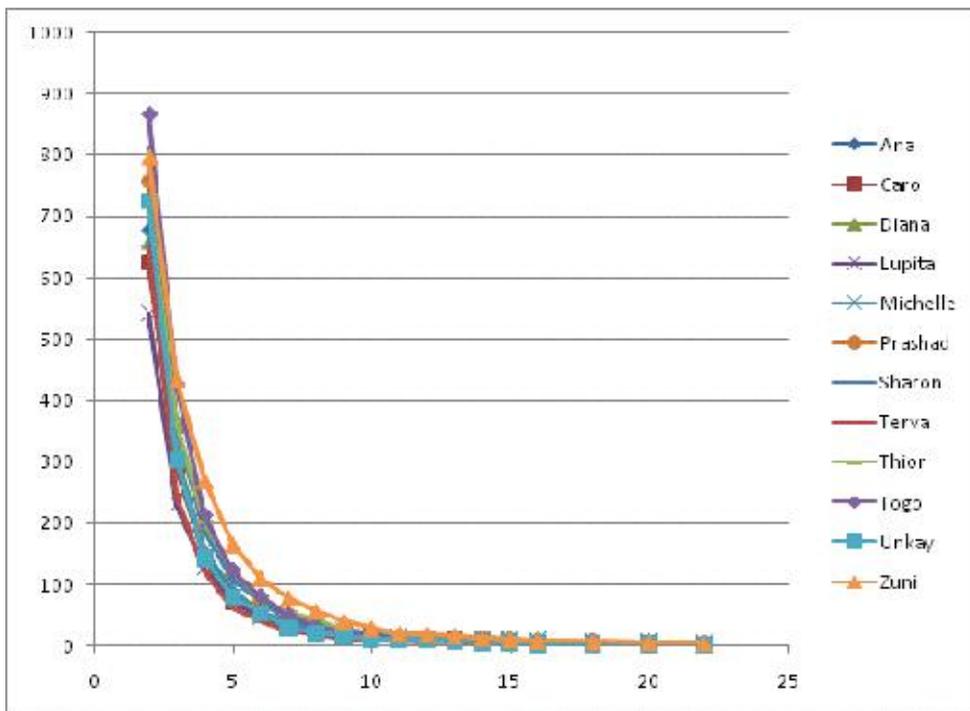


Fig. 36 Tolerancia vs. Cantidad de colores. Bloque 6: Rostros.

Tabla 2 Cantidad de colores originales y obtenidos para los bloques 1 y 2.

Nombre	Cantidad de colores	
	Original	Obtenidos
Bloque 1: Color		
Color(0)	106383	46
Color(1)	27639	48
Color(2)	18608	35
Color(3)	9212	13
Color(4)	28407	40
Color(5)	20513	33
Color(6)	33196	45
Color(7)	14219	25
Color(8)	20369	24
Color(9)	47785	21
Color(10)	50757	22
Color(11)	176371	66
Color(12)	70589	16
Color(13)	48333	27
Color(14)	102904	54
Color(15)	108807	34
Bloque 2: Otras		
Bridge	256	48
cartoon1	397	41
cartoon2	63420	79
cartoon3	894	24
Clown	32959	23
Label0	27414	67
Label1	32061	61
Label2	42376	47
Mapa1	144997	38
Mapa2	36084	22
Paint1	306233	46
Paint2	103316	22
Paletas	63268	98
Parrots	35120	44
Pool	21010	43
Texto1	158	2
Texto2	2989	24
Veleros	255	52

Tabla 3 Cantidad de colores originales y obtenidos para los bloques 3, 4, 5 y 6.

Nombre	Cantidad de colores	
	Original	Obtenidos
Bloque 3: Picasso		
Picasso(0)	65812	24
Picasso(1)	113931	35
Picasso(2)	81144	83
Picasso(3)	58569	61
Picasso(4)	67267	38
Picasso(5)	90904	29
Picasso(6)	79774	43
Picasso(7)	104573	54
Picasso(8)	86372	28
Bloque 4: Memorama		
Memo (1)	33612	26
Memo (2)	34599	30
Memo (3)	35549	27
Memo (5)	31513	23
Memo (6)	28678	26
Memo (7)	27317	26
Memo	53845	36
Bloque 5: Rayos X		
RayosX(0)	3851	6
RayosX(1)	285	4
RayosX(2)	366	6
RayosX(3)	297	6
RayosX(4)	256	6
Bloque 6: Rostros		
Ana	11357	35
Caro	12238	25
Diana	10327	28
Lupita	10632	28
Michelle	11735	29
Prashad	12082	35
Sharon	13638	33
Terva	14707	18
Thior	11932	42
Togo	13748	33
Unkay	14335	22
Zuni	10724	56

Capítulo 4 *Evaluación de resultados*

Tabla 4 Valores estadísticos de la cantidad de colores obtenidos por bloque.

Bloque	Mínimo	Máximo	Promedio	Mediana
1 Color	13	66	34.31	33.5
2 Otros	2	98	43.38	43.5
3 Picasso	24	83	43.88	38
4 Memorama	23	36	27.71	26
5 Rayos X	4	6	5.6	6
6 Rostros	18	56	32	31

Se puede observar que las imágenes de los bloques 2 y 5 tienen menos colores. Primeramente, en el bloque 2 tenemos la imagen de texto1, la cual a pesar de contar con 158 colores inicialmente, el algoritmo la cuantificó a solo dos colores. Este es un resultado esperado, pues es claramente visible en esta imagen que solo cuenta en lo fundamental con el color del fondo y el color de los caracteres. En el bloque 5, “Rayos X”, observamos que el resultado brinda también una pequeña cantidad de colores, la mayoría con tan solo 6 colores (niveles de gris) o menos.

En las figuras 37, 38 y 39 se agrupan todos los bloques con las mismas imágenes, ordenadas de izquierda a derecha y de arriba hacia abajo, por la cantidad de colores obtenidos con el algoritmo de cuantificación propuesto.

Se demuestra que no tienen nada que ver con el resultado obtenido, la cantidad de colores originales y el tamaño de la imagen. Los colores aquí encontrados dependen de manera intrínseca de las propiedades y distribución relativa de los objetos que componen la imagen.

Capítulo 4 *Evaluación de resultados*

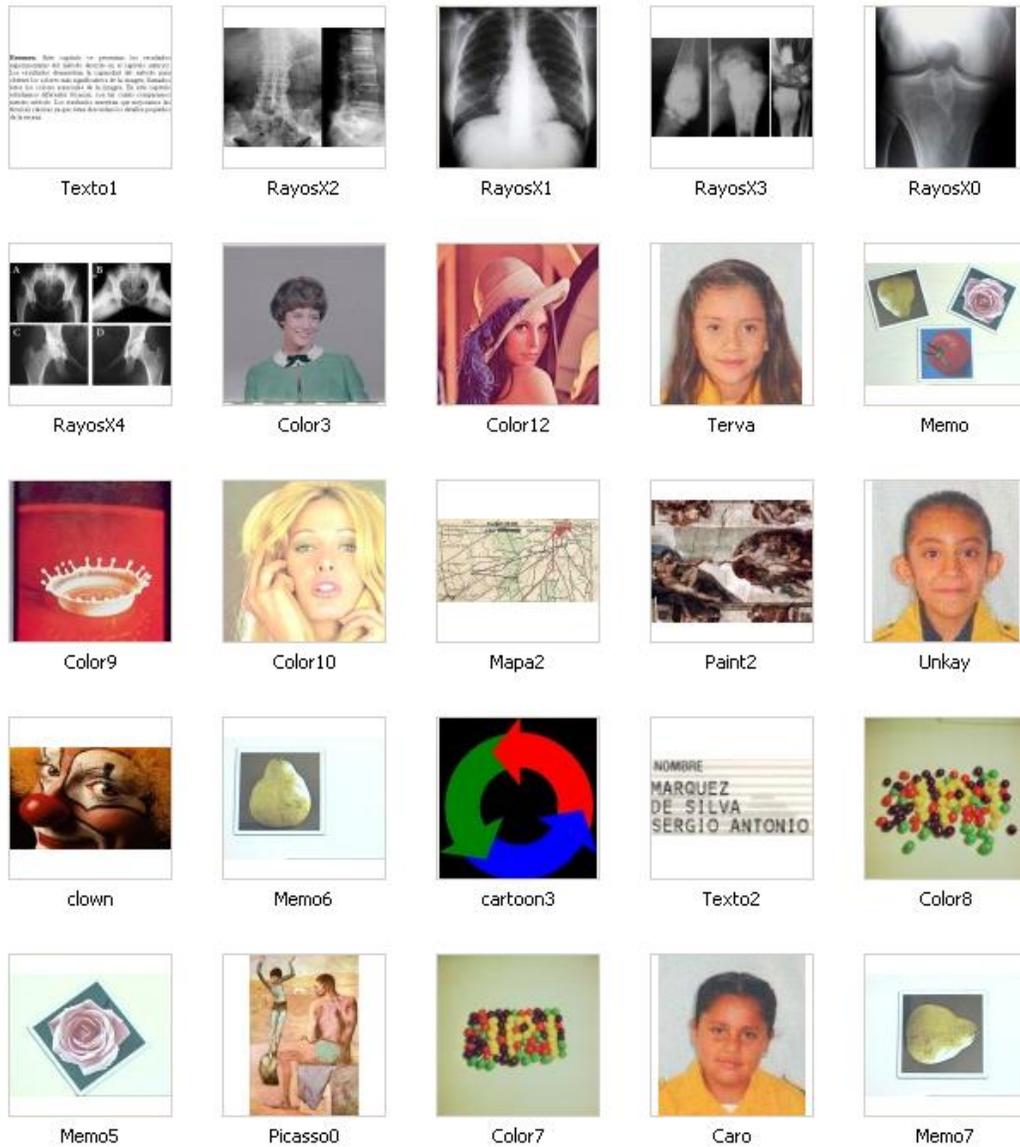


Fig. 37 Imágenes ordenadas por su cantidad de colores encontrados (parte 1).

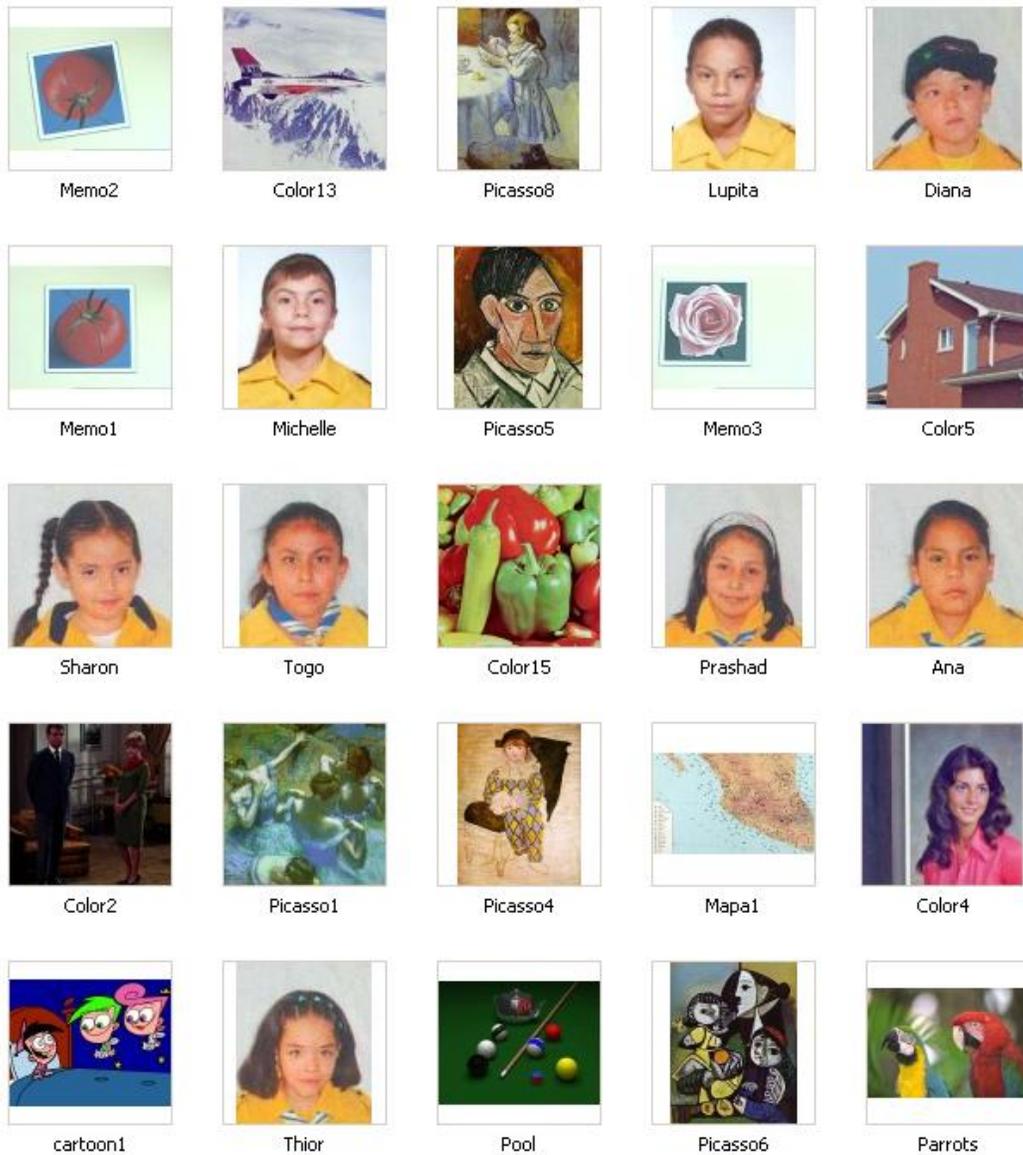


Fig. 38 Imágenes ordenadas por su cantidad de colores encontrados (parte 2).

