

# Sistema Experto para la Selección de algoritmos de constancia de color.

Cepeda-Negrete, J.

Cita:

Cepeda-Negrete, J. (2012). *Sistema Experto para la Selección de algoritmos de constancia de color* (Tesis de Maestría). Universidad de Guanajuato DICIS, Salamanca, México.

Dirección estable: <https://www.aacademica.org/jcepedanegrete/8>

ARK: <https://n2t.net/ark:/13683/pa8v/Ach>



Esta obra está bajo una licencia de Creative Commons.  
Para ver una copia de esta licencia, visite  
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>.

*Acta Académica es un proyecto académico sin fines de lucro enmarcado en la iniciativa de acceso abierto. Acta Académica fue creado para facilitar a investigadores de todo el mundo el compartir su producción académica. Para crear un perfil gratuitamente o acceder a otros trabajos visite: <https://www.aacademica.org>.*



**UNIVERSIDAD DE GUANAJUATO**

---

---

División de Ingenierías  
Campus Irapuato-Salamanca

**SISTEMA EXPERTO PARA LA SELECCIÓN  
DE ALGORITMOS DE CONSTANCIA DE  
COLOR**

**TESIS PROFESIONAL**

QUE PARA OBTENER EL GRADO DE  
MAESTRO EN INGENIERÍA ELÉCTRICA  
OPCIÓN: INSTRUMENTACIÓN Y SISTEMAS DIGITALES

PRESENTA:

**Ing. Jonathan Cepeda Negrete**

Asesor:

**Dr. Raúl Enrique Sánchez Yáñez**

# Agradecimientos

---

A mi esposa **Pamela Fiscal**, por todo el apoyo brindado durante este proceso de formación y desarrollo del proyecto. Por estar a mi lado en los mejores y peores momentos incondicionalmente.

A mi madre **Magdalena Negrete** y mi hermano **Eduardo Cepeda**, por brindarme siempre su apoyo durante la realización del proyecto.

A mi asesor, el **Dr. Raúl Enrique Sánchez Yáñez**, por todas sus valiosas enseñanzas académicas y personales. Por toda la confianza y apoyo en la realización de nuestro proyecto.

Al **Dr. Victor Ayala Ramirez**, por sus valiosas palabras y consejos. Además de ser un pilar importante en mi proceso de formación.

A todos mis compañeros del LaViRIA sin excepción alguna, por su valiosa compañía e intercambio de ideas.

*"Para las personas creyentes, Dios esta al principio.  
Para los científicos está al final de todas sus reflexiones".*

Max Planck (1858-1947) Físico alemán.

# Agradecimientos Institucionales

---

A la Universidad de Guanajuato, por permitirme seguir siendo parte de su formación educativa.



Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por el financiamiento proporcionado para el programa de Maestría en Ingeniería Eléctrica con número de beca 254884.



A la Dirección de Apoyo a la Investigación y al Posgrado (DAIP), por las becas de excelencia brindadas en cada periodo.



# Índice general

---

<b>Índice general</b>	<b>II</b>
<b>Índice de figuras</b>	<b>V</b>
<b>Índice de tablas</b>	<b>VII</b>
<b>Resumen</b>	<b>1</b>
<b>1. Introducción</b>	<b>3</b>
1.1. Color . . . . .	3
1.2. Constancia de Color . . . . .	4
1.3. Estimación del color de la fuente luminosa . . . . .	6
1.4. Otras aportaciones . . . . .	7
1.5. Propuesta . . . . .	8
1.6. Resumen . . . . .	8
<b>2. Reproducción del color</b>	<b>10</b>
2.1. Teoría Retinex . . . . .	10
2.2. Espacios de color . . . . .	12
2.2.1. sRGB . . . . .	12
2.2.2. YCbCr . . . . .	13
2.2.3. CIEXYZ . . . . .	13
2.2.4. CIELab . . . . .	14
2.2.5. CIELuv . . . . .	15
2.2.6. RLab . . . . .	16
2.2.7. Coordenadas cilíndricas de los espacios . . . . .	18
2.3. Corrección gama . . . . .	18
2.4. Medición y calidad del color . . . . .	20
2.4.1. Índices de tonalidad . . . . .	20
2.4.2. Métrica del Power Spectrum . . . . .	23

## ÍNDICE GENERAL

---

2.4.3. Promedio de la croma . . . . .	23
2.4.4. Histogramas de color . . . . .	24
2.5. Resumen . . . . .	26
<b>3. Algoritmos para constancia de color</b>	<b>27</b>
3.1. Clasificación de los algoritmos . . . . .	27
3.2. Transformación de la imagen . . . . .	27
3.3. Algoritmos para escenas con iluminación uniforme . . . . .	28
3.3.1. White Patch Retinex . . . . .	29
3.3.2. Gray World . . . . .	30
3.3.3. Variante de Horn . . . . .	31
3.3.4. White Patch en CIELab . . . . .	32
3.3.5. Shades-of-Gray . . . . .	32
3.3.6. General Gray-World . . . . .	33
3.3.7. Gray-Edges . . . . .	34
3.4. Algoritmos para escenas con iluminación no uniforme . . . . .	34
3.4.1. Promedio de color en espacio local . . . . .	35
3.4.2. Filtrado homomórfico . . . . .	36
3.5. Evaluación de los algoritmos de constancia de color . . . . .	38
3.6. Resumen . . . . .	38
<b>4. Diseño del sistema experto</b>	<b>39</b>
4.1. Metodología del sistema desarrollado . . . . .	39
4.2. Extracción de características en las imágenes . . . . .	40
4.2.1. Color . . . . .	41
4.2.2. Iluminación . . . . .	41
4.2.3. Textura . . . . .	41
4.3. Aprendizaje de las reglas . . . . .	42
4.3.1. Formulación de las reglas <i>SI-ENTONCES</i> . . . . .	42
4.3.2. Definición de los términos lingüísticos . . . . .	43
4.3.3. Regla de evaluación para el reconocimiento de los algoritmos . . . . .	43
4.4. Base de datos . . . . .	44
4.5. Clasificación de las imágenes de entrenamiento . . . . .	45
4.6. Resumen . . . . .	47
<b>5. Evaluación del sistema</b>	<b>48</b>
5.1. Resultados utilizando una regla por clase . . . . .	48
5.2. Resultados utilizando cinco reglas por clase . . . . .	48
5.3. Resultados optimizando las reglas . . . . .	51

## ÍNDICE GENERAL

---

5.4. Comparación con otros clasificadores . . . . .	54
5.5. Tiempos de procesamiento . . . . .	55
5.6. Resumen y Discusión . . . . .	57
<b>6. Estudios realizados en paralelo al proyecto de investigación</b>	<b>58</b>
6.1. Experimentos con el White Patch Retinex en los espacios de color RGB y CIELab . . . . .	58
6.1.1. Justificación del uso de CIELab . . . . .	58
6.1.2. Metodología de los experimentos . . . . .	59
6.1.3. Resultados en los experimentos . . . . .	60
6.2. Combinación de la constancia de color y la corrección gama para la mejora de imágenes . . . . .	63
6.2.1. Justificación en el uso de la corrección gama . . . . .	63
6.2.2. Metodología en la combinación de los algoritmos . . . . .	63
6.2.3. Resultados de la combinación . . . . .	64
6.2.4. Conclusiones del capítulo . . . . .	68
<b>Conclusiones y Perspectivas</b>	<b>69</b>
<b>A. Base de datos SFU Laboratory</b>	<b>72</b>
<b>Bibliografía</b>	<b>74</b>

# Índice de figuras

---

1.1. El triángulo de color. Muestra la interacción entre la luz, los objetos y los humanos [Fairchild2005]. . . . .	4
1.2. Tarjeta de calibración bajo dos fuentes de iluminación distintas, azul y amarilla. Así mismo, la tarjeta bajo iluminación ideal mostrando los colores correctos de los parches. . . . .	5
2.1. Una imagen mondriana, similar a la usada por Land y McCann en su experimento [Land1977]. . . . .	11
2.2. Espacio de color sRGB [Ebner2007]. . . . .	12
2.3. Representación del espacio $YCbCr$ . . . . .	13
2.4. sRGB visualizado en el espacio $L^*a^*b^*$ [Ebner2007]. . . . .	15
2.5. sRGB visualizado en el espacio $L^*u^*v^*$ [Ebner2007]. . . . .	17
2.6. sRGB visualizado en coordenadas cilíndricas del espacio $L^*a^*b^*$ [Tomada de <a href="http://www.pocketspec.com/whatiscielab.html">www.pocketspec.com/whatiscielab.html</a> ]. . . . .	19
2.7. Ejemplo de imágenes excluidas del análisis. . . . .	21
2.8. a) Imagen con varios colores junto con su histograma 2D en plano $ab$ . b) Imagen con un color predominantes y que muestra un histograma 2D concentrado. . . . .	21
2.9. a) Imagen con varios colores y su respectivo $CE$ . a) Imagen con un color predominantes y su respectivo $CE$ . . . . .	22
2.10. Dos escenas distintas y cada una con dos imágenes de distinta calidad. Las imágenes de la derecha tienen mayor calidad que las de la izquierda de acuerdo al APSV ( $\times 10^9$ ). . . . .	24
2.11. Dos escenas distintas y cada una con dos imágenes de distinta calidad de acuerdo la el promedio de la croma. . . . .	25
3.1. a) Imagen original. b) Imagen procesada con el algoritmo WP original. c) Imagen procesada con la variante de Finlayson. . . . .	30
3.2. a) Imagen original. b) Imagen procesada con el algoritmo WPR de Finlayson. c) Imagen procesada con GW. . . . .	31



## ÍNDICE DE FIGURAS

---

3.3. a) Imagen original. b) WP en RGB. c) WP en CIELab. d) WP en ambos espacios . . . . .	33
3.4. a) Imagen original. b) Promedio de color en espacio local. . . . .	36
3.5. a) Imagen original. b) Filtrado homomórfico. . . . .	37
4.1. Diagrama de la metodología seguida en el diseño del sistema experto. . . .	40
4.2. Representación de conjuntos difusos triangulares para una característica. . .	44
4.3. Imágenes de muestra, pertenecientes a la base de datos SFU Laboratory. . .	45
5.1. Algunas imágenes seleccionadas de forma errónea. . . . .	54
6.1. Tres aproximaciones para la evaluación experimental del WPR. . . . .	59
6.2. Comportamiento del APSV para los enfoques del WPR en el conjunto de imágenes. . . . .	60
6.3. Tendencia del APSV en los enfoques usando ajuste a la curva para el conjunto de imágenes. . . . .	61
6.4. Algunas imágenes de muestra de entrada y sus resultantes . . . . .	62
6.5. Evaluación experimental de cuatro enfoques combinando algoritmos de constancia de color y corrección gama. . . . .	64
6.6. Tendencia de los APSVs para cada imagen de prueba y sus resultantes en los enfoques usando WPR. . . . .	65
6.7. Seis muestras de 236 imágenes probadas al WPR y sus correspondientes resultantes. . . . .	66
6.8. Tendencia de los APSVs para cada imagen de prueba y sus resultantes en los enfoques usando GW. . . . .	67
6.9. Seis muestras de las 236 imágenes probadas al GW y sus correspondientes resultantes. . . . .	67

# Índice de tablas

---

3.1. Clasificación de los algoritmos de constancia de color según [Gijssenij2011]. . . . .	28
4.1. Clasificación de las imágenes de entrenamiento en base al promedio de la cromacia. . . . .	46
4.2. Probabilidad a priori de resultar ser el mejor algoritmo. . . . .	47
5.1. Resultados de la clasificación usando cinco reglas por clase. . . . .	51
5.2. Matriz de confusión de los resultados usando conjuntos triangulares e inferencia Mamdani. . . . .	53
5.3. Matriz de confusión de los resultados usando conjuntos triangulares e inferencia Larsen. . . . .	53
5.4. Matriz de confusión de los resultados usando conjuntos Gaussianos e inferencia Mamdani. . . . .	53
5.5. Matriz de confusión de los resultados usando conjuntos Gaussianos e inferencia Larsen. . . . .	53
5.6. Comparación entre clasificadores. . . . .	55
5.7. Tiempos medidos por rutina (ms) para diferentes tamaños de imágenes. . . . .	56
6.1. Medida de calidad(APSV) para algunas imágenes de muestra y sus resultados. . . . .	61
6.2. Medidas de calidad ( $APSV \times 10^8$ ) para las imágenes en la Fig. 6.7. . . . .	65
6.3. Medidas de calidad ( $APSV \times 10^8$ ) para las imágenes en la Fig. 6.9. . . . .	68

# Resumen

---

Imagínese comprando un automóvil en la agencia. Frecuentemente el color del automóvil es un factor muy importante para su elección. Sin embargo, al observarlo nuevamente en el exterior se observa que el color no es exactamente el mismo. Éste, es un ejemplo de que el sistema visual humano es limitado. Afortunadamente, la mayoría de la veces, los colores de una superficie en particular, parecen ser los mismos, en interiores o exteriores, en la mañana o en la tarde. A este fenómeno se le conoce como Constancia de Color (*Color Constancy* en inglés), y es tratada a lo largo de este proyecto. Por otro lado, se incluyen los aportes en el tema generados en las últimas décadas, las problemáticas existentes y la propuesta contemplada, serán revisadas en el Capítulo 1.

En el Capítulo 2, se abordará el tema del color de manera conceptual y su formación en las imágenes. Además, se describen algunos de los espacios de color existentes y utilizados en el proyecto. Y finalmente, se indican los atributos y características asociadas con el color relevantes que serán de gran importancia en aspectos futuros del trabajo.

En el Capítulo 3, algunos algoritmos propuestos para resolver la constancia de color son revisados. Los algoritmos son separados en dos grupos, algoritmos para casos donde la iluminación es uniforme, y algoritmos para iluminación que no es uniforme o o se tienen múltiples iluminantes. Finalmente, se revisa la métrica comúnmente utilizada para evaluar la estimación realizada por los algoritmos de constancia de color.

Desafortunadamente, ningún algoritmo de constancia de color puede ser adoptado como universal. Por otra parte, el diseño de un selector de algoritmos de constancia de color es una tarea difícil debido a las muchas características que están involucradas en el problema. Para esto, técnicas de computación flexible pueden ser usadas para modelar problemas con soluciones complicadas o múltiples variables. Ejemplo de estas técnicas, es el caso de los sistemas difusos basados en reglas. En el Capítulo 4, será tratado el desarrollo de un sistema experto basándose en lógica difusa. Este sistema deberá seleccionar un algoritmo de constancia de color óptimo, el cual está directamente relacionado con las características visuales de la escena actual.

En el Capítulo 5, se muestran y analizan los resultados obtenidos por el sistema selector de algoritmos de constancia de color. Recordando que el sistema, en este caso difuso, está basado en reglas que proporcionan la información necesaria para que éste tome una

decisión. Tales reglas, son generadas en base a la información obtenida en imágenes de prueba. El número de reglas y la forma de evaluar el sistema, son puntos que son contemplados a continuación.

En el Capítulo 6 se abordarán dos metodologías trabajadas de forma paralela al proyecto de investigación tratado en los capítulos anteriores. Por un lado, se realizaron algunos experimentos en adaptación cromática utilizando el algoritmo White-Patch en el espacio CIELab. Por otra parte, se comparó el uso de la corrección gama en combinación con algoritmos de constancia de color con propósitos de mejorar una imagen.

---

# Capítulo 1

## Introducción

---

Imagínese comprando un automóvil en la agencia. Frecuentemente el color del automóvil es un factor muy importante para su elección. Sin embargo, al observarlo nuevamente en el exterior se observa que el color no es exactamente el mismo. Éste, es un ejemplo de que el sistema visual humano es limitado. Afortunadamente, la mayoría de la veces, los colores de una superficie en particular, parecen ser los mismos, en interiores o exteriores, en la mañana o en la tarde. A este fenómeno se le conoce como Constancia de Color (*Color Constancy* en inglés), y es tratada a lo largo de este proyecto. Por otro lado, se incluyen los aportes en el tema generados en las últimas décadas, las problemáticas existentes y la propuesta contemplada, serán revisadas en este capítulo.

### 1.1. Color


El color es un factor importante en la visión por computadora y temas relacionados como el procesamiento de imágenes, la interacción hombre-maquina [Yang1998], la extracción de características por color [Gijsenij2011], y los modelos en apariencia de color [Fairchild2005]. Los colores que están presentes en imágenes son determinados por propiedades intrínsecas de objetos y superficies, así como el color de la fuente de luz. Para un sistema robusto basado en color, estos efectos de la fuente de luz deberían ser filtrados.

El color es un atributo de la sensación visual y de la apariencia de los objetos [Fairchild2005], dependiendo de tres componentes para su formación, como se muestra en la Figura 1.1. El primer atributo requerido es una fuente de energía electromagnética visible necesaria para iniciar el proceso de medición. Esta energía, es entonces modulada por propiedades físicas y químicas de un objeto. Así, la energía modulada es captada por el ojo, detectada por los fotorreceptores y procesada por los mecanismos neuronales del sistema visual humano, produciendo nuestra percepción del color.

Un rayo de luz sale de una fuente luminosa y alcanza el objeto en algún punto en particular. El coeficiente de reflexión en ese punto, como un resultado de las propiedades

## 1.2 Constancia de Color

---



**Figura 1.1:** El triángulo de color. Muestra la interacción entre la luz, los objetos y los humanos [Fairchild2005].

del material del objeto, determina la cantidad de luz incidente que es reflejada. Esta luz que se refleja, entra al ojo y es medida. Existen tres tipos de receptores en la retina humana, que miden dicha luz. Ellos absorben la luz con longitud de onda en la parte larga, mediana y corta del espectro electromagnético. Con el fin de describir la cantidad de luz reflejada por el objeto, tendríamos que medir la reflectancia de todo el espectro visible. La reflexión podría medirse mediante la iluminación de los objetos con luz blanca o alguna otra fuente de luz cuya distribución de energía sea conocida. Sin embargo, un dispositivo de medición, como una cámara, no conoce la distribución de energía de la fuente luminosa. Es decir, no mide la reflectancia. En su lugar, se mide el producto de la reflexión del objeto y la cantidad de luz que llega al objeto. Aquí tenemos dos incógnitas, la reflexión y el tipo de fuente de luz [Ebner2007].

El color puede ser descrito con nombres de descripción cromática tales como azul, rojo, verde, amarillo y acromáticos como blanco, negro, gris. También, puede ser calificado por brillante, claro, oscuro, etc. El color percibido depende de la distribución espectral del estímulo del color. También depende del tamaño, forma, estructura y lo que rodea al área del estímulo. Además, del estado de adaptación del sistema visual del observador, y de la experiencia previa del observador en situaciones similares en observaciones.

## 1.2. Constancia de Color


La habilidad de distinguir los colores correctos de una o varias superficies, independiente del color de la fuente de luz presente en la escena, se conoce como *Constancia de Color* [Zeki1993].

Un ejemplo se da en la Figura 1.2, donde se representa la misma tarjeta de calibración bajo dos diferentes fuentes de iluminación. Cuando observamos los parches superiores en

## 1.2 Constancia de Color

---

las tarjetas, los humanos podríamos observar los colores rosa y amarillo, respectivamente, cuando realmente es beige. De forma similar, para los parches inferiores, los colores observados son distintos al color real, gris.



**Figura 1.2:** Tarjeta de calibración bajo dos fuentes de iluminación distintas, azul y amarilla. Así mismo, la tarjeta bajo iluminación ideal mostrando los colores correctos de los parches.

La constancia de color permite la interpretación de los colores en el contexto de su entorno. El sistema visual humano aprende de manera natural esta habilidad [Fairchild2005], hasta cierto punto. Sin embargo, los mecanismos que están involucrados en esta habilidad no están del todo entendidos aún [Gijssenij2011]. Por lo contrario, los sistemas visuales mecánicos y electrónicos, solamente reciben luz del entorno, por lo cual resulta complicado entender la información correcta de la escena proporcionada [Agarwal2006]. En consecuencia, es necesario realizar una calibración de cámara o un post-procesamiento para producir una imagen real y atractiva. Otras aplicaciones de visión por computadora, como el reconocimiento de objetos o escenas, la segmentación, el seguimiento por video y la atención visual, pudieran beneficiarse de una precisa constancia de color.

Desde el punto de vista computacional, la constancia de color se define como la transformación de una imagen de entrada, tomada bajo una iluminación desconocida, a una imagen que aparenta ser tomada bajo una luz conocida, comúnmente blanca. Para esto, se necesita estimar el color de la fuente de luz en la imagen. Estos valores del color de la fuente luminosa, son usados para transformar la imagen de entrada a una de salida. La imagen resultante representa la misma escena que la imagen de entrada, pero ahora aparentando ser tomada bajo una fuente de luz conocida (blanca).

Por lo general, los métodos computacionales de constancia de color únicamente consideran los valores de los píxeles, sin tomar en cuenta las relaciones espaciales entre ellos.

### 1.3 Estimación del color de la fuente luminosa

---

Esto limita el potencial del algoritmo, y no toda la información se puede utilizar. Además, se ha planteado que el sistema visual humano es específicamente sensible al contraste local [Weber1846]. Esto significa que la respuesta del sistema visual humano, depende de las variaciones locales a los valores de luminancia de su alrededor, en vez de los valores de luminancia globales.

Por décadas, varios investigadores han intentado resolver el problema de la constancia de color, proponiendo varios algoritmos y métodos. Sin embargo, no se ha podido establecer una única solución que resuelva el problema. Debido al amplio rango de aplicaciones de visión por computadora que requieren de la constancia de color, es imposible tener una solución única para todos los casos. Ésto, ha llevado a las investigaciones en identificar un conjunto de posibles enfoques que puedan aplicarse a problemas particulares. Principalmente, los esfuerzos se concentran en identificar aproximaciones de constancia de color para el seguimiento por video en tiempo real [Agarwal2006].

Como bien es mencionado, no existe una única solución a un problema en particular. Por lo tanto, cada uno de los algoritmos presentan un desempeño distinto y no óptimo. Como consecuencia, los estudios se dividen en dos sentidos; originando nuevos algoritmos o mejoras en los existentes, y en la búsqueda del algoritmo correcto para necesidades particulares.

### 1.3. Estimación del color de la fuente luminosa

Las imágenes se componen de una combinación de reflectancia del objeto, la posición geométrica en que se encuentra y el color de la fuente de luz. Ésto hace que el problema de la estimación de la fuente de luz sea mal planteado, y no pueda ser recuperada en base sólo a los colores de las imágenes. Debido a esto, todos los algoritmos hacen uso de suposiciones para simplificar el problema. Una de las suposiciones más conocidas y utilizadas, es la suposición del Mundo Gris o *Gray-World* [Buchsbaum1980]. Esta asume que la iluminación reflejada por los objetos (reflectancia) promedio en una escena, bajo una fuente de luz blanca, es acromática. Otro algoritmo muy conocido se basa en la suposición del Parhce Blanco o *White-Patch*, es decir, la suposición de que la respuesta máxima en los canales del espacio RGB es causada por una reflectancia perfecta [Land1971]. Otros métodos que se basan en estadísticas simples de las imágenes, son los algoritmos de Tonos de Gris o *Shades-of-Gray* [Finlayson2004], Bordes en Gris o *Gray-Edges* [Weijer2007a] y el algoritmo de Local Space Average Color [Ebner2009].

