

Trabajo Fin de Grado.  
Grado en Ingeniería de las Tecnologías de  
Telecomunicación.

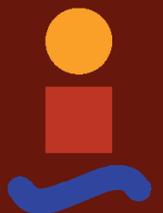
Segmentación automática de la excavación en  
retinografías basada en gradientes de color y  
clasificador Complex Tree

Autora: Ana Isabel García Noguer

Tutora: Irene Fondón García

**Dep. Teoría de la Señal y Comunicaciones**  
**Escuela Técnica Superior de Ingeniería**  
**Universidad de Sevilla**

Sevilla, 2015





Trabajo Fin de Grado  
Grado en Ingeniería de las Tecnologías de Telecomunicación

# Segmentación automática de la excavación en retinografías basada en gradientes de color y clasificador Complex Tree

Autora:

Ana Isabel García Noguera

Tutora:

Irene Fondón García,  
Profesora Contratada Doctora

Departamento de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2015



# **Trabajo Fin de Grado: Segmentación automática de la excavación en retinografías basada en gradientes de color y clasificador Complex Tree**

Autora: Ana Isabel García Noguer

Tutora: Irene Fondón García

El tribunal nombrado para juzgar el Trabajo Fin de Grado arriba indicado, compuesto por los siguientes miembros:

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2015

El Secretario del Tribunal



# AGRADECIMIENTOS

---

En primer lugar, agradecer a mi tutora Irene, y a Uxi, porque gracias a sus indicaciones y a su apoyo diario, he reunido fuerzas para alcanzar los objetivos para que este proyecto sea posible.

A mis compañeros y compañeras, con los que he compartido todos estos años. Habéis sido una parte muy importante de esta experiencia ya que juntos hemos reído, llorado, hemos compartido apuntes, conocimientos, hemos celebrado los éxitos, y sobre todo, hemos creado unos lazos de amistad muy grandes. Gracias a Adri, Sergio, Marina, Miguel Nájera, Arturo, Javi, Kike, Antonio Morillo, Antonio Martínez, Natalia, Rocío y Mounir. Gracias, en especial, a Carlos, por tu cariño, tu apoyo incondicional y por haber estado conmigo siempre y sobre todo, estos últimos meses. Gracias a todos los que no nombro, sois muchos más.

A mis amigas y amigos, Clara R, Clara M, Javi, Miguel, César, Christian y Juanra. Ellos fueron mis compañeros y compañeras de instituto, y ahora somos grandes amigos. Han estado conmigo siempre que lo he necesitado y me han apoyado siempre. Gracias por todo.

Por supuesto, agradecer este trabajo a ellas, a mis amigas de la infancia, las que siempre están pase lo que pase, las que no fallan nunca. Juntas hemos recorrido este camino. Vosotras también sois parte de él. A Geno, Yayo y Reyes. Gracias.

Finalmente, a mi madre, a mi padre y a mi hermano. Habéis sido el pilar fundamental sobre el que apoyarme durante esta etapa. De no ser por vuestro cariño, vuestro ánimo y vuestros consejos, tampoco habría sido posible. Gracias, de corazón, por darme la gran oportunidad de estudiar esta carrera y hacer de mí la persona que soy hoy.

*Ana Isabel García Noguera  
Sevilla, 2015*



<b>Agradecimientos</b> .....	<b>7</b>
<b>Índice</b> .....	<b>9</b>
<b>Índice de Tablas</b> .....	<b>11</b>
<b>Índice de Figuras</b> .....	<b>13</b>
<b>Resumen</b> .....	<b>15</b>
<b>1 Objetivo</b> .....	<b>17</b>
<b>2 Acercamiento al problema</b> .....	<b>19</b>
2.1. <i>El Sistema Visual Humano (SVH)</i> .....	19
2.2. <i>El Glaucoma</i> .....	21
2.2.1. ¿Por qué se produce el glaucoma?.....	21
2.2.2. El nervio óptico.....	22
2.2.3. ¿Qué medidas se emplean para su diagnóstico? .....	22
2.3. <i>La Retinografía</i> .....	24
<b>3 Estado del Arte</b> .....	<b>25</b>
<b>4 Espacios de Color</b> .....	<b>29</b>
4.1. <i>Introducción</i> .....	29
4.1.1. Luz y Color.....	29
4.1.2. Sensores de luz en el ojo: conos y bastones. ....	29
4.1.3. La percepción del color.....	30
4.1.4. Características del color.....	32
4.2. <i>Espacios de color</i> .....	34
4.2.1. Colorimetría.....	34
4.2.2. La Comisión Internacional de la Iluminación .....	34
4.2.3. El Observador Patrón CIE (1931). El espacio 1931 CIE RGB .....	35
4.2.4. Espacio 1931 CIE XYZ .....	38
4.2.5. Escala Uniforme UCS 1960 .....	41
4.2.6. Espacio $U^*V^*W^*$ .....	43
4.2.7. Espacio CIE LUV .....	43
4.2.8. Espacio CIE LAB.....	45
4.2.9. Familia HSL.....	46
4.2.10. Espacio de color CIECAM 02.....	49
4.2.11. Resumen de espacios de color.....	50
4.3. <i>Distancias de color</i> .....	50
<b>5. Clasificadores</b> .....	<b>55</b>
5.1. <i>K-Nearest Neighbor</i> .....	55
5.2. <i>Redes Neuronales</i> .....	58
5.3. <i>Support Vector Machine (SVM)</i> .....	59
5.4. <i>Árboles de decisión</i> .....	62