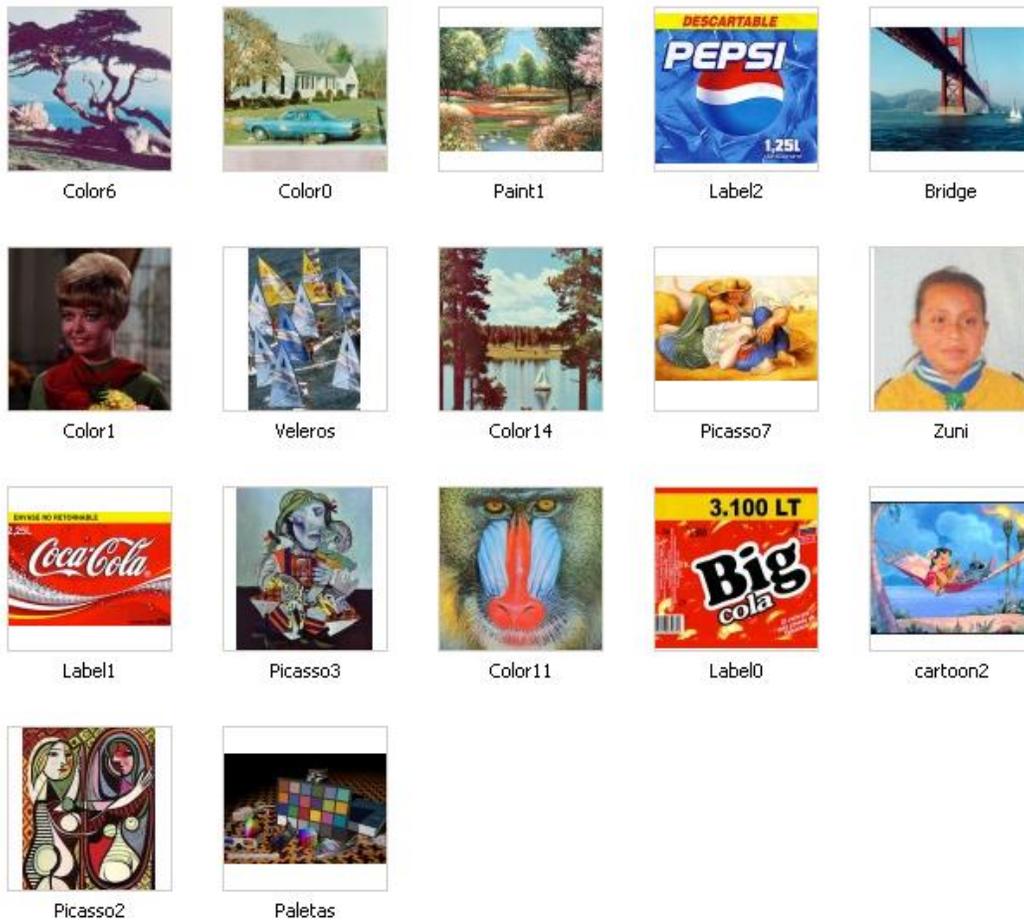


Fig. 39 Imágenes ordenadas por la cantidad de colores final con que quedaron (parte 3)

Se ha utilizado el bloque del “Memorama” para analizar cómo imágenes semejantes arrojan colores semejantes y la misma cantidad aproximada de estos. Los colores mostrados en las paletas de colores (PC) de cada imagen (figuras 40, 41, 42 y 43) están ordenados de izquierda a derecha y de arriba hacia abajo por su frecuencia de ocurrencia en la imagen.

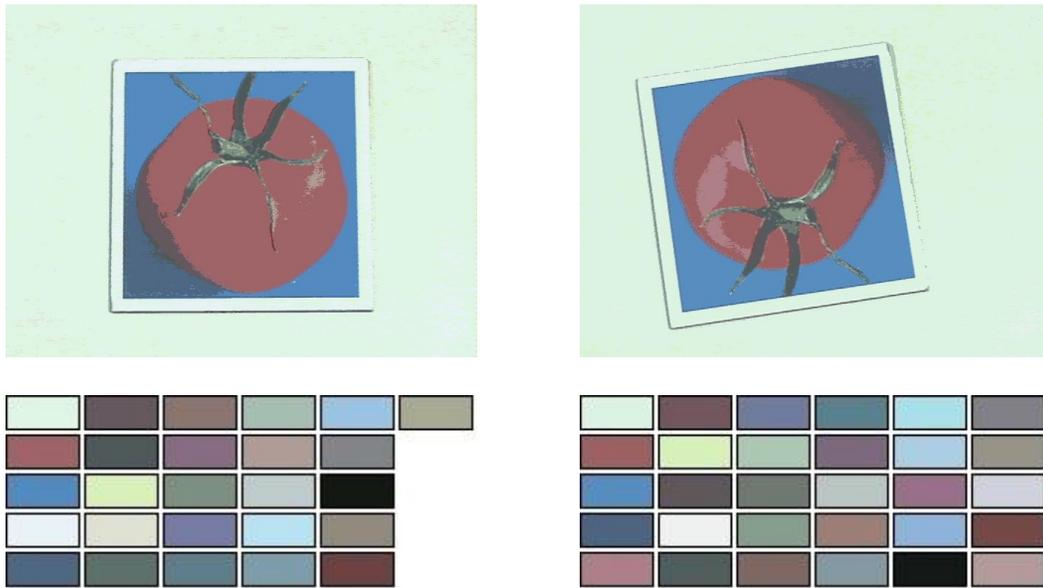


Fig. 40 Imágenes del jitomate con su PC.



Fig. 41 Imágenes de la rosa con su PC.

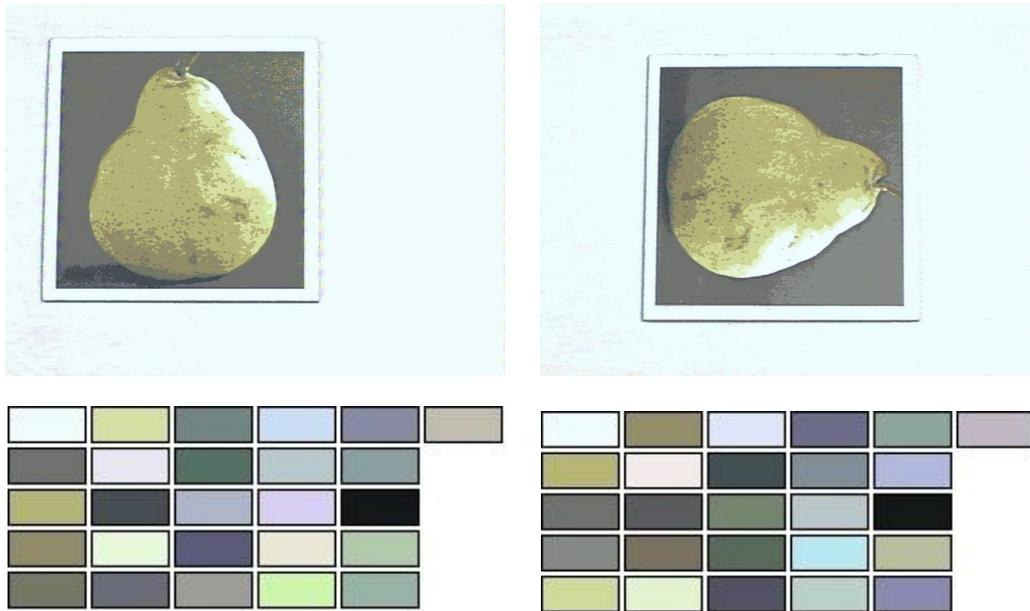


Fig. 42 Imágenes de la pera con su PC.

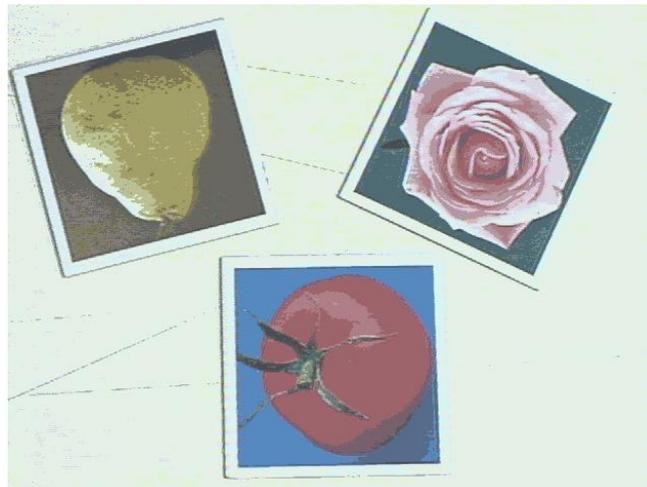


Fig. 43 Imagen con las tres cartas del Memorama y su PC.

Como puede observarse en las imágenes individuales, los 3 colores más frecuentes que representan el fondo de la imagen, el fondo de la tarjeta y el color representativo del objeto, se conservan en sus diferentes versiones. La cantidad de colores que ha resultado varían para el caso del jitomate y de la rosa tan solo en 4 colores, mientras que en la imagen de la pera no hay variación en la cantidad de colores.

En la imagen que agrupa las 3 tarjetas del Memorama (Fig. 43) presenta una mayor cantidad de colores como era de esperarse. Se puede observar cómo los colores representativos para cada imagen se han conservado en ésta; además, los comunes en las tres tarjetas (como el del fondo de la imagen) se ha agrupado en uno solo. Esto nos indica que se logra una PC general igual a la suma del conjunto de colores de las PC de cada imagen individual, lo cual puede ser ventajoso en las aplicaciones donde se trabaja con escenas similares del mismo tipo y objetos con colores que varían poco entre una toma y otra.

4.3 Cantidad de colores vs. Cantidad de regiones

Como es mencionado en la sección 3.3 el análisis de la relación existente entre la cantidad de colores con la cantidad de regiones resultantes para diferentes niveles de tolerancia, constituye una herramienta muy útil para medir la calidad la imagen final.

Se presentan a continuación las gráficas de estos resultados para cada bloque de imágenes. Bloque 1: Color (Fig. 44); Bloque 2: Otras (Fig. 45); Bloque 3: Picasso (Fig. 46); Bloque 4: Memorama (Fig. 47); Bloque 5: RayosX (Fig. 48) y Bloque 6: Rostros (Fig. 49).

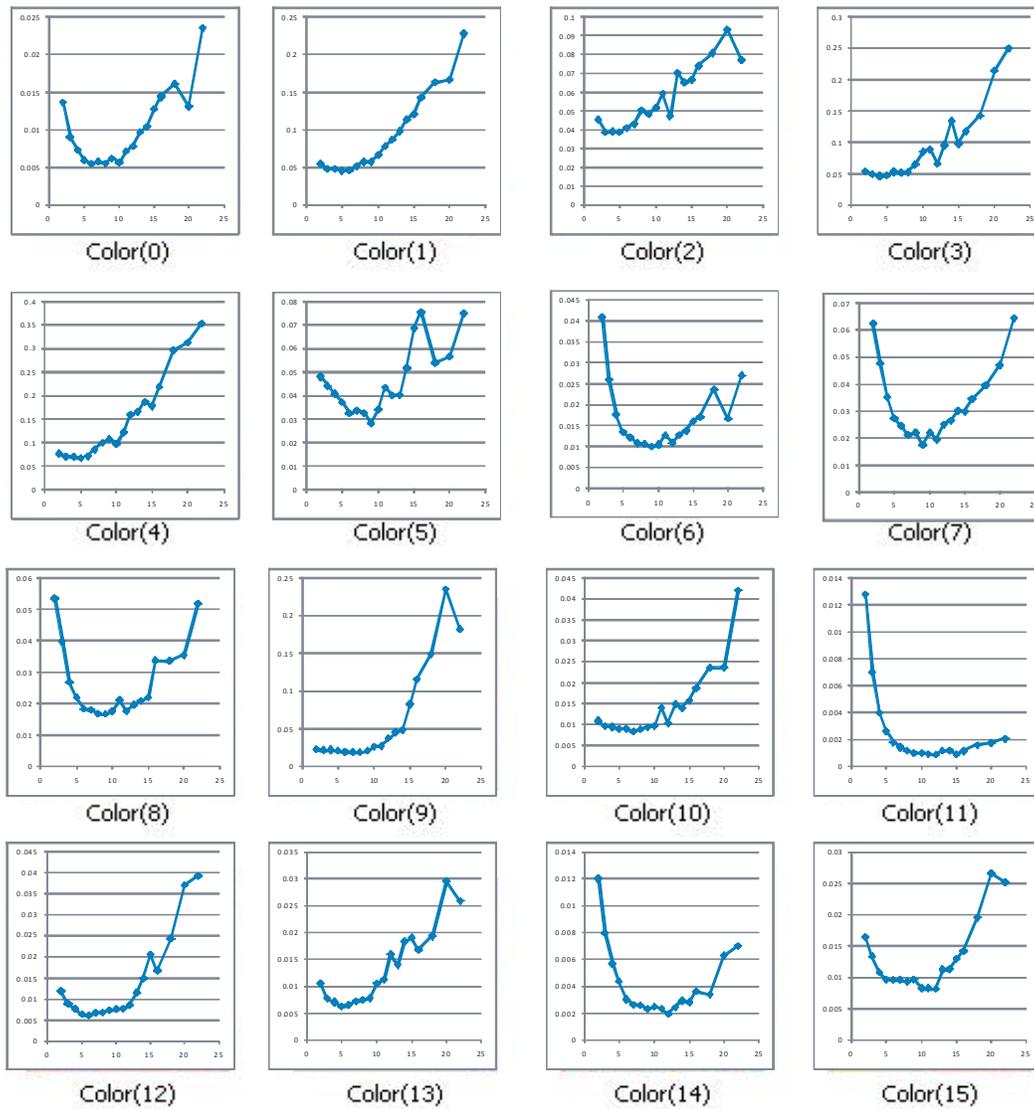


Fig. 44 Colores/Regiones vs. Tolerancia. Bloque 1: Color.

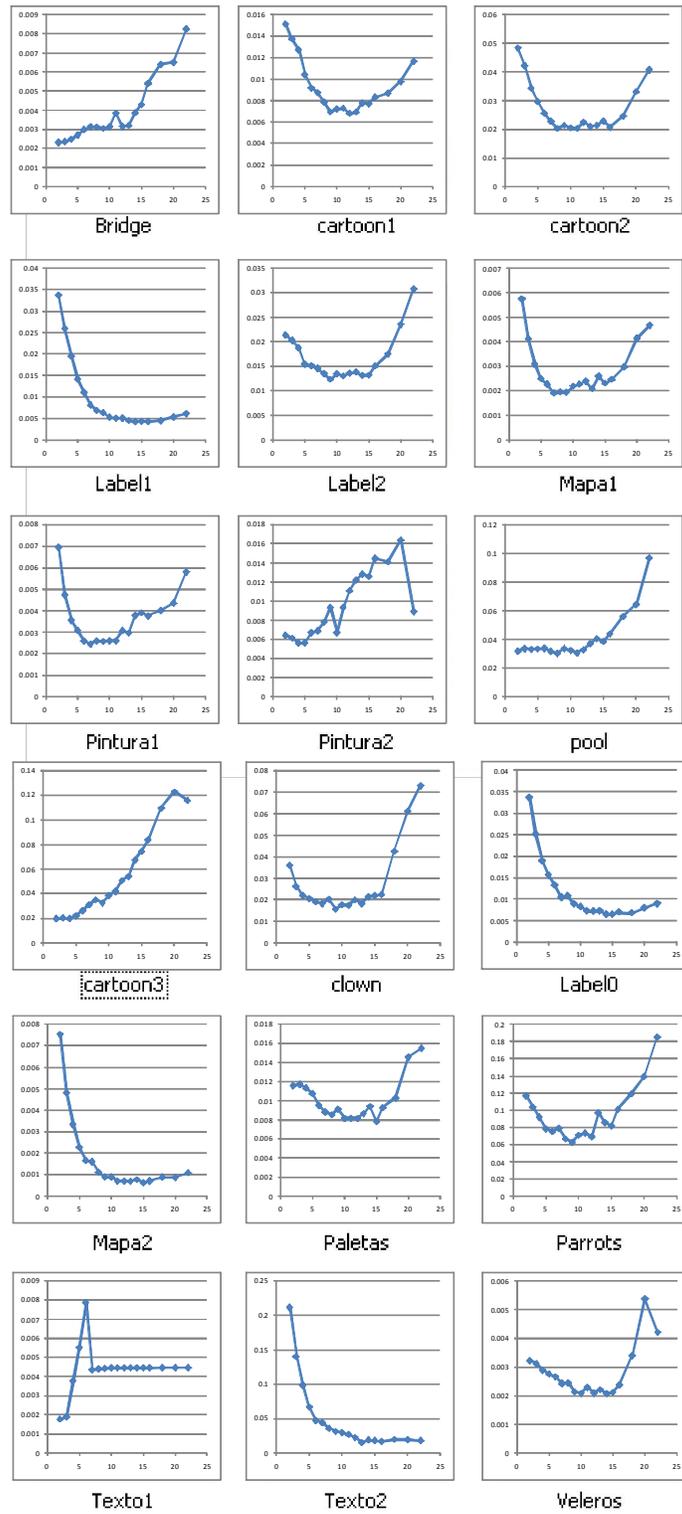


Fig. 45 Colores/Regiones vs. Tolerancia. Bloque 2: Otras.