Por otra parte, los métodos más complejos se desarrollan en base a la información adquirida en una fase de aprendizaje. Las posibles fuentes de luz, la distribución de los colores en posibles reflectancias y las previas probabilidades sobre la combinación de colores, se aprenden y se utilizan para estimar el color de la fuente de luz. Uno de los primeros



## 1.4 Otras aportaciones

---

algoritmos de este tipo, es el algoritmo Gamut-Mapping [Forsyth1990]. Este algoritmo, se basa en la suposición de que en imágenes del mundo real, para una iluminación dada, sólo un número limitado de colores pueden ser observados. Al hacer uso de esta suposición, la fuente luminosa se puede estimar comparando la distribución de los colores en la imagen actual y una distribución pre-aprendida de los colores (llamada gama canónica). Muchos algoritmos se han derivado del algoritmo original incluyendo el Color-by-Correlation [Finlayson2001], la estimación del Gamut constrained [Finlayson2006a] y el más reciente Generalized Gamut-Mapping [Gijssenij2010]. Otros enfoques están basados en métodos probabilísticos [Brainard1997] [D’Zmura1995] y en computación flexible [Ebner2006]. Sin embargo, ninguna de estas extensiones consideran estadísticas de orden superior, descartando mucha información presente en las imágenes.

## 1.4. Otras aportaciones

Schroeder y Moser fueron los primeros en proponer el uso del contenido basado en el análisis de imágenes para su corrección automática [Schroeder2001]. Ellos clasifican las imágenes en varias clases (e.g. interior, exterior, vegetación, montañas, etc.) con un algoritmo correspondiente (White Patch o Gray World). Después, Gasparini y Schettini propusieron un método para el análisis por índices de intensidad del color en las imágenes y su clasificación [Gasparini2004]. Esta clasificación (e.g. piel, cielo, mar o vegetación) podría detectar la necesidad de eliminar algún iluminante. También, Van de Weijer *et. al.* propusieron el uso de información visual de alto nivel, para modelar las imágenes como una mezcla de clases semánticas (e.g. piel, camino, edificios, pasto, etc.) [Weijer2007b]. Con el fin de explotar esta información para seleccionar el mejor iluminante dentro de un conjunto posible. Por otra parte, Bianco *et. al.* clasifican en categorías de exteriores e interiores [Bianco2008]. Además, ellos tienen implementado un selector automático de algoritmos de constancia de color [Bianco2010] tomando en cuenta propiedades de bajo nivel en las imágenes. Este selector está basado en el entrenamiento por árboles de decisión. Su método es comparado con otros algoritmos del estado del arte, obteniendo muy buenos resultados.

Particularmente en la Universidad de Guanajuato, Elizarrarás propuso un selector automático de algoritmos de constancia de color [Elizarraras2011]. En su estudio, utiliza un conjunto de imágenes oscuras y otras con múltiples iluminaciones. A cada imagen se le extrae una serie de características y las asocia con un algoritmo de constancia de color. Sin embargo, en su estudio no presenta una forma cuantitativa en la evaluación de las imágenes para realizar la pre-clasificación. Es decir, es de forma subjetiva la categorización de las imágenes pertenecientes a un algoritmo óptimo. Por otra parte, la selección se realiza de forma SI-ENTONCES, con lo cual el sistema pierde flexibilidad en la decisión.

### 1.5. Propuesta

Desafortunadamente, ningún algoritmo de constancia de color puede ser adoptado como universal. Por otra parte, el diseño de un selector de algoritmos de constancia de color es una tarea difícil debido a las muchas características que están involucradas en el problema. Para esto, técnicas de computación flexible pueden ser usadas para modelar problemas con soluciones complicadas o múltiples variables. Ejemplo de estas técnicas, es el caso de los sistemas difusos (*fuzzy*) basados en reglas.

Los sistemas basados en reglas permiten representar un conocimiento, basado en la experiencia, en un conjunto de reglas tipo SI-ENTONCES. En las reglas, un grupo de premisas son evaluadas para concluir un resultado. Estos sistemas han demostrado resultados satisfactorios en una gran cantidad de aplicaciones como sistemas de control [Bernard1988] entre otros. Además, han incrementado su flexibilidad, robustez y su interpretabilidad, cuando son fusionados con otras técnicas de computación flexible como la lógica difusa [Cordon1999]. Zadeh presentó el concepto fundamental de conjunto difuso y lógica difusa como una extensión de la teoría clásica de conjuntos [Zadeh1965] [Zadeh1973]. Actualmente, la lógica difusa ha sido apreciada como una herramienta completa para el manejo de la información en los sistemas basados en reglas [Ishibuchi2004], debido a su tolerancia a la imprecisión, a la ambigüedad y a la falta de información.

En este trabajo, se propone un sistema basado en reglas difusas para la selección de algoritmos de constancia de color. Para nuestro enfoque, cada clase ligada a un algoritmo, es modelada por una o más reglas. Una regla está basada en un proceso de difusificación (*fuzzification*) y el agrupamiento de algunas características visuales dentro de un conjunto de imágenes de entrenamiento. Para la clasificación, una imagen desconocida se somete a un proceso de inferencia, en donde es etiquetada como una clase cuya regla obtiene el más alto nivel de activación. La importancia de este enfoque es el modelado de las clases a través de reglas simples, es la habilidad de manejar grandes conjuntos de información multidimensional y la tolerancia a la ambigüedad. Es importante mencionar que la aproximación propuesta está principalmente enfocada en el modelado del conocimiento y el método de clasificación.

### 1.6. Resumen

En este capítulo se presentó la importancia del tema, principalmente de la constancia de color. También se abordaron las aportaciones generadas en las últimas décadas sobre el tema de la constancia de color. Se identificó la problemática que existe con la constancia de color y las posibles direcciones que existen para seguir realizando aportaciones en su solución. Por último, se hace referencia en el uso de un sistema experto para seleccionar

## 1.6 Resumen

---

algunos algoritmos de constancia de color con fines de mejorar imágenes.

En el Capítulo 2 se abordarán los temas relacionados con la formación del color y medidas para evaluar la calidad del mismo. Luego, en el Capítulo 3 se presentan una variedad de algoritmos de constancia de color existentes, así como la métrica para evaluarlos. Más tarde, en el Capítulo 4 se describe nuestro sistema experto, tanto la base de datos usada y la formulación de las reglas difusas son unos de los puntos importantes a tratar. Posteriormente, el Capítulo 5 presenta los resultados obtenidos por el sistema experto, además de presentar algunas discusiones ellos. Finalmente, el Capítulo 6 trata de algunos estudios realizados de forma paralela al proyecto de investigación que comprende el sistema experto.

---

## Capítulo 2

# Reproducción del color

---

Como se señaló al principio del Capítulo 1, el color es un factor importante en la visión por computadora y temas relacionados como el procesamiento de imágenes, la interacción hombre-maquina [Yang1998], la extracción de características por color [Gijssenij2011], y los modelos en apariencia de color [Fairchild2005]. Los colores que están presentes en imágenes, son determinados por propiedades intrínsecas de objetos y superficies, así como el color de la fuente de luz. Para un sistema robusto basado en color, estos efectos de la fuente de luz deberían ser filtrados.

En este capítulo, se abordará el tema del color de manera conceptual y su formación en las imágenes. Además, se describen algunos de los espacios de color existentes y utilizados en el proyecto. Y finalmente, se indican los atributos y características asociadas con el color relevantes que serán de gran importancia en aspectos futuros del trabajo.

### 2.1. Teoría Retinex

En 1962, Edwin Herbert Land se dio cuenta de que el color de un objeto no dependía de las longitudes de onda reflejadas o absorbidas por el objeto [Land1962], teoría que había propuesto Newton como la teoría clásica del color. Land supuso que existían conjuntos de receptores independientes. Es decir, un conjunto para el rojo, uno para el verde y uno para el azul, que operan conjuntamente para producir el color percibido. Él llamó a este sistema, capaz de calcular los descriptores de color, como Retinex. El nombre Retinex es una mezcla entre las palabras en inglés para retina y corteza, ya que en ese momento, Land no sabía si los descriptores se calculaban en la retina o si la corteza visual del cerebro también estaba involucrada. De acuerdo con la teoría Retinex, el procesamiento de la información visual se inicia con los receptores de la retina. Dentro de la retina, la información visual de los tres tipos de receptores que miden la luz de los colores rojo, verde y azul del espectro, es procesada de manera independiente para las tres bandas de color.

Land y McCann desarrollaron una teoría computacional para la constancia de color,

## 2.1 Teoría Retinex

---

la teoría Retinex [Land1971] . En sus experimentos ellos usaron un estímulo similar a las de las pinturas del pintor holandés Piet Mondrian, llamadas pinturas Mondrianas. Ellos utilizaron papeles rectangulares de colores, éstos colocados de manera aleatoria como se muestra en la Figura 2.1. Los colores de los papeles fueron matizados para evitar la reflexión especular. Tres proyectores con filtros pasa-bandas precisos se usaron para iluminar la figura Mondriana. El primer filtro permite solamente longitudes de onda corta, el segundo permite longitudes de onda media y el tercero permite las longitudes de onda larga. La cantidad de luz emitida por cada proyector podía ser variada independientemente.

Todos los proyectores fueron encendidos y colocados de tal forma que iluminaran el patrón Mondriano y aparentara colores intensos. Además, los blancos en el patrón tenían que ser "blancos ideales". Después, un fotómetro telescópico se usó para medir la cantidad de luz reflejada en una sección en particular del patrón, decidiendo usar un rectángulo blanco. El experimento consistió en medir el área blanca con un proyector encendido a la vez. Land y McCann obtuvieron 60 unidades de onda corta, 35 de onda media y 6 de onda larga. El mismo proceso se aplicó a todos los rectángulos distintos de la figura mondriana obteniendo en éstos los mismo resultados.

Con este experimento, ellos demostraron que el color percibido de un objeto no depende de la luz reflejada por el objeto. El color percibido depende de la reflectancia, la cual especifica cuanta luz que incide sobre un objeto, es reflejada por éste.

Los humanos podemos deducir la reflectancia de cada objeto para así reconocer su color, mientras que las cámaras lo único que hacen es medir la reflectancia. Por esta razón, es necesario realizar un post-procesamiento a las imágenes para intentar simular correctamente la escena capturada.



**Figura 2.1:** Una imagen mondriana, similar a la usada por Land y McCann en su experimento [Land1977].

### 2.2. Espacios de color

Existe un gran número de espacios de color utilizados tanto en el análisis de imágenes, en dispositivos de visualización, en impresoras, etc. La mayoría de los espacios son justamente una transformación lineal del sistema de coordenadas. Cada espacio de color fue creado para una cierta tarea. Por ejemplo, unos espacios son empleados solamente en dispositivos electrónicos y otros para representar la percepción del color.

#### 2.2.1. sRGB

En el espacio de color RGB, el color está definido por un cubo unitario [Foley1996], véase la Figura 2.2. Su nombre se origina de las siglas en inglés referentes a los tres colores de sus ejes (rojo, verde y azul). Este espacio de color es usado por los dispositivos electrónicos. Las componentes roja, verde y azul, representan la intensidad de un píxel en la imagen. Las ocho esquinas pueden ser etiquetadas por los colores negro, verde, rojo, azul, amarillo, magenta y cian. El gris está localizado en el interior del cubo. Éste comienza en el origen  $(0,0,0)$  y se extiende en todas las direcciones del cubo hasta llegar al blanco  $(1,1,1)$ .

El sRGB es el espacio estandarizado de RGB propuesto por HP y Microsoft en 1996. Está basado en un colorímetro calibrado al espacio RGB. Se recomienda aplicar corrección gama dependiendo de la pantalla del dispositivo usado. El sRGB asume un nivel gama en pantalla de valor 2.2. Ello permite la comunicación ambigua del color sin sobrecarga de almacenamiento de un color con cada imagen.




Figura 2.2: Espacio de color sRGB [Ebner2007].

## 2.2 Espacios de color

### 2.2.2. YCbCr

Es un espacio de color utilizado en sistemas de video y de fotografía digital.  $Y'$  es la componente de luminancia y,  $Cb$  al igual que  $Cr$ , son las componentes cromáticas.  $Y'$  se distingue de  $Y$ , si la luminancia ha sido linealizada o no, usando corrección gama. Este espacio es una representación alterna al espacio RGB. Es decir, el color real que se muestra, depende de la señal real proveniente del RGB. La gran ventaja de este espacio, está en la posibilidad de analizar el color y la luminancia de forma independiente. No así en RGB, donde estas dos variables están implícitas en sus coordenadas.

La transformación de color recomendada por ITU-R Rec. [BT.601] para llevar al espacio YCbCr desde el sRGB, está dada por

$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 65.74 & 129.06 & 25.06 \\ -37.95 & -74.50 & 112.44 \\ 112.44 & -94.15 & -18.29 \end{bmatrix} \begin{bmatrix} r \\ g \\ b \end{bmatrix}, \quad (2.1)$$

y su transformación inversa está dada por

$$\begin{bmatrix} r \\ g \\ b \end{bmatrix} = - \begin{bmatrix} 16 \\ 128 \\ 128 \end{bmatrix} + \begin{bmatrix} 1.16 & 0.00 & 25.06 \\ 1.16 & -0.39 & -0.81 \\ 1.16 & 2.01 & 0.00 \end{bmatrix} \begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix}, \quad (2.2)$$

donde  $r, g, b \in [0, 1]$ . En la Figura 2.3 podemos ver la representación gráfica del espacio YCbCr.




Figura 2.3: Representación del espacio YCbCr.

### 2.2.3. CIEXYZ

La Comisión Internacional de Iluminación (*Commission Internationale de l'Éclairage*, CIE) estableció un estándar para la reproducción exacta del color. CIE 1931 o CIEXYZ, está definido como un conjunto de colores imaginarios primarios que pueden adicionar

## 2.2 Espacios de color

únicamente pesos positivos  $X$ ,  $Y$  y  $Z$  para crear todos los colores posibles. Para transformar una imagen de RGB a CIEXYZ, es necesario determinar qué espacio RGB será usado. Aquí, el estándar sRGB es usado porque se basa en un colorimétrico calibrado en el espacio RGB [Stokes1996].

Las transformaciones de los espacios perceptuales usados en este estudio, son aplicadas al espacio de color CIEXYZ [Shanda2007]. Todas las imágenes necesitan ser convertidas del espacio sRGB al CIEXYZ, y entonces las ecuaciones de transformación pueden ser aplicadas. Para este propósito, se usa (2.3), donde  $r, g, b \in [0, 1]$ , son las componentes de color normalizadas

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.4124 & 0.3576 & 0.1805 \\ 0.2126 & 0.7152 & 0.0722 \\ 0.0193 & 0.1192 & 0.9505 \end{bmatrix} \begin{bmatrix} r \\ g \\ b \end{bmatrix}, \quad (2.3)$$

mientras la transformación inversa está dada por (2.4),

$$\begin{bmatrix} r \\ g \\ b \end{bmatrix} = \begin{bmatrix} 3.2410 & -1.5374 & -0.4986 \\ -0.9692 & 1.8760 & 0.0416 \\ 0.0556 & -0.2040 & 1.0570 \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix}. \quad (2.4)$$

### 2.2.4. CIELab

El CIE 1976  $L^*a^*b^*$  (CIELab), es un espacio de color perceptualmente uniforme y fue propuesto por la CIE en 1976 [Shanda2007]. El espacio de color CIELab es calculado desde CIEXYZ usando (2.5)-(2.8), para obtener las componentes del espacio.

$$f(X) = \begin{cases} X^{1/3} & X > \sigma^3 \\ X/(3\sigma^2) + 16/116 & X \leq \sigma^3, \end{cases} \quad (2.5)$$

$$L^* = 116f(Y/Y_n) - 16, \quad (2.6)$$

$$a^* = 500 [f(X/X_n) - f(Y/Y_n)], \quad (2.7)$$

$$b^* = 200 [f(Y/Y_n) - f(Z/Z_n)], \quad (2.8)$$

donde  $X_n$ ,  $Y_n$  y  $Z_n$  son el estímulo del blanco de referencia para la escena en CIEXYZ y  $\sigma = 6/29$ .  $L^*$  describe la luminancia y su rango va de 0 (negro) al 100 (blanco). La componente  $a^*$  representa lo rojizo-verdoso de una muestra y tiene un rango de  $[-86.13, 98.29]$ . La componente  $b^*$  representa lo amarillento-azulado, y su rango es de  $[-107.86, 94.47]$ . Estos rangos de los canales fueron calculado transformando todos los valores de colores posibles de sRGB a CIELab.

Para la transformación inversa de CIELab a CIEXYZ, se requiere el cálculo de tres variables intermedias,  $f_Y$ ,  $f_X$  y  $f_Z$ , obtenidas usando (2.9)-(2.11),



## 2.2 Espacios de color

$$f_Y = (L^* + 16)/166 \quad (2.9)$$

$$f_X = f_Y + (a^*/500) \quad (2.10)$$

$$f_Z = f_Y - (b^*/200) \quad (2.11)$$

y posteriormente (2.12)-(2.14) son usadas para finalizar la transformación de una imagen de CIELab al espacio CIEXYZ.

$$Y = \begin{cases} Y_n f_Y^3 & f_Y > \sigma \\ f_Y - 16/116 & f_Y \leq \sigma \end{cases} \quad (2.12)$$

$$X = \begin{cases} X_n f_X^3 & f_X > \sigma \\ f_X - 16/116 & f_X \leq \sigma \end{cases} \quad (2.13)$$

$$Z = \begin{cases} Z_n f_Z^3 & f_Z > \sigma \\ f_Z - 16/116 & f_Z \leq \sigma \end{cases} \quad (2.14)$$




Figura 2.4: sRGB visualizado en el espacio  $L^*a^*b^*$  [Ebner2007].

### 2.2.5. CIELuv

El CIE 1976  $L^*u^*v^*$  (CIELuv), fue propuesto al mismo tiempo que el espacio CIELab por la CIE en 1976. Es uno de los espacios de color perceptualmente uniforme más usados y populares. A diferencia del CIELab, el CIELuv requiere menor costo computacional para su transformación de coordenadas [Correa-Tome2011], representando una ventaja para aplicaciones en tiempo real.

Muy parecido al CIELab, este espacio cuenta con la componente de luminancia  $L^* \in [-8.38, 99.85]$ , y las componentes cromáticas  $u^* \in [-86.44, 172.60]$  y  $v^* \in [-130.71, 115.87]$

## 2.2 Espacios de color

---

transformando desde sRGB. La transformación comienza calculando unas variables intermedias  $u'$  y  $v'$  dadas por

$$u' = \frac{4X}{X + 15Y + 3Z'} \quad (2.15)$$

$$v' = \frac{9Y}{X + 15Y + 3Z'}. \quad (2.16)$$

De igual forma es necesario obtener las variables  $u'_n$  y  $v'_n$  derivadas del estímulo del blanco de referencia mencionado anteriormente. Y finalmente, para calcular las componentes  $L^*$ ,  $u^*$  y  $v^*$  se hace uso de las siguientes ecuaciones

$$L^* = \begin{cases} \left(\frac{29}{3}\right)^3 Y/Y_n & Y/Y_n \leq \left(\frac{6}{29}\right)^3 \\ 116f(Y/Y_n)^3 - 16 & Y/Y_n > \left(\frac{6}{29}\right)^3, \end{cases} \quad (2.17)$$

$$u^* = 13L^*(u' - u'_n), \quad (2.18)$$

$$v^* = 13L^*(v' - v'_n). \quad (2.19)$$

La transformación inversa para regresar al espacio CIEXYZ se efectúa mediante las siguientes ecuaciones

$$u' = \frac{u^*}{13L^*} + u'_n, \quad (2.20)$$

$$v' = \frac{v^*}{13L^*} + v'_n, \quad (2.21)$$

$$Y = \begin{cases} Y_n L^* \left(\frac{3}{29}\right)^3 & L^* \leq 8 \\ Y_n \left(\frac{L^*+16}{116}\right)^3 & L^* > 8, \end{cases} \quad (2.22)$$

$$X = Y \frac{9u'}{4v'}, \quad (2.23)$$

$$Z = Y \frac{12 - 3u' - 2v'}{4v'}. \quad (2.24)$$

### 2.2.6. RLab

El espacio de color RLab, es otro espacio perceptualmente uniforme. Surge del resultado de modificaciones hechas al espacio CIELab, presentando las mismas propiedades perceptuales bajo condiciones de iluminación normales (luz natural). Sin embargo, CIELab presenta problemas de uniformidad perceptual al tratar iluminaciones extremas




Figura 2.5: sRGB visualizado en el espacio  $L^*u^*v^*$  [Ebner2007].

(muy bajas o altas). RLab, surge de la necesidad de incluir modificaciones a este espacio, con el fin de hacer uniforme la percepción, incluso bajo estas condiciones [Fairchild1993].

Originalmente, RLab incluía características innecesarias que intentaban predecir efectos en la apariencia del color que dependían de la luminancia. Sin embargo, esto producía otros problemas que perjudicaban en otros sentidos al espacio. Además, de que la complejidad matemática era mayor en las ecuaciones. Fue entonces, que Fairchild desarrolló un refinamiento sobre su espacio RLab propuesto en 1993 [Fairchild1996], donde corrigió todos los problemas presentados en el modelo. Además, simplificó sustancialmente las ecuaciones requeridas para la transformación de CIEXYZ a RLab.

Este espacio, presenta un desarrollo matemático muy extenso. Aquí, solo se darán las ecuaciones principales y simplificadas para realizar las transformaciones. Sin embargo, se pueden consultar en [Fairchild1996] y en [Correa-Tome2009], más detalles en el desarrollo matemático. La transformación de CIEXYZ a Rlab está dada por

$$\mathbf{RAM} = \begin{bmatrix} 1.0020 & -0.0401 & 0.0084 \\ -0.0042 & 0.9666 & 0.0008 \\ 0.0000 & 0.0000 & 0.9110 \end{bmatrix}, \quad (2.25)$$

$$\begin{bmatrix} X_{ref} \\ Y_{ref} \\ Z_{ref} \end{bmatrix} = \mathbf{RAM} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix}. \quad (2.26)$$

$$L^R = 100(Y_{ref})^\sigma, \quad (2.27)$$

$$a^R = 430[(X_{ref})^\sigma - (Y_{ref})^\sigma], \quad (2.28)$$

$$b^R = 170[(Y_{ref})^\sigma - (Z_{ref})^\sigma]. \quad (2.29)$$

## 2.3 Corrección gama

---

Dependiendo de la luminancia relativa del entorno,  $\sigma$  puede ser de  $\sigma = 1/2.3$  para una luminancia igual o mayor al 20% de blanco en la imagen,  $\sigma = 1/2.9$  para una luminancia menor a ese 20% o  $\sigma = 1/3.5$  para una luminancia cero.