<b>6. Algoritmo Implementado .....</b>	<b>65</b>
6.1. Selección de imágenes de retinografías .....	67
6.1. Pre-procesado .....	75
6.2. Extracción de características .....	83
6.3. Entrenamiento.....	84
6.4. Clasificación.....	88
6.5. Post-Procesado.....	89
<b>7. Resultados .....</b>	<b>93</b>
7.1. Resultado del entrenamiento.....	95
7.2. Resultado de la clasificación.....	103
7.3. Estudio comparativo .....	115
<b>8. Conclusiones y Líneas futuras .....</b>	<b>121</b>
<b>9. Referencias .....</b>	<b>123</b>
<b>10. Anexo I: ROI de Imágenes Originales .....</b>	<b>127</b>
<b>11 Anexo II: ROI de imágenes resultado comparadas con la verdad de referencia .....</b>	<b>137</b>

# ÍNDICE DE TABLAS

---

TABLA 1. RESUMEN ESPACIOS DE COLOR.....	50
TABLA 2. CONDICIONES DE REFERENCIA ADOPTADAS EN CIE94.....	53
TABLA 3. RESUMEN DISTANCIAS DE COLOR.....	53
TABLA 4. RESUMEN DE LAS BASES DE DATOS ESCOGIDAS.....	70
TABLA 5. MATRIZ DE CONFUSIÓN SVM LINEAR.....	95
TABLA 6. MATRIZ DE CONFUSIÓN SVM CUADRÁTICO.....	96
TABLA 7. MATRIZ DE CONFUSIÓN SVM CÚBICO.....	96
TABLA 8. MATRIZ DE CONFUSIÓN KNN FINE.....	97
TABLA 9. MATRIZ DE CONFUSIÓN KNN MEDIUM.....	97
TABLA 10. MATRIZ DE CONFUSIÓN COMPLEZ TREE.....	98
TABLA 11. MATRIZ DE CONFUSIÓN MEDIUM TREE.....	98
TABLA 12. MATRIZ DE CONFUSIÓN SIMPLE TREE.....	99
TABLA 13. MATRIZ DE CONFUSIÓN TREE BAGGER.....	99
TABLA 14. MATRIZ DE CONFUSIÓN ADABOOST TREE.....	100
TABLA 15. CURVA ROC PARA LA CLASE 1.....	101
TABLA 16. CURVA ROC DE LA CLASE 2.....	102
TABLA 17. CURVA ROC PARA LA CLASE 3.....	102
TABLA 18. TABLA COMPARATIVA ENTRE JCH Y LAB.....	119



# ÍNDICE DE FIGURAS

## Capítulo 2. Acercamiento al problema

FIGURA 2.1: ESTRUCTURA DEL OJO HUMANO [3] .....	20
FIGURA 2.2. ESQUEMA DEL AUMENTO DE LA PIO [4] .....	21
FIGURA 2.3. REPRESENTACIÓN DE LA ESTRUCTURA DE LA RETINA [7] .....	22
FIGURA 2.4. EXCAVACIÓN PAPILAR [4].....	23
FIGURA 2.5. RETINOGRAFÍA DETALLADA [4].....	24

## Capítulo 4. Espacios de Color

FIGURA 4. 1. ESPECTRO ELECTROMAGNÉTICO Y FRANJA VISIBLE [20] .....	29
FIGURA 4. 2. RELACIÓN ENTRE LA RESPUESTA DE CONOS Y BASTONES EN LA RETINA Y $\Lambda$ . .....	30
FIGURA 4. 3. MECANISMO DE FORMACIÓN DE UNA IMAGEN EN LA RETINA [24]. .....	31
FIGURA 4. 4. EJEMPLO DE DALTONISMO .....	32
FIGURA 4. 5. DIFERENCIAS DE TONO O MATIZ. ....	32
FIGURA 4. 6. DIFERENCIAS DE LUMINANCIA (%). ....	33
FIGURA 4. 7. DIFERENCIAS DE SATURACIÓN (%) .....	33
FIGURA 4. 8. EXPERIMENTO DE CORRESPONDENCIA DE COLORES MEDIANTE MEZCLA ADITIVA. [26] .....	35
FIGURA 4. 9. LO QUE VE EL OBSERVADOR, DURANTE EL EXPERIMENTO CIE 1931 [26]. ....	36
FIGURA 4. 10. FUNCIONES DE IGUALACIÓN DE COLOR [29] .....	37
FIGURA 4. 11. COLORES EN EL SISTEMA RGB [26].....	38
FIGURA 4. 12. NUEVAS FUNCIONES DE IGUALACIÓN DE COLOR (TODOS LOS COEFICIENTES POSITIVOS) [26].....	39
FIGURA 4. 13. EFICIENCIA LUMINOSA ESPECTRAL. [26].....	40
FIGURA 4. 14. AUMENTO DEL ÁNGULO VISUAL PARA EL EXPERIMENTO DEL OBSERVADOR CIE 1964. [26] .....	41
FIGURA 4. 15. CIE 1960 DIAGRAMA DE CROMATICIDAD UCS [31] .....	42
FIGURA 4. 16. COORDENADAS CARTESIANAS Y CILÍNDRICAS DEL ESPACIO DE COLOR CIE LAB [30].....	45
FIGURA 4. 17. BICONO DEL MODELO HSL [34] .....	47
FIGURA 4. 18. ESPACIO HSI Y PLANO TONO-SATURACIÓN PARA EL MÁXIMO DE INTENSIDAD. ....	48
FIGURA 4. 19. ESPACIO DE COLOR CIECAM 02 .....	49
FIGURA 4. 20. ESQUEMÁTICO MODELO CIECAM 02.....	49

## Capítulo 5. Clasificadores

FIGURA 5. 1. EJEMPLO ESPACIO DE MUESTRAS K-NN [39] .....	56
FIGURA 5. 2. RED NEURONAL. [40].....	58
FIGURA 5. 3. HIPERPLANO Y MARGEN CASO 2D [43]. ....	60
FIGURA 5. 4. ÁRBOL DE DECISIÓN. ¿OFERTAR PRODUCTO AL CLIENTE? [40].....	62