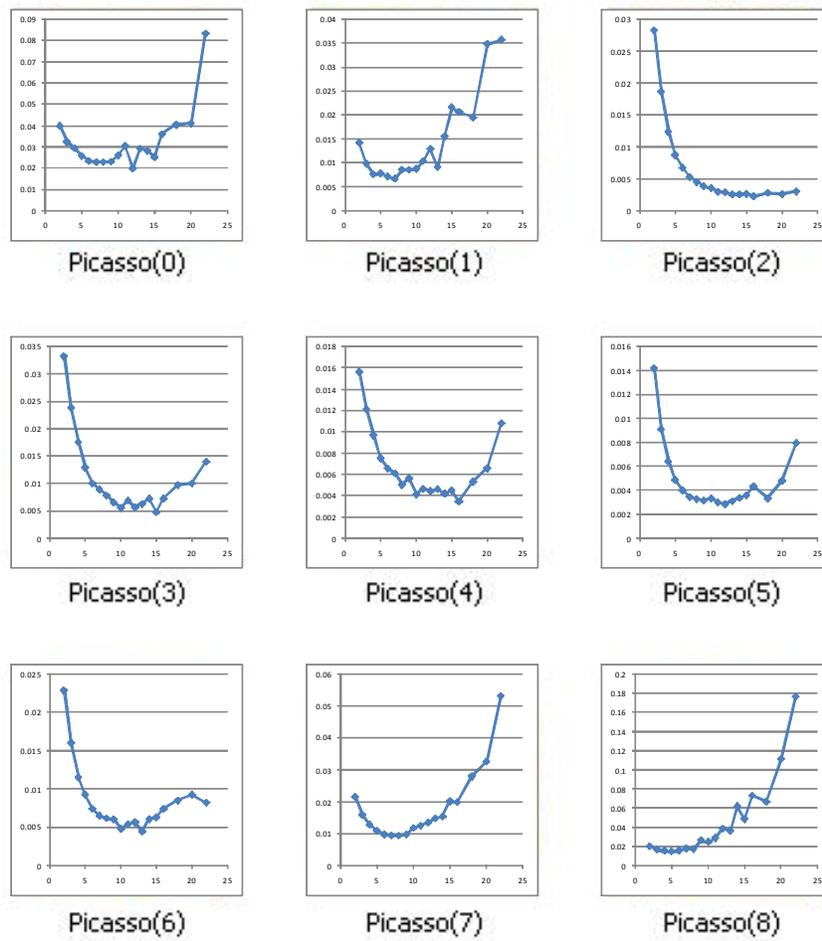


Fig. 46 Colores/Regiones vs. Tolerancia. Bloque 3: Picasso.

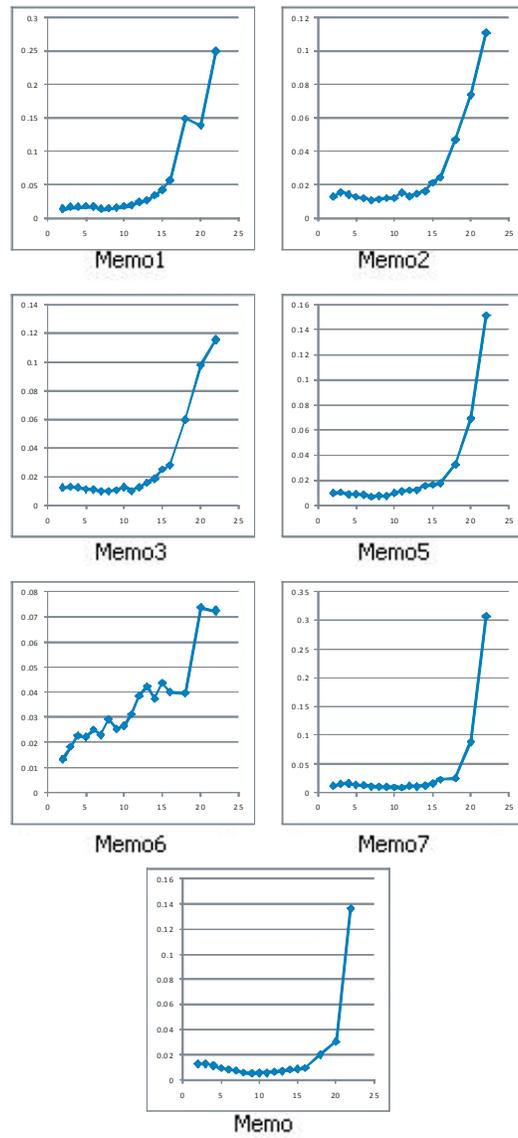


Fig. 47 Colores/Regiones vs. Tolerancia. Bloque 4: Memorama.

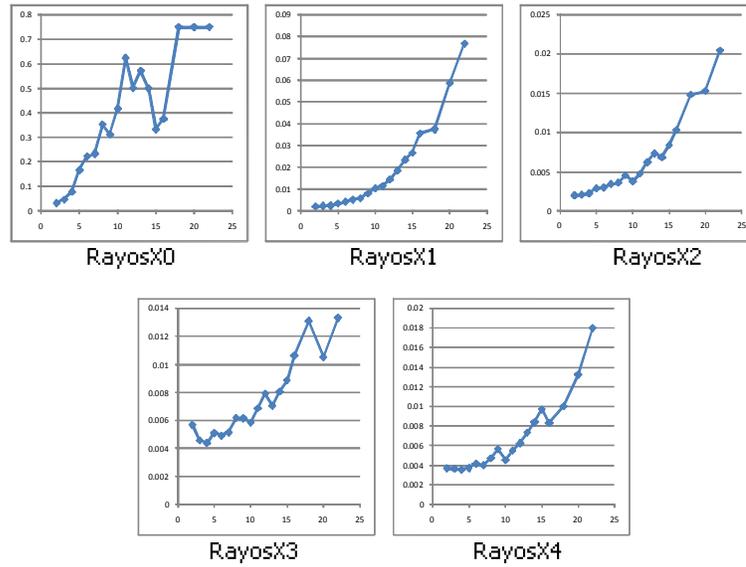


Fig. 48 Colores/Regiones vs. Tolerancia. Bloque 5: Rayos X.

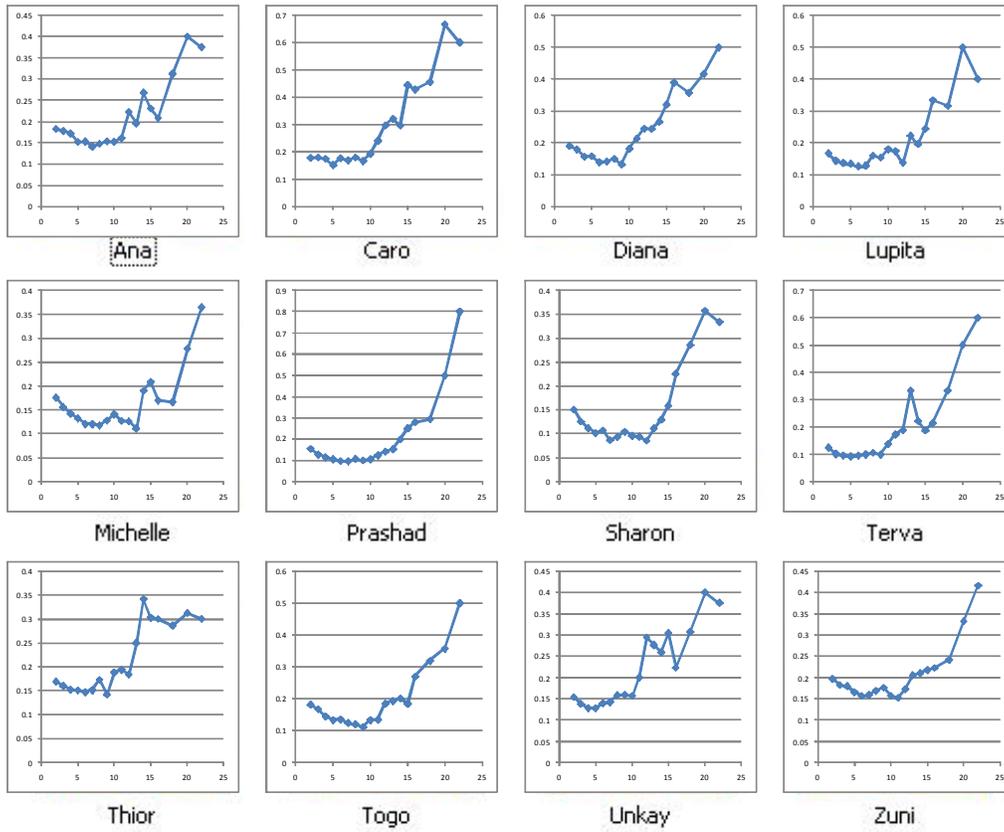


Fig. 49 Colores/Regiones vs. Tolerancia. Bloque 6: Rostros.

Capítulo 4 *Evaluación de resultados*

Con base en la información obtenida de los experimentos anteriores, se ha hallado el mejor valor de tolerancia que conserva más regiones (detalles) con menos colores, para cada imagen.

En la Tabla 5 se presenta el promedio del nivel de tolerancia hallado para cada bloque de imágenes.

Tabla 5. Nivel de tolerancia "óptimo" por cada bloque.

Bloque	Tolerancia promedio
1 Color	7.6
2 Otras	9.1
3 Picasso	11.5
4 Memorama	7.1
5 Rayos X	2.1
6 Rostros	8.1

En los bloques Color, Memorama, Rostros y Otras, el nivel de tolerancia es próximo al valor de ocho elegido como nivel de tolerancia global en nuestros experimentos; solo en ciertos tipos de imágenes como las de Rayos X y Picasso, el nivel de tolerancia se aleja, dada la evidencia de que las imágenes englobadas en estos bloques tiene características muy particulares.

4.4 Comparación con otros algoritmos

A continuación se presenta la comparación cualitativa de los resultados logrados con las imágenes de cada bloques con los algoritmos *Median-Cut* y de Componentes Principales.

Las imágenes son dispuestas en sus respectivos bloques: Color - Fig. 50; Otros- Fig. 51; Memorama - Fig. 52; Picasso- Fig. 53; Rayos X - Fig. 54; y Rostros - Fig. 55. En la primera columna se muestra el resultado obtenido con el algoritmo propuesto, en la segunda con el algoritmo de *Median-Cut* y finalmente en la tercera columna con el algoritmo de Componentes principales también llamado Cuantificador de Wu. Con el fin de apreciar de mejor manera ciertos resultados, las imágenes se muestran con su histograma 3D en el espacio RGB y algunas de ellas con ampliaciones de una parte de las mismas.

Capítulo 4 *Evaluación de resultados*

No. de colores	Solución propuesta	<i>Median-Cut</i>	Componentes Principales
Color(0) 46 colores			
Color(1) 48 colores			
Color(2) 35 colores			

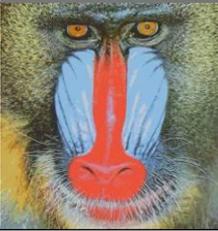
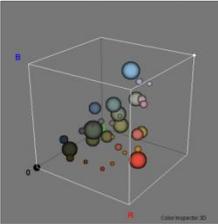
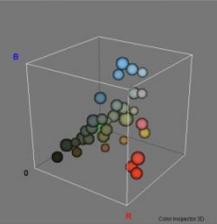
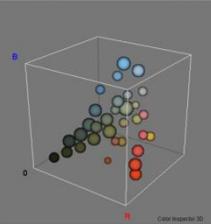
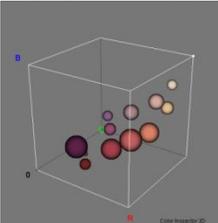
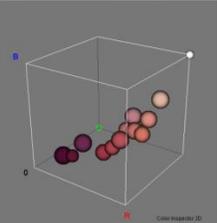
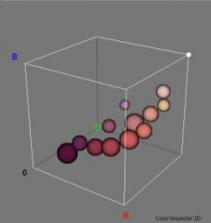
Capítulo 4 *Evaluación de resultados*

<p>Color(3) 13 colores</p>			
<p>Color(4) 40 colores</p>			
<p>Color(5) 33 colores</p>			
<p>Color(6) 45 colores</p>			