Las ecuaciones para transformar de regreso al espacio CIEXYZ están dadas por

$$Y_{ref} = \left( \frac{L^R}{100} \right)^{1/\sigma}, \quad (2.30)$$

$$X_{ref} = \left[ \left( \frac{a^R}{430} \right) + (Y_{ref})^\sigma \right]^{1/\sigma}, \quad (2.31)$$

$$Z_{ref} = \left[ (Y_{ref})^\sigma - \left( \frac{b^R}{170} \right) \right]^{1/\sigma}, \quad (2.32)$$

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = (\mathbf{RAM})^{-1} \begin{bmatrix} X_{ref} \\ Y_{ref} \\ Z_{ref} \end{bmatrix}. \quad (2.33)$$

### 2.2.7. Coordenadas cilíndricas de los espacios

Cualquier espacio que cuente con las componentes cromáticas independientes de la luminancia, puede representarse en términos de coordenadas cilíndricas. Así, es posible trabajar con predictores de croma  $C^*$  y de matiz  $h^*$  (matiz en grados). Estos predictores se describen a continuación:

$$C^* = \sqrt{c_1^{*2} + c_2^{*2}} \quad (2.34)$$

$$h^* = \tan^{-1} \left( \frac{c_2^*}{c_1^*} \right) \quad (2.35)$$

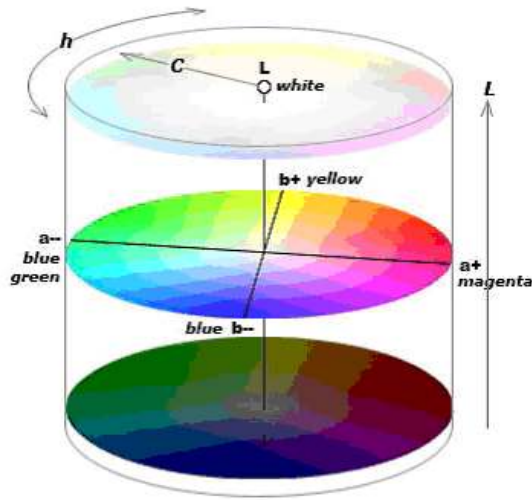
donde  $c_1$  representa la primera de las dos componentes de croma ( $a^*$ ,  $u^*$ ,  $Cb^*$ , etc), y  $c_2$  representa la otra componente cromática ( $b^*$ ,  $v^*$ ,  $Cr^*$ , etc). La representación gráfica en estas coordenadas se muestra en la Figura 2.6. Finalmente, un atributo más que puede obtenerse de estas coordenadas es la saturación,

$$S^* = \frac{C^*}{L^*}. \quad (2.36)$$

## 2.3. Corrección gama

La mayoría de los sistemas de imágenes, producen valores proporcionales a una radiancia, que aproxima a los valores rojo, verde y azul del espacio RGB. Sin embargo,

## 2.3 Corrección gama



**Figura 2.6:** sRGB visualizado en coordenadas cilíndricas del espacio  $L^*a^*b^*$  [Tomada de [www.pocketspec.com/whatiscielab.html](http://www.pocketspec.com/whatiscielab.html)].

frecuentemente esos valores no son proporcionales a la intensidad y están sujetos a una función de transferencia no lineal. La corrección gama, (*Gamma Correction* en inglés, GC) puede ser visto como el proceso de compensación de la no linealidad para alcanzar la reproducción correcta de la luminancia relativa [Poynton2003]. La no linealidad de la luminancia dada por los dispositivos de imágenes, está descrita como una operación de la forma

$$g[f_i(x, y)] = f_i(x, y)^\gamma, \quad (2.37)$$

donde  $f_i(x, y) \in [0, 1]$  representa la intensidad en la imagen para la componente  $i$ . Si el valor de  $\gamma$  es conocido, entonces el proceso inverso es trivial

$$g^{-1}[f_i(x, y)] = f_i(x, y)^{1/\gamma}. \quad (2.38)$$

El valor de  $\gamma$  es determinado experimentalmente con la ayuda de un blanco de calibración, tomando una gama completa en valores de luminancia conocidos a través del sistema de imágenes [Chang1996]. Sin embargo, a menudo la calibración no está disponible o el acceso directo al dispositivo de imagen no es posible, como por ejemplo cuando una imagen es descargada del Internet. Para muchas aplicaciones en fotografía digital, procesamiento de imágenes y visión por computadora, sería ventajoso corregir esas no linealidades, antes de las tareas posteriores de procesamiento. En la práctica, la mayoría de dispositivos de imágenes tienen un valor numérico de gama cercano a 2.5 [Poynton2003].

Diferentes funciones de transferencia para la corrección gama han sido estandarizadas y son usadas. Rec. 709, SMPTE 240M, sRGB y SDTV, son algunos ejemplos de funciones de transferencia. La notación sRGB [Stokes1996] es ampliamente usada en las imá-

## 2.4 Medición y calidad del color

---

genes de computadoras personales, y el intercambio por Internet. En este trabajo, únicamente es usada la función de transferencia del espacio sRGB para la corrección gama, y está dada por

$$g[f_i(x, y)] = \begin{cases} 12.92f_i(x, y) & f_i(x, y) \leq 0.0031308 \\ 1.055f_i(x, y)^{\frac{1}{2.4}} & f_i(x, y) > 0.0031308. \end{cases} \quad (2.39)$$

## 2.4. Medición y calidad del color

La medición del color puede estar dada por distintos descriptores de color como lo son: momentos estadísticos de las componentes cromáticas en un espacio de color, histogramas de color, índices de tonalidad e información espectral. Algunas de éstas, han sido usadas como medidas de calidad en imágenes sin referencia.

La calidad de una imagen suele darse de una valoración subjetiva. Esto se debe a que cada persona tiene distintos criterios para determinar lo que aprecian más en una imagen. Distintas métricas han tratado la calidad de las imágenes basándose en la semejanza entre ellas teniendo una verdad de referencia [Eskicioglu1995] [Sheikh2006a] [Sheikh2006b] [Nachlieli2011]. Por otro lado, existen métricas de calidad que no necesitan referencia [Sheikh2005] [Yan2006] [Yan2011]. Sin embargo, éstas suelen ser subjetivas ayudándose de un conjunto de personas en la valoración de las mismas. Además, están modeladas para resolver casos particulares y distinguen únicamente entre calificativos como "mala calidad" y "buena calidad", por poner un ejemplo.

### 2.4.1. Índices de tonalidad

Básicamente la idea de los índices de tonalidad, consiste en el análisis de la distribución del color en la imagen. Para ésto, debe realizarse el análisis sobre un espacio de color adecuado (luminancia y croma independientes) haciendo uso de estadística simple. Estos índices fueron propuestos por Gasparini y Schettini para la clasificación de imágenes (e.g piel, cielo, mar o vegetación) [Gasparini2004].

Los valores en sRGB son mapeados a un espacio de color que tenga sus dos componentes de croma independientes de la luminancia. En esta sección, la descripción está basada en el espacio CIELab.

Primeramente, se analizan solo los píxeles en un intervalo de luminancia que excluye a los puntos más brillantes y oscuros. Ésto, porque las imágenes que consideremos pueden haber sido procesadas durante la adquisición y supondremos que desconocemos el dispositivo de captura. Las cámaras digitales comúnmente alteran el croma de las regiones mas luminosas y oscuras convirtiendo el punto mas brillante a blanco y el mas oscuro a negro. Gasparini en su experiencia con un conjunto de datos y varios miles de imágenes

## 2.4 Medición y calidad del color

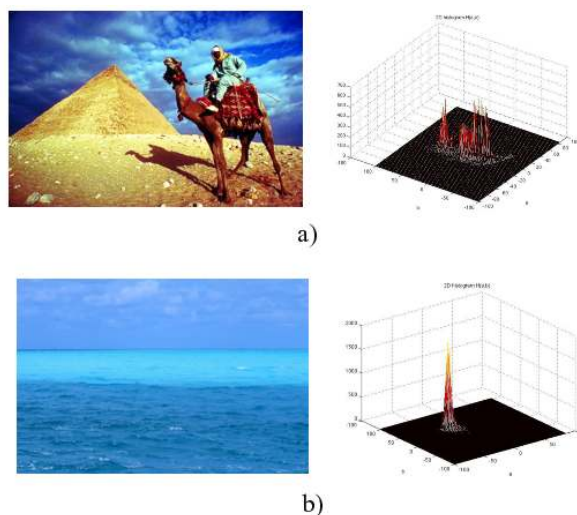
sugiere considerar un intervalo de luminancia:  $30 < L^* < 95$  al identificar la tonalidad. Si el tamaño de la porción considerada de la imagen es menor del 20% de la imagen, las estadísticas a utilizar no serían del todo confiables. Este es el caso para imágenes muy oscuras o muy luminosas, véase la Figura 2.7. Cualquier otro caso, el algoritmo procede al siguiente punto.



**Figura 2.7:** Ejemplo de imágenes excluidas del análisis.

Posteriormente, se calcula un histograma bidimensional,  $H(a, b)$ , para los colores de la imagen en el plano  $ab$ . Para una imagen con varios colores, presentará el histograma varios picos distribuidos en el plano, mientras que para una imagen con un color predominante, tendrá un solo pico o unos cuantos en una región limitada, véase la Figura 2.8. Cuanto más concentrado esté el histograma y más alejado del origen, la tonalidad será más intensa.

La distribución del color es modelada usando las siguientes medidas estadísticas, con  $k = a, b$ :



**Figura 2.8:** a) Imagen con varios colores junto con su histograma 2D en plano  $ab$ . b) Imagen con un color predominantes y que muestra un histograma 2D concentrado.

## 2.4 Medición y calidad del color

$$\mu_k = \int_k kH(a, b)dk, \quad (2.40)$$

$$\sigma_k^2 = \int_k (\mu_k - k)^2 H(a, b)dk, \quad (2.41)$$

la media y la varianza de los valores en el histograma respectivamente.

Un *Circulo equivalente (CE)* con centro  $C = (\mu_a, \mu_b)$ , y radio  $\sigma = \sqrt{\sigma_a^2 + \sigma_b^2}$  es asociado a cada histograma. El *CE* se caracteriza cuantitativamente obteniendo una distancia  $D$ :


$$D = \mu - \sigma, \quad (2.42)$$

donde  $\mu = \sqrt{\mu_a^2 + \mu_b^2}$ , y el radio:

$$D_\sigma = D/\sigma. \quad (2.43)$$

$D$  es una medida de hasta qué punto del histograma (identificado por el *CE*) se encuentra del origen ( $a = 0, b = 0$ ), mientras  $\sigma$  es una medida de cómo se extiende el histograma,  $D_\sigma$  hace que sea posible cuantificar la magnitud de la tonalidad.

El procedimiento analiza en el plano cromático  $ab$  la distribución del color en el histograma, examinando al *CE* y calculando los valores estadísticos  $D$  y  $D_\sigma$ . Si el histograma no está concentrado y además está muy cercano al origen, los colores de la imagen son entonces encerrados en un *CE* grande dentro del plano  $ab$ , Figura 2.9 a). Un color predominante debería corresponder generalmente a áreas como vegetación, cielo, piel, mar o bien, a un único color en primer plano, como en la Figura 2.9 b).



**Figura 2.9:** a) Imagen con varios colores y su respectivo *CE*. a) Imagen con un color predominantes y su respectivo *CE*.



### 2.4.2. Métrica del Power Spectrum

La calidad de una imagen puede ser evaluada usando la Métrica del Espectro de potencia o *Power Spectrum*, MPS [Yan2011]. La MPS determina la información cromática en una imagen. Transformar una imagen al dominio de la frecuencia permite el análisis de características en señales desde otro punto de vista. La transformada discreta de Fourier a una  $f(x, y)$  de tamaño  $M \times N$  está definida por

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \exp \left[ -2\pi i x \frac{u}{M} \right] \exp \left[ -2\pi i y \frac{v}{N} \right] f(x, y), \quad (2.44)$$

donde  $u$  y  $v$  son los componentes de la respuesta en frecuencia,  $x$  y  $y$  son las componentes de la respuesta espacial.

El Valor Promedio del Espectro de Potencia (*Average Power Spectrum Value*, APSV en Inglés) es la media del espectro de potencia en la imagen. Esta medida, es usada en ocasiones como un índice de calidad, y está dada por

$$APSV = \frac{1}{i} \sum_i |F|_i^2, \quad (2.45)$$

donde  $i$  corresponde a la componente de color en RGB y  $|F|^2$  está dado por

$$|F|^2 = \frac{1}{NM} \sum_{u=1}^M \sum_{v=1}^N |F(u, v)|^2. \quad (2.46)$$

Es importante señalar que el APSV indica la calidad de una imagen. Entre más grande es el APSV, la calidad de la imagen es mejor. Es decir, no se necesita comparar con otra imagen o información de la iluminación, para la evaluación de la imagen en cuestión. El APSV tiende a ser mayor cuando las imágenes muestran una buena iluminación y numerosos colores.

En la Figura 2.10 se pueden apreciar dos escenas diferentes bajo condiciones de iluminación distintas. Las imágenes de la izquierda han sido procesadas con algún algoritmo de constancia de color mientras que las de la derecha se encuentran sin procesar. Por tal razón, al haber sido aplicado un mejoramiento de imágenes, el APSV registra mayor información cromática en esas imágenes, proporcionando valores más grandes.

### 2.4.3. Promedio de la croma

La componente de croma, como parte de las coordenadas cilíndricas vistas anteriormente, es una componente que representa un vector de magnitud entre dos componentes cromáticas de un espacio de color. Es decir, como todo vector, entre más grande su valor,

## 2.4 Medición y calidad del color

---



**Figura 2.10:** Dos escenas distintas y cada una con dos imágenes de distinta calidad. Las imágenes de la derecha tienen mayor calidad que las de la izquierda de acuerdo al APSV ( $\times 10^9$ ).

mayor es la distancia que existe al origen. En este caso, entre mayor sea el valor de la croma, mayor es la distancia entre el color actual y el origen (negro, gris o blanco). En otras palabras, entre más grande sea la croma esto nos indica que el color es más intenso.

En base a nuestra experiencia, el ser humano tiene la tendencia natural de apreciar positivamente una imagen, si ésta cuenta con colores más vívidos o intensos. La razón de esto, no es comprendida del todo aún, pero se podría pensar que se debe a un efecto placebo de la mente al apreciar colores intensos y contrastantes entre si.


La croma es un atributo relacionado con la intensidad de los colores. Así, entre más grande sea la croma, más intenso es un color. En este estudio, se va a considerar el promedio de la croma en la imagen, como un indicador de esta calidad percibida por los humanos. Entre mayor sea el promedio de esta, mayor será la calidad de nuestra imagen. Una métrica de calidad en imágenes está basada en esta idea en [Tsagaris2005].

Un estudio de calidad fue realizado en nuestro proyecto, analizando una serie de imágenes con el promedio de la croma. Habitualmente, el valor promedio de la croma sí corresponde a la apreciación humana como imagen de mayor calidad ("más bonita"). En la Figura 2.11, se pueden observar dos ejemplos de la relación existente entre la apreciación humana y el valor de la croma. Esta métrica de calidad en imágenes a color, será usada posteriormente en nuestro proyecto.

### 2.4.4. Histogramas de color

Los histogramas de color registran la ocurrencia de un cierto color dentro de una casilla. Una casilla es considerada como un espacio de registro de los valores correspondientes a un rango determinado. Un histograma de niveles de grises a 8 bits (256 valores)

## 2.4 Medición y calidad del color



**Figura 2.11:** Dos escenas distintas y cada una con dos imágenes de distinta calidad de acuerdo a el promedio de la croma.

puede contener un número máximo de 256 casillas, cada una registrando la ocurrencia de cada nivel de intensidad. Sin embargo, es posible tener una menor cantidad de casillas. Por ejemplo 26, donde cada una registre 10 valores consecutivos, excepto la casilla 26, la cual sólo registra los seis últimos valores.

### Número de colores

Un histograma de color registra la ocurrencia de una cantidad  $n$  de colores. Para el espacio RGB existe la posibilidad de registrar poco mas de 16 millones de colores ( $2^8 \times 2^8 \times 2^8$ ) con 8 bits de precisión. Bianco *et. al.*, utilizan este histograma para obtener el número de colores en una imagen [Bianco2008]. Es decir, obtener el conteo de toda aquella casilla que registró al menos un color.

Bianco *et. al.*, también sugieren manejar un histograma de 27 casillas para el registro de colores típicos [Bianco2010]. Este histograma se obtiene particionando cada canal del RGB en 3 ( $3 \times 3 \times 3$ ), dando como resultado el registro de colores generales (e.g. rojo claro, rojo oscuro, azul oscuro, verde pasto, etc).

En imágenes oscuras, es conveniente utilizar un espacio perceptualmente uniforme. En donde las casillas estén conformadas por los colores primarios incluyendo el gris, el blanco y el negro. Aproximadamente entre 10 y 20 casillas son consideradas aceptables para la distinción de varios colores comunes.

### Color dominante

El color dominante es otra característica que puede extraerse de un histograma de color. Para ésto, es necesario analizar el histograma y detectar la casilla o cierta cantidad de

## 2.5 Resumen

---

casillas adjuntas, cuya cantidad registrada sobrepase un cierto porcentaje de todo el histograma. Comúnmente, un 50 % es suficiente como parámetro para determinar si existe un color dominante en la escena.

El porcentaje del color dominante también puede ser usado como característica de una imagen. Es decir, a diferencia de sólo detectar si existe o no un color dominante, es posible utilizar el porcentaje del color que prevalezca en mayor cantidad sobre la imagen. Y con esto, tener un referente sobre qué porcentaje de algún color dominante existe en la escena.

## 2.5. Resumen

En este capítulo se revisaron aspectos muy importantes para el desarrollo del proyecto. Se presentaron también algunos de los espacios de color usados para la reproducción y análisis del color, pero especialmente aquellos en los cuales la información del color se encuentra independiente de la luminancia. Por otra parte, técnicas que nos permiten analizar tanto la distribución del color como la calidad del mismo sobre una imagen, fueron explicadas.

En el capítulo siguiente, será abordado por completo el cálculo o estimación del color de la fuente de luz que altera nuestra imagen. Así mismo, algoritmos de constancia de color, sustentados en diferentes teorías son tratados, ya sea en condiciones de iluminación uniforme o no.

# Algoritmos para constancia de color

---

Por décadas, investigadores han intentado resolver el problema de la constancia de color proponiendo varios algoritmos y métodos. Sin embargo, no se ha podido establecer una única solución que resuelva el problema. Ya que debido al amplio rango de aplicaciones de visión por computadora que requieren de la constancia de color, es imposible tener una solución única para todos los casos. Esto ha llevado a las investigaciones en identificar un conjunto de posibles enfoques que puedan aplicarse a problemas particulares.

En este capítulo, algunos algoritmos propuestos para resolver la constancia de color son revisados. Los algoritmos son separados en dos grupos, algoritmos para casos donde la iluminación es uniforme, y algoritmos para iluminación que no es uniforme o o se tienen múltiples iluminantes. Finalmente, se revisa la métrica comúnmente utilizada para evaluar la estimación realizada por los algoritmos de constancia de color.

### 3.1. Clasificación de los algoritmos

Gijsenij *et. al.* clasifican a los algoritmos en tres tipos: i) métodos estáticos, ii) métodos basados en la asignación de una gama de colores, y iii) métodos de aprendizaje [Gijsenij2011]. Por otro lado, Ebner divide los algoritmos en dos grupos, acorde al tipo de iluminación: uniforme o no uniforme [Ebner2007].

En este proyecto, los algoritmos contemplados para el análisis pertenecen a la clasificación de estáticos de acuerdo con [Gijsenij2011]. Por otra parte, la mayoría de éstos, pertenecen al grupo de algoritmos para iluminación uniforme, y otros pocos para iluminación no uniforme, según la clasificación de [Ebner2007].

### 3.2. Transformación de la imagen

Una vez que el color de la fuente de luz se ha estimado, ésta es usada para transformar la imagen de entrada de modo que produce una imagen de salida. La cual, aparenta

### 3.3 Algoritmos para escenas con iluminación uniforme

**Tabla 3.1:** Clasificación de los algoritmos de constancia de color según [Gijssenij2011].

Tipo de algoritmos	Positivo	Negativo
Estáticos	Implementación simple Ejecución rápida No requieren entrenamiento	Mal desempeño en algunos casos
Asignación de Gama	Elegante desarrollo teórico Excelente desempeño	Requieren de entrenamiento Implementaciones complicadas Requieren pre-procesamiento
Por aprendizaje	Adaptables a datos específicos Muy alto desempeño	Requieren de entrenamiento Implementaciones complicadas Ejecución lenta

haber sido tomada bajo una fuente de luz canónica, este proceso es llamado adaptación cromática. La adaptación cromática usualmente se modela utilizando una transformación lineal, que a su vez se puede simplificar a una transformación en diagonal, cuando se cumplan ciertas condiciones [Finlayson1994], [Funt2000], [West1982]. Este tipo de transformación es utilizada en esta tesis. Este modelo escala los canales de color de un píxel de forma independiente, con base en la fuente luminosa que estima, de manera que el color original es transformado para que aparente haber sido capturado bajo una fuente de luz blanca. Existen otros métodos de adaptación cromática, incluyendo correlación de diagonal o modelo Von Kries [VonKries1970], linealizado Bradford [Lam1985] y CIECAT02 [Moroney2002], pero todos estos métodos suponen que el color de la fuente de luz en la imagen original es conocido.

### 3.3. Algoritmos para escenas con iluminación uniforme

Los algoritmos considerados en esta sección, asumen que la iluminación es uniforme a través de la escena. La Ecuación (3.1) nos indica la relación que existe para la formación del color en una imagen

$$f_i(x, y) = G(x, y)R_i(x, y)I_i, \quad (3.1)$$

donde, la  $f_i(x, y)$  es la intensidad del píxel en la posición  $(x, y)$  de una imagen o un cuadro de video,  $G(x, y)$  es un factor que depende de la geometría de la escena,  $R_i(x, y)$  es la reflectancia de un punto del objeto mostrado en la misma posición e,  $I_i$  es el iluminante en la escena. El índice  $i$  corresponde al canal de color en la imagen.