## Capítulo 6. El Algoritmo Implementado

FIGURA 6. 1. ESQUEMA GENERAL DEL ALGORITMO DEL CLASIFICADOR.....	65
FIGURA 6. 2. RETINOGRAFÍA DE ERLANGEN DATABASE (I) .....	71
FIGURA 6. 3. RETINOGRAFÍA DE ERLANGEN DATABASE (II) .....	71
FIGURA 6. 4. RETINOGRAFÍA DE ARIA DATASET (I).....	71
FIGURA 6. 5. RETINOGRAFÍA DE ARIA DATASET (II). EXCAVACIÓN DIFUSO. ....	72
FIGURA 6. 6. RETINOGRAFÍA DE STARE DATABASE (I). EXCAVACIÓN DIFERENCIABLE. ....	72
FIGURA 6. 7. RETINOGRAFÍA DE STARE DATABASE (II). EXCAVACIÓN DIFERENCIABLE. ....	72
FIGURA 6. 8. RETINOGRAFÍA DE MEDISSOR DATABASE (I).....	73

FIGURA 6. 9. RETINOGRAFÍA DE MEDISSOR DATABASE (II).....	73
FIGURA 6. 10. RETINOGRAFÍA DE DRIVE DATABASE (I). EXCAVACIÓN DIFERENCIABLE.....	73
FIGURA 6. 11. RETINOGRAFÍA DE DRIVE DATABASE (II).....	74
FIGURA 6. 12. RETINOGRAFÍA DE DMED (I). EXCAVACIÓN DIFUSO.....	74
FIGURA 6. 13. RETINOGRAFÍA DE DMED (II). EXCAVACIÓN DIFUSO.....	74
FIGURA 6. 14. RETINOGRAFÍA DE STARE DATABASE (III).....	75
FIGURA 6. 15. ESQUEMA PRE-PROCESADO.....	75
FIGURA 6. 16. ESQUEMA VERDAD REFERENCIA.....	75
FIGURA 6. 17. SELECCIÓN DE LA ROI SOBRE LA RETINOGRAFÍA.....	76
FIGURA 6. 18. RESULTADO DEL RECORTE DE LA ROI.....	76
FIGURA 6. 19. ROI ORIGINAL.....	78
FIGURA 6. 20. M ( $\Theta=0^\circ$ ).....	78
FIGURA 6. 21. M ( $\Theta=15^\circ$ ).....	78
FIGURA 6. 22. M ( $\Theta=30^\circ$ ).....	78
FIGURA 6. 23. M ( $\Theta=45^\circ$ ).....	79
FIGURA 6. 24. M ( $\Theta=60^\circ$ ).....	79
FIGURA 6. 25. M ( $\Theta=75^\circ$ ).....	79
FIGURA 6. 26. M ( $\Theta=90^\circ$ ).....	79
FIGURA 6. 27. M ( $\Theta=105^\circ$ ).....	79
FIGURA 6. 28. M ( $\Theta=120^\circ$ ).....	79
FIGURA 6. 29. M ( $\Theta=135^\circ$ ).....	79
FIGURA 6. 30. M ( $\Theta=150^\circ$ ).....	79
FIGURA 6. 31. M ( $\Theta=165^\circ$ ).....	80
FIGURA 6. 32. M ( $\Theta=180^\circ$ ).....	80
FIGURA 6. 33. M ( $\Theta=195^\circ$ ).....	80
FIGURA 6. 34. M ( $\Theta=210^\circ$ ).....	80
FIGURA 6. 35. M ( $\Theta=225^\circ$ ).....	80
FIGURA 6. 36. M ( $\Theta=240^\circ$ ).....	80
FIGURA 6. 37. M ( $\Theta=255^\circ$ ).....	80
FIGURA 6. 38. M ( $\Theta=270^\circ$ ).....	80
FIGURA 6. 39. M ( $\Theta=285^\circ$ ).....	81
FIGURA 6. 40. M ( $\Theta=300^\circ$ ).....	81
FIGURA 6. 41. M ( $\Theta=315^\circ$ ).....	81
FIGURA 6. 42. M ( $\Theta=330^\circ$ ).....	81
FIGURA 6. 43. M ( $\Theta=345^\circ$ ).....	81
FIGURA 6. 44. M ( $\Theta=360^\circ$ ).....	81
FIGURA 6. 45. CONSTRUCCIÓN VERDAD DE REFERENCIA.....	82
FIGURA 6. 46. ESTRUCTURA DE LA MATRIZ DE CARACTERÍSTICAS.....	84
FIGURA 6. 47. "L".....	86
FIGURA 6. 48. "A".....	86
FIGURA 6. 49. "B".....	86
FIGURA 6. 50. MÓDULO GRADIENTE.....	86
FIGURA 6. 51. MÓDULO GRADIENTE.....	87
FIGURA 6. 52. VERDAD DE REFERENCIA.....	87
FIGURA 6. 53. VISIÓN GENERAL DEL POST-PROCESADO.....	89
FIGURA 6. 54. NUBE DE PUNTOS RESULTADO DE CLASIFICACIÓN (A) Y CORRECCIÓN (B).....	90
FIGURA 6. 55. RESULTADOS POST-PROCESADO.....	91

## Capítulo 7. Resultados

FIGURA 7. 1. MODELO TABLA DE CONFUSIÓN.....	93
---	----

En este proyecto se presenta un algoritmo automático de segmentación de la excavación del nervio óptico en retinografías basada en gradientes de color. La utilidad principal es servir como herramienta para la detección de la retinopatía conocida como glaucoma o “ceguera silenciosa”.

El método que se presenta está basado en el artículo [1], que utiliza gradientes de color como característica fundamental para su aplicación al área de la excavación, zona de especial dificultad por presentar gran variedad de tamaños, tonalidades, así como un borde que, a menudo, puede ser difuso. La novedad que presenta este trabajo es que lo que se pretende detectar esta vez es la excavación, en lugar del disco óptico. Como segunda novedad, para realizar la clasificación se hace uso del clasificador Complex Tree (un solo árbol de decisión).