Capítulo 4 *Evaluación de resultados*

Color(7) 25 colores			
Color(8) 24 colores			
Color(9) 21 colores			

Capítulo 4 *Evaluación de resultados*

<p>Color(10) 22 colores</p>			
<p>Color(11) 66 colores</p>			
			
<p>Color(12) 16 colores</p>			
			

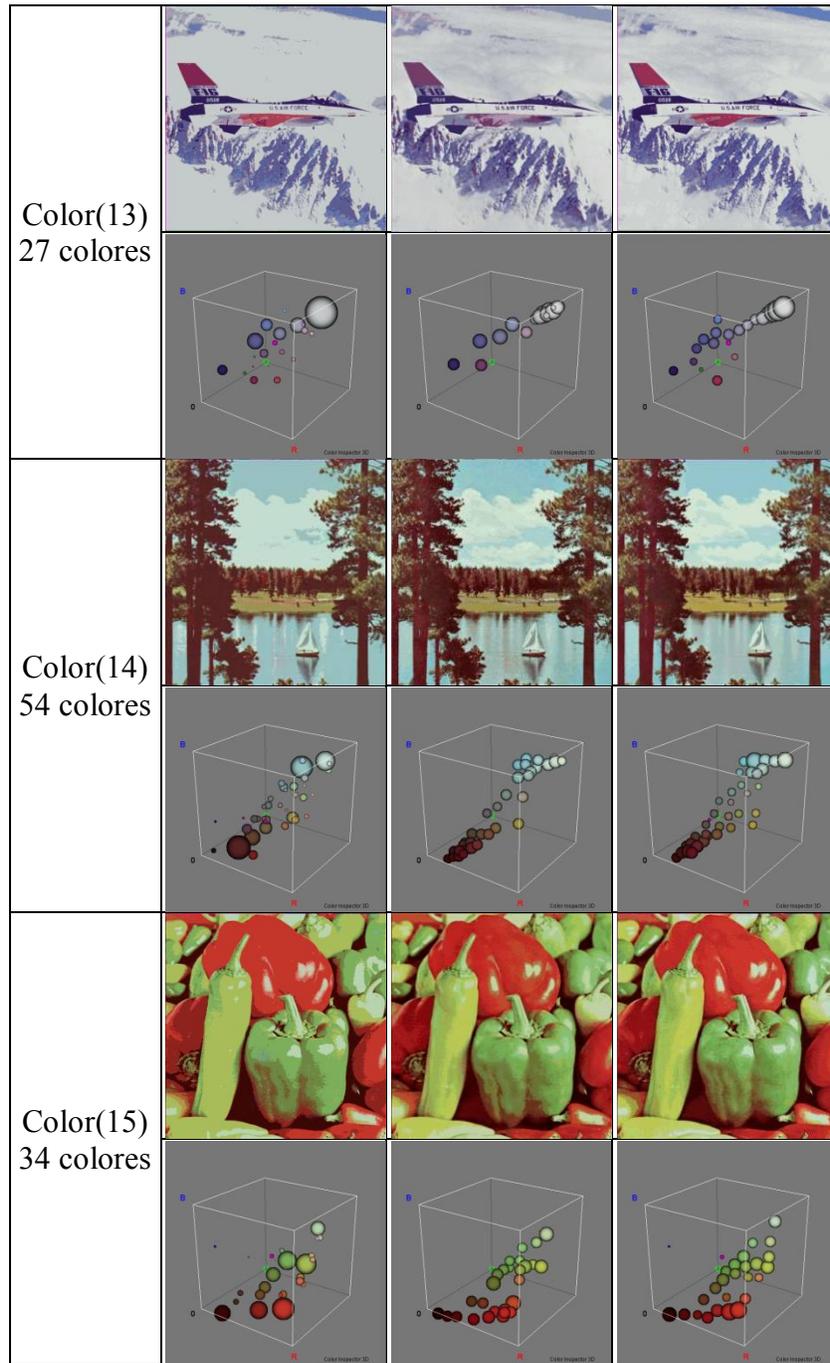
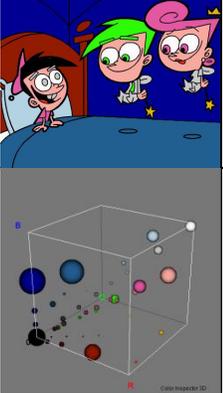
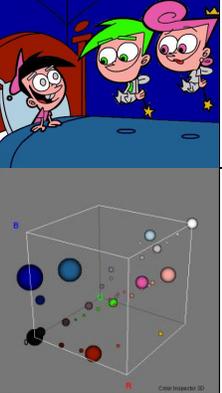
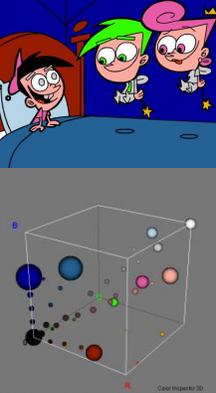
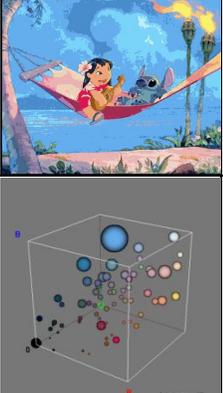
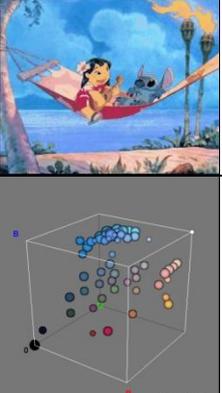
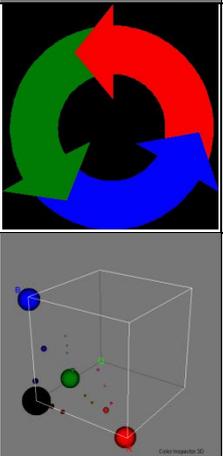
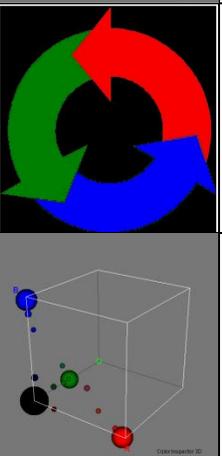
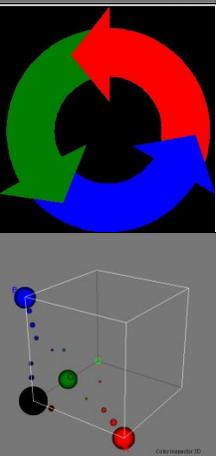
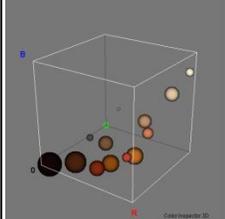
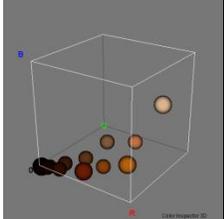
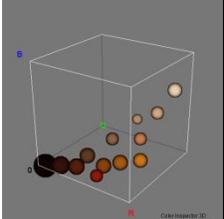
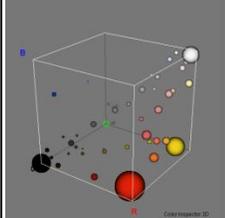
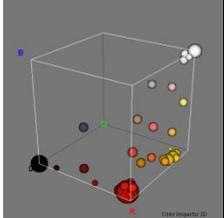
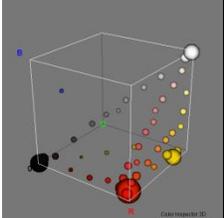
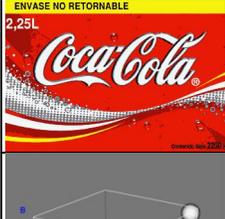
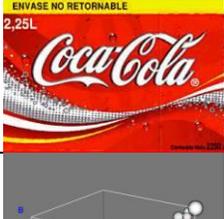
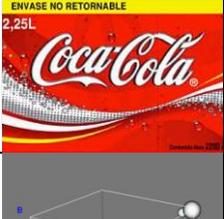
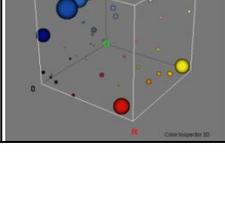
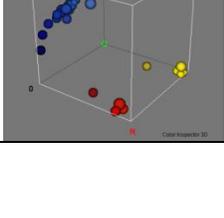
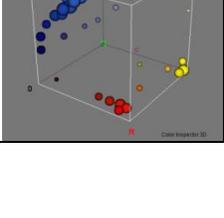


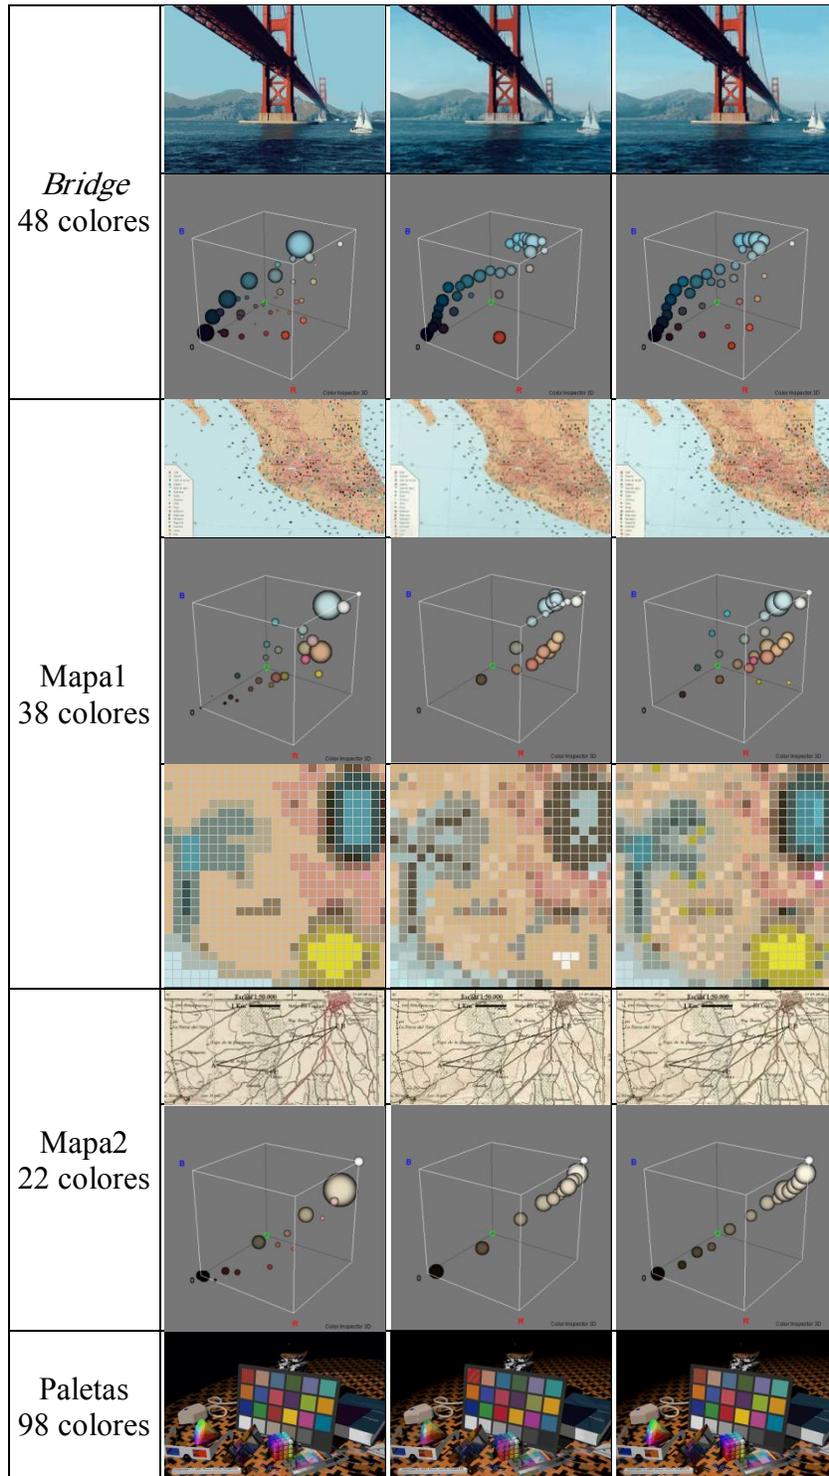
Fig. 50 Comparación de los resultados con las imágenes del primer bloque “Color”.

Capítulo 4 *Evaluación de resultados*

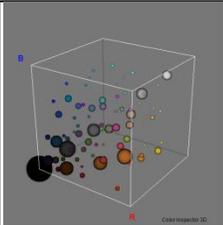
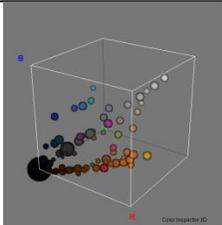
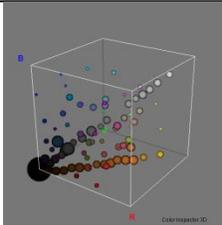
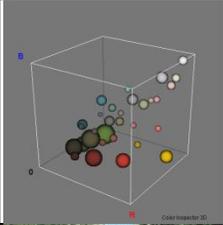
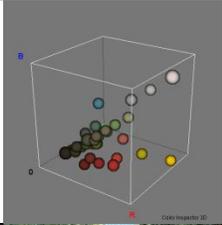
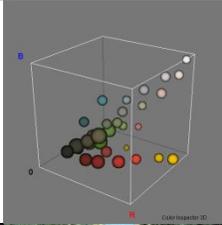
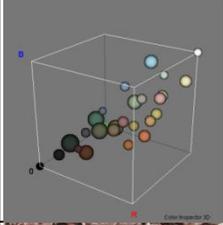
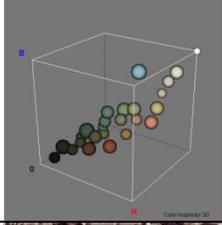
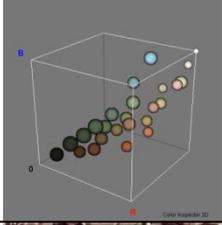
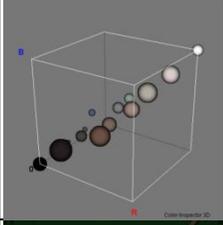
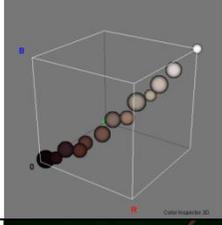
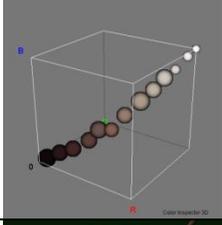
No. de colores	Solución propuesta	<i>Median-Cut</i>	Componentes Principales
<p><i>Cartoon1</i> 41 colores</p>			
<p><i>Cartoon2</i> 79 colores</p>			
<p><i>Cartoon3</i> 24 colores</p>			
<p><i>Clown</i> 23 colores</p>			

Capítulo 4 *Evaluación de resultados*

			
<i>Label 0</i> 67 colores			
			
<i>Label 1</i> 61 colores			
			
<i>Label 2</i> 47 colores			
			



Capítulo 4 *Evaluación de resultados*

			
<i>Parrots</i> 44 colores			
			
<i>Paint1</i> 46 colores			
			
<i>Paint2</i> 22 colores			
			
<i>Pool</i> 43 colores			

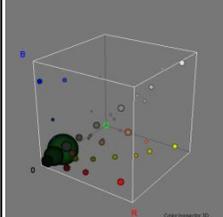
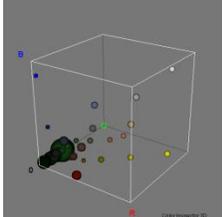
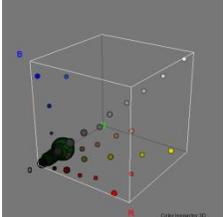
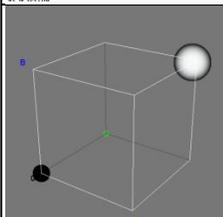
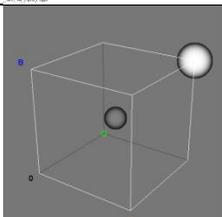
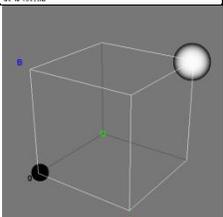
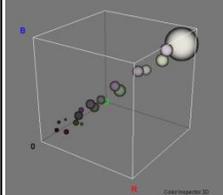
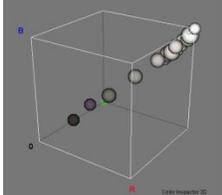
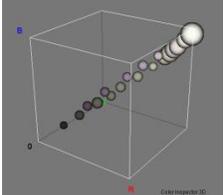
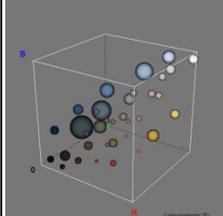
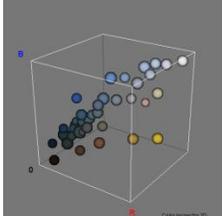
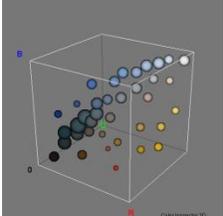
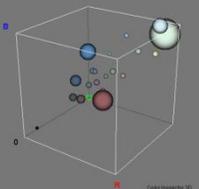
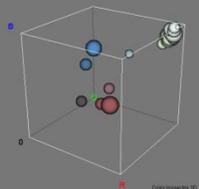
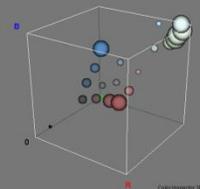
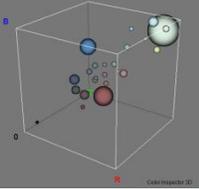
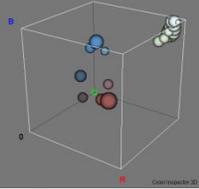
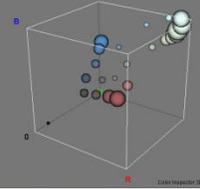
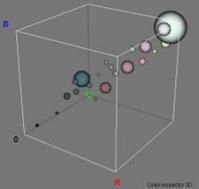
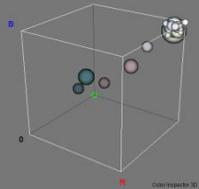
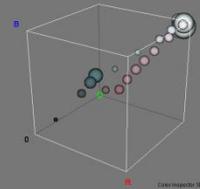
			