Para escenas con iluminación uniforme, los algoritmos de constancia de color asumen que  $G(x, y) = 1$  y  $R_i(x, y) = 1$ , permitiendo que el iluminante dependa totalmente de la imagen de entrada. Por otra parte, una imagen de salida ideal, es aquella donde no existe

### 3.3 Algoritmos para escenas con iluminación uniforme

---

un iluminante que altere la escena, o mejor dicho, este iluminante sea el blanco perfecto,

$$o_i(x, y) = G(x, y)R_i(x, y). \quad (3.2)$$

La imagen de salida resultante de la sustitución de las variables en las ecuaciones está dada finalmente por

$$o_i(x, y) = \frac{f_i(x, y)}{I_i}. \quad (3.3)$$

#### 3.3.1. White Patch Retinex

El algoritmo Retinex fue propuesto por Land y McCann [Land1971], [Land1977]. El algoritmo Retinex en su forma más simple, el White Patch (WPR), o Parche Blanco en Español, toma en cuenta el valor más grande en cada componente de color como una representación del blanco de la imagen. Computacionalmente, este parche blanco es encontrado al buscar la máxima intensidad en cada canal, y está dado por

$$I_{i_{max}} = \text{máx}\{f_i(x, y)\}. \quad (3.4)$$

Después, todas las intensidades de los píxeles son escalados usando (3.5), en base al iluminante calculado.

$$o_i(x, y) = \frac{f_i(x, y)}{I_{i_{max}}} \quad (3.5)$$

El algoritmo WPR puede hacerse más robusto si se calcula un histograma  $H_i$  para cada componente de color. El histograma nos muestra cuantos píxeles de la imagen tienen una intensidad particular por cada componente. Donde  $n_b$  es el número de casillas del histograma y  $H_i(j)$  es el histograma de un canal,  $j$  es el índice para una casilla de la intensidad correspondiente en el histograma. En lugar de elegir el píxel con la intensidad máxima para cada canal de color, se puede elegir la intensidad de tal manera que todos los píxeles con intensidades altas, no influyan en la estimación. Este método es usado en [Finlayson2006b] para remover sombras. Siendo  $f_i(j)$  la intensidad de cada canal  $i$  representada por la casilla  $j$  del histograma  $H_i$ . Entonces la iluminación estimada está dada por

$$I_i = f_i(j_i), \quad (3.6)$$

Para la selección de  $j_i$  deben cumplirse las siguientes dos condiciones:

$$pn \leq \sum_{k=j_i}^{n_b} H_i(k) \quad \text{y} \quad pn \geq \sum_{k=j_i+1}^{n_b} H_i(k), \quad (3.7)$$

donde  $pn$  es un porcentaje (usualmente cerca del 1 %) del total de los píxeles en la imagen [Ebner2007].

### 3.3 Algoritmos para escenas con iluminación uniforme




Figura 3.1: a) Imagen original. b) Imagen procesada con el algoritmo WP original. c) Imagen procesada con la variante de Finlayson.

#### 3.3.2. Gray World

La suposición del Gray World (GW), Mundo Gris en Español, es el algoritmo más conocido de constancia de color. Propuesto por Buchsbaum, y es usado como referencia por otros algoritmos [Buchsbaum1980], el GW está basado en la suposición de que, en promedio, el mundo es gris, y estima el iluminante usando el color promedio de todos los píxeles. Se asume que la información dada por el promedio de cada canal de la imagen representa el nivel gris.

El primer paso a realizar es calcular el color promedio en la imagen, como se indica en (3.8),

$$a_i = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} \{f_i(x, y)\}, \quad (3.8)$$

donde  $M$  y  $N$  son el número de columnas y filas, respectivamente. Igualmente,  $a_i$  puede ser representado por

$$a_i = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} G(x, y) R_i(x, y) I_i, \quad (3.9)$$

$$a_i = I_i \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} G(x, y) R_i(x, y), \quad (3.10)$$

$$a_i \approx I_i E[GR_i] = I_i E[G] E[R_i]. \quad (3.11)$$

La función  $E[GR_i]$  es el valor esperado por el factor de geometría  $G$  multiplicado por la reflectancia  $R_i$ . Ambos pueden ser considerados como variables independientes, ya que no hay correlación en la forma y el color de un objeto. Suponiendo que muchos colores diferentes están presentes en la escena y cada color está igualmente equilibrado, la reflectancia puede ser considerada una variable aleatoria con rango  $[0, 1]$ , y

$$E[G] E[R_i] = E[G] \left( \int_0^1 x dx \right) = E[G] \frac{1}{2}, \quad (3.12)$$

$$a_i \approx I_i E[G] \frac{1}{2}. \quad (3.13)$$



### 3.3 Algoritmos para escenas con iluminación uniforme

Una vez que este valor global es conocido, el iluminante  $I_i$  es calculado. Suponiendo que hay una orientación perpendicular entre el objeto y la cámara,  $E[G] = 1$ . La Ecuación (3.14) describe el cálculo del factor  $\phi$  para ser usado después en (3.15).

$$\phi = \frac{2}{E[G]} = 2 \quad (3.14)$$

$$I_i \approx \frac{2}{E[G]} a_i = \phi a_i \quad (3.15)$$

Más tarde, desde  $f_i(x, y) = G(x, y)R_i(x, y)I_i$ , el valor de salida está dado por

$$o_i(x, y) = \frac{f_i(x, y)}{I_i} = \frac{f_i(x, y)}{\phi a_i}. \quad (3.16)$$




Figura 3.2: a) Imagen original. b) Imagen procesada con el algoritmo WPR de Finlayson. c) Imagen procesada con GW.

#### 3.3.3. Variante de Horn

En 1974 Horn trabajó en este algoritmo que se basa en que el color es el producto de la reflectancia y la luminancia,  $f_i(x, y) = R_i(x, y)I_i$  [Horn1974]. Si calculamos el logaritmo natural para  $f_i(x, y)$  podemos expresar la relación como

$$\ln(f_i(x, y)) = \ln(R_i(x, y)) + \ln(I_i). \quad (3.17)$$

Para poder remover la constante  $\ln(I_i)$  podemos normalizar con respecto a un parche blanco que suponemos que existe en la imagen. Para hacer ésto, solamente debemos buscar el máximo nivel de intensidad en cada canal de la siguiente forma

$$o_i(x, y) = \exp(\ln(f_i(x, y)) - \max_i), \quad (3.18)$$

donde  $\max_i = \max\{\ln(f_i(x, y))\}$ , este algoritmo tendrá un desempeño igual al del parche blanco.

A este algoritmo se le puede aplicar el enfoque del mundo gris de la siguiente forma

### 3.3 Algoritmos para escenas con iluminación uniforme

---

$$o_i(x, y) = \exp(\ln(f_i(x, y)) - \ln(a_i) - 1), \quad (3.19)$$

donde  $n$  es el número de píxeles y  $a_i$  es el valor promedio calculado en cada componente. Esta versión del algoritmo es recomendada cuando se necesita un mejor desempeño. Sin embargo, el tiempo computacional es mayor. La demostración matemática completa de esta variante, puede ser consultada en [Ebner2007] pág. 113.

#### 3.3.4. White Patch en CIELab

En la teoría del algoritmo WPR únicamente los valores de máxima intensidad son considerados. Esta suposición se hace porque es común procesar imágenes oscuras que tienen como valor mínimo  $(0, 0, 0)$  en RGB. Sin embargo, es posible encontrar casos donde exista un mínimo diferente a este valor. La Ecuación (3.20) describe al WPR sin esta suposición

$$o_i(x, y) = \frac{f_i(x, y) - I_{i_{min}}}{I_{i_{max}} - I_{i_{min}}}, \quad (3.20)$$

donde  $I_{i_{min}}$  es

$$I_{i_{min}} = \text{mín}\{f_i(x, y)\}. \quad (3.21)$$

Si consideramos el rango dinámico del espacio de color, la ecuación final esta dada por

$$o_i(x, y) = \left( \frac{f_i(x, y) - I_{i_{min}}}{I_{i_{max}} - I_{i_{min}}} \right) (S_{i_{max}} - S_{i_{min}}) + S_{i_{min}}, \quad (3.22)$$

donde  $S_{i_{min}}$  y  $S_{i_{max}}$  son los valores mínimo y máximo, respectivamente, para cada componente de color. En RGB, (3.22) es simplificada porque  $S_{i_{min}}$  es 0. Para CIELab  $S_{i_{min}}$  y  $S_{i_{max}}$  son los límites de las componentes descritas en el capítulo anterior.

Este algoritmo funciona mejor cuando es combinado con la aplicación posterior del WPR en RGB. En el Capítulo 6 se realiza un estudio resumido de este algoritmo.

#### 3.3.5. Shades-of-Gray

Finlayson y Trezzi propusieron un algoritmo de constancia de color más general basado en la norma Minkowski [Finlayson2004], donde los algoritmos Gray World y White Patch, son dos casos particulares de éste. El algoritmo es llamado Shades-of-Gray (SG), Tonos de Gris en Español, y está dado por

$$\mathbf{I} = \left( \frac{\int (\mathbf{f}(\mathbf{x}))^p d\mathbf{x}}{\int d\mathbf{x}} \right)^{1/p}, \quad (3.23)$$

### 3.3 Algoritmos para escenas con iluminación uniforme



Figura 3.3: a) Imagen original. b) WP en RGB. c) WP en CIELab. d) WP en ambos espacios

$$I_i = \frac{\left( \sum_{x=1}^m \sum_{y=1}^n f_i(x, y)^p \right)^{1/p}}{(m \cdot n)^{1/p}}, \quad (3.24)$$

donde  $p$  es la norma Minkowski o también conocida norma- $p$ . Se puede observar que cuando  $p = 1$  en la ecuación, es equivalente a la suposición del Gray World, y cuando  $p = \infty$ , corresponde al algoritmo White Patch. Este algoritmo tiene la particularidad de optimizar su desempeño según el tipo de imágenes o base de datos a usar. Es decir, la norma Minkowski óptima se obtiene de la evaluación a un conjunto determinado de imágenes hasta encontrar la  $p$  ideal. Finlayson encuentra en su estudio que una  $p = 6$  es una buena opción a usar para casos generales.

#### 3.3.6. General Gray-World

Como una extensión del algoritmo Shades-of-Gray, Van de Weijer *et al.* consideran en aplicar primero un promediado local [Weijer2007a]. La ecuación para el algoritmo Shades-of-Gray es una operación global a la imagen, la cual ignora la importante correlación local entre los píxeles. Un difuminado local es usado como correlación local para reducir la influencia de ruido. Este pre-procesamiento, fue discutido como una mejora en algoritmos de constancia de color por Barnard [Barnard2002b]. Ellos presentan el difuminado local con un filtro Gaussiano,  $G^\sigma$ , donde  $\sigma$  es la desviación estandar. Las ecuaciones de esta variante son

### 3.4 Algoritmos para escenas con iluminación no uniforme

---

$$\mathbf{I} = \left( \frac{\int (\mathbf{f}^\sigma(\mathbf{x}))^p d\mathbf{x}}{\int d\mathbf{x}} \right)^{1/p}, \quad (3.25)$$

$$I_i = \frac{\left( \sum_{x=1}^m \sum_{y=1}^n f_i^\sigma(x, y)^p \right)^{1/p}}{(m \cdot n)^{1/p}}, \quad (3.26)$$

donde  $\mathbf{f}^\sigma = \mathbf{f} \otimes \mathbf{G}^\sigma$ .

#### 3.3.7. Gray-Edges

Este algoritmo surge de una teoría alternativa a la del General Gray-World, la cual denominan Van de Weijer *et al.* como teoría del Gray-Edge (GE), Borde Gris en Español [Weijer2007a]. Esta teoría supone que el iluminante es el promedio en las diferencias de las reflectancias. Además, adoptó el modelo del algoritmo Shades-of-Gray con la extensión de la derivada espacial de la imagen y está dada por

$$\mathbf{I} = \left( \int \left| \frac{\partial^n \mathbf{f}^\sigma(\mathbf{x})}{\delta \mathbf{x}^n} \right|^p d\mathbf{x} \right)^{1/p}, \quad (3.27)$$

$$I_i = \frac{\left( \sum_{x=1}^m \sum_{y=1}^n h_i^\sigma(x, y)^p \right)^{1/p}}{(m \cdot n)^{1/p}}. \quad (3.28)$$

donde  $\mathbf{h}^\sigma = \left( \sqrt{(\partial \mathbf{f}_x)^2 + (\partial \mathbf{f}_y)^2} \right) \otimes \mathbf{G}^\sigma$ .

Esta ecuación describe un marco de trabajo el cual produce diferentes estimaciones del color de la iluminación dependiente de tres variables. i) El orden  $n$  de la derivada en la imagen, ii) la norma Minkowski  $p$ , y, iii) el tamaño de  $\sigma$  para el difuminado local. Para este trabajo, solo se usa este algoritmo con  $n = 1$  (primer derivada de la imagen) (GE1).

### 3.4. Algoritmos para escenas con iluminación no uniforme

Los algoritmos considerados en esta sección, asumen que la iluminación no es uniforme a través de la escena. La Ecuación (3.29) nos indica la relación que existe para la formación del color en una imagen

$$f_i(x, y) = G(x, y)R_i(x, y)I_i(x, y), \quad (3.29)$$

donde, la  $I_i(x, y)$  es la imagen de iluminantes en cada posición  $(x, y)$ , y las demás variables siguen siendo las mismas que se vieron en la sección anterior.

### 3.4 Algoritmos para escenas con iluminación no uniforme

---

Si  $o_i(x, y) = G(x, y)R_i(x, y)$  como se explicó anteriormente, la imagen de salida resultante de la sustitución de las variables en las ecuaciones esta dada finalmente por

$$o_i(x, y) = \frac{f_i(x, y)}{I_i(x, y)}. \quad (3.30)$$

#### 3.4.1. Promedio de color en espacio local

Para estimar la iluminación por espacios locales hay que hacer otras suposiciones. En algoritmos anteriores, se ha visto que la iluminación puede ser aproximada de forma global. Sin embargo, en situaciones donde en las escenas, la iluminación cambia suavemente a través de varios objetos, podemos usar una iluminación local. Donde la información se toma de varios objetos analizando por zonas a través de una imagen [Ebner2004].

Si se aplica la suposición del Gray-World, entonces necesitamos promediar localmente la iluminación. Un método rápido para calcular el color promedio por espacio local es una convolución. Teniendo un máscara que define una vecindad alrededor del píxel que se procesa, el color promedio del espacio local se calcula por

$$a_i = k \int_x \int_y f_i(x, y) g(x - x', y - y') dx' dy'. \quad (3.31)$$

La función  $g(x, y)$  es la máscara donde la constante  $k$  está dada por

$$k = \frac{1}{\int_x \int_y g(x, y) dx dy'} \quad (3.32)$$

y la máscara se puede considerar como una función Gaussiana descrita por

$$g(x, y) = e^{-\frac{x^2+y^2}{2\sigma^2}}. \quad (3.33)$$

Es necesario un gran marco como máscara para la convolución, este marco debería cubrir varios objetos con diferentes reflectancias para poder así promediar de forma adecuada el color local. La variable  $\sigma$  proporciona el tamaño del marco de la máscara. Según [Ebner2007], un valor sugerido es  $\sigma = 0.093n_{max}$ , dado  $n_{max} = \max(n_x, n_y)$ , donde  $n_x$  y  $n_y$  son el ancho y alto de la imagen, respectivamente. Otra posible función para la máscara es la exponencial, y su ecuación está dada por

$$g(x, y) = e^{-\frac{\sqrt{x^2+y^2}}{\sigma^2}}. \quad (3.34)$$

El valor sugerido por Ebner para esta función es  $\sigma = 0.087n_{max}$ . La diferencia del uso entre estas máscaras, es que en la función exponencial, los píxeles inmediatos en la vecindad contribuyen menos al promedio mientras que los lejanos contribuyen más. En la función Gaussiana influyen de forma contraria.

### 3.4 Algoritmos para escenas con iluminación no uniforme

Una vez que calculamos la iluminación local de la forma anteriormente descrita, el siguiente paso es efectuar el escalado propuesto por el algoritmo Gray-World. La ecuación resultante con respecto a la iluminación calculada es

$$o_i(x, y) = \frac{f_i(x, y)}{2 * a_i(x, y)} \quad (3.35)$$

donde  $a_i(x, y)$  es la imagen con la iluminación local por cada píxel.



Figura 3.4: a) Imagen original. b) Promedio de color en espacio local.

#### 3.4.2. Filtrado homomórfico

Stockham propuso por primera vez procesar una imagen en el contexto de un modelo del sistema visual humano, pero él lo hizo en una sola banda [Stockham1972]. Faugeras extendió la idea para trabajar con imágenes a color, proponiendo usar el Filtro homomórfico para el mejoramiento del color de la imagen [Faugeras1979].

En el filtrado homomórfico, la imagen de entrada es transformada a un espacio donde la operación deseada es fácil de realizar. La baja variación de cada componente de color en una imagen puede ser atribuido a la baja variación de la luminancia. Por otro lado, la rápida variación de un componente es causado por el cambio en la reflectancia.

Una aproximación para obtener un color constante en la imagen es remover las frecuencias bajas de la imagen, esto se puede hacer en un espacio de frecuencia. Dicho lo anterior, para poder remover los efectos de la iluminación necesitamos transformar la imagen de entrada a un espacio de frecuencia usando la transformada de Fourier. La transformada de Fourier en dos dimensiones se describe de la siguiente manera

$$F_i(u, v) = \sum_{x=1}^M \sum_{y=1}^N \exp \left[ -2\pi i x \frac{u}{M} \right] \exp \left[ -2\pi i y \frac{v}{N} \right] f_i(x, y). \quad (3.36)$$

Esta transformada puede ser vista como coordenadas espaciales transformadas en frecuencias. Estando en el espacio de frecuencias, podemos volver a coordenadas espaciales

### 3.4 Algoritmos para escenas con iluminación no uniforme

---

mediante la transformada inversa de Fourier. La transformada inversa es descrita de la siguiente manera

$$f_i(x, y) = \frac{1}{M \cdot N} \sum_{u=1}^M \sum_{v=1}^N \exp \left[ 2\pi i u \frac{x}{M} \right] \exp \left[ 2\pi i v \frac{y}{N} \right] F_i(u, v). \quad (3.37)$$

En el Filtro Homomórfico las bajas frecuencias se atenúan, mientras las altas frecuencias se enfatizan. Esto se obtiene con un filtro de énfasis de altas. El filtro es descrito en la siguiente forma

$$G_i(u, v) = (\gamma_H - \gamma_L) \left[ 1 - \exp(-c(D_i^2(u, v)/D_0^2)) \right] + \gamma_L \quad (3.38)$$

donde  $D_i(u, v)$  es el radio del filtro a usar,  $\gamma_H = 1$ ,  $\gamma_L = 0.5$  y  $D_0$  es la frecuencia de corte.

$$G_i(u, v) = (1 - 0.5) \left[ 1 - \exp(-(D_i^2(u, v)/16)) \right] + 0.5 \quad (3.39)$$

Los pasos a realizar para la implementación de este algoritmo son los siguientes:

1. Obtener el logaritmo natural de la imagen de entrada.
2. Realizar la transformada rápida de Fourier a cada canal de la imagen de entrada.
3. Hacer el corrimiento de la frecuencia cero al centro.
4. Realizar el filtro homomórfico para cada canal.
5. Hacer el corrimiento de la frecuencia cero al origen.
6. Realizar la transformada rápida de Fourier inversa para así obtener la imagen de salida auxiliar.
7. Obtener el exponencial de la imagen de salida auxiliar.



Figura 3.5: a) Imagen original. b) Filtrado homomórfico.

## 3.5. Evaluación de los algoritmos de constancia de color

Para evaluar el desempeño de los algoritmos de constancia de color, una métrica de error debe ser considerada. La constancia de color debe ser evaluada de acuerdo al color de la iluminación estimada, independientemente de la intensidad de la misma.

Hordley y Finlayson mostraron que una buena medida para evaluar la constancia de color es el error angular [Hordley2004].

$$\mathbf{e}_{ang} = \cos^{-1} \left( \frac{\mathbf{I}_r \mathbf{I}_e}{|\mathbf{I}_r| |\mathbf{I}_e|} \right) \quad (3.40)$$

donde  $\mathbf{I}_r$  es el color de la iluminación real de la escena (verdad de referencia) y  $\mathbf{I}_e$  es el color de la iluminación estimada por un algoritmo. Nótese que para evaluar la constancia de color, es necesario contar con la verdad de referencia, comúnmente proporcionada por los autores de la base de datos.

Estudios realizados en diferentes publicaciones, señalan el desempeño de diferentes algoritmos de constancia de color para alguna base de datos en particular [Barnard2002b], [Ebner2007], [Weijer2007a], [Ebner2009], [Bianco2010], [Gijzenij2011], entre otros. Cabe señalar que los algoritmos tratados en este capítulo y en el resto del documento, han sido evaluados como algoritmos de buen desempeño. Algunos en casos específicos, y otros, de forma global.

## 3.6. Resumen

A lo largo de este capítulo, fueron revisados algunos de los algoritmos más importantes o muy conocidos en el área. También, algunos otros con un considerable buen desempeño en casos o condiciones específicas. A pesar de que existe una gran cantidad de algoritmos propuestos para la solución de la constancia de color, los revisados aquí, han sido catalogados por los expertos como los fundamentales y de buen desempeño para la estimación del iluminante.

En el siguiente capítulo, se abordará el diseño e implementación del sistema experto. Este sistema, seleccionará un algoritmo de constancia de color en base a las características presentes de nuestra imagen de entrada. Todo esto, basándose en una técnica de computación flexible como lo es la lógica difusa.



# Diseño del sistema experto

---

Desafortunadamente, ningún algoritmo de constancia de color puede ser adoptado como universal. Por otra parte, el diseño de un selector de algoritmos de constancia de color es una tarea difícil debido a las muchas características que están involucradas en el problema. Para esto, técnicas de computación flexible pueden ser usadas para modelar problemas con soluciones complicadas o múltiples variables. Ejemplo de estas técnicas, es el caso de los sistemas difusos basados en reglas.

En este capítulo, será tratado el desarrollo de un sistema experto basándose en lógica difusa. Este sistema deberá seleccionar un algoritmo de constancia de color óptimo, el cual está directamente relacionado con las características visuales de la escena actual.

### 4.1. Metodología del sistema desarrollado

Es importante reiterar que para este trabajo, el sistema experto es orientado a la elección de un algoritmo de constancia de color que mejore en mayor medida la calidad en color de una escena dada. Cabe señalar, que el conjunto de imágenes contempladas en este estudio, son de escenas oscuras bajo iluminación controlada [Barnard2002], aunque con anterioridad se ha experimentado en una variedad de categorías tomadas de otras bases de datos [Ciurea2003], [Martin2001]. Lo cual resulta de nuestro problema, el mejoramiento del color en cada imagen usando cualquier algoritmo. Lo anterior, independientemente si el algoritmo elegido tiene la mejor estimación del iluminante o no. En conclusión, el problema se restringe a la mejora de la imagen mediante una buena adaptación cromática, y no a la estimación exacta del iluminante.

En la Figura 4.1 se muestra un diagrama de la metodología usada en el diseño del sistema experto.