Las imágenes que se han utilizado como entrada del algoritmo han sido extraídas de 6 bases de datos públicas, haciendo una selección de 30 imágenes para el entrenamiento del clasificador y 50 imágenes para realizar las pruebas y verificar la calidad del mismo.

Para cuantificar la sensibilidad y la robustez del método propuesto se han realizado cálculos estadísticos, teniendo como verdad de referencia la detección de la excavación.



# 1 OBJETIVO

---

El objetivo de este Trabajo Fin de Grado es encontrar un algoritmo automático de segmentación de la excavación del nervio óptico en retinografías, adaptado a la percepción humana del color.

Es importante conseguir que este diagnóstico pueda hacerse mediante algoritmos automáticos, ya que se pretende que la intervención humana sea mínima. Esto agiliza, consecuentemente, la detección y curación de este tipo de patologías.

El algoritmo debe emular el diagnóstico hecho por un médico experto y, por tanto, la información de color debe estar correlacionada con la percepción humana de los colores y las diferencias entre ellos.

Se ha elegido, entre las posibles, la segmentación de la excavación circular, debido a que el posterior cálculo del CDR se realiza por comparación entre el diámetro de la excavación y el diámetro total del disco óptico.



## 2 ACERCAMIENTO AL PROBLEMA

---

### 2.1. El Sistema Visual Humano (SVH)

El Sistema Visual Humano (SVH) es el responsable de convertir las ondas electromagnéticas, que pertenecen al espectro visible y que son percibidas por los ojos, en señales nerviosas que son interpretadas por el cerebro [2].

El ojo humano es una estructura prácticamente esférica en la que entra la luz sólo por un pequeño agujero, que es la pupila. La cubierta externa del ojo es opaca y el interior del ojo es translúcido.

La cubierta del ojo está compuesta por dos membranas, que son la esclerótida y la coroides. La esclerótida es la membrana más externa del ojo. Es opaca, salvo en la parte anterior, que es transparente y se llama córnea. La coroides se trata de una membrana, que se encuentra a continuación de la esclerótida, pigmentada y vascularizada, que recubre prácticamente todo el ojo.

En su parte anterior se encuentran el iris, que es una expansión muscular, y la pupila, que es una abertura redonda por la que entra la luz en el ojo. La función del iris es controlar el diámetro de la pupila. Según el diámetro que tenga la pupila, así será la cantidad de luz que entra en el ojo.

La córnea y el cristalino funcionan como lentes. Por el fenómeno de la difracción de la luz, la córnea concentra la luz externa para que pase a través de la pupila y el cristalino hace la función inversa, consiguiendo que la luz se concentre en la fovea.

El ojo posee dos cámaras, rellenas de sustancia líquida. Una de las cámaras se sitúa en la parte anterior del ojo, rellena de humor acuoso (líquido transparente). La otra cámara está en la zona posterior, rellena

de humor vítreo (gel proteínico).

En la figura 2.1. se puede ver la estructura del ojo humano con sus diferentes partes bien diferenciadas.

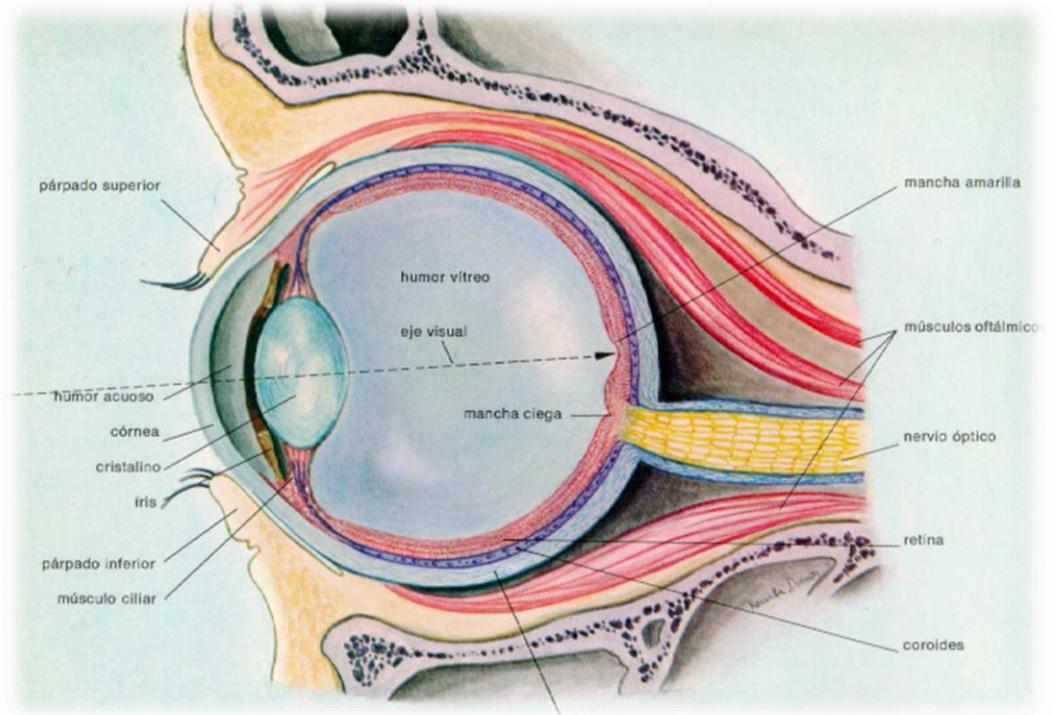


Figura 2.1: Estructura del ojo humano [3]

En este trabajo es de especial importancia el estudio de la retina, que es una membrana sensible a la luz y que cubre, prácticamente, la coroides. Esta membrana también es conocida como “fondo del ojo”.