Texto1 2 colores	<p>Resumen. Este capítulo presenta los resultados experimentales del método de reducción de la capacidad de almacenamiento de los resultados de acuerdo a la capacidad de almacenamiento de los colores más representativos de la imagen. Cada uno de los colores representados de la imagen. En este capítulo se muestra el método de reducción de la capacidad de almacenamiento de los resultados de acuerdo a la capacidad de almacenamiento de los colores más representativos de la imagen. En este capítulo se muestra el método de reducción de la capacidad de almacenamiento de los resultados de acuerdo a la capacidad de almacenamiento de los colores más representativos de la imagen.</p>	<p>Resumen. Este capítulo presenta los resultados experimentales del método de reducción de la capacidad de almacenamiento de los resultados de acuerdo a la capacidad de almacenamiento de los colores más representativos de la imagen. Cada uno de los colores representados de la imagen. En este capítulo se muestra el método de reducción de la capacidad de almacenamiento de los resultados de acuerdo a la capacidad de almacenamiento de los colores más representativos de la imagen.</p>	<p>Resumen. Este capítulo presenta los resultados experimentales del método de reducción de la capacidad de almacenamiento de los resultados de acuerdo a la capacidad de almacenamiento de los colores más representativos de la imagen. Cada uno de los colores representados de la imagen. En este capítulo se muestra el método de reducción de la capacidad de almacenamiento de los resultados de acuerdo a la capacidad de almacenamiento de los colores más representativos de la imagen.</p>
			
Texto2 24 colores	<p>NOMBRE MARQUEZ DE SILVA SERGIO ANTONIO</p>	<p>NOMBRE MARQUEZ DE SILVA SERGIO ANTONIO</p>	<p>NOMBRE MARQUEZ DE SILVA SERGIO ANTONIO</p>
			
Veleros 52 colores			
			

Fig. 51 Comparación de los resultados con las imágenes del segundo bloque “Otras”.

No. de colores	Solución propuesta	<i>Median-Cut</i>	Componentes Principales
Memo(1) 26 colores			
			
Memo(2) 30 colores			
			
Memo(3) 27 colores			
			
Memo(5) 23 colores			
			

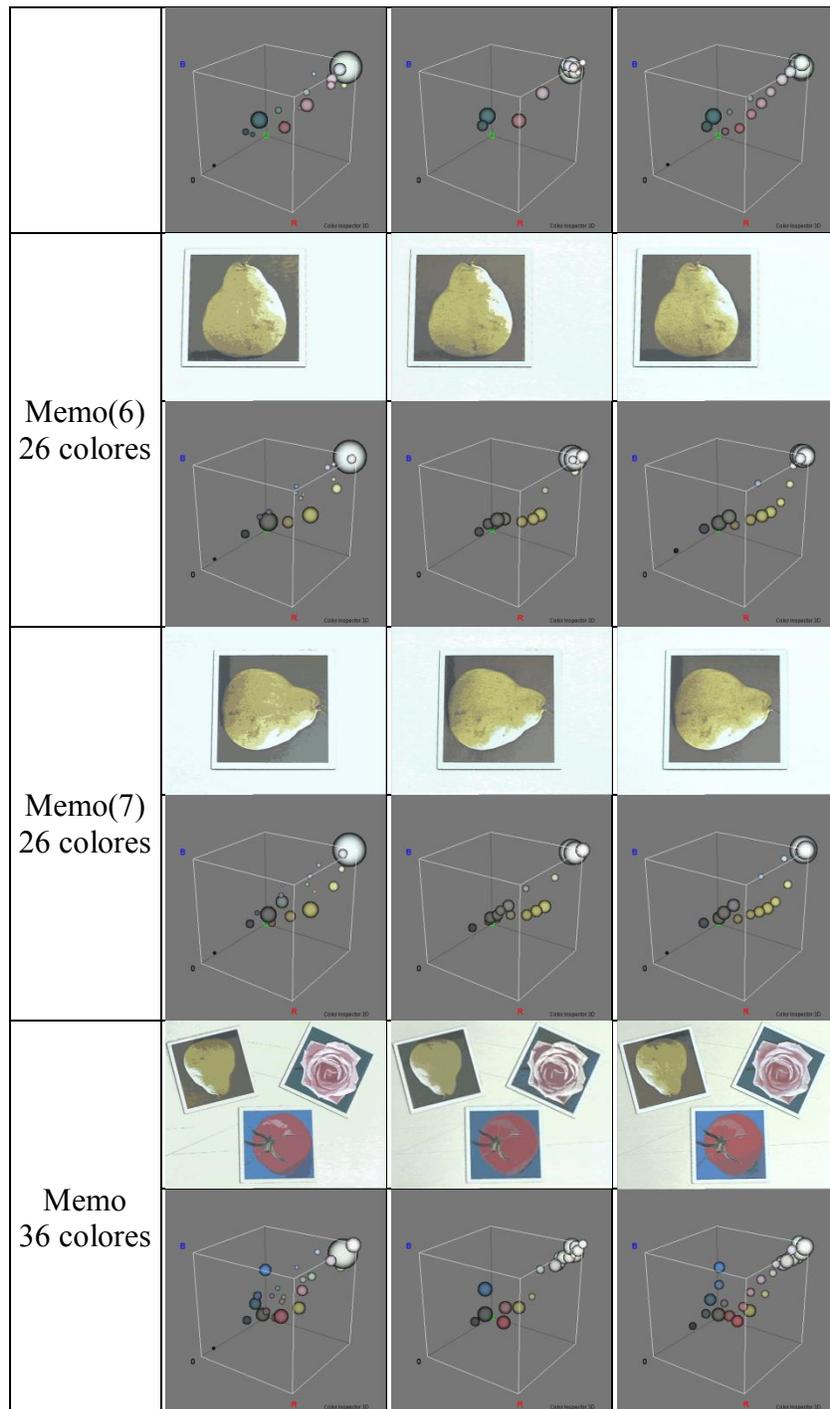
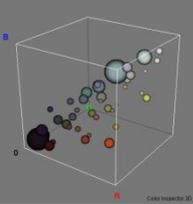
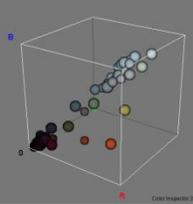
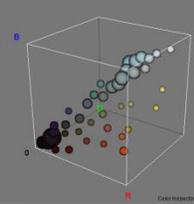
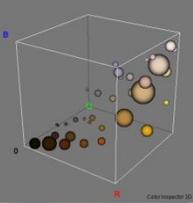
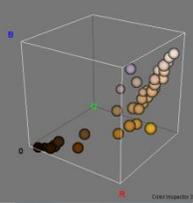
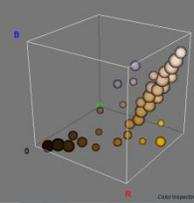


Fig. 52 Comparación de los resultados con las imágenes del tercer bloque “Memorama”.

Capítulo 4 *Evaluación de resultados*

No. de colores	Solución propuesta	<i>Median-Cut</i>	Componentes Principales
Picasso(0) 24 colores			
Picasso(1) 35 colores			
Picasso(2) 83 colores			

Capítulo 4 *Evaluación de resultados*

<p>Picasso(3) 61 colores</p>			
			
<p>Picasso(4) 38 colores</p>			
			
<p>Picasso(5) 29 colores</p>			
			
<p>Picasso(6) 43 colores</p>			

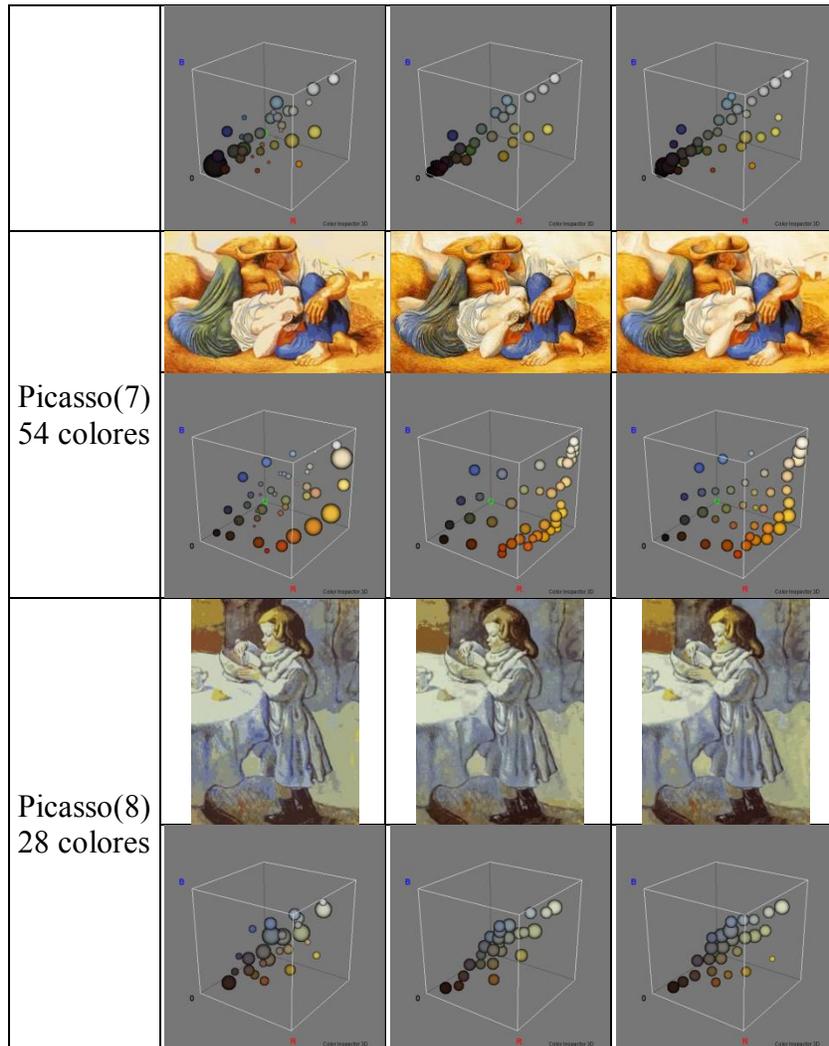
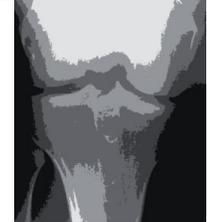
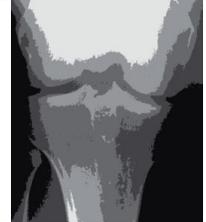
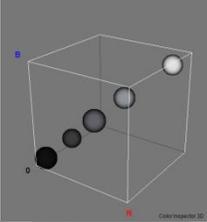
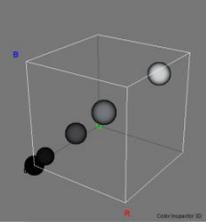
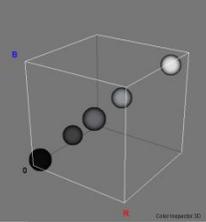
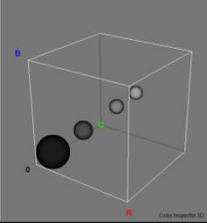
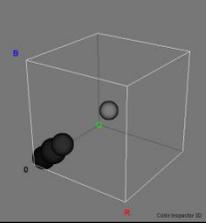
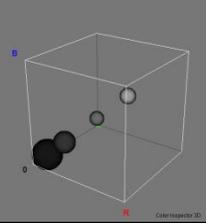
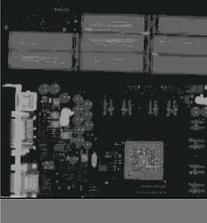
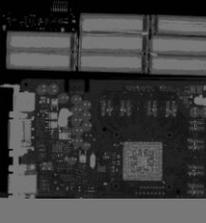
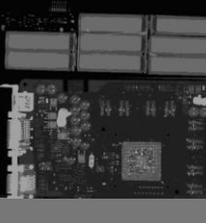
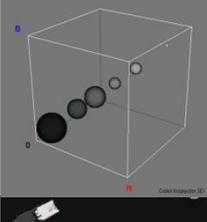
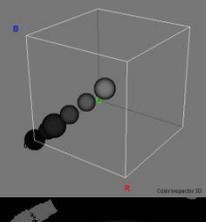
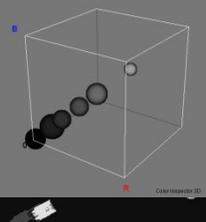


Fig. 53 Comparación de los resultados con las imágenes del cuarto bloque “Picasso”.