En las siguientes secciones, se describen de manera particular los módulos que constituyen el sistema desarrollado. Primeramente, se revisan las características que serán usadas en nuestro sistema selector experto. Además, será explicado el diseño del sistema

## 4.2 Extracción de características en las imágenes

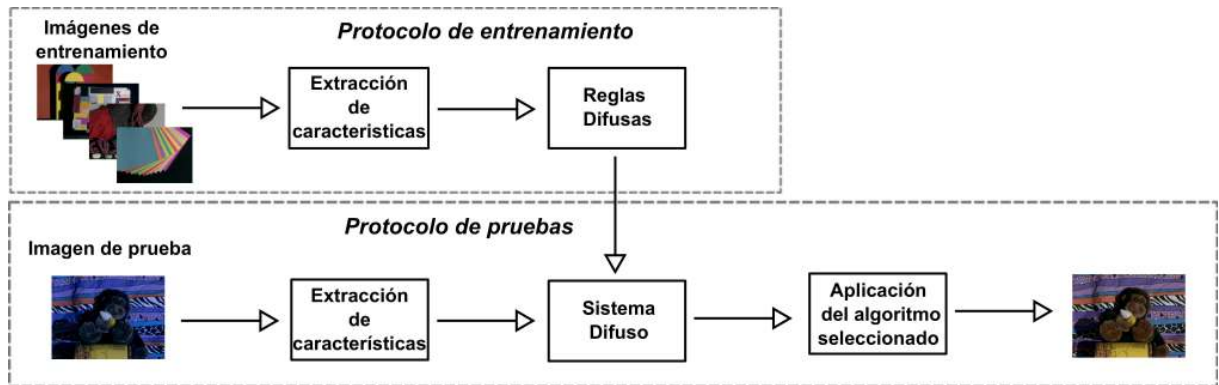


Figura 4.1: Diagrama de la metodología seguida en el diseño del sistema experto.

basado en la teoría de la lógica difusa. Para esto, es necesario contar con la información obtenida de imágenes de prueba, y diseñar un conjunto de reglas que brinden la información al selector para la toma de decisiones. Por último, se especificará el conjunto de imágenes a usar y la forma en que se efectúa la clasificación para un conjunto de entrenamiento.

## 4.2. Extracción de características en las imágenes

La extracción de características, como su nombre lo dice, consiste en extraer información en una imagen con el propósito de representarla mediante datos de ciertas características relevantes. Las características pueden estar relacionadas con el color, la textura o la forma de uno o varios objetos en la imagen. Éstas también pueden describir una escena de la imagen.

Las características deben tener la propiedad de ser discriminantes con fines de clasificación. Es decir, deben proporcionar información que permita distinguir con mayor facilidad entre una clase de imágenes con otras.

Las características que se contemplaron para este proyecto, están principalmente relacionadas con la descripción del color en una imagen. Algunas de estas características han sido trabajadas con propósitos semejantes al nuestro [Bianco2008] [Bianco2010]. Además, otro número de características son contempladas para la descripción de textura, iluminación y color de la escena.

Un total de 13 características son usadas para la selección en el sistema,

- Color (7),
- Iluminación (2),
- Textura (4).

## 4.2 Extracción de características en las imágenes

---

### 4.2.1. Color

Las características de color que fueron tomadas en cuenta para el selector son las siguientes:

1. Número de colores en RGB.
2. Valor promedio del espectro de potencia (APSV).
3. Índices de tonalidad.
4. Promedio de la croma.
5. Color dominante (porcentaje).

Todas estas características pueden consultarse en la Sección 2.4. Además, cabe señalar que fue elegido el espacio de color RLab para la extracción de características de color.

### 4.2.2. Iluminación

Dos características de iluminación son contempladas para nuestro sistema.

1. Promedio de la luminancia.
2. Porcentaje de especularidad.

Estas características se obtienen una vez teniendo la imagen en un espacio perceptual, donde la componente de luminancia es independiente del color. Recordando que la iluminación de nuestra imagen depende directamente de esta componente de luminancia.

La especularidad se refiere al destello luminoso que es emitido por el reflejo de un objeto. Ésta depende de las propiedades del material y normalmente representa muy pequeños porcentajes de la imagen. Para calcular la especularidad es necesario obtener el histograma de la luminancia (comúnmente con rango entre 0 y 100) y contemplar la información que se encuentre entre los últimos 10 valores o casillas de la luminancia.

### 4.2.3. Textura

Como características de textura, son usadas un subconjunto de características estadísticas propuestas por [Haralick1973]. Estas características son calculadas usando Histogramas de Sumas y Diferencias (SDH) como una alternativa rápida [Unser1986].

### 4.3 Aprendizaje de las reglas

---

Las cuatro características utilizadas son

$$\text{Homogeneidad} = \sum_j \frac{1}{1+j^2} \cdot P_d(j) \quad (4.1)$$

$$\text{Entropía} = - \sum_i P_s(i) \cdot \log(P_s(i)) - \sum_j P_d(j) \cdot \log(P_d(j)) \quad (4.2)$$

$$\text{Energía} = \sum_i P_s(i)^2 \cdot \sum_j P_d(j)^2 \quad (4.3)$$

$$\text{Contraste} = \sum_j j^2 \cdot P_d(j) \quad (4.4)$$

donde  $P_s$  y  $P_d$  son los histogramas de sumas y diferencias normalizados.

El vector relativo de desplazamiento ( $\mathbf{V}$ ) entre dos elementos de la imagen, es un parámetro SDH y está definido como la composición del producto cartesiano  $R \times \theta$ , donde  $R = \{1, 2\}$  y  $\theta = \{0, \frac{\pi}{4}, \frac{\pi}{2}, \frac{3\pi}{4}\}$ .

### 4.3. Aprendizaje de las reglas

Primero que nada, debemos definir las características operacionales y funcionales de nuestro sistema. Una vez teniendo en cuenta las características y el número de clases, será necesario definir los términos lingüísticos y la metodología para la formulación de la base de reglas.

El enfoque propuesto consiste en un sistema tipo MISO (múltiples entradas y una salida), con 13 entradas (características de color, textura e iluminación) y una salida (etiqueta de la clase correspondiente) en algunos modelos de inferencia como el de Mamdani [Mamdani1976] y el producto de Larsen [Vadiee1993]. Para este modelo, las entradas y salidas son términos lingüísticos, a través de un conjunto de reglas *SI-ENTONCES*.

Considerando un conjunto de entradas  $\mathbf{X} = \{x_1, x_2, \dots, x_i\}$ , que corresponde a un vector de  $i$  características. Son 13 características que componen al vector  $\mathbf{X}$ : Número de colores en RGB ( $x_1$ ), APSV ( $x_2$ ), radio del CE ( $x_3$ ), distancia al CE ( $x_4$ ), fuerza del CE ( $x_5$ ), promedio de la croma ( $x_6$ ), promedio de la luminancia ( $x_7$ ), entropía ( $x_8$ ), energía ( $x_9$ ), contraste ( $x_{10}$ ), homogeneidad ( $x_{11}$ ), especularidad ( $x_{12}$ ) y color dominante ( $x_{13}$ ). Todas éstas normalizadas entre 0 y 1.

La salida del sistema ( $\Omega$ ), toma valores de un conjunto  $\Omega = \{\omega_1, \omega_2, \dots, \omega_n\}$ , que corresponde con las etiquetas de  $n$  clases conocidas. Las clases de nuestro conjunto de salida pertenecen a los algoritmos contemplados para el selector.

#### 4.3.1. Formulación de las reglas *SI-ENTONCES*

Un paso importante en el proceso de aprendizaje, es el conocimiento o formulación de las reglas. El enfoque propuesto, entradas y salidas son representadas por términos

### 4.3 Aprendizaje de las reglas

---

lingüísticos relacionados por reglas del tipo *SI-ENTONCES*. Tales reglas son expresiones que declaran un proceso de inferencia, tal que si un conjunto de hechos son conocidos (antecedentes), una consecuencia (consecuente) puede inferirse. La forma genérica de la  $n$ -ésima regla es

$$R^n : \text{SI } x_1 \text{ es } A_{(1,m_1)} \text{ y } x_2 \text{ es } A_{(2,m_2)} \text{ y } \dots \text{ y } x_i \text{ es } A_{(i,m_i)}, \text{ ENTONCES } \Omega \text{ es } \omega^n,$$

donde,  $A_{(i,m)}$  es el conjunto difuso  $m_i$  en la característica  $i$  para la regla  $n$ , y  $\omega^n$  representa el conjunto difuso  $n$  en  $\Omega$ .  $R^n$  es la regla  $n$  que proviene del conjunto de reglas  $\mathbf{R}$ , donde  $n$  es el índice correspondiente a las clases de salida.

Para la formulación de una regla  $n$ , la cual corresponde a la clase  $n$ , se obtiene el promedio de cada característica  $i$  de las imágenes de entrenamiento, y es evaluado en el conjunto difuso correspondiente  $m$ . La definición del antecedente  $A_{(i,m)}$  está dado por

$$A_{(i,m)} = \max_m \left[ \mu_{(i,1)}(x_i), \mu_{(i,2)}(x_i), \dots, \mu_{(i,m)}(x_i) \right] \quad (4.5)$$

donde  $\mu_{(i,m)}(x_i)$  es el grado de membresía de  $x_i$  en el conjunto difuso  $A_{(i,m)}$ . El consecuente de la regla  $n$  es  $\omega^n$ .

#### 4.3.2. Definición de los términos lingüísticos

De cada vector de características  $\mathbf{X}$ , cada entrada  $x_i$ , es un valor en el dominio de términos lingüísticos, particionado en un cierto número de conjuntos difusos. La definición de conjuntos difusos puede consultarse en [Zadeh1965] ó [Cepeda2011].

En base a la experimentación y observación empírica sobre los casos de prueba, 4 términos lingüísticos separados en conjuntos difusos, son considerados apropiados para obtener una buena resolución. La formación de los conjuntos difusos, comienza del agrupamiento en 4 subconjuntos por cada característica  $i$  de los promedios generados en las reglas. Se calcula la media  $a_m$  de cada uno de los cuatro grupos, siendo este valor, el punto de máximo grado de pertenencia para el conjunto  $m$  y el mínimo para los conjuntos  $m - 1$  y  $m + 1$ . Un ejemplo de una definición de término lingüístico se muestra en la Figura 4.2. Las formas triangular y Gaussiana, son usadas para los conjuntos difusos en este proyecto. Para caso específicos, las etiquetas de  $A_{(i,m)}$  pueden ser convenientemente remplazadas por términos intuitivos como "MUY PEQUEÑO", "PEQUEÑO", "MEDIANO", "GRANDE", etc.

#### 4.3.3. Regla de evaluación para el reconocimiento de los algoritmos

Reconocimiento de los algoritmos es el proceso de asignar a una imagen desconocida, una clase conocida mediante una etiqueta. Es en esta parte, donde a cada imagen de

## 4.4 Base de datos

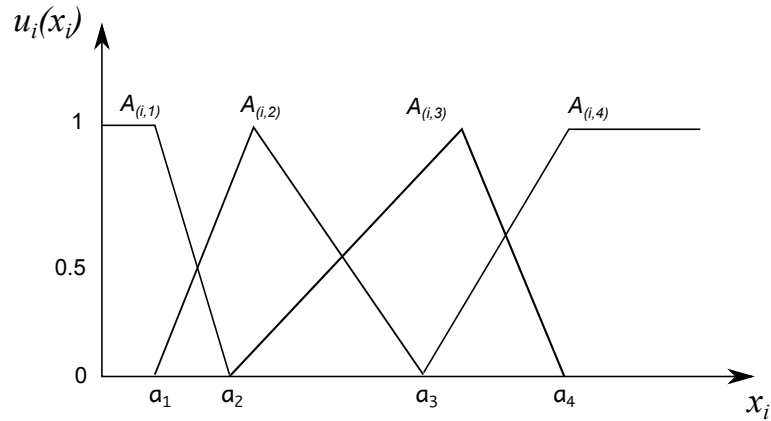


Figura 4.2: Representación de conjuntos difusos triangulares para una característica.

prueba se le calcula el vector de características. El vector de características determina el mejor algoritmo de acuerdo a la base de conocimiento ya establecida y a través de un proceso de inferencia. Usando el modelo de inferencia Mamdani, el grado de pertenencia a una clase  $n$  se calcula mediante

$$\mu_{\omega}^n(\mathbf{x}) = \min \left[ \mu_{(1,m)}^n(x_1), \mu_{(2,m)}^n(x_2), \dots, \mu_{(i,m)}^n(x_i) \right] \quad (4.6)$$

y usando el producto de Larsen, el grado de pertenencia se calcula por

$$\mu_{\omega}^n(\mathbf{x}) = \prod_i \mu_{(i,m)}^n(x_i) \quad (4.7)$$

y la etiqueta  $\Omega$  asignada, corresponde al máximo nivel de activación de todas las reglas.

$$\Omega = \max[\mu_{\omega}^1(\mathbf{x}), \mu_{\omega}^2(\mathbf{x}), \dots, \mu_{\omega}^n(\mathbf{x})] \quad (4.8)$$

## 4.4. Base de datos

El conjunto de imágenes que se usarán para el selector pertenecen a la Universidad de Simon Fraser. Este conjunto de imágenes recibe el nombre de SFU Laboratory, y fueron creadas por Kobus Barnard en el 2002. Este conjunto de datos contiene 529 imágenes oscuras con iluminaciones controladas. Todas las imágenes cuentan con el valor del iluminante en RGB (verdad de referencia) [Barnard2002].

Aproximadamente 50 escenas distintas con 11 iluminaciones diferentes conforman al conjunto de las 529 imágenes. Las escenas están divididas en 4 subconjuntos:

1. Especificidades mínimas (22 escenas, 223 imágenes).
2. Especificidades dieléctricas (9 escenas, 98 imágenes).

## 4.5 Clasificación de las imágenes de entrenamiento

---

3. Especularidades metálicas (14 escenas, 149 imágenes).
4. Superficies fluorescentes (6 escenas, 59 imágenes).

En la Figura 4.3, se muestran imágenes de escenas distintas pertenecientes al conjunto de datos SFU Laboratory. Cada escena es un ejemplo de las imágenes pertenecientes a un subconjunto.



**Figura 4.3:** Imágenes de muestra, pertenecientes a la base de datos SFU Laboratory.

Para este proyecto, 100 imágenes serán utilizadas como conjunto de datos de entrenamiento y 429 para el conjunto de datos de prueba. La elección de las imágenes de entrenamiento, se realizó extrayendo una imagen de cada 5 del conjunto total. El restante se preservó para el conjunto de prueba.

## 4.5. Clasificación de las imágenes de entrenamiento

La clasificación de las imágenes de entrenamiento o preclasificación, depende totalmente de la aplicación o un propósito específico a tratar. Para este trabajo, la clasificación se orientó a la elección de un algoritmo de constancia de color que mejore en mayor medida la calidad en color de una escena dada.

La medida que nos permitirá realizar la clasificación, deberá indicarnos previamente la imagen resultante por los algoritmos que tuvo una mejor adaptación cromática. Esta adaptación cromática tiene una alta correlación con la mejora de una imagen de acuerdo a la percepción humana.

Tras una serie de pruebas experimentales se observó que la medida del promedio de la croma, proporciona la información más acertada acerca de la calidad del color. Esta me-

## 4.5 Clasificación de las imágenes de entrenamiento

---

didada, también coincide en la mayoría de las veces con la apreciación humana calificando una imagen como de mayor calidad.

Recordando, croma es una coordenada cilíndrica obtenida de un espacio de color que excluya la luminancia de sus componentes cromáticas. Esta medida se analizó en la Sección 2.4, donde el promedio de la croma, cuanto mayor sea, mejor la calidad en color de la imagen.

Fueron aplicados todos los algoritmos contemplados para el sistema selector a todo el conjunto de imágenes de entrenamiento. Se obtuvo la medida de calidad para cada imagen resultante, con lo cual la clasificación se hace en base al valor más alto de esta medida en las 100 imágenes. Esta clasificación será nuestra verdad de referencia de ahora en adelante, asumiendo que representa la información de las mejores imágenes resultantes por un algoritmo, y donde al final se comparará con la decisión del selector para evaluar el desempeño del mismo.

Los algoritmos contemplados para el selector son tres

- White Patch de Finlayson (WP),
- Gray World (GW),
- Gray Edges con derivada de primer orden (GE1).

La razón por la que se eligieron estos tres, fue debido a su alta popularidad, se sustentan en teorías diferentes, son adecuados para imágenes oscuras, y además, son los tres que mejor realce de color efectúan en una imagen. Ésto, independientemente de su desempeño en la estimación de la iluminación.

**Tabla 4.1:** Clasificación de las imágenes de entrenamiento en base al promedio de la croma.

Índice	WP	GW	GE1	Clase
0	22.24	<b>23.43</b>	21.79	2
1	21.03	<b>22.04</b>	19.83	2
2	<b>30.12</b>	22.39	25.86	1
3	<b>33.25</b>	23.84	27.56	1
4	14.43	<b>14.79</b>	12.17	2
5	13.53	<b>13.88</b>	12.11	2
		⋮		
97	<b>27.29</b>	19.16	25.36	1
98	<b>23.85</b>	12.75	22.30	1
99	<b>25.11</b>	13.90	22.37	1



## 4.6 Resumen

---

Con los tres algoritmos se efectuó el entrenamiento comenzando por la clasificación. La probabilidad a priori de resultar ser el mejor algoritmo de los tres contemplados, se puede ver en la Tabla 4.2.

**Tabla 4.2:** Probabilidad a priori de resultar ser el mejor algoritmo.

Algoritmo	Probabilidad
WP	0.36
GW	0.48
GE1	0.16

## 4.6. Resumen

A lo largo de este capítulo, se revisaron las características que serán usadas en nuestro sistema selector experto. Además, fue explicado el diseño del sistema basado en la teoría de la lógica difusa. Para esto, es necesario contar con la información obtenida de imágenes de prueba, y diseñar un conjunto de reglas que brinden la información al selector para la toma de decisiones. Por último, se especificó el conjunto de imágenes a usar y la forma en que se efectúa la clasificación para un conjunto de entrenamiento.

En el siguiente capítulo, se abordará la evaluación del sistema diseñado. Se describe el sistema utilizando distintas reglas generadas con información de entrenamiento. Además, la evaluación se hace combinando dos tipos de inferencia difusa y dos tipos de conjuntos difusos diferentes. Finalmente, se compara nuestro sistema con otros sistemas de clasificación.

---

## Capítulo 5

# Evaluación del sistema

---

En el presente capítulo, se muestran y analizan los resultados obtenidos por el sistema selector de algoritmos de constancia de color. Recordando que el sistema, en este caso difuso, está basado en reglas que proporcionan la información necesaria para que éste tome una decisión. Tales reglas, son generadas en base a la información obtenida en imágenes de prueba. El número de reglas y la forma de evaluar el sistema, son puntos que son contemplados a continuación.

### 5.1. Resultados utilizando una regla por clase

Inicialmente el selector fue diseñado con tres reglas, una por cada clase de salida. Todas las imágenes de entrenamiento por cada clase se involucraron para generar su respectiva regla. Sin embargo, los resultados indicaron un desempeño muy bajo del clasificador, teniendo una tasa de clasificación cercana al 30 %. Esto nos indica que existen dos posibles fallas en el sistema. La primera es, que las características contempladas, no sean lo suficientemente discriminantes. O la segunda es, que existen imágenes con distintas características y que pertenecen a la misma clase, esto es, que un algoritmo específico resulta apropiado para una variedad de imágenes.

### 5.2. Resultados utilizando cinco reglas por clase

Asumiendo que existen imágenes con características distintas, y a pesar de esto, pertenecen a la misma clase, arbitrariamente se particiona cada clase en 5 subconjuntos para generar el mismo número de reglas. Se usó el algoritmo K-means para la agrupación y

## 5.2 Resultados utilizando cinco reglas por clase

---

poder generar cinco reglas por clase. Obteniendo un total de 15 reglas para el sistema.

Recordando que la notación usada representa lo siguiente

Variable	Significado
$x_1$	No. Colores RGB
$x_2$	APSV
$x_3$	Radio del CE
$x_4$	Distancia al CE
$x_5$	Fuerza del CE
$x_6$	Promedio de la cromia
$x_7$	Promedio de la luminancia
$x_8$	Entropía
$x_9$	Energía
$x_{10}$	Contraste
$x_{11}$	Homogeneidad
$x_{12}$	Especularidad
$x_{13}$	Color dominante
$A_{(i,1)}$	"MUY BAJO(A)"
$A_{(i,2)}$	"BAJO(A)"
$A_{(i,3)}$	"MEDIO(A)"
$A_{(i,4)}$	"ALTO(A)"
$\omega^1$	WP
$\omega^2$	GW
$\omega^3$	GE1

Las 15 reglas que se formularon fueron las siguientes:

$R^1$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,2)}$  y  $x_4$  es  $A_{(4,3)}$  y  $x_5$  es  $A_{(5,2)}$  y  $x_6$  es  $A_{(6,2)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,2)}$  y  $x_9$  es  $A_{(9,3)}$  y  $x_{10}$  es  $A_{(10,1)}$  y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{12}$  es  $A_{(12,3)}$  y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^2$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,2)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_5$  es  $A_{(5,3)}$  y  $x_6$  es  $A_{(6,3)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,2)}$  y  $x_9$  es  $A_{(9,3)}$  y  $x_{10}$  es  $A_{(10,1)}$  y  $x_{11}$  es  $A_{(11,2)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,4)}$ , ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^3$  : SI  $x_1$  es  $A_{(1,2)}$  y  $x_2$  es  $A_{(2,2)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,2)}$  y  $x_5$  es  $A_{(5,2)}$  y  $x_6$  es  $A_{(6,4)}$  y  $x_7$  es  $A_{(7,3)}$  y  $x_8$  es  $A_{(8,3)}$  y  $x_9$  es  $A_{(9,2)}$  y  $x_{10}$  es  $A_{(10,1)}$  y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,3)}$ , ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^4$  : SI  $x_1$  es  $A_{(1,3)}$  y  $x_2$  es  $A_{(2,4)}$  y  $x_3$  es  $A_{(3,1)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_5$  es  $A_{(5,4)}$  y  $x_6$  es  $A_{(6,4)}$  y  $x_7$  es  $A_{(7,4)}$  y  $x_8$  es  $A_{(8,4)}$  y  $x_9$  es  $A_{(9,2)}$  y  $x_{10}$  es  $A_{(10,4)}$  y  $x_{11}$  es  $A_{(11,2)}$  y  $x_{12}$  es  $A_{(12,2)}$  y  $x_{13}$  es  $A_{(13,4)}$ , ENTONCES  $\Omega$  es  $\omega^1$ ,