La retina es, realmente, el entramado nervioso formado por las células terminales de las fibras del nervio óptico. En su parte posterior presenta una pequeña depresión llamada fóvea que es muy importante en la visión de los detalles y en el estudio del glaucoma [2].

La retina contiene dos tipos de receptores de luz: los conos y los bastones. Los primeros son sensibles al color y se localizan principalmente en la parte posterior del ojo (fóvea). Necesitan un nivel de luz suficiente para que funcionen bien. Los bastones son mucho más numerosos, no son sensibles al color y se encuentran distribuidos por toda la retina [2].

## 2.2. El Glaucoma

*“El glaucoma es la patología ocular más traicionera que tenemos en la actualidad. Es una de las causas más frecuente de ceguera irreversible en los países desarrollados. Lo que se pierde de visión en el glaucoma no se vuelve a recuperar. Se le llama “ceguera silenciosa”, ya que cuando la persona se da cuenta de que lo tiene puede estar casi ciega” [4].*

El glaucoma crónico simple se ha definido como una enfermedad crónica bilateral que cursa con una elevación de la presión intraocular (PIO). Es una enfermedad crónica de evolución lenta que no da síntomas iniciales [4].

### 2.2.1. ¿Por qué se produce el glaucoma?

El principal factor es el aumento de la presión intraocular. La presión arterial de perfusión [5] que requiere el ojo encuentra dificultades para entrar, debido al aumento de la PIO. Esto origina una hipoperfusión en la retina, en la zona donde se localiza el nervio óptico, llegando a producir una isquemia [6], es decir, una disminución del riego sanguíneo [4].

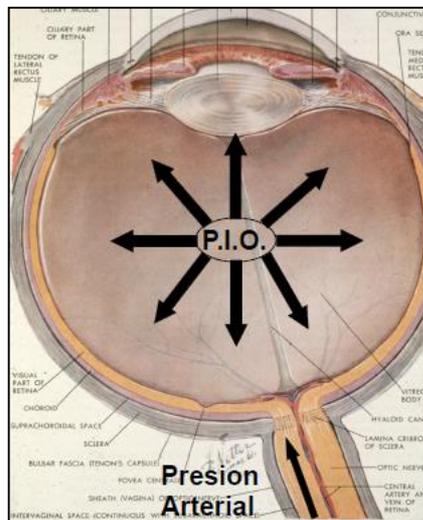


Figura 2.2. Esquema del aumento de la PIO [4]

Este aumento de presión conduce a la lesión de los axones de las células ganglionares [7] y por lo tanto, a la atrofia óptica progresiva del nervio óptico. Estas células conducen la información a través del nervio óptico, debido a sus largos axones que llegan hasta el cerebro.

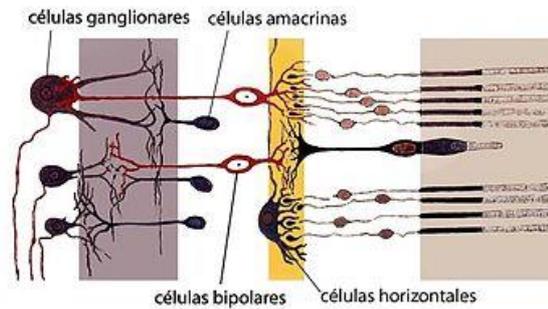


Figura 2.3. Representación de la estructura de la retina [7]

En la figura 2.3. la luz penetra por la izquierda y debe atravesar diferentes capas celulares para alcanzar las células fotorreceptoras (conos y bastones) a la derecha.

### 2.2.2. El nervio óptico

El nervio óptico [4] tiene más de un millón de fibras que llevan información hasta la corteza occipital, situada en el cerebro. Cualquier daño en él implica un fallo en la conducción y por tanto una reducción de la visión. La fovea es el lugar de máxima sensibilidad visual. Esta zona tiene que estar intacta para que la visión sea del 100%.

Como ya se ha mencionado anteriormente, el glaucoma produce un daño irreparable en el nervio óptico. Se le denomina “nervio excavado” por las lesiones que se aprecian. La consecuencia es la reducción de la visión y defectos dentro del campo visual, pudiendo llegar a la ceguera total.

### 2.2.3. ¿Qué medidas se emplean para su diagnóstico?

Para poder detectar los síntomas del glaucoma, los médicos especialistas realizan una serie de pruebas al paciente, como son [4]:

- **Tonometría de aplanación.** Se toma la tensión del paciente en el ojo con un tonómetro o medidor de tensión ocular.

- **Gonioscopia.** Que se utiliza para medir el ángulo de la cámara anterior. Para ello, se evalúa la profundidad del seno camerular con ayuda de una lámpara de hendidura y lentes especiales llamadas gonioscopios.
- **Campimetría.** Prueba para valorar alteraciones en el campo visual. Se enseñan numerosos estímulos al paciente hasta que este sea capaz de verlo. Mide los decibelios de sensibilidad que tienen los puntos explorados.
- **Tomografía de coherencia óptica.** cuantifica el número o la cantidad de fibras nerviosas que están lesionadas en el nervio óptico. Es una técnica en 3D y su uso resulta muy costoso.
- **Estudio de Retinografías.** Esta técnica es similar a la Tomografía, pero en 2D. Podemos pensar que estamos perdiendo calidad de diagnóstico pero resulta mucho más eficiente y es más barato que la técnica anterior. Para estudiar el nervio óptico y el daño producido por el glaucoma se utiliza el método llamado excavación papilar. Hay una regla muy elemental: mido el diámetro del nervio óptico y comparo el diámetro de la excavación. Por ejemplo, si la excavación ocupa la tercera parte, la excavación es de 0,3. Si ocupa la sexta parte sería de 0,6. A medida que aumenta es más grave.