No. de colores	Solución propuesta	<i>Median-Cut</i>	Componentes Principales
RayosX(0) 6 colores			
			
RayosX(1) 4 colores			
			
RayosX(2) 6 colores			
			
RayosX(3) 6 colores			
			

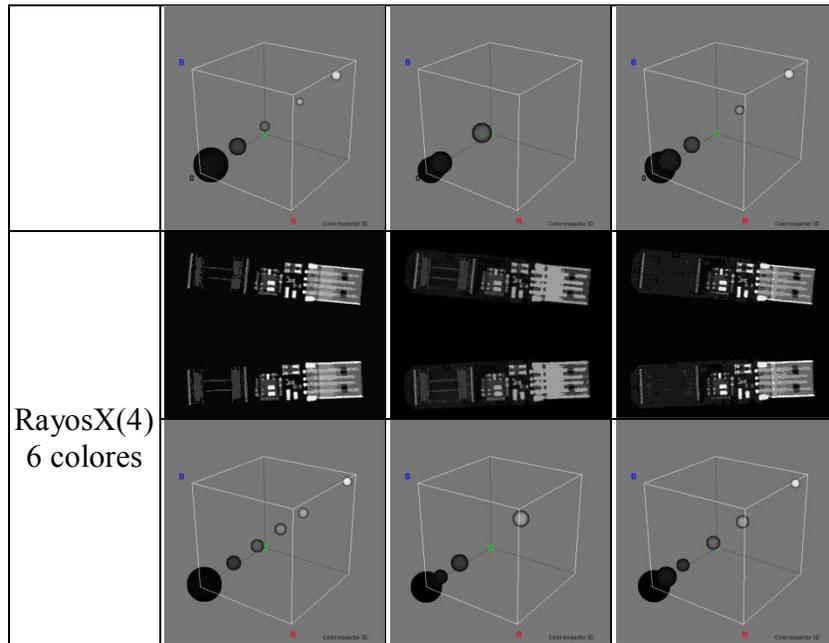
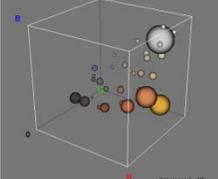
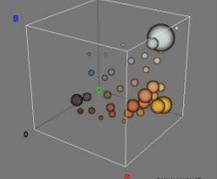
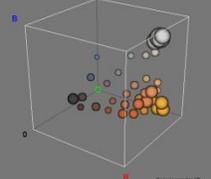
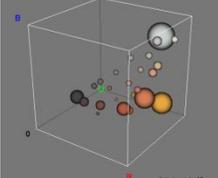
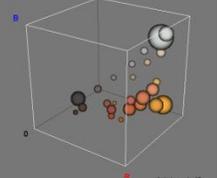
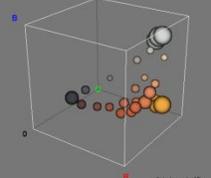
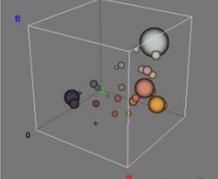
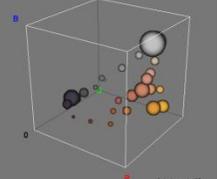
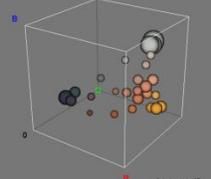
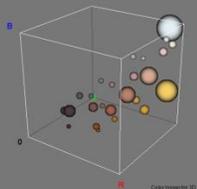
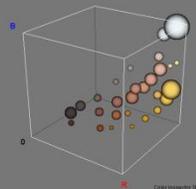
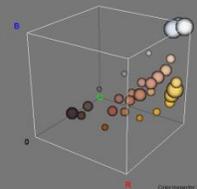
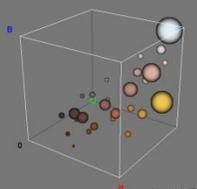
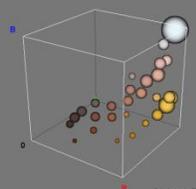
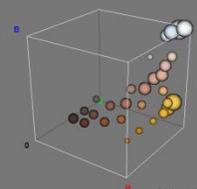
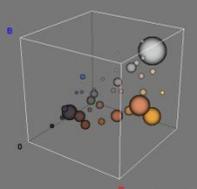
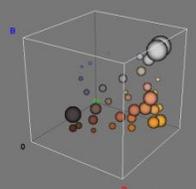
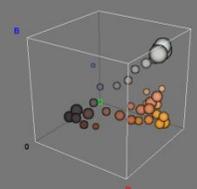


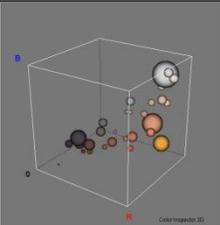
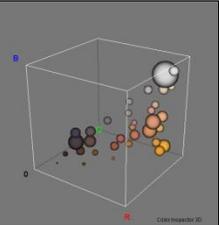
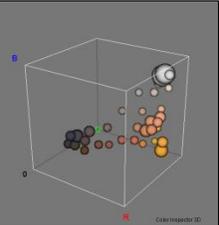
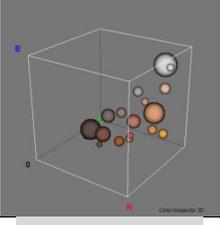
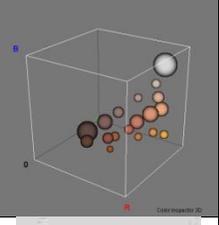
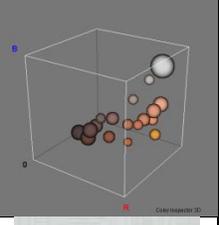
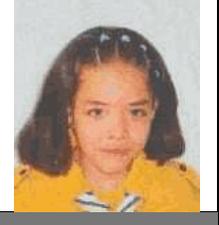
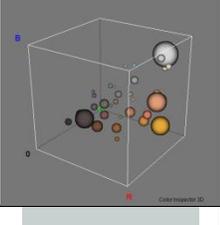
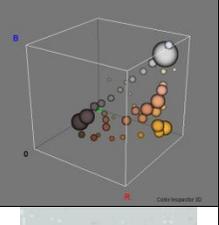
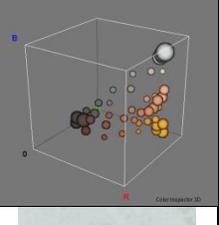
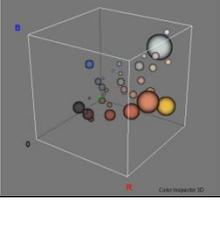
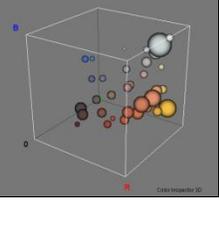
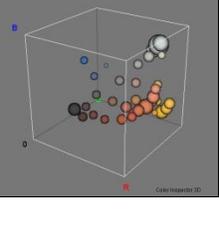
Fig. 54 Comparación de los resultados con las imágenes del quinto bloque “Rayos X”.

No. de colores	Solución propuesta	<i>Median-Cut</i>	Componentes Principales
<p>Ana 35 colores</p>			
			
<p>Caro 25 colores</p>			
			
<p>Diana 28 colores</p>			
			

Capítulo 4 *Evaluación de resultados*

<p>Lupita 28 colores</p>			
			
<p>Michelle 29 colores</p>			
			
<p>Prashad 35 colores</p>			
			
<p>Sharon 33 colores</p>			

Capítulo 4 *Evaluación de resultados*

			
Terva 18 colores			
			
Thior 42 colores			
			
Togo 33 colores			
			

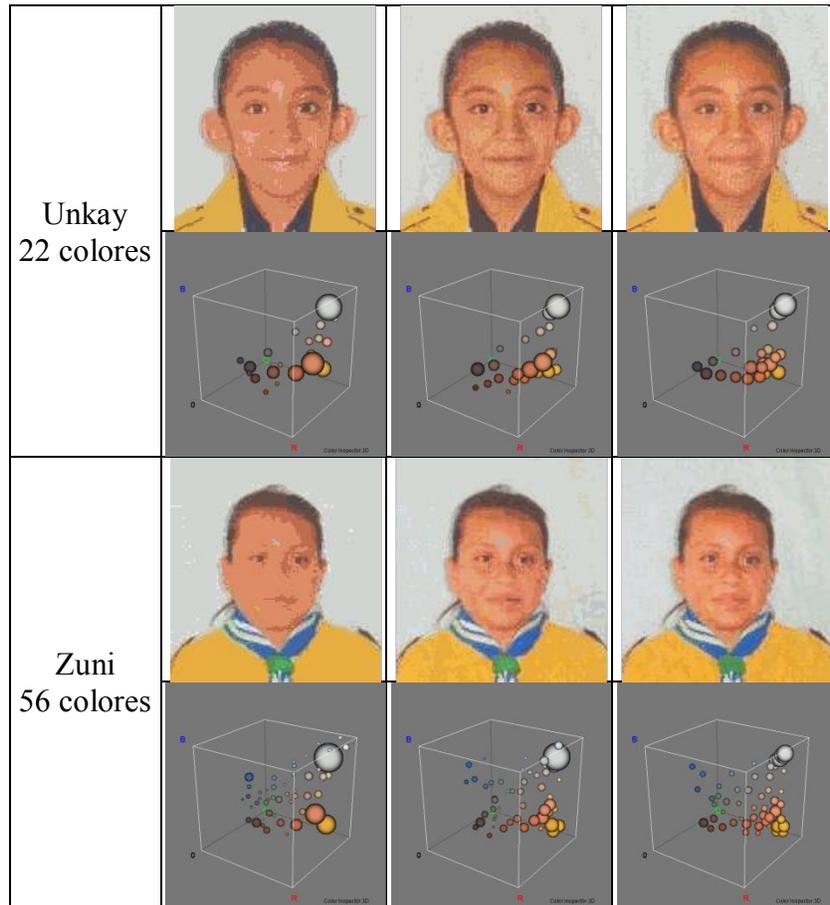


Fig. 55 Comparación de los resultados con las imágenes del sexto bloque “Rostros”.

4.5 Discusión de los resultados

Al observar las imágenes con el número de colores ya reducido, se puede apreciar cómo el algoritmo de cuantificación propuesto y el algoritmo de Componentes Principales son los que brindan las imágenes más parecidas a la original, mientras que el algoritmo de *Median-Cut* presenta en varias de ellas la omisión de algunos colores esenciales, lo que da lugar a que la imagen resultado no tenga los colores adecuados en objetos específicos.

A continuación resaltaremos las características encontradas al comparar las imágenes de los distintos bloques lo que reflejará el comportamiento general del algoritmo propuesto.

En el bloque “Color” se cuenta con diversas imágenes del tipo “naturales”, las que son clásicas dentro del campo del análisis de las imágenes. En la imagen de Lena (Color(12)), el algoritmo reduce a 16 colores, debido a la poca variedad de colores

Capítulo 4 *Evaluación de resultados*

que se puede apreciar en la imagen original. Este comportamiento es en efecto el esperado.

De la imagen del Mandril (Color(11)), se ha realizado una ampliación del ojo para apreciar cómo el método propuesto es más noble con los detalles y preserva mejor la relación de tonos que los métodos clásicos.

Las imágenes Color(7) y Color(8) son dos fotografías de los mismos objetos, pero con una distribución diferente; aquí observamos que la cantidad de colores entre estas dos imágenes difiere tan solo en uno.

En el bloque “Otras” contamos con imágenes de las distintas clasificaciones descritas. En la imagen nombrada *Cartoon1*, no apreciamos ninguna alteración del color con respecto a la imagen original, es decir, no se observa una diferencia significativa en los resultados obtenidos por los tres métodos de cuantificación comparados. Se puede concluir entonces que la cantidad de colores esenciales definida por nuestro algoritmo es útil para los otros 2 métodos de cuantificación.

En la imagen *Cartoon2*, encontramos que la cantidad inicial de colores es muy alta respecto a la de su predecesora. Reconocemos el poder y la eficiencia de nuestro método de cuantificación al observar en los histogramas cómo el método propuesto agrupa la gran variedad de azules, mientras que los otros métodos mantienen la redundancia que existe en los azules, lo que los lleva a tener un espectro más limitado para aceptar otros colores que pudiesen ser esenciales.

La imagen *Paint1* es una imagen con una gran cantidad de colores inicialmente (306 233), los que fueron reducidos a solamente 46 colores. El algoritmo de *Median-Cut* presenta una variación significativa en las tonalidades (véase el cielo azul), mientras que ambos, el de Componentes Principales y el método propuesto, mantienen una gran semejanza con los colores que se aprecian en la imagen original.

En la imagen *Paint2*, puede observarse que el método propuesto es el único que conserva el área azul, sin perder el tono original en la parte central izquierda de la imagen.

La imagen Mapa de México es una imagen representativa de un problema que intentamos solucionar con la metodología propuesta: facilitar el reconocimiento de los símbolos cartográficos sobre la base de su color. Para ello analizamos cómo se comportan los algoritmos considerados con algunos símbolos gráficos al cuantificar la imagen completa. Aquí mostramos los resultados con el símbolo limón. El algoritmo *Median-Cut* deteriora perceptiblemente la imagen, pues desaparece el color amarillo, mientras que los otros métodos lo preservan. Los

Capítulo 4 *Evaluación de resultados*

mejores resultados se obtienen con el método propuesto, dado que genera una imagen con fronteras más definidas entre los objetos. Esta es una ventaja debido a que una imagen con las fronteras bien definidas sería muy útil para el reconocimiento y la segmentación de los objetos gráficos.

En la imagen nombrada Mapa2 se puede observar claramente cómo los dos algoritmos de comparación, el *Median-Cut* y el de Componentes Principales, pierden el color rojo que indica ciertas construcciones y caminos, mientras que el método propuesto lo mantiene. Se encontró en esta imagen la desventaja común de que con los tres métodos se pierde la tonalidad verde.

En el caso de la imagen Texto1, acertadamente el algoritmo propuesto reconoce solo 2 colores como los esenciales. Podemos observar entonces que nuestro algoritmo logra de manera automática llevar a binaria la imagen inicial.

El bloque “Memorama” contiene imágenes escaneadas de diferentes tarjetas de este juego. No se aprecia diferencia entre los tres métodos, debido a la simplicidad de los objetos presentes en la imagen y a que no tienen gran cantidad de detalles, además de que también los colores esenciales que la forman son también los más frecuentes. La cantidad de colores que se obtiene con el algoritmo propuesto entre dos tomas de la misma tarjeta difiere como máximo en 4.

El bloque “Picasso” engloba imágenes del tipo pinturas, donde el uso del color en algunas es muy variado y en otras escaso. Es de gran importancia en estas imágenes apreciar las tonalidades que toman los colores esenciales en las imágenes resultado. El algoritmo propuesto mantiene estas tonalidades mejor que los otros.

Con las imágenes del bloque “Rayos X”, como era de esperarse, las imágenes resultado cuentan con pocos colores esenciales: 6 colores para la mayoría de las imágenes. En todos los métodos los degradados o difuminaciones de tonalidades de gris en las imágenes se pierden y dan paso a áreas definidas de un solo color. Esto puede ser resuelto empleando el algoritmo de difuminado (*dithering*) explicado anteriormente.

El último bloque denominado “Rostros” muestra cómo los diferentes algoritmos se ajustan bien a la cantidad de colores ordenada por el algoritmo propuesto y no se aprecia pérdida de algún color en ninguna imagen. Con el algoritmo propuesto, zonas como el rostro, el fondo, la camisola, son cuasi - asignadas a un solo color esencial. Los otros métodos le dan más tonalidades a estas zonas, pero en el caso de los detalles presentes (en pequeñas regiones) las tonalidades cambian.

4.6 Desempeño de los métodos de cuantificación del color

El desempeño de los algoritmos de cuantificación del color no debe ser determinado únicamente por una percepción subjetiva de la imagen. Es necesario usar una métrica para comparar y evaluar los diferentes métodos de cuantificación.

En esta tesis propusimos usar el error cuadrático medio en términos de la fórmula CIE2000, denominada por nosotros CIESE (CIE2000 + *Square Error*), para medir las discrepancias entre la imagen original y las imágenes cuantificadas. Esta fórmula se define de la siguiente manera:

$$CIESE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N CIE2000(c[i, j], q(c[i, j]))^2 \quad (22)$$

Donde $c[i, j]$ y $q(c[i, j])$ son el píxel original y el píxel cuantificado respectivamente y M y N representan las M columnas y las N filas de la imagen en cuestión.