## 5.2 Resultados utilizando cinco reglas por clase

---

- $R^5$  : SI  $x_1$  es  $A_{(1,4)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,2)}$  y  $x_5$  es  $A_{(5,2)}$   
y  $x_6$  es  $A_{(6,3)}$  y  $x_7$  es  $A_{(7,3)}$  y  $x_8$  es  $A_{(8,4)}$  y  $x_9$  es  $A_{(9,1)}$  y  $x_{10}$  es  $A_{(10,2)}$   
y  $x_{11}$  es  $A_{(11,1)}$  y  $x_{12}$  es  $A_{(12,2)}$  y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^1$ ,
- $R^6$  : SI  $x_1$  es  $A_{(1,3)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,2)}$  y  $x_5$  es  $A_{(5,1)}$   
y  $x_6$  es  $A_{(6,2)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,3)}$  y  $x_9$  es  $A_{(9,2)}$  y  $x_{10}$  es  $A_{(10,2)}$   
y  $x_{11}$  es  $A_{(11,2)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^7$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,3)}$  y  $x_4$  es  $A_{(4,1)}$  y  $x_5$  es  $A_{(5,1)}$   
y  $x_6$  es  $A_{(6,2)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,2)}$  y  $x_9$  es  $A_{(9,3)}$  y  $x_{10}$  es  $A_{(10,3)}$   
y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{12}$  es  $A_{(12,4)}$  y  $x_{13}$  es  $A_{(13,1)}$ , ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^8$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_2$  es  $A_{(2,3)}$  y  $x_3$  es  $A_{(3,3)}$  y  $x_4$  es  $A_{(4,3)}$  y  $x_5$  es  $A_{(5,2)}$   
y  $x_6$  es  $A_{(6,2)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,2)}$  y  $x_9$  es  $A_{(9,3)}$  y  $x_{10}$  es  $A_{(10,1)}$   
y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^9$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,2)}$  y  $x_4$  es  $A_{(4,2)}$  y  $x_5$  es  $A_{(5,1)}$   
y  $x_6$  es  $A_{(6,1)}$  y  $x_7$  es  $A_{(7,1)}$  y  $x_8$  es  $A_{(8,1)}$  y  $x_9$  es  $A_{(9,4)}$  y  $x_{10}$  es  $A_{(10,1)}$   
y  $x_{11}$  es  $A_{(11,4)}$  y  $x_{12}$  es  $A_{(12,3)}$  y  $x_{13}$  es  $A_{(13,3)}$ , ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^{10}$  : SI  $x_1$  es  $A_{(1,2)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,1)}$  y  $x_5$  es  $A_{(5,1)}$   
y  $x_6$  es  $A_{(6,3)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,3)}$  y  $x_9$  es  $A_{(9,3)}$  y  $x_{10}$  es  $A_{(10,2)}$   
y  $x_{11}$  es  $A_{(11,2)}$  y  $x_{12}$  es  $A_{(12,2)}$  y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^{11}$  : SI  $x_1$  es  $A_{(1,2)}$  y  $x_2$  es  $A_{(2,4)}$  y  $x_3$  es  $A_{(3,2)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_5$  es  $A_{(5,3)}$   
y  $x_6$  es  $A_{(6,4)}$  y  $x_7$  es  $A_{(7,4)}$  y  $x_8$  es  $A_{(8,4)}$  y  $x_9$  es  $A_{(9,2)}$  y  $x_{10}$  es  $A_{(10,2)}$   
y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,4)}$ , ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{12}$  : SI  $x_1$  es  $A_{(1,3)}$  y  $x_2$  es  $A_{(2,2)}$  y  $x_3$  es  $A_{(3,3)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_5$  es  $A_{(5,3)}$   
y  $x_6$  es  $A_{(6,4)}$  y  $x_7$  es  $A_{(7,3)}$  y  $x_8$  es  $A_{(8,3)}$  y  $x_9$  es  $A_{(9,2)}$  y  $x_{10}$  es  $A_{(10,1)}$   
y  $x_{11}$  es  $A_{(11,2)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{13}$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,3)}$  y  $x_5$  es  $A_{(5,2)}$   
y  $x_6$  es  $A_{(6,3)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,2)}$  y  $x_9$  es  $A_{(9,3)}$  y  $x_{10}$  es  $A_{(10,1)}$   
y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{12}$  es  $A_{(12,2)}$  y  $x_{13}$  es  $A_{(13,3)}$ , ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{14}$  : SI  $x_1$  es  $A_{(1,4)}$  y  $x_2$  es  $A_{(2,3)}$  y  $x_3$  es  $A_{(3,3)}$  y  $x_4$  es  $A_{(4,1)}$  y  $x_5$  es  $A_{(5,1)}$   
y  $x_6$  es  $A_{(6,2)}$  y  $x_7$  es  $A_{(7,4)}$  y  $x_8$  es  $A_{(8,4)}$  y  $x_9$  es  $A_{(9,1)}$  y  $x_{10}$  es  $A_{(10,3)}$   
y  $x_{11}$  es  $A_{(11,1)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{15}$  : SI  $x_1$  es  $A_{(1,3)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,1)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_5$  es  $A_{(5,4)}$   
y  $x_6$  es  $A_{(6,3)}$  y  $x_7$  es  $A_{(7,3)}$  y  $x_8$  es  $A_{(8,4)}$  y  $x_9$  es  $A_{(9,1)}$  y  $x_{10}$  es  $A_{(10,1)}$   
y  $x_{11}$  es  $A_{(11,1)}$  y  $x_{12}$  es  $A_{(12,1)}$  y  $x_{13}$  es  $A_{(13,3)}$ , ENTONCES  $\Omega$  es  $\omega^3$ .

### 5.3 Resultados optimizando las reglas

Hay que recordar que para este trabajo se contempló el uso de conjuntos difusos triangulares y Gaussianos, y las inferencias difusas de Mamdani y Larsen. Los resultados obtenidos en la clasificación utilizando las 15 reglas en lugar de 3 son los siguientes.

**Tabla 5.1:** Resultados de la clasificación usando cinco reglas por clase.

Conjuntos	Inferencia	Desempeño (%)
Triangulares	Mamdani	25.3
Triangulares	Larsen	25.3
Gaussianos	Mamdani	60.1
Gaussianos	Larsen	62.2

### 5.3. Resultados optimizando las reglas

El espacio multidimensional de las características es demasiado grande y el número de reglas posibles para cubrirlo en su totalidad, es de  $4^{13}$ , aproximadamente 60 millones de reglas. Esto quiere decir, que al considerar solamente 15 reglas en nuestro sistema experto, una gran parte del espacio de características no se está tomando en cuenta. Sin embargo, si cada regla se optimiza de manera que abarque un mayor espacio de características, el desempeño en la clasificación podría ser mayor. Para incrementar el espacio de características en cada regla reglas, es necesario excluir una o varias premisas en el antecedente. Es decir, la regla se vuelve más robusta y al mismo tiempo incluye a otras reglas.

La optimización de las reglas se realizó mediante experimentación empírica de prueba y error. Se realizaron todas las combinaciones en la base de conocimiento generada por las 15 reglas, evaluando cada una de éstas.

Las reglas que se generaron en la optimización fueron las siguientes:

$R^1$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_3$  es  $A_{(3,2)}$  y  $x_4$  es  $A_{(4,3)}$  y  $x_6$  es  $A_{(6,2)}$  y  $x_7$  es  $A_{(7,2)}$   
y  $x_8$  es  $A_{(8,2)}$  y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{12}$  es  $A_{(12,3)}$  y  $x_{13}$  es  $A_{(13,2)}$ ,  
ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^2$  : SI  $x_3$  es  $A_{(3,2)}$  y  $x_6$  es  $A_{(6,3)}$  y  $x_7$  es  $A_{(7,2)}$ , ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^3$  : SI  $x_2$  es  $A_{(2,2)}$  y  $x_4$  es  $A_{(4,2)}$  y  $x_6$  es  $A_{(6,4)}$ , ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^4$  : SI  $x_2$  es  $A_{(2,4)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_5$  es  $A_{(5,4)}$  y  $x_{10}$  es  $A_{(10,4)}$ ,  
ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^5$  : SI  $x_2$  es  $A_{(2,1)}$  y  $x_4$  es  $A_{(4,2)}$  y  $x_5$  es  $A_{(5,2)}$  y  $x_7$  es  $A_{(7,3)}$  y  $x_8$  es  $A_{(8,4)}$   
y  $x_{10}$  es  $A_{(10,2)}$  y  $x_{11}$  es  $A_{(11,1)}$  y  $x_{13}$  es  $A_{(13,2)}$ ,  
ENTONCES  $\Omega$  es  $\omega^1$ ,

$R^6$  : SI  $x_1$  es  $A_{(1,3)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,2)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,3)}$   
y  $x_{11}$  es  $A_{(11,2)}$ , ENTONCES  $\Omega$  es  $\omega^2$ ,

### 5.3 Resultados optimizando las reglas

---

- $R^7$  : SI  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,3)}$  y  $x_4$  es  $A_{(4,1)}$  y  $x_6$  es  $A_{(6,2)}$  y  $x_8$  es  $A_{(8,2)}$ ,  
ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^8$  : SI  $x_2$  es  $A_{(2,3)}$  y  $x_3$  es  $A_{(3,3)}$  y  $x_6$  es  $A_{(6,2)}$  y  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,2)}$ ,  
ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^9$  : SI  $x_7$  es  $A_{(7,2)}$  y  $x_8$  es  $A_{(8,3)}$  y  $x_{11}$  es  $A_{(11,2)}$ , ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^{10}$  : SI  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,1)}$  y  $x_7$  es  $A_{(7,2)}$ ,  
ENTONCES  $\Omega$  es  $\omega^2$ ,
- $R^{11}$  : SI  $x_1$  es  $A_{(1,2)}$  y  $x_2$  es  $A_{(2,4)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_5$  es  $A_{(5,3)}$  y  $x_6$  es  $A_{(6,4)}$   
y  $x_8$  es  $A_{(8,4)}$ , ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{12}$  : SI  $x_1$  es  $A_{(1,3)}$  y  $x_4$  es  $A_{(4,4)}$  y  $x_6$  es  $A_{(6,4)}$  y  $x_7$  es  $A_{(7,3)}$  y  $x_8$  es  $A_{(8,3)}$   
y  $x_{13}$  es  $A_{(13,2)}$ , ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{13}$  : SI  $x_1$  es  $A_{(1,1)}$  y  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,4)}$  y  $x_4$  es  $A_{(4,3)}$  y  $x_7$  es  $A_{(7,2)}$   
y  $x_8$  es  $A_{(8,2)}$  y  $x_{11}$  es  $A_{(11,3)}$  y  $x_{13}$  es  $A_{(13,3)}$ , ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{14}$  : SI  $x_1$  es  $A_{(1,4)}$  y  $x_2$  es  $A_{(2,3)}$  y  $x_6$  es  $A_{(6,2)}$  y  $x_{11}$  es  $A_{(11,1)}$ ,  
ENTONCES  $\Omega$  es  $\omega^3$ ,
- $R^{15}$  : SI  $x_2$  es  $A_{(2,1)}$  y  $x_3$  es  $A_{(3,1)}$  y  $x_5$  es  $A_{(5,4)}$  y  $x_7$  es  $A_{(7,3)}$ ,  
ENTONCES  $\Omega$  es  $\omega^3$ .

Una matriz de confusión es una herramienta de visualización que comúnmente se emplea en el aprendizaje supervisado. Cada columna de la matriz representa el número o porcentaje de predicciones por clase, mientras que cada fila representa las instancias de la clase real. La principal ventaja de esta herramienta es que facilita observar la confusión entre clase y clase. Una matriz de confusión representando valores ideales, debería mantener toda la información en la diagonal principal.

Un “acierto” se da cuando el sistema infiere correctamente el algoritmo al que pertenece una imagen. Así mismo, éste se registra en la diagonal principal de la matriz de confusión, coincidiendo con la fila y columna del algoritmo correspondiente. Por otra parte, un “error” es aquel en el que el sistema infiere incorrectamente el algoritmo correcto al que pertenece una imagen. Y éste se registra en la fila del algoritmo correcto y en la columna del algoritmo inferido por el sistema.

Los resultados obtenidos cuando se usaron conjuntos difusos triangulares con una inferencia de Mamdani se pueden observar en la Tabla 5.2.

Los resultados obtenidos cuando se usaron conjuntos difusos triangulares con una inferencia de Larsen se pueden observar en la Tabla 5.3.

Los resultados obtenidos cuando se usaron conjuntos difusos Gaussianos con una inferencia de Mamdani se pueden observar en la Tabla 5.4.

Los resultados obtenidos cuando se usaron conjuntos difusos Gaussianos con una inferencia de Larsen se pueden observar en la Tabla 5.5.

El alto traslape de las características es un indicador de que éstas son demasiado simi-

### 5.3 Resultados optimizando las reglas

---

**Tabla 5.2:** Matriz de confusión de los resultados usando conjuntos triangulares e inferencia Mamdani.

Alg.	WP	GW	GE1
WP	<b>26</b>	22	52
GW	06	<b>70</b>	23
GE1	18	19	<b>73</b>
total	54 %		

**Tabla 5.3:** Matriz de confusión de los resultados usando conjuntos triangulares e inferencia Larsen.

Alg.	WP	GW	GE1
WP	<b>25</b>	22	52
GW	05	<b>72</b>	22
GE1	18	09	<b>73</b>
total	55 %		

**Tabla 5.4:** Matriz de confusión de los resultados usando conjuntos Gaussianos e inferencia Mamdani.

Alg.	WP	GW	GE1
WP	<b>70</b>	15	15
GW	17	<b>74</b>	08
GE1	36	08	<b>56</b>
total	69 %		

**Tabla 5.5:** Matriz de confusión de los resultados usando conjuntos Gaussianos e inferencia Larsen.

Alg.	WP	GW	GE1
WP	<b>80</b>	15	06
GW	13	<b>83</b>	04
GE1	31	09	<b>60</b>
total	78 %		

lares, aún entre imágenes de distinta categoría, razón por la cual, al evaluar las imágenes de prueba, muchas de éstas presentan al menos una característica fuera del espacio de búsqueda en todas las reglas. Recordando que, si una característica está fuera del dominio establecido por la regla, el grado de pertenencia será nulo en la premisa. Y por lo tanto, el nivel de activación final será de cero. Aplicando lo mismo para cada regla, el nivel de activación máximo seguirá siendo de cero, por lo que el selector no podrá tomar una decisión y elegirá el último o el primero de los algoritmos posibles, según la

## 5.4 Comparación con otros clasificadores

codificación en la comparación para encontrar este máximo.

El motivo por el cual el desempeño es menor al utilizar conjuntos de tipo triangular, se debe precisamente a la complejidad del problema. Es decir, los conjuntos triangulares acotan con límites fijos la evaluación de una característica en la premisa. Y por esta razón, existe mucha probabilidad en nuestro problema, de que resulte cero este nivel de pertenencia. Sin embargo, los conjuntos Gaussianos garantizan un grado de pertenencia por mínimo que sea, dándole flexibilidad al sistema de tener información para la elección.

En nuestro clasificador, *Selector Difuso GaLa (Gaussiano Larsen)*, generalmente si no elige el mejor, selecciona el segundo más próximo. En la Figura 5.1 se pueden apreciar algunas imágenes que selecciona incorrectamente.<sup>el</sup> selector.



Figura 5.1: Algunas imágenes seleccionadas de forma errónea.

## 5.4. Comparación con otros clasificadores

Varios clasificadores comúnmente usados y muy populares fueron comparados con el sistema Selector Difuso GaLa, observando que nuestra propuesta resulta un tanto mejor que los demás clasificadores. Véase la Tabla 5.6.

El clasificador con menor desempeño resultó el K-means para 3 grupos. Esto resulta razonable, ya que recordemos que asumir que todas las imágenes pertenecientes a un algoritmo son iguales o muy parecidas, es incorrecto. El algoritmo K-nn ( $K$  vecinos más cercanos), resultó tener mucho mayor desempeño que el anterior. Este algoritmo de clasi-



## 5.5 Tiempos de procesamiento

---

Tabla 5.6: Comparación entre clasificadores.

Método	Taza de Clasificación (%)
K-means (3 grupos)	43.7
K-nn (3 vecinos)	60.5
K-nn (1 vecino)	62.4
K-means (15 grupos)	64.0
QDC	66.9
LDC	72.3
Selector Difuso GaLa	<b>78.0</b>

ficación obtiene ligeramente mejor desempeño cuando se considera solo un vecino en su análisis. Después tenemos el K-means pero para 15 grupos. Tomando en cuenta que nuestro selector considera 15 reglas posibles (5 para cada algoritmo), es conveniente medirse de la misma forma con los demás clasificadores no supervisados como K-means y K-nn. Teniendo así, el K-means una clasificación del 64 %. Un poco más que sus similares de K-nn. Por otra parte, se compara con clasificadores supervisados. El *Quadratic Discriminant Classifier* (QDC) y el *Linear Discriminant Classifier* (LDC), tuvieron todavía un mejor desempeño, resultando el último más alto. Sin embargo, con nuestro enfoque, utilizando un selector difuso para la selección, se puede apreciar que resulta en aproximadamente 6 % un tanto mejor que el más cercano.

## 5.5. Tiempos de procesamiento

Especificaciones del equipo utilizado en el proyecto

- Modelo **iMac apple**
- Procesador **2.5 GHz Intel Core i5**
- Memoria **4 GB 1333 MHz DDR3**
- Gráficos **AMD Raedon HD 6750M 512 MB**
- Almacenamiento **500 GB**

La Tabla 5.7 muestra los tiempos generados de cada rutina empleada por el sistema experto. Los tiempos medidos se encuentran en mili-segundos y fueron efectuados para tres tamaños de imágenes diferentes. Podemos ver, que la rutina que consume más tiempo, es la que calcula el espectro de potencia. De no ser por el tiempo consumido en el cálculo del espectro de potencia, podríamos concluir que el sistema se puede considerar para aplicaciones en tiempo real.

## 5.5 Tiempos de procesamiento

---

**Tabla 5.7:** Tiempos medidos por rutina (ms) para diferentes tamaños de imágenes.

Rutina	300 × 200	600 × 400	1200 × 800
WPR	2.4	9.5	39.6
GW	3.3	14.5	54.2
GE1	321.5	1306.8	4492.9
RLab	30.7	127.4	461.4
No. Colores	105.1	109.3	122.8
APSV	6584.5	60612.3	—
Radio del CE	0.7	3.3	11.8
Distancia al CE	0.7	3.3	11.8
Fuerza del CE	0.7	3.3	11.8
Promedio de Croma	0.06	0.3	0.9
Promedio de Luminancia	0.06	0.3	0.9
Entropía	4.5	18.3	71.6
Energía	4.5	18.5	70.8
Contraste	4.6	18.9	69.9
Homogeneidad	4.5	18.9	72.4
Especularidad	0.1	0.5	2.1
Color Dominante	1.1	4.3	12.5
Sistema Experto	70.5	70.5	70.5
Total aproximado	6745	61070	—

### 5.6. Resumen y Discusión

En el capítulo, se revisó la evaluación efectuada sobre el sistema experto selector de algoritmos de constancia de color. Diversas variantes fueron realizadas, específicamente en la formulación de las reglas y el diseño de los conjuntos difusos. Además, dos tipos de inferencia difusa fueron contempladas: Mamdani y el producto de Larsen. Finalmente, se comparó el sistema propuesto con otras metodologías de clasificación.

Podemos concluir que nuestro sistema propuesto obtiene los mejores resultados comparándolo con otras metodologías comúnmente usadas en clasificación. La tasa de clasificación máxima lograda, fue del 78 % utilizando conjuntos difusos de tipo Gaussiano y una inferencia difusa Larsen.

En el siguiente capítulo, se presentarán algunos estudios realizados en paralelo a este proyecto. Experimentos en el espacio de color CIELab y el uso de la corrección gama como apoyo en la mejora de las imágenes, son los temas desarrollados, respectivamente.

# Estudios realizados en paralelo al proyecto de investigación

---

En este capítulo se abordarán dos metodologías trabajadas de forma paralela al proyecto de investigación tratado en los capítulos anteriores. Por un lado, se realizaron algunos experimentos en adaptación cromática utilizando el algoritmo White-Patch en el espacio CIELab. Por otra parte, se comparó el uso de la corrección gama en combinación con algoritmos de constancia de color con propósitos de mejorar una imagen.

### 6.1. Experimentos con el White Patch Retinex en los espacios de color RGB y CIELab

La constancia de color es un proceso importante en múltiples tarea de visión por computadora. La mayoría de las imágenes obtenidas por los dispositivos electrónicos operan en el espacio de color RGB y, usualmente, los procesos en las imágenes se efectúan en este espacio, sin embargo, algunos de estos procesos han mostrado un mejor desempeño cuando son utilizados espacios de color perceptuales. En este estudio, algunos experimentos con el White Patch Retinex, son efectuados sobre ambos espacios de color con propósitos de comparación: RGB y CIELAB. Aquí, es usada una métrica de calidad para imágenes sin referencia. Los resultados experimentales utilizan un conjunto de imágenes con las cuales se analizan y se discuten algunos de los resultados.

#### 6.1.1. Justificación del uso de CIELab

El color es una propiedad visual del humano [Fairchild2005]. En otras palabras, el color depende de la percepción de cada individuo. Desafortunadamente, la mayoría de las investigaciones no se han enfocado directamente en la corrección del color en espacios de color perceptuales. Por esta razón, es considerado pertinente analizar un algoritmo

## 6.1 Experimentos con el White Patch Retinex en los espacios de color RGB y CIELab

básico en un espacio de color perceptual como el CIELab.

### 6.1.2. Metodología de los experimentos

La mayoría de los algoritmos de constancia de color han sido propuestos e implementados en el espacio de color RGB [Ebner2007]. En este estudio, el WPR, es comparado en los espacios RGB y CIELab usando tres aproximaciones particulares, como se representa en la Figura 6.1.

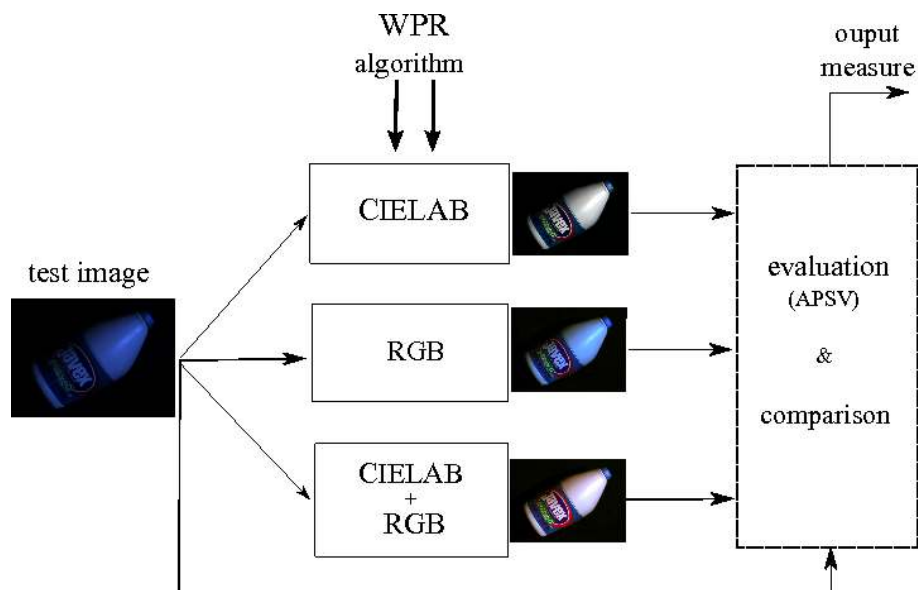


Figura 6.1: Tres aproximaciones para la evaluación experimental del WPR.

Básicamente, la metodología consiste en los siguientes módulos:

- Aplicar el algoritmo WPR para todas las imágenes en el espacio CIELab.
- Aplicar el algoritmo WPR para todas las imágenes en el espacio RGB.
- Aplicar el algoritmo WPR primero en el espacio CIELab después en el espacio RGB.
- Para cada imagen de entrada obtener una métrica de calidad para las tres aproximaciones.
- Hacer una comparación entre las tres medidas obtenidas.