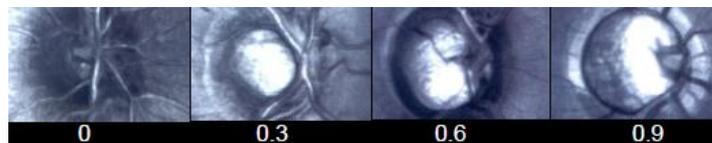


Figura 2.4. Excavación Papilar [4]

Todas estas exploraciones nos ayudan al diagnóstico preciso de esta patología ocular. Dado que este trabajo se basa en esta última técnica, dedicaremos un apartado completo a explicarlo con detalle.

### 2.3. La Retinografía

La Retinografía es una prueba diagnóstica que permite a los oftalmólogos obtener una imagen de la retina o del fondo del ojo [8].

Se trata de una prueba rápida, eficaz, segura, sencilla, muy útil, muy cómoda, que no causa dolor y no es invasiva [8]. Cuando nos fijamos en el fondo del ojo, nos encontramos cuatro estructuras importantes: (ver Figura 2.5.) [8].

1. El propio tejido de la retina, que es la parte que aporta el color rojo-anaranjado.
2. La mácula, que es la zona central y la más importante de la retina porque se encarga de la visión del detalle y de la alta precisión.
3. La cabeza del nervio óptico, que tiene un color mucho más amarillento y es más brillante.
4. La circulación o vasos que alimentan la retina.

Las imágenes obtenidas en esta prueba pueden almacenarse mediante un sistema informático y compararse en el tiempo, de manera que la retinografía no solo ha demostrado utilidad en la detección precoz de muchas enfermedades del fondo de ojo sino que también nos permite evaluar la evolución de estas enfermedades retinianas a lo largo del tiempo [8].

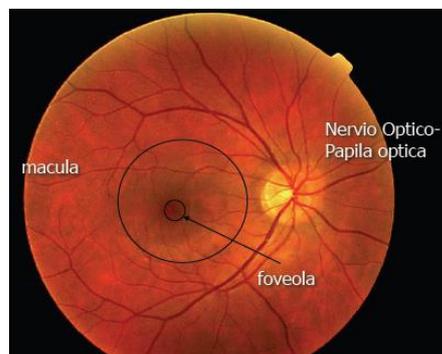


Figura 2.5. Retinografía detallada [4].

## 3 ESTADO DEL ARTE

---

La investigación acerca de un algoritmo para detectar la enfermedad del glaucoma es novedosa como se verá a continuación.

Uno de los principales indicadores de glaucoma que se usa en la práctica clínica es la relación disco-excavación (CDR). Mientras que el disco óptico contiene fibras nerviosas, la excavación es el área que se encuentra dentro de él y que no contiene fibras en absoluto. A medida que avanza el glaucoma, la excavación se agranda debido a la muerte de células ganglionares hasta que ocupa la mayor parte de la zona del disco. Por lo tanto, si la relación entre el área de la excavación y el área del disco óptico, CDR, excede un cierto valor, se puede sospechar la existencia de glaucoma.

Se han propuesto una amplia variedad de métodos para la detección del disco óptico en el pasado. De entre ellos cabe destacar:

“D.W.K. Wong et al.” [9] presentaron un método que combinaba ARGALI [10] con el clasificador SVM (Support Vector Machine, explicado en el capítulo 5) que se analizó como una alternativa para sustituir a las redes neuronales.

“Joshi G.D. et al.” [11] propusieron un método que integraba la información de cada punto de interés de la imagen en un espacio de características multidimensional. Además, presentaron como novedad considerar la curvatura de los vasos sanguíneos para la segmentación del disco óptico. Estos expertos consideraron que es una información relevante.

“I. Fondón et al.” [12], obtienen la segmentación del disco óptico utilizando el espacio de color uniforme CIELAB y la distancia de color CIE94.

Centrándose en la excavación, debido a las características físicas, se puede diferenciar del resto la curvatura de los vasos sanguíneos y el característico color amarillento brillante. Un método basado en este conocimiento previo podría proporcionar el resultado deseado. La información de color, por lo tanto, juega un papel importante en la detección de la excavación. Para ello se pueden utilizar planos de color de espacios uniformes o de espacios no uniformes.

En cuanto a los espacios de color uniformes, uno de los planos de color que más se utiliza es el G, del espacio de color RGB [10], [13] y [14].

Hay otros algoritmos que hacen uso de otros planos de color, sobre todo B y R del espacio de color RGB [15] - [16].

Joshi [11], [17], presentó un método en el que la apariencia de la zona de excavación en el plano R se combinó con el conocimiento anatómico sobre los vasos que atraviesan la región del disco óptico. Así, la excavación fue modelada como una región que encierra la palidez y está definido por un límite que pasa a través de un conjunto de vasos curvados.

Existen otros métodos que utilizan los espacios uniformes. El plano de color utilizado por Joshi et al. en [18] es  $a^*$  de CIE  $L^*a^*b^*$ . El motivo alegado por estos autores es que la región de la excavación presenta un aspecto continuo y bien contrastado con el fondo.

Algunos autores [9] - [10] adoptan una combinación de planos de color, aunque el procesamiento se realiza por separado en cada canal de color.

Para la estimación de la excavación, debido a la dificultad de encontrar un borde preciso de la zona que es generalmente difusa y obstruida por los vasos sanguíneos, hay pocos métodos.

Existe un método reciente [19] para segmentar la excavación que utiliza el espacio de color uniforme JCh, modelo de apariencia de color de CIECAM 02 (Modelo de apariencia de color adaptado por CIE en 2002).

Usando el clasificador Random Forest, el método propuesto combina la

información sobre la curvatura de los vasos junto con el color para identificar píxeles pertenecientes al área de la excavación.