La ecuación (22) es usada como un criterio para evaluar el error de cuantificación. Un valor pequeño de este error significa una alta calidad en la imagen reconstruida. Así, se tomaron las mismas imágenes de evaluación para calcular su error cuadrático medio.

La comparación del desempeño en términos de los valores calculados por CIESE se muestra en las figuras 56, 57, 58, 59, 60 y 61. Los valores utilizados para crear estas gráficas se muestran en la Tabla 7, ordenados de menor a mayor según el valor obtenido con las imágenes del algoritmo propuesto. La barra azul pertenece al algoritmo de *Median-Cut* (MC), la barra roja al algoritmo propuesto denominado en inglés como *Selective Quantifier* (SQ) y por último la barra verde perteneciente al algoritmo de Componentes Principales propuesto por Wu (WU).

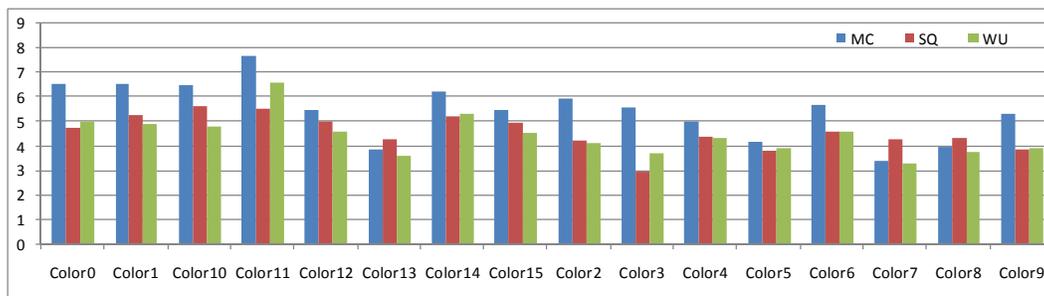


Fig. 56 Comparación de los resultados obtenidos por CIESE. Bloque "Color".

Capítulo 4 *Evaluación de resultados*

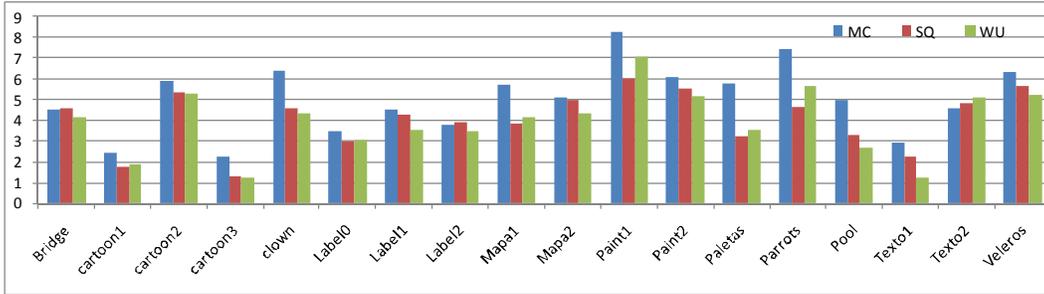


Fig. 57 Comparación de los resultados obtenidos por CIESE. Bloque "Otras".

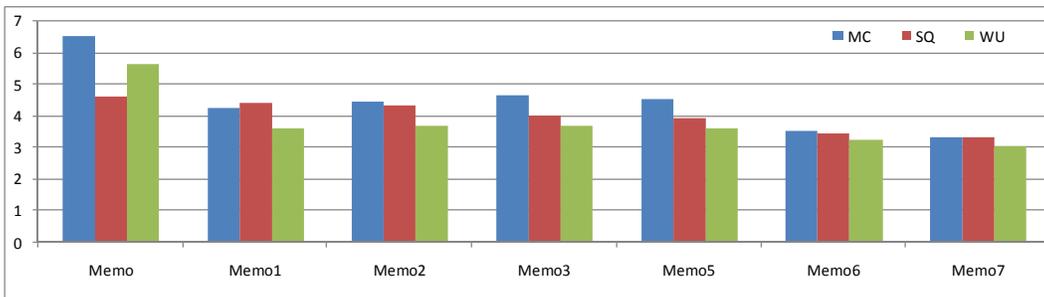


Fig. 58 Comparación de los resultados obtenidos por CIESE. Bloque "Memorama".

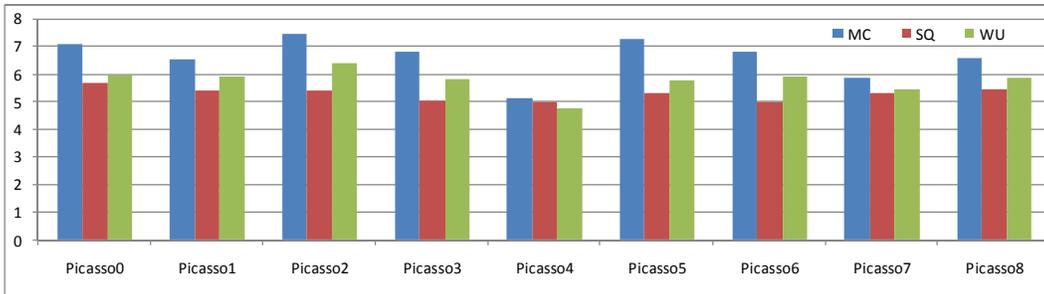


Fig. 59 Comparación de los resultados obtenidos por CIESE. Bloque "Picasso".

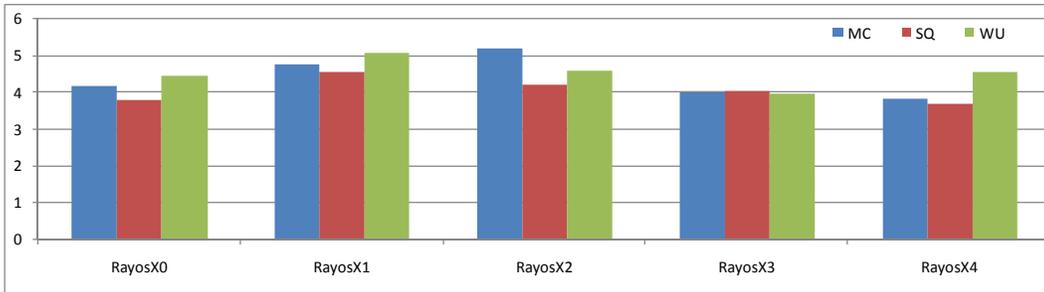


Fig. 60 Comparación de los resultados obtenidos por CIESE. Bloque "Rayos X".

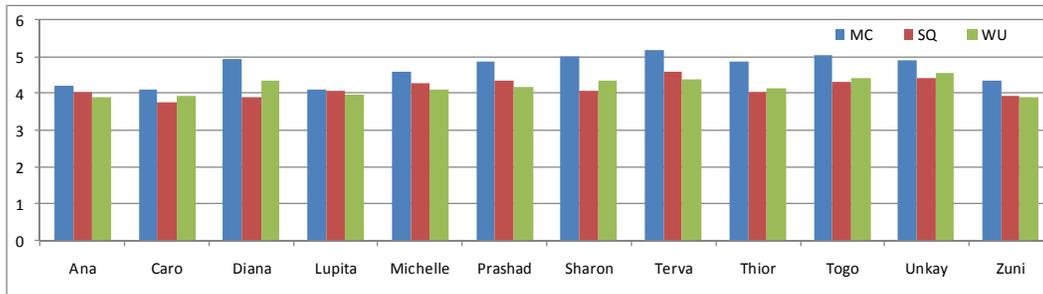


Fig. 61 Comparación de los resultados obtenidos por CIESE. Bloque "Rostr os".

En ciertas imágenes, el algoritmo de Componentes Principales llega a tener mejores resultados que con el método propuesto en este trabajo, como por ejemplo con el Mapa2 (Fig. 57), pero como recordamos de los resultados arriba mostrados, en esa imagen nuestro método es el único que conserva el color rojo de ciertos elementos. La razón por la que el error cuadrático medio es menor para el algoritmo de Componentes Principales que para el nuestro, es debido al cambio de color en ciertos píxeles del fondo que nuestro algoritmo propuso para uniformizarlo, mientras que el otro algoritmo conserva esas tonalidades; sin embargo, ello no implica ni pérdida ni aporte de información contextual relevante en la imagen.

Revisando los resultados con los diferentes bloques de imágenes, el algoritmo propuesto supera notablemente al algoritmo de *Median-Cut*. Como se menciona arriba, el algoritmo de Componentes Principales tiene mejores resultados en varias imágenes, pero a su vez, como se demuestra en la Tabla 6, el algoritmo propuesto asegura un error máximo global de 6 (mostrado en rojo), mientras que los otros algoritmos tienen siempre errores que alcanzan valores mayores que 7.

Tabla 6 Análisis de los valores CIESE.

	Promedio	Max	Min	Mediana
MC	4.891139653	8.268178497	2.254590403	4.904318163
SQ	4.096959119	5.994592027	1.284003108	4.178981318
WQ	4.042772244	7.04661703	1.235497941	4.169388006

Tabla 7 Valores CIESE obtenidos.

Nombre	MC	SQ	WU
cartoon3	2.2545904	1.28400311	1.25580175
cartoon1	2.41200128	1.7621709	1.8841568
Texto1	2.92693108	2.25948828	1.23549794
Color3	5.57462586	2.94307189	3.67329096

Capítulo 4 *Evaluación de resultados*

Label0	3.47624473	2.98076527	3.04275088
Paletas	5.7653528	3.22773147	3.51057967
Memo7	3.29779007	3.30964177	3.01905108
Pool	4.96829476	3.31902857	2.6635396
Memo6	3.52008493	3.40047981	3.22062117
RayosX4	3.79176798	3.68001843	4.54721693
Caro	4.12448789	3.75947166	3.94664547
RayosX0	4.16825204	3.77537065	4.44026419
Color5	4.15083084	3.78451661	3.9076515
Color9	5.30925981	3.84506669	3.89261085
Mapa1	5.68195839	3.87782356	4.15066333
Diana	4.94294331	3.89126888	4.34706296
Memo5	4.49748492	3.90895348	3.57001966
Label2	3.80375551	3.92736365	3.47660771
Zuni	4.3441984	3.94421585	3.91950562
Memo3	4.65195774	3.97384641	3.65320908
RayosX3	3.96410025	4.02710897	3.94874224
Ana	4.23635016	4.04359595	3.91158764
Thior	4.87043554	4.05297603	4.16343554
Sharon	5.03803303	4.07536307	4.3756294
Lupita	4.11146509	4.09245875	3.9700998
RayosX2	5.14637592	4.19331182	4.58027736
Color2	5.9237905	4.19402483	4.08072681
Color7	3.36761634	4.24911491	3.24345696
Color13	3.8406041	4.26142247	3.60334328
Label1	4.54331697	4.26550388	3.54749376
Michelle	4.5987644	4.29135969	4.1039762
Memo2	4.44301438	4.29751275	3.6488299
Togo	5.05655358	4.31156407	4.41523764
Color8	3.92232888	4.33598824	3.75917819
Prashad	4.87915835	4.35379407	4.19928737
Color4	5.00875046	4.38576446	4.30356813
Memo1	4.21835259	4.38770227	3.57031371
Unkay	4.92947798	4.44071532	4.55575478
RayosX1	4.75922901	4.53160692	5.07217782
clown	6.37050014	4.57414653	4.345722
Bridge	4.53686248	4.59180555	4.17534047

Color6	5.68959603	4.59222578	4.57379506
Memo	6.51200266	4.60988881	5.63093205
Terva	5.1885629	4.61141509	4.38116193
Parrots	7.43375519	4.64574744	5.63643245
Color0	6.53369594	4.75504998	4.9893041
Texto2	4.57559224	4.84508156	5.05996154
Color15	5.48333967	4.92773558	4.50079438
Picasso4	5.1277901	4.96496471	4.75349523
Color12	5.45876391	4.97730409	4.56245296
Mapa2	5.05923223	4.97872191	4.35819368
Picasso6	6.78992106	4.98172414	5.89094251
Picasso3	6.79795705	5.03740178	5.79637277
Color14	6.22559853	5.2060446	5.3104402
Color1	6.51164549	5.27056987	4.88850979
Picasso5	7.26519701	5.3212169	5.75394578
Picasso7	5.84704758	5.32210591	5.43861818
cartoon2	5.90807881	5.32843497	5.24942598
Picasso2	7.45209242	5.37334077	6.37938583
Picasso1	6.48983906	5.39086907	5.90561409
Picasso8	6.57378804	5.41890218	5.8824133
Paint2	6.0947634	5.5261396	5.16167419
Color11	7.67842641	5.55204938	6.57358813
Color10	6.49271285	5.64212311	4.77570664
Veleros	6.33435005	5.65202686	5.19332419
Picasso0	7.09127736	5.65467043	5.9540022
Paint1	8.2681785	5.99459203	7.04661703

Los resultados mostrados fueron ordenados de menor a mayor según el error cuadrático medio encontrado en nuestro método (SQ) para los valores hallados y mostrados en la Tabla 7. Como puede observarse, el algoritmo propuesto es mejor en la mayoría de los casos que los otros dos algoritmos. Adicionalmente, encontramos que existen ciertos tipos de imágenes que presentan comportamientos particulares. Las pinturas son las imágenes que presentan mayor error, mientras que con la caricatura1 (*Cartoon1*) y el texto1 el error es casi nulo. Cuando se analiza solo un segmento de la imagen, por ejemplo algún área con detalles específicos, podemos observar cómo nuestro método es mucho mejor que los otros dos. Esto lo encontramos en las ampliaciones que se llevaron a cabo para la imagen del mandril (en la Fig. 50) y del mapa de México (en la Fig. 51).

5 Conclusiones

Resumen. Finalmente, se detallan las ventajas y desventajas del algoritmo propuesto a modo de conclusiones, los aportes y contribuciones hechas, las propuestas para trabajos futuros, así como algunas recomendaciones.

5.1. Conclusiones

El algoritmo de selección de colores esenciales propuesto es un método de cuantificación del color no supervisado, el cual ha de constituir una herramienta para cubrir la necesidad de reconocer e interpretar más fiablemente la información existente en las imágenes en colores. Su propósito ha sido, mediante la aplicación del espacio de color $L^*a^*b^*$ y la fórmula de diferencia de color CIE2000, hallar automáticamente los colores esenciales de una imagen para que al regenerarla con solo estos colores no pierda la mayor parte de la información descriptiva de los objetos.

Las ventajas fundamentales que brinda son:

Automatización: La cantidad de colores obtenidos en la paleta de colores son independientes del nivel de tolerancia elegido según las propiedades intrínsecas en la imagen, propiedades que escapan del alcance de los métodos clásicos.

Eficacia: La descripción cualitativa de una imagen en colores puede ser muy precisa. Los pequeños detalles de una imagen, como los ojos del mandril o los símbolos en el Mapa 1, son claramente percibidos sin perder los detalles.

El algoritmo desarrollado no es un algoritmo que limpie ruido de la imagen, dado que si el color con el que cuenta el píxel de ruido particular no se mezcla con su fondo (lo que es muy probable con los ruidos de tipo sal y pimienta o bien aleatorios), se considera como un detalle en la imagen y el algoritmo lo preservaría.