Las ecuaciones de transformación para el espacio CIELab se pueden consultar en la Sección 2.2.4. De igual forma, la medida de calidad del Espectro de Potencia (APSV), nos proporciona un referente de la cantidad cromática en la escena, y puede consultar en la

## 6.1 Experimentos con el White Patch Retinex en los espacios de color RGB y CIELab

Sección 2.4.2. Específicamente en este trabajo, el espectro de potencia fue ajustado en base a un modelo de imágenes de potencia sugerido en [Yan2011].

El algoritmo White Patch Retinex puede ser consultado en la Sección 3.3.1. Por otro lado, el algoritmo principal de este trabajo, WPR aplicado en CIELab, se encuentra en la Sección 3.3.4.


### 6.1.3. Resultados en los experimentos

La base de datos seleccionada consistió de 100 imágenes. La mayoría de las imágenes pertenecen a la base de datos de Barnard [Barnard2002] y el resto de las imágenes fueron tomadas de una colección particular o imágenes populares de Internet. Aproximadamente el 75 % son imágenes oscuras con una fuente de iluminación. El resto son imágenes naturales.

El índice de todas las imágenes fue reordenado en base al APSV de las imágenes originales. El índice va en orden ascendente, en correspondencia a la calidad medida. Esto es, el índice 0 corresponde a la imagen con el APSV menor, mientras el índice 100 pertenece a la imagen con la calidad mas alta.


Los resultados experimentales para el WPR en RGB, CIELab, y CIELab + RGB, son mostrados en la Figura 6.2. Para aclarar la interpretación de los resultados, los APSVs obtenidos fueron aproximados por ajuste a la curva. Esta aproximación fue calculada por un polinomio de tercer grado, de tal manera que, el ajuste a la curva muestra la tendencia de un enfoque particular, como se muestra en la Figura 6.6.

Una revisión minuciosa nos permite observar que aplicando el WPR en CIELab proporciona imágenes resultantes con peor calidad cuando se comparan con las resultantes aplicando el algoritmo solamente en RGB. Sin embargo, la combinación secuencial de los ajustes constantemente supera los enfoques individuales.



**Figura 6.2:** Comportamiento del APSV para los enfoques del WPR en el conjunto de imágenes.

## 6.1 Experimentos con el White Patch Retinex en los espacios de color RGB y CIELab



**Figura 6.3:** Tendencia del APSV en los enfoques usando ajuste a la curva para el conjunto de imágenes.

La Figura 6.4 muestra seis ejemplos de imágenes y sus resultados correspondientes. Esas imágenes son muestras tomadas en intervalos de aproximadamente cada 20 imágenes, de acuerdo a su índice.

**Tabla 6.1:** Medida de calidad (APSV) para algunas imágenes de muestra y sus resultantes.

Índice de imagen	Imagen original	White Patch Retinex		
		RGB	CIELab	CIELab + RGB
03	441.77	3339.39	3324.00	<b>3926.28</b>
21	1039.38	4393.36	4499.47	<b>6385.03</b>
38	1663.77	7343.47	6963.36	<b>8707.58</b>
62	2743.98	<b>8962.07</b>	4316.49	8841.02
79	5112.61	9824.82	6528.07	<b>10117.70</b>
99	14221.00	14698.50	12121.30	<b>14977.70</b>

La Tabla 6.2 muestra los APSVs para cada imagen presente en la Figura 6.4. El APSV para la primer imagen de entrada es menor que el de la última imagen que se muestra. La mayoría de las imágenes de entrada son oscuras. Por esta razón, el APSV en estas imágenes es menor que el valor de las imágenes corregidas, independientemente del enfoque tomado.

El enfoque usando únicamente el WPR en CIELab es el peor de los tres. Sin embargo, aplicando este enfoque es cierta medida mejor que la imagen original, en la mayoría de los casos. Podemos apreciar que usando de manera secuencial los enfoques, las imágenes resultantes son consistentemente mejores, de acuerdo con los resultados cuantitativos previamente dados.

## 6.1 Experimentos con el White Patch Retinex en los espacios de color RGB y CIELab

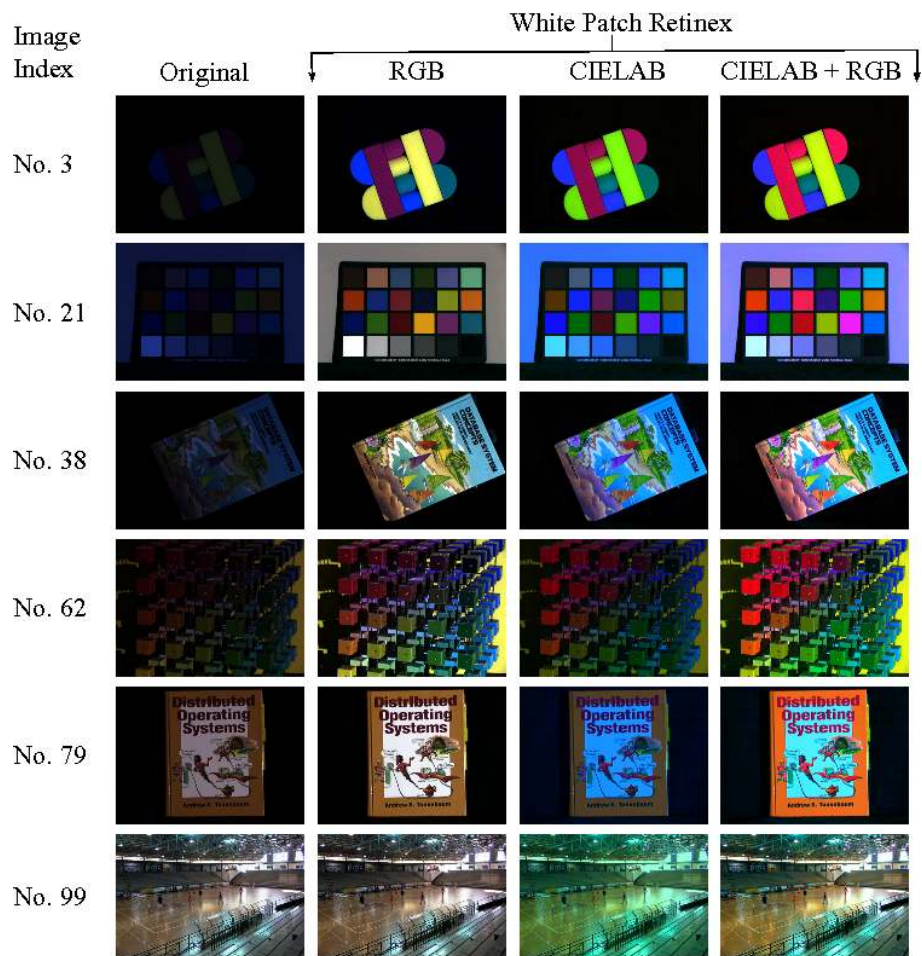


Figura 6.4: Algunas imágenes de muestra de entrada y sus resultantes



### 6.2. Combinación de la constancia de color y la corrección gama para la mejora de imágenes

En este estudio, tareas para la mejora de imágenes son tratadas por el análisis del efecto de dos algoritmos muy conocidos de constancia de color en combinación con la corrección gama. Esos efectos son estudiados aplicando los algoritmos separadamente y en combinación. Imágenes del conjunto de datos de Barnard y de Berkeley son considerados para las pruebas experimentales. El desempeño de los enfoques es evaluado comparando el APSV de la imágenes probadas y sus correspondientes salidas, como una medida calidad.

#### 6.2.1. Justificación en el uso de la corrección gama

Las metodologías de constancia de color y la corrección gama, son comúnmente usadas en aplicaciones practicas que requieren una corrección del rango dinámico. Esto es, de manera similar a algunos enfoques de constancia de color, investigaciones sobre la corrección gama han sido enfocadas a la corrección del rango dinámico para la mejora de imágenes, como tareas para el contraste dinámico [Scott2009] y aplicaciones de alto rango dinámico [Yuan2011]. Por consiguiente, probar el efecto causado por la aplicación conjunta de estas dos técnicas para el mejoramiento de imágenes, es considerado interesante.

Se propone la aplicación de un algoritmo de constancia de color en combinación con la corrección gama para la mejora en la calidad de las imágenes. Los resultados son evaluados usando la métrica del espectro de potencia [Yan2011] como una medida en la calidad de la imagen. Las imágenes consideradas en la serie de pruebas, son tomadas de dos base de datos distintas [Barnard2002], [Martin2001].

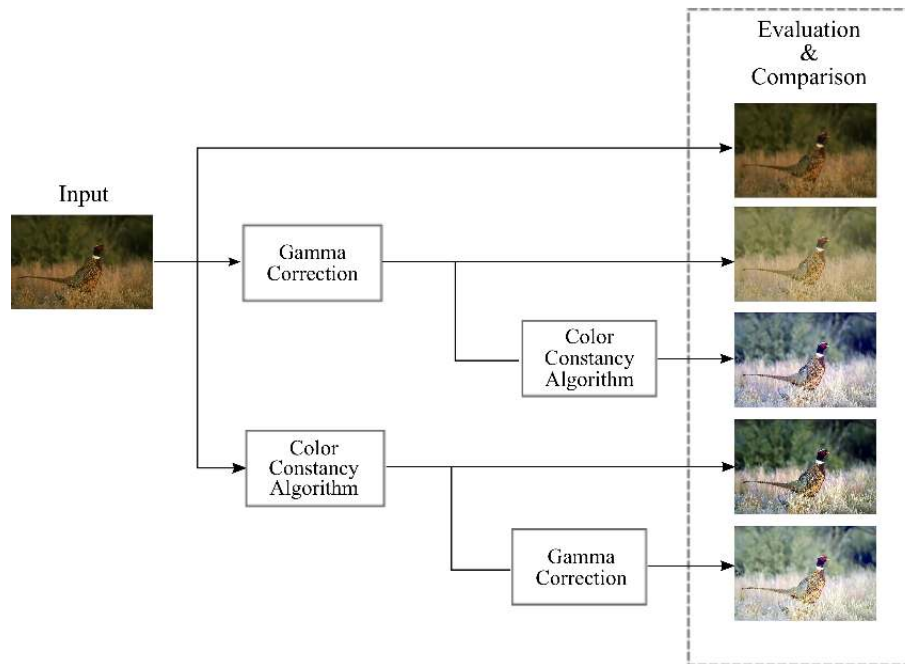
#### 6.2.2. Metodología en la combinación de los algoritmos

En este estudio, el efecto combinado de dos algoritmos básicos en el campo de la constancia de color, el WPR y el GW, son probados en combinación con la corrección gama. Los resultantes de los cuatro enfoques particulares son comparados, como se indica en la Fig. 6.5.

Básicamente, los enfoques son aplicados a cada algoritmo de constancia de color, separadamente, como sigue.

1. Corrección gama,
2. Algoritmo de constancia de color,
3. Corrección gama y posteriormente, el algoritmos de constancia de color,

## 6.2 Combinación de la constancia de color y la corrección gama para la mejora de imágenes



**Figura 6.5:** Evaluación experimental de cuatro enfoques combinando algoritmos de constancia de color y corrección gama.

### 4. Algoritmo de constancia de color y posteriormente la corrección gama.

Después de obtener las imágenes resultantes, el APSV es calculado para cada imagen de entrada y sus respectivos resultantes. Finalmente, las cinco medidas de calidad obtenidas son comparadas.

La corrección gama usada se puede consultar en la Sección 2.3. Por otro lado, los algoritmos White-Patch Retinex y Gray-World se describen en el Capítulo 3.

### 6.2.3. Resultados de la combinación


El conjunto de imágenes seleccionado para las pruebas consiste de 236 imágenes. 70 imágenes son tomadas del conjunto de imágenes de Barnard [Barnard2002], 148 imágenes son del conjunto de imágenes de Berkeley [Martin2001], y las 18 restantes son imágenes tomadas de una colección particular o proveniente de Internet. Es importante señalar que, las 70 imágenes pertenecientes al conjunto de Barnard son imágenes oscuras bajo una iluminación uniforme. El resto son imágenes naturales con iluminación no uniforme.

Los resultados experimentales consisten en un análisis comparativo entre la imagen original y sus resultantes de los cuatro enfoques para cada algoritmo de constancia de color. Por lo tanto, 944 ( $236 \times 4$ ) imágenes resultantes son obtenidas. Así, los APSVs fueron calculados para las 944 resultantes y, adicionalmente para las 236 imágenes de entrada, obteniendo un total de 1180 APSVs para el estudio del WPR. 944 valores adicionales son obtenidos para las pruebas del GW.

## 6.2 Combinación de la constancia de color y la corrección gama para la mejora de imágenes

### Resultados para el White Patch Retinex

El índice de todas las imágenes fue previamente re-ordenado en orden ascendente, en base al APSV (calidad) de las imágenes de entrada. Sin embargo, los APSVs para los otros enfoques no siguen una tendencia igual, y su comportamiento es considerablemente inestable y variado. Es por esto que, para clarificar la tendencia de los resultados, los APSVs obtenidos son aproximados por el ajuste a la curva. Esta aproximación fue calculada usando siete términos de las Series de Fourier, así, la curva ajustada representa la tendencia de una enfoque en particular, como se muestra en la Fig. 6.6.



**Figura 6.6:** Tendencia de los APSVs para cada imagen de prueba y sus resultantes en los enfoques usando WPR.

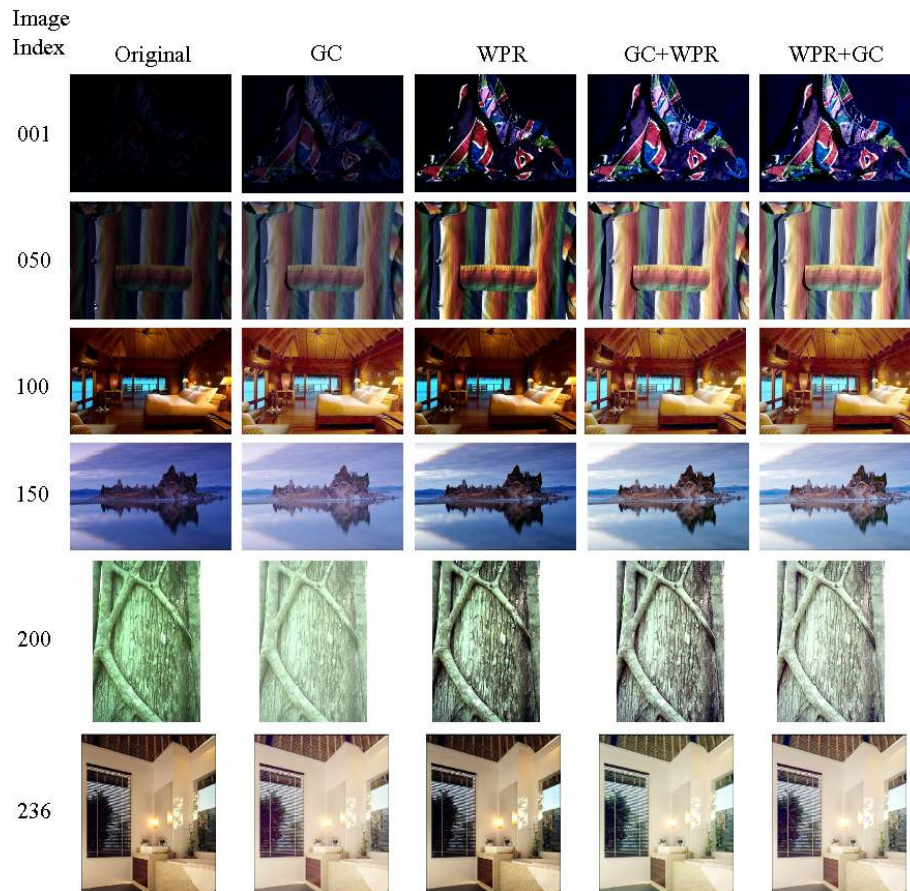
En algunos casos, aplicando solamente la GC es mejor que adicionando la corrección por el WPR. Sin embargo, cuando el WPR y después la GC es aplicada, los resultados son generalmente, los mejores. De acuerdo a los resultados, la diferencia es pequeña entre los enfoques combinados. A pesar de esto, aplicando el WPR y posteriormente, la GC es, sin excepción, la mejor propuesta.

**Tabla 6.2:** Medidas de calidad (APSV  $\times 10^8$ ) para las imágenes en la Fig. 6.7.

Índice de imagen	Imagen original	GC	WPR	GC + WPR	WPR + GC
001	0.06	1.53	8.89	16.26	<b>19.14</b>
050	2.95	22.18	26.97	55.93	<b>61.06</b>
100	12.34	27.46	12.88	27.26	<b>27.93</b>
150	20.48	43.33	26.69	40.53	<b>48.45</b>
200	29.80	<b>53.91</b>	27.99	37.17	49.47
236	64.14	<b>113.20</b>	63.59	105.82	111.99

Particularmente, las imágenes de entrada y las resultantes son mostradas en la Fig. 6.7 para el caso del algoritmos WPR. La primer columna contiene las imágenes originales. Las

## 6.2 Combinación de la constancia de color y la corrección gama para la mejora de imágenes



**Figura 6.7:** Seis muestras de 236 imágenes probadas al WPR y sus correspondientes resultantes.

resultantes aplicando los enfoques están dados en las columnas 2 a 5, como se indica.


La Tabla 6.2 indica los APSVs de cada imagen de ejemplo. Es posible apreciar que, consistentemente, los valores numéricos más grandes están en la última columna. Incluso en aquellos casos cuando este valor no es el más grande, está lo suficientemente cercano del que si lo es. Esta columna incluye los resultados de los resultantes aplicando el algoritmos de constancia de color y después la GC.

### Resultados para Gray World

De forma similar al WPR, los enfoques propuestos fueron aplicados usando el algoritmo GW. La Fig. 6.8 muestra los resultados del APSV en el conjunto de imágenes.

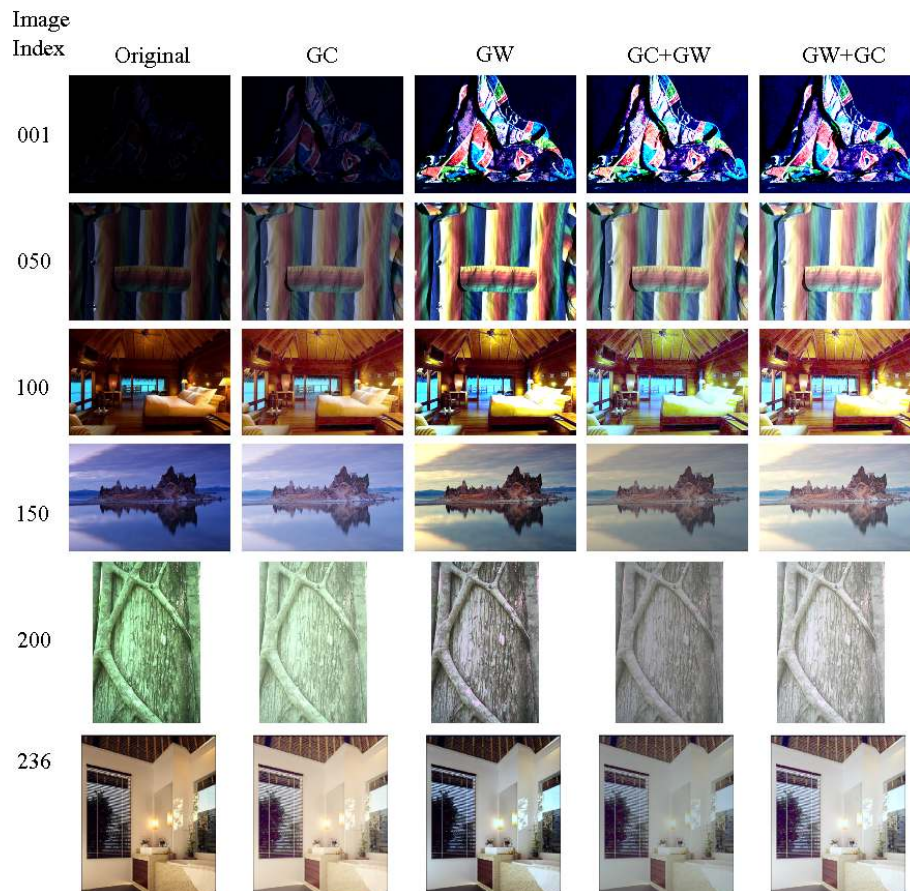
De acuerdo a los resultados, para las primeras 70 imágenes re-ordenadas, el comportamiento usando el GW es similar a los resultados del WPR. Sin embargo, se puede apreciar en la Fig. 6.8 que, de la imagen 70 en adelante, los APSVs sobre las imágenes mantiene un valor similar, particularmente en los enfoques usando el algoritmo GW. Este comportamiento es observado, porque esas imágenes contienen una cantidad numerosa de colores, y el algoritmo GW calcula un promedio que tiende al nivel gris. En otros

## 6.2 Combinación de la constancia de color y la corrección gama para la mejora de imágenes



**Figura 6.8:** Tendencia de los APSVs para cada imagen de prueba y sus resultantes en los enfoques usando GW.

palabras, para un conjunto de imágenes grisáceas los APSVs son muy similares. Los resultados indican que aplicando el algoritmo GW y posteriormente la GC, es como regla, mejor que los otros enfoques.



**Figura 6.9:** Seis muestras de las 236 imágenes probadas al GW y sus correspondientes resultantes.

La Fig. 6.9 muestra las mismas imágenes de ejemplo previamente indicadas, pero



## 6.2 Combinación de la constancia de color y la corrección gama para la mejora de imágenes

---

ahora, los enfoques fueron aplicados usando el algoritmos GW. Además, la Tabla 6.3 indica los APSVs obtenidos para esas imágenes y sus resultantes. Se puede apreciar que de acuerdo a los resultados en la tabla, es repetidamente mejor aplicar el algoritmos GW y después la GC. De forma similar, al WPR, en aquellos casos cuando el APSV no es el más grande, la diferencia es pequeña al que si lo es.

**Tabla 6.3:** Medidas de calidad (APSV  $\times 10^8$ ) para las imágenes en la Fig. 6.9.

Índice de imagen	Imagen original	GC	GW	GC + GW	GW + GC
001	0.06	1.53	37.03	<b>49.50</b>	47.55
050	2.95	22.18	58.35	57.11	<b>94.08</b>
100	12.34	27.46	32.17	38.74	<b>49.09</b>
150	20.48	43.33	29.30	26.33	<b>52.57</b>
200	29.80	<b>53.91</b>	28.38	25.75	53.18
236	64.14	113.20	91.00	80.53	<b>136.40</b>

Las imágenes que pertenecen al conjunto de Barnard, están contenidas dentro de las primeras 70 imágenes re-ordenadas. El comportamiento de los resultados en esas imágenes es diferente al resto debido a que las primeras son imágenes oscuras, y en este tipo de imágenes la corrección de color incrementa mucho el rango dinámico. Así, los APSVs son altos debido a la diversa información cromática en la imagen. Se puede apreciar que en las Figuras 6.6 y 6.8 que, aplicando el algoritmos GW es generalmente mejor que el WPR, especialmente, en imágenes oscuras.