El algoritmo ha sido probado no sólo en el espacio de color JCh sino también en RGB y *CIE L\*a\*b\**. La detección de vasos y la curvatura de computación se ha hecho sobre los planos de color *J*, *G*, *R* and *L\**, mientras que la información de color considerada como la entrada para el clasificador ha sido de los espacios completos (*JCh*, *RGB* and *CIE L\*a\*b\**) [19].

Este último método es el más novedoso y se utilizará para comparar los resultados obtenidos con el algoritmo que se presenta en este trabajo.

En resumen, se comprueba que hay pocos algoritmos de detección de color en espacio uniforme.



# 4 ESPACIOS DE COLOR

## 4.1. Introducción

### 4.1.1. Luz y Color

La luz es una radiación electromagnética u onda electromagnética caracterizada por una determinada frecuencia o longitud de onda del espectro electromagnético.

De todas las frecuencias que comprende el espectro, una pequeña franja, entre los 380 y los 780 nm, pertenece al espectro visible. Cada frecuencia del espectro visible corresponde a un solo color (color monocromático).

Así, el **color blanco** será la superposición de todas las frecuencias del espectro visible, y el **color negro** la no existencia de componentes espectrales en la franja visible.

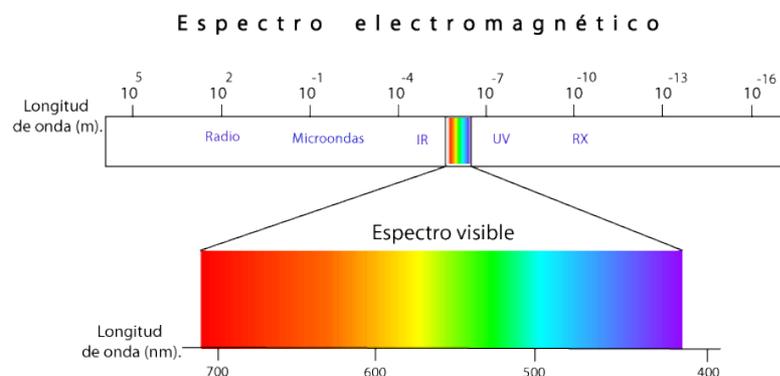


Figura 4. 1. Espectro electromagnético y franja visible [20]

### 4.1.2. Sensores de luz en el ojo: conos y bastones.

Como ya se ha visto en el Capítulo 2, en el apartado del sistema visual humano, la retina está compuesta de unas células fotorreceptoras que son los conos y los bastones.

Los conos presentan una menor sensibilidad a la luz que los bastones. Son los responsables de la percepción del color. Sólo se activan en condiciones de iluminación normal o diurna, es decir, nos

proporcionan una visión fotópica. Tienen concentración máxima en la zona central de la retina (eje de visión).

Los bastones son muy sensibles a las señales luminosas. No responden a colores sino a la iluminación que tenga la imagen. Son los responsables de la visión en condiciones de baja luminosidad, es decir, a la visión escotópica. Se distribuyen en la periferia de la retina.

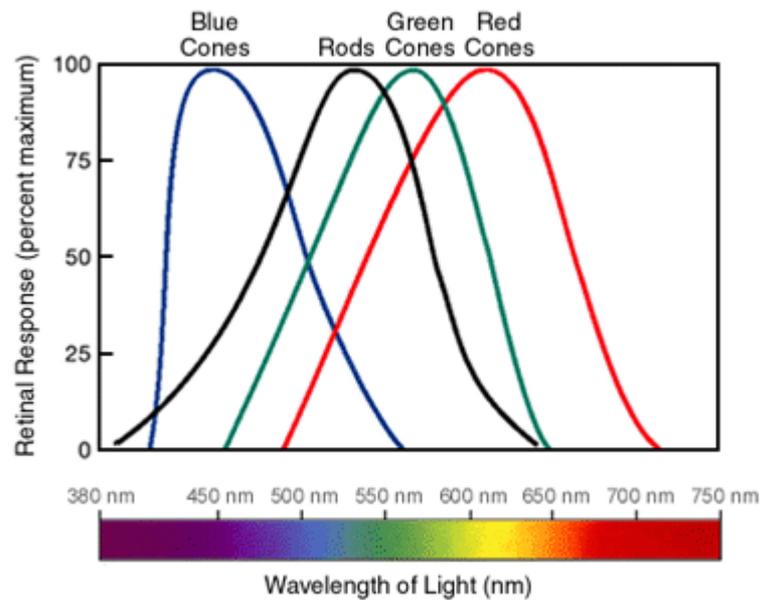


Figura 4. 2. Relación entre la respuesta de conos y bastones en la retina y  $\lambda$ .

#### 4.1.3. La percepción del color

El color es una sensación producida por los rayos luminosos que impresionan los órganos visuales y que depende de la longitud de onda [21].

Según la Comisión Internacional de la Iluminación (en francés CIE, 1970), el color percibido se define como el aspecto de la percepción visual mediante el cual un observador puede distinguir entre dos objetos del mismo tamaño, forma y textura basándose en las diferencias en la composición espectral de las radiaciones relacionadas con la observación [22].

La energía electromagnética que incide sobre los conos y los bastones es transformada en impulsos nerviosos que llegan hasta las células ganglionares cuyos axones se unen para formar el nervio óptico en el disco óptico, llamado punto ciego porque carece de células fotorreceptoras y no es sensible a la luz [23].

Los haces nerviosos de cada ojo se encuentran en el quiasma óptico donde parte de ellos se cruzan para ir a parar al hemisferio cerebral opuesto, de manera que las fibras que salen del lado izquierdo de ambas retinas (y que corresponden al lado derecho del campo visual) se proyectan hacia el hemisferio izquierdo y las que salen del lado derecho de ambas retinas (y que corresponden al lado izquierdo del campo visual) se proyectan hacia el hemisferio derecho [23].