Adicionalmente encontramos que funciona con imágenes digitales sin importar su procedencia, esto es, ya sea con imágenes escaneadas o generadas por computadora, los resultados de la cuantificación del color son los mismos; mantiene los contornos de los patrones gráficos presentes; no se requiere conocer ninguna información a priori sobre su contenido; no se requiere ningún tipo de preprocesamiento; los resultados son independientes de la orientación de los objetos; por ser un método de agrupamiento de píxeles, puede ser utilizado en la segmentación de imágenes sobre la base del color.

Encontramos como desventaja de nuestro algoritmo con respecto a los demás métodos de cuantificación el tiempo de cómputo requerido. Se plantea como un trabajo futuro implementar nuevas soluciones que compensen esta desventaja.

5.1 Resultado colateral: Segmentación de imágenes

Como se ha explicado anteriormente, la metodología propuesta arroja una imagen regionalizada que es de gran utilidad para la segmentación de los objetos presentes en las imágenes. En esta sección analizaremos algunos resultados obtenidos segmentando imágenes a partir del empleo de la imagen regionalizada como máscara.

La Fig. 62 a continuación, muestra dos segmentos del mapa de México y otras cuatro imágenes empleadas para este análisis; tres de estas imágenes son de la base en [UCS Universidad del sur de California, 2008]; en todas ellas nosotros empleamos el nivel de tolerancia predefinido de 8. Se muestra para cada imagen, la original, la imagen regionalizada a ser empleada como máscara y la imagen de salida que contiene algún objeto de interés de la imagen original.

Se aprecia claramente la ventaja de segmentar pequeños objetos con base en su color. Esta técnica aplicada a los mapas cartográficos, facilitara la segmentación de los mismos y una posterior minería de datos sobre ellos.

Capítulo 5 Conclusiones

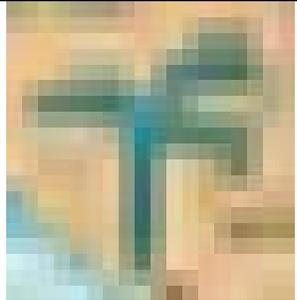
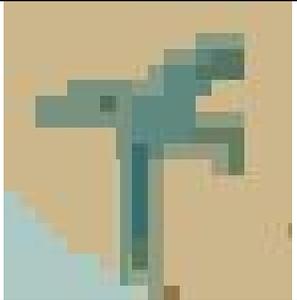
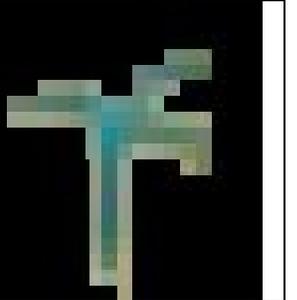
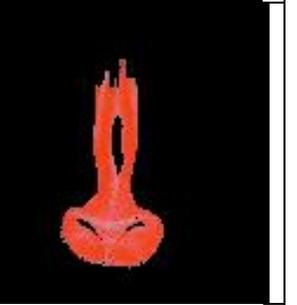
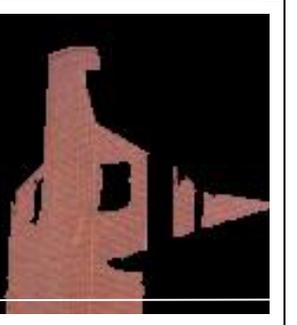
Imagen original	Imagen regionalizada	Resultado de segmentación
		
		
		
		
		
		

Fig. 62 Segmentaciones de objetos de interés en 4 imágenes, empleando el método propuesto.

Como puede observarse el método propuesto sirve como una herramienta de segmentación no supervisada de imágenes, ya que el valor de tolerancia de ocho ha demostrado tener la capacidad de segmentar los objetos de mayor interés en imágenes con distintas características.

5.2 Resultado colateral: Compresión de imágenes

El tamaño de una imagen mientras se procesa con un programa o se muestra en un explorador es el que corresponde a su número de píxeles y profundidad de bits. La compresión, en realidad, consiste en sustituir la cadena de datos por otra más corta cuando se guarda el archivo. Ciertos métodos son reversibles (*lossless*), porque permiten la reconstrucción exacta del original. Pero con otros, la información original sólo se recupera aproximadamente, ya que se descarta una parte de los datos (*lossy*) a cambio de relaciones de compresión mucho mayores.

Encontramos en nuestro algoritmo una herramienta para preprocesamiento en la compresión de imágenes, dado que al reducir la cantidad de colores de manera adaptativa a la imagen en sí, ayuda a los algoritmos de compresión a reducir aún más el tamaño del archivo comprimido.

Para llegar a esta conclusión se han explorado algoritmos de compresión de imágenes dedicados, como es el formato PNG, el cual es un formato de almacenamiento sin pérdida y el algoritmo de compresión ZIP, para almacenar conjunto de archivos en este caso de imágenes.

En la Tabla 8 se muestran los diferentes grupos de imágenes comprimidas a partir de los originales y a partir de las imágenes cuantificadas mediante nuestro algoritmo; ambos tipos de imágenes se encuentran almacenadas en formato BMP. Debido a que ambas imágenes tienen el mismo tamaño espacial (la misma cantidad de píxeles) pesan lo mismo los bloques de imágenes originales y los bloques de las imágenes cuantificadas; la ventaja se muestra una vez que son comprimidas.

Se han elegido las 20 imágenes más grandes en formato BMP de todos los bloques para ser comparadas en su conversión a PNG. De la misma manera convertimos a este formato las imágenes originales y las imágenes cuantificadas para su comparación. Los resultados se muestran en la Tabla 9. El tamaño de los archivos es mostrado en KB.

Capítulo 5 Conclusiones

Tabla 8 Comparación de la compresión en los bloques de imágenes (ZIP).

Bloque	Originales	Cuantificadas	Tasa
Color	5631	609	0.10815131
Memorama	3124	284	0.09090909
Otras	7618	979	0.12851142
Picasso	4056	542	0.13362919
RayosX	751	75	0.09986684
Rostros	582	61.3	0.10532646

Tabla 9 Comparación de la compresión en archivos individuales de imágenes (PNG).

Nombre	Original	Cuantificada	Tasa
Bridge.png	456,665	170,517	0.37339625
Color10.png	502,893	98,315	0.19549884
Color11.png	681,548	438,337	0.64314913
Color12.png	517,575	96,152	0.18577404
Color13.png	452,772	90,909	0.20078318
Color14.png	577,170	251,399	0.43557184
Color15.png	518,938	129,090	0.24875804
Mapa1.png	925,406	278,197	0.30062157
Memo.png	555,096	121,215	0.21836763
Memo1.png	499,248	58,355	0.1168858
Memo2.png	512,465	61,866	0.12072239
Memo3.png	429,314	81,400	0.18960481
Memo5.png	469,540	69,464	0.14794054
Memo6.png	383,285	59,465	0.15514565
Memo7.png	413,636	60,929	0.14730101
Paint1.png	1,838,032	724,959	0.39442132
Paint2.png	1,490,641	398,290	0.26719378
Paletas.png	519,054	189,686	0.3654456
Picasso8.png	585,154	175,207	0.29942032
RayosX0.png	330,490	36,284	0.1097885

Como se puede observar, la tasa de compresión en bloques a través del algoritmo ZIP es de 1:10 aproximadamente y en archivos individuales con el formato PNG es de 1:4 en promedio. Por lo tanto, el algoritmo de cuantificación automática constituye una herramienta muy útil para el preprocesamiento de las imágenes antes de su compresión por lo que bien podría ser incluido dentro de los mismos algoritmos clásicos y modernos de compresión con el fin de mejorar su rendimiento. Si bien la pérdida de información en la cuantificación es reducida

para la mayoría de las imágenes, en algunas esta pérdida podría ser inaceptable para una aplicación de compresión; esto puede evitarse llevando el nivel de tolerancia empleado a 2 en lugar de 8, dado que según los desarrolladores de la CIE2000 una diferencia de 2 en esta métrica es inapreciable por el ojo humano. Esto llevaría sin duda a más colores y tamaños de archivos más grandes que los mostrados en este trabajo, pero indudablemente las mejoras existirían.

5.3 Aportes y contribuciones

Los avances en el desarrollo de este trabajo dieron lugar a las siguientes publicaciones:

La cuantificación del color: una aproximación al estado del arte, 2008, Sergio A. Márquez De Silva y Edgardo M. Felipe Riverón. Informe Técnico, Serie Azul, No. 236, abril de 2008, CIC-IPN, México.

A new quantization method for digital color images, 2008, Sergio A. Márquez De Silva y Edgardo M. Felipe Riverón. Ponencia presentada en la 9th *Conference on Computing CORE*, abril del 2008.

A simple and effective method of color image quantization, 2008, Sergio A. Márquez De Silva y Edgardo M. Felipe Riverón. Ponencia presentada en el XIII Iberoamerican Congress on Pattern Recognition CIARP 2008 en La Habana, Cuba, septiembre del 2008.

5.4 Trabajo futuro

En el futuro pensamos acometer las tareas siguientes:

1. Optimizar el algoritmo y llevar un análisis en cuanto a tiempo de cómputo para ser comparado con otros algoritmos de cuantificación del color.
2. Generar el algoritmo o la herramienta de tal forma, que nos permita encontrar el nivel de tolerancia óptimo para cada imagen, sin que esto implique una búsqueda exhaustiva o largos periodos de tiempo de cómputo.
3. Llevar a cabo un análisis en cuanto a la eficiencia del algoritmo para la segmentación de imágenes, y comparar los resultados obtenidos con los métodos clásicos y actuales de segmentación de imágenes en colores.

5.5 Recomendaciones

De acuerdo con los resultados obtenidos, hacemos las siguientes recomendaciones:

1. Aplicar el paquete de software creado en aplicaciones que requieran llevar a cabo un análisis de imágenes para la extracción de información.
2. Preparar un paquete de demostración, con el fin de brindarlo como un trabajo terminado del CIC.
3. Brindar el programa ejecutable a todo alumno de maestría, en caso de que lo considere útil, para utilizarlo como herramienta para su tesis. En este caso se exigirían las recomendaciones que con su experiencia de uso, nos puedan brindar.
4. Publicar en eventos científicos y revistas nacionales e internacionales, los resultados aun no publicados y todo aquel que surja de las nuevas experiencias dadas por su uso.

Referencias

- Balasubramanian, R., C. A. Bouman, et al. (1995). "Sequential Scalar Quantization of Vectors an Analysis." IEEE transactions on image processing 4(9): 1282-1295.
- Bezdek, J. C. (1981). Pattern Recognition with Fuzzy Objective Function Algorithms. Nueva York, EE.UU., Plenum Press.
- Braun, G. J., M. D. Fairchild, et al. (1998). Color gamut mapping hue-linearized CIELAB color space. IS&T/SID Sixth Color Imaging Conference: Color Science, Systems and Applications. Scottsdale, AZ: 163-168.
- CIE Proc (1964). 15th Session, Vienna 1963 ; Vol A, 35 (recomendation 1). Paris.
- Domanski, M. y M. Bartkowiak (1998). "Compression", The Colour Image Processing Handbook. Cambridge, Gran Bretaña, Chapman & Hall.
- Floyd, R. y L. Steinberg (1975). An adaptive algorithm for spatial gray scale, in SID, Ed., Int. Symp. Dig. Tech. Papers 36.
- Gervautz, M. y W. Purgathofer (1988). A simple method for color quantization: octree quantization. New York, N. Magnenat-Thalmann and D. Thalmann.
- González, R. C. y R. E. Woods (2008). Tratamiento Digital de Imágenes. Wilmington, EE.UU., Addison – Wesley.
- Heckbert, P. (1982). "Color Image Quantization for Frame Buffer Display." Computer Graphics 16: 297-307.
- Hunt, R. W. G. (1995). The reproduction of Colour, Fountain Press.
- Jain, A. K. y W. K. Pratt (1972). Color Image Quantization. Houston, EE.UU., Proceedings National Telecommunications Conference.
- Kender, J. R. (1976). Saturation, Hue and Normalized Color: Calculation, Digitation Effects, and Use, Carnegie-Mellon Univ.
- Kolpatzik, B. W. y C. A. Bouman (1995). "Optimized Universal Palette Design for Error Diffusion." Journal of Electronic Imaging 4(2): 131-143.
- Linde, Y., A. Buzo, et al. (1980). "An Algorithm for Vector Quantizer Design." Communications, IEEE Transactions on 28(1): 84-95.

Lucchese, L. y S. K. Mitra (2001). "Color Segmentation Based on Separate Anisotropic Diffusion of Chromatic and Achromatic Channels." IEEE Proceedings: Vision, Image, and Signal Processing **148**.

Luo, M. R., G. Cui, et al. (2001). The development of the CIE 2000 colour difference formula: CIEDE2000, *Color Res. Appl.* **26 (5)**: 340–350.

MacAdam, D. L. (1942). Visual sensitivities to color differences in daylight, *J. Opt. Soc. Am.* **Vol. 32**: 247-273.

Munsell, A. H. (1905). A Color Notation. Baltimore, MD, Munsell Color Co.

Orchard, M. T. y C. A. Bouman (1991). "Color Quantization of Images." Signal Processing, IEEE Transactions on **39(12)**: 2677-2690.

Piñero, B. A. (2002). Segmentación y clasificación de imágenes en color. Aplicación al diagnóstico de quemaduras. Sevilla.

Plataniotis, K. N. y A. N. Venetsanopoulos (2000). Color Image Processing and Applications. Berlin, Alemania, Springer.

Poynton, C. (1999). "Frequently Asked Questions about Color." from www.inforamp.net/~poynton.

Pratt, W. K. (2001). Digital Image Processing. Nueva York, EE.UU., Wiley.

Ramos, G. M. E. y R. E. M. Felipe (2002). Mejoramiento de imágenes digitales impresas en semitonos. México D.F., CIC.

Sangwine, S. J. y R. E. N. Horne (1998). The Colour Image Processing Handbook. Cambridge, Gran Bretaña, Chapman & Hall.

Sharma, G. y H. J. Trussel (1997). "Digital Color Processing." IEEE Trans. Image Proc. **IP-6(7)**: 901-932.

Sheunders, P. (1996). A Genetic Approach towards Optimal Color Image Quantization. International Conference on Image Processing, Lausanne (Suiza).

Tenenbaum, J. M. (1975). Research on Interactive Scene Analysis. Menlo Park, California, Stanford Research Institute.

UCS Universidad del sur de California (2008). "Base de imagenes." from <http://sipi.usc.edu/services/database/Database.html>.

Wan, S., S. Wong, et al. (1988). An Algorithm for Multidimensional Data Clustering.

Weeks, A. R. y G. E. Hague (1997). Color Segmentation in the HIS Color Space Using the K-means Algorithm.

Wu, X. (1992). "Color quantization by dynamic programming and principal analysis." ACM Transactions on Graphics (TOG) 11(4): 348-372.

Wyszecky, G. y W. S. Stiles (1982). Color Science. Concepts and Methods, Quantitative Data and Formulae. Nueva York, EE.UU., Wiley.