### 6.2.4. Conclusiones del capítulo

Dos artículos fueron generados como producto de los estudios revisados en este capítulo. El primero se publico en una revista arbitrada [Cepeda2012a] y el segundo en las memorias de un congreso internacional [Cepeda2012b]. En el siguiente capítulo de conclusiones se hablará un poco más acerca de estos dos artículos. Además, se darán las conclusiones general y particulares de este proyecto desarrollado.

# Conclusiones y Perspectivas

---

## Conclusiones del proyecto

Es importante reiterar que para este proyecto, el sistema experto ha sido orientado a la elección de un algoritmo de constancia de color que mejore en mayor medida la calidad en color de una escena dada. Cabe señalar, que el conjunto de imágenes contempladas en este estudio, son de escenas oscuras bajo iluminación controlada [Barnard2002], aunque a lo largo del proyecto también se ha experimentado con una variedad de categorías tomadas de otras bases de datos [Ciurea2003], [Martin2001]. Es muy importante enfatizar que al utilizar imágenes oscuras, siempre habrá mejora del color en todas las imágenes usando cualquier algoritmo. Lo anterior, independientemente si el algoritmo elegido tiene la mejor estimación del iluminante o no.

Se ha diseñado el sistema experto utilizando conjuntos difusos de tipo triangular y de tipo Gaussiano. Siendo estos últimos los que proporcionan mucho mayor desempeño al sistema. El motivo por el cual el desempeño es menor al utilizar conjuntos de tipo triangular, se debe precisamente a la complejidad del problema. Es decir, los conjuntos triangulares acotan con límites fijos la evaluación de una característica en la premisa. Y por esta razón, existe mucha probabilidad en nuestro problema, de que resulte cero este nivel de pertenencia. Sin embargo, los conjuntos Gaussianos garantizan un grado de pertenencia por mínimo que sea, dándole flexibilidad al sistema de tener información para la elección.

Podemos concluir que nuestro sistema propuesto ha obtenido los mejores resultados comparándolo con otras metodologías comúnmente usadas en clasificación. La tasa de clasificación máxima conseguida ha sido del 78 %, esto utilizando conjuntos difusos de tipo Gaussiano y una inferencia difusa producto de Larsen.

Por otra parte, los tiempos medidos se encuentran en milisegundos y se han registrado para tres tamaños de imágenes diferentes. La rutina mas costosa computacionalmente, ha sido la que calcula el espectro de potencia. De no ser por el tiempo consumido en el cálculo del espectro de potencia, podríamos concluir que el sistema se puede considerar para aplicaciones en tiempo real.

## Conclusiones de los estudios en paralelo

El WPR es un algoritmo que depende del máximo valor de intensidad en cada componente de color. En el primer estudio, el WPR ha sido aplicado en el espacio de color CIELab, en el RGB, y en ambos de manera secuencial. Una medida de calidad ha sido obtenida para cada imagen resultante, para comparar las salidas de cada enfoque. De acuerdo a la métrica, el APSV, adecuadamente se asemeja a nuestra apreciación cualitativa de la calidad en la imagen. Se ha encontrado que el rendimiento del WPR en CIELab es peor que en RGB, pero cuando los ajustes de color se aplican en secuencia, primero en CIELab y luego en RGB, mucho mejores resultados son obtenidos.

Una meta paralela de la aplicación de algoritmos de constancia de color es el mejorar la imagen, independientemente del iluminante removido. De acuerdo al segundo estudio, los enfoques usando el algoritmo WPR, así como el GW, incrementan la calidad de la imagen en gran medida. Se ha visto que la corrección gama ilumina áreas oscuras en la imagen, permitiendo una mayor claridad de los colores. La corrección gama es principalmente usada en aplicaciones prácticas que requieren una corrección del rango dinámico, un efecto que también produce la constancia de color. A pesar del mejoramiento de la imagen producido por un solo algoritmo, la aplicación combinada de un algoritmo de constancia de color y posteriormente la corrección gama, proporciona mejores resultados. Finalmente, de acuerdo a este estudio, se sugiere el uso de la corrección gama después de un algoritmo de constancia de color para el mejoramiento de imágenes oscuras. Tal mejora puede ser útil en un gran número de tareas de visión por computadora y procesamiento de imágenes.

## Perspectivas

Es importante mencionar, que el proyecto no concluye en esta tesis. Se tiene contemplado elaborar un artículo de investigación y someterlo a una revista indizada con alto factor de impacto. Esto, durante el periodo de los 6 meses próximos.

Por otro lado, este proyecto puede orientarse por varios caminos. Podría extenderse a la mejora de imágenes con iluminación natural, algunas bases de datos con estas características se encuentran en [Martin2001] [Ciurea2003] [Bianco2008]. Otro camino por el cual podría extenderse el proyecto, consiste en el diseño del sistema excluyendo el APSV como característica y enfocarlo a aplicaciones en tiempo real. Por último, la orientación del problema también podría ser cambiada. Especialmente para resolver ahora si, el problema de la constancia de color (estimación del iluminante). Este problema también fue abordado, sin embargo, el problema es más complejo ya que existe mucho más traslape en las características.



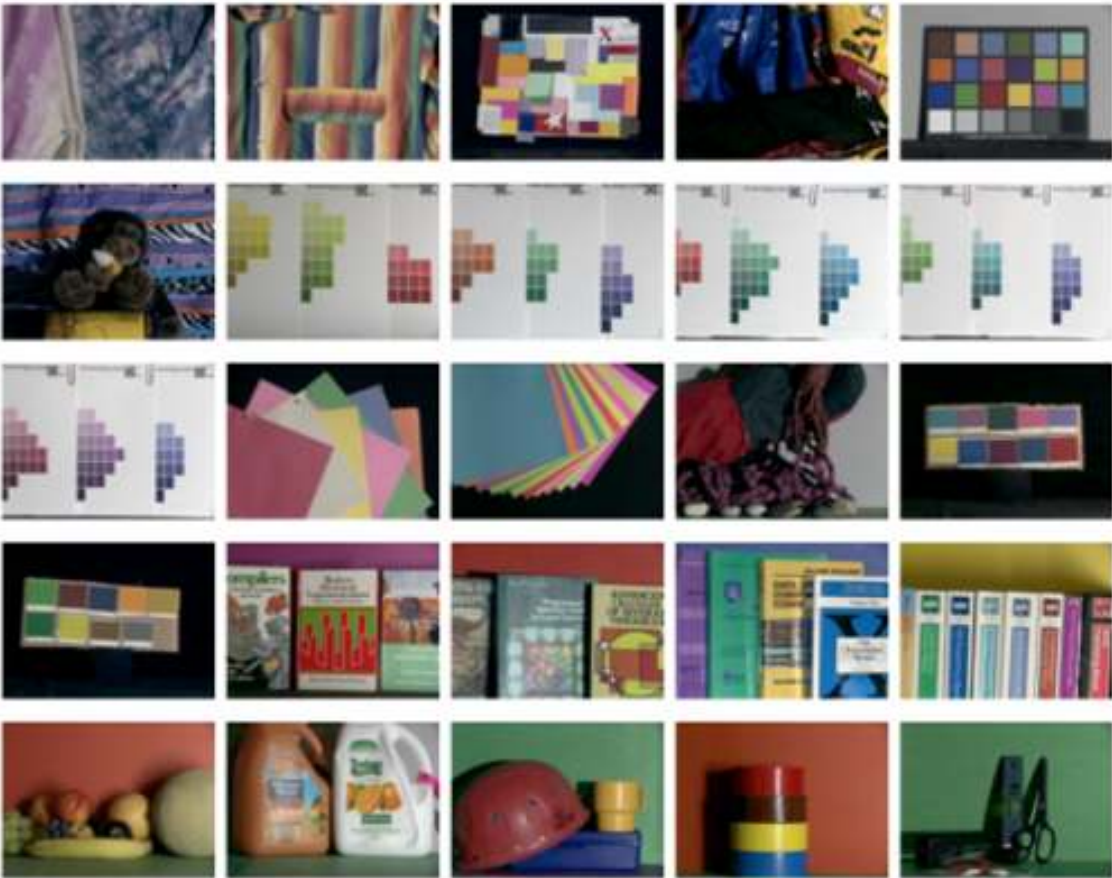
## Productos de investigación

A lo largo del proyecto se efectuaron estudios en paralelo que concluyeron en tres productos de investigación. A continuación se presenta la cita de cada uno:

- J. Cepeda-Negrete and R.E. Sanchez-Yanez, "*Color Constancy Algorithms in Practice*", Proceedings of the Robotics Summer Meeting (ROSSUM), pag. 78-79, Xalapa Veracruz, Jun. 2011.
- J. Cepeda-Negrete and R.E. Sanchez-Yanez, "*Experiments on the White Patch Retinex in RGB and CIELAB color spaces*", Acta Universitaria, 22(NE-1), pag. 21-26, 2012.
- J. Cepeda-Negrete and R.E. Sanchez-Yanez, "*Combining Color Constancy and Gamma Correction for Image Enhancement*", 2012 IEEE Electronics, Robotics and Automotive Mechanics Conference (CERMA), pag. 25-30, Cuernavaca Morelos, Nov. 2012.

Además, se cuenta con un artículo aún no publicado. El estudio realizado en este artículo consiste en la estimación del iluminante en espacios de color perceptuales y será sometido en congreso internacional.





# Bibliografía

---

- [Agarwal2006] V. Agarwal, B. R. Abidi, A. Koshan, and M. A. Abidi. An overview of color constancy algorithms. *J. Pattern Recogn. Res.*, 1:42–54, 2006.
- [BT.601] ITU-R Rec. BT. 601. Encoding parameters of digital television for studios. Technical report, ITU, Geneva, Switerland, 1995.
- [Barnard2002] K. Barnard, L. Martin, B. Funt, and A. Coath. A data set for color research. *Color research and applications*, 27(3):148–152, 2002.
- [Barnard2002b] K. Barnard, L. Martin, A. Coath, and B. Funt. A comparison of computational color constancy algorithms - Part II: Experiments on image data. *IEEE Trans. Image Process.*, 11(9):985–986, 2002.
- [Bernard1988] J.A. Bernard. Use of a rule-based system for process control. *IEEE Control Systems Magazine*, 8(5):3–13, 1988.
- [Bianco2008] S. Bianco, G. Ciocca, C. Cusano, and R. Schettini. Improving color constancy using indoor-outdoor image classification. *IEEE Trans. Image Process.*, 17(12):2381–2392, 2008.
- [Bianco2010] S. Bianco, G. Ciocca, C. Cusano, and R. Schettini. Automatic color constancy algorithm selection and combination. *Pattern Recognition*, 43(3):695–705, 2010.
- [Brainard1997] D. H. Brainard and W. T. Freeman. Bayesian color constancy. *J. Opt. Soc. Am. A*, 14(7):1393–1411, 1997.
- [Buchsbaum1980] G. Buchsbaum. A spatial processor model for object colour perception. *Journal of The Franklin Institute*, 310:1–26, 1980.
- [Cepeda2011] J. Cepeda-Negrete. *Modelado de Sistemas Difusos de múltiples entradas y salidas*. Universidad de Guanajuato, Salamanca, Gto., 2011.

## BIBLIOGRAFÍA

---

- [Cepeda2012a] J. Cepeda-Negrete and R. E. Sanchez-Yanez. Experiments on the white patch retinex in RGB and CIELAB color spaces. *Acta Universitaria*, 22(NE-1):21–26, 2012.
- [Cepeda2012b] J. Cepeda-Negrete and R. E. Sanchez-Yanez. Combining color constancy and gamma correction for image enhancement. In *IEEE Conference on Electronics, Robotics and Automotive Mechanics (CERMA)*, pages 1–6, 2012.
- [Chang1996] Y.C Chang and J.F. Reid. RGB calibration for color image analysis in machine vision. *IEEE Trans. Image Process.*, 5(10):1414–1422, 1996.
- [Ciurea2003] F. Ciurea and B. Funt. A large image database for color constancy research. In Scottsdale, editor, *Proceedings of the Imaging Science and Technology Eleventh Color Imaging Conference*, pages 160–164, 2003.
- [Cordon1999] O. Cordon, M. J. del Jesus, and F. Herrera. A proposal on reasoning methods in fuzzy rule-based classification systems. *Inter. J. Approx. Reasoning*, 20(1):21–45, 1999.
- [Correa-Tome2009] F. E. Correa-Tome. *Segmentación de Imágenes Naturales en Espacios de Color Perceptuales*. Universidad de Guanajuato, Salamanca, Gto., 2009.
- [Correa-Tome2011] F. E. Correa-Tome, R. E. Sanchez-Yanez, and V. Ayala-Ramirez. Comparison of perceptual color spaces for natural image segmentation tasks. *Opt. Eng.*, 50:117203, 2011.
- [D’Zmura1995] M. D’Zmura, G. Iverson, and B. Singer. Probabilistic color constancy. *Geometric Representations of Perceptual Phenomena*, pages 187–202, 1995.
- [Ebner2004] M. Ebner. A parallel algorithm for color constancy. *J. Parallel Distrib. Comput.*, 64:79–88, 2004.
- [Ebner2006] M. Ebner. Evolving color constancy. *Pattern Recognition Letters*, 27(11):1220–1229, 2006.
- [Ebner2007] M. Ebner. *Color Constancy*. Wiley Publishing, Würzburg, Germany, 1st edition, 2007.
- [Ebner2009] M. Ebner. Color constancy based on local space average color. *Machine Vision and Applications*, 20:283–301, 2009.
- [Elizarraras2011] S. Elizarraras-Montenegro. *Sistema de selección automática de algoritmos en constancia de color*. Universidad de Guanajuato, Salamanca, Gto., 2011.

## BIBLIOGRAFÍA

---

- [Eskicioglu1995] A.M. Eskicioglu and P.S. Fisher. Image quality measures and their performance. *IEEE Trans. Communications*, 43(12):2959–2965, 1995.
- [Fairchild1993] M. D. Fairchild. Rlab: a color appearance space for color reproduction. *Proc. SPIE*, 1909:19–29, 1993.
- [Fairchild1996] M. D. Fairchild. Refinement of the rlab color space. *Color Res. Appl.*, 21:338–346, 1996.
- [Fairchild2005] M.D. Fairchild. *Color Appearance Models*. Wiley, Hoboken, 2 edition, 2005.
- [Faugeras1979] O. Faugeras. Digital color image processing within the framework of a human visual model. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 27(4):380 – 393, 1979.
- [Finlayson1994] G. D. Finlayson, Drew M. S., and B. Funt. Spectral sharpening: sensor transformations for improved color constancy. *J. Opt. Soc. Am. A*, 11(5):1553–1563, 1994.
- [Finlayson2001] G. D. Finlayson, S. D. Hordley, and P. M. Hubel. Color by correlation: A simple, unifying framework for color constancy. *IEEE Trans. Pattern Anal. Mach. Intell.*, 23(11):1209–1221, 2001.
- [Finlayson2004] G. D. Finlayson and E. Trezzi. Shades of gray and colour constancy. In *Color Imaging Conference*, 2004.
- [Finlayson2006a] G. D. Finlayson, S. D. Hordley, and I. Tastl. Gamut constrained illuminant estimation. *Inter.l J. Comput. Vision*, 67:93–109, 2006.
- [Finlayson2006b] G. D. Finlayson, S. D. Hordley, C. Lu, and M. S. Drew. On the removal shadows from images. *IEEE Trans. Pattern Anal. Mach. Intell.*, 28(1):59–68, 2006.
- [Foley1996] J. Foley, A. van Dam, S. Feiner, and J. Hughes. *Computer Graphics: Principles and Practice*. Addison-Wesley Professional, 2 edition, 1990.
- [Forsyth1990] D. A. Forsyth. A novel algorithm for color constancy. *Int. J. Comput. Vision*, 5(1):5–36, 1990.
- [Funt2000] B. Funt and B. C. Lewis. Diagonal versus affine transformations for color correction. *J. Opt. Soc. Am. A*, 17(11):2108–2112, 2000.
- [Gasparini2004] F. Gasparini and R. Schettini. Color balancing of digital photos using simple image statistics. *Pattern Recognition*, 37(6):1201 – 1217, 2004.

## BIBLIOGRAFÍA

---

- [Gijssenij2010] A. Gijssenij, T. Gevers, and J. van de Weijer. Generalized gamut mapping using image derivative structures for color constancy. *Int. J. of Computer Vision*, 86(2):127–139, 2010.
- [Gijssenij2011] A. Gijssenij, T. Gevers, and J. van de Weijer. Computational color constancy: Survey and experiments. *IEEE Trans. Image Process.*, 20(9):2475–2489, 2011.
- [Haralick1973] R. M. Haralick, K. Shanmugam, and I. Dinstein. Textural features for image classification. *IEEE Trans. On Sys. Man and Cyber.*, 3(6):610–621, 1973.
- [Hordley2004] S. D. Hordley and G. D. Finlayson. Re-evaluating colour constancy algorithms. In *Proceedings of the Pattern Recognition, 17th International Conference on (ICPR'04)*, pages 76–79, 2004.
- [Horn1974] B. Horn. Determining lightness from an image. *Computer Graphics and Image Processing*, 3(4), 1974.
- [Ishibuchi2004] Hisao Ishibuchi, Tomoharu Nakashima, and Manabu Nii. *Classification and Modeling with Linguistic Information Granules*. Springer-Verlag, Secaucus, NJ, USA, 2004.
- [Lam1985] K.M Lam. *Metamerism and colour constancy*. PhD thesis, University of Bradford, 1985.
- [Land1962] E. H. Land and N. W. Daw. Binocular combination of projected images. *Science*, 138(3540):589–590, 1962.
- [Land1971] E. H. Land and J. J. McCann. Lightness and retinex theory. *J. Opt. Soc. Am.*, 61(1):1–11, 1971.
- [Land1977] E. H. Land. The retinex theory of color vision. *Scientific American*, 237(6):108–128, 1977.
- [Mamdani1976] E.H. Mamdani. Advances in the linguistic synthesis of fuzzy controllers. *Inter. J. of Man Mach. Stud.*, 8(6):669–678, 1976.
- [Martin2001] D. Martin, C. Fowlkes, D. Tal, and J. Malik. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics. In *Proc. 8th Int'l Conf. Computer Vision*, volume 2, pages 416–423, 2001.
- [Moroney2002] N. Moroney, M.D. Fairchild, R. Hunt, C. Li, M. R. Luo, and T. Newman. The ciecam02 color appearance model. In *IS&T/SID 10th Color Imaging Conference*, pages 23–27, 2002.

## BIBLIOGRAFÍA

---

- [Nachlieli2011] H. Nachlieli and D. Shaked. Measuring the quality of quality measures. *IEEE Trans. Image Process.*, 20(1):76–87, 2011.
- [Poynton2003] C. Poynton. *Digital Video and HDTV Algorithms and Interfaces*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 1 edition, 2003.
- [Schroeder2001] M. Schroeder and S. Moser. Automatic color correction based on generic content-based image analysis. In *Color Imaging Conference'01*, pages 41–45, 2001.
- [Scott2009] J. Scott and M. Pusateri. Towards real-time hardware gamma correction for dynamic contrast enhancement. In *Applied Imagery Pattern Recognition Workshop (AIPRW), 2009 IEEE*, pages 1–5, 2009.
- [Shanda2007] J. Schanda. *Colorimetry: Understanding the CIE System*. John Wiley, 2007.
- [Sheikh2005] H.R. Sheikh, A.C. Bovik, and L. Cormack.
- [Sheikh2006a] H.R. Sheikh and A.C. Bovik. Image information and visual quality. *IEEE Trans. Image Process.*, 15(2):430–444, 2006.
- [Sheikh2006b] H.R. Sheikh, M.F. Sabir, and A.C. Bovik. A statistical evaluation of recent full reference image quality assessment algorithms. *IEEE Trans. Image Process.*, 15(11):3440–3451, 2006.
- [Stockham1972] T.G. Jr. Stockham. Image processing in the context of a visual model. *Proceedings of the IEEE*, 60(7):828–842, 1972.
- [Stokes1996] M. Stokes, M. Anderson, S. Chandrasekar, and R. Motta. A standard default color space for the internet - sRGB. Technical report, Hewlett-Packard, Microsoft, 1996.
- [Tsagaris2005] V. Tsagaris, G. Ghirstoulas, and V. Anastassopoulos. A measure for evaluation of the information content in color images. In *IEEE Inter. Conf. Imag. Process.*, volume 1, pages 417–20, 2005.
- [Unser1986] M. Unser. Sum and difference histograms for texture classification. *IEEE Trans. Pattern Anal. Mach. Intell.*, 8(1):118–125, 1986.
- [Vadiee1993] N. Vadiee. *Fuzzy Logic and control: Software and hardware applications*, chapter 4. Prentice Hall, Englewood, Cliffla, N.J., 1993.
- [VonKries1970] J. Von Kries. *Sources of Color Vision*, chapter Influence of adaptation on the effects produced by luminous stimuli Vision, pages 109–119. MIT Press, 1970.



## BIBLIOGRAFÍA

---

- [Weber1846] E. H. Weber. Der tastinn und das gemeingföhl. *Handwörterbüch der Physiologie*, 3:481–588, 1846.
- [Weijer2007a] J. van de Weijer, T. Gevers, and A. Gijsenij. Edge-based color constancy. *IEEE Trans. Image Process.*, 16(9):2207–2214, 2007.
- [Weijer2007b] J. van de Weijer, C. Schmid, and J. Verbeek. Using high-level visual information for color constancy. In *Proceedings of the International Conference on Computer Vision*, pages 1–8, 2007.
- [West1982] G. West and M. H. Brill. Necessary and sufficient conditions for von kries chromatic adaptation to give color constancy. *Journal of Mathematical Biology*, 15:249–258, 1982.
- [Yan2006] Yan Ke, Xiaoou Tang, and Feng Jing. The design of high-level features for photo quality assessment. In *IEEE Conference on Computer Vision and Pattern Recognition*, volume 1, pages 419–426, 2006.
- [Yan2011] Yan Zhang, Ping An, Qiuwen Zhang, Liquan Shen, and Zhaoyang Zhang. A no-reference image quality evaluation based on power spectrum. In *3DTV Conference: The True Vision - Capture, Transmission and Display of 3D Video (3DTV-CON)*, pages 1–4, 2011.
- [Yang1998] J. Yang, R. Stiefelhagen, U. Meier, and A. Waibel. Visual tracking for multimodal human computer interaction. In *Proc. of the Conference on Human factors in computing systems*, pages 140–147, 1998.
- [Yuan2011] Yuan Cao and A. Bermak. An analog gamma correction method for high dynamic range applications. In *SOC Conference (SOCC), 2011 IEEE International*, pages 318–322, 2011.
- [Zadeh1965] L. A. Zadeh. Fuzzy sets. *Information and Control*, 8:338–353, 1965.
- [Zadeh1973] L. A. Zadeh. Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Trans. on Sys. Man, and Cyber.*, 3(1):28–44, 1973.
- [Zeki1993] Semir Z. *A vision of the brain*. Wiley-Blackwell, January 15, 1993.