Es interesante saber que al formar la imagen en la retina, se produce una inversión de esta, debido a la teoría de la difracción de la luz.

En la Figura 4.3. se ilustra de forma evidente el recorrido de la luz a su paso por el ojo humano y la formación de la imagen en el cerebro.

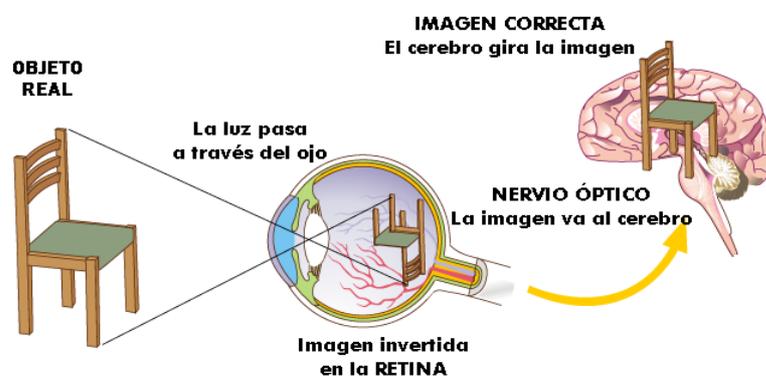


Figura 4. 3. Mecanismo de formación de una imagen en la retina [24].

El proceso de identificación de colores depende del cerebro y del sistema ocular de cada persona.

El concepto de color es totalmente subjetivo, dependiendo de la persona en sí. Dos personas diferentes pueden interpretar un color dado de forma distinta. Puede haber tantas interpretaciones de un color como personas hay.

Un caso particular es la patología denominada Daltonismo, que es un defecto genético que ocasiona dificultad para distinguir colores [25]. En la figura 4.4. se muestra un ejemplo del Daltonismo más clásico.



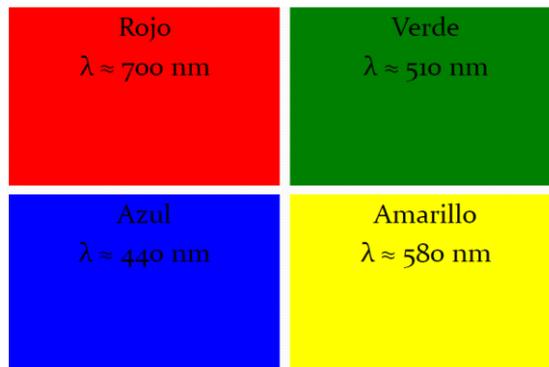
*Figura 4. 4. Ejemplo de Daltonismo*

*Izquierda: Cómo vería la bandera una persona no daltónica. Derecha: Cómo vería la bandera una persona daltónica.*

#### 4.1.4. Características del color

Las tres características más importantes de un color son el matiz o tono, el brillo y la saturación.

El **matiz** es la variable psicológica que describe los efectos de variación del espectro sobre la sensación de color percibida. Corresponde al aspecto al que nos referimos cuando decimos que un objeto es rojo o es azul. Hay colores acromáticos, o sin matiz, como son el blanco, el negro y los grises. El resto de colores se denominan cromáticos [26].



*Figura 4. 5. Diferencias de tono o matiz.*

El **brillo** es un atributo de la sensación visual según el cual un estímulo visual parece ser más o menos intenso. Está relacionado con la luminancia, que es una magnitud perfectamente definida, pero no se puede medir con instrumentos. El brillo puede definir por sí solo todos los colores grises (del blanco al negro). Es decir, toda la gama de grises se diferencia únicamente por la cantidad de luminancia [26].



Figura 4. 6. Diferencias de luminancia (%).

La  **saturación**  representa el grado de pureza, es decir, en qué medida un color está mezclado con otros colores. Se puede evaluar a partir de la cantidad de gris que contiene. Los colores puros tienen una saturación máxima. La saturación baja produce tonos pastel [26].

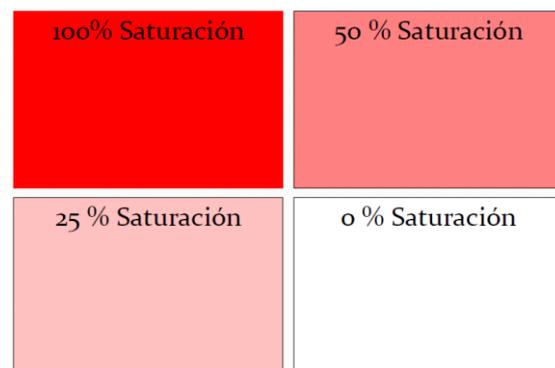


Figura 4. 7. Diferencias de saturación (%)

## 4.2. Espacios de color

### 4.2.1. Colorimetría

La colorimetría es la ciencia que estudia objetivamente los colores y su medición, teniendo en cuenta la manera como los percibe el ojo humano. Se trata de la ciencia encargada de estudiar los aspectos psicofísicos del color.

Herman Grassmann, físico alemán, enunció cuatro leyes en 1853, con el nombre de Las cuatro Leyes de Grassmann.

A estas las llamó: de la **trivarianza**, de la **luminancia**, de **proporcionalidad** y de **aditividad**; pero se pueden reunir en dos: [27]

1. El efecto sobre el ojo de un color cualquiera (C), es el mismo que el producido por la suma aditiva de tres colores cualesquiera (R), (G), y (B), siempre que se mezclen en las proporciones adecuadas.

$$C = \alpha \cdot (R) + \beta \cdot (G) + \gamma \cdot (B) \quad (1)$$

2. Si se suman dos colores cualesquiera, obteniéndose otro color resultante, este podría haberse obtenido también sumando los primarios de cada uno de los colores origen.

$$C_3 = C_1 + C_2 \quad (2)$$

$$C_3 = (\alpha_1 + \alpha_2) \cdot (R) + (\beta_1 + \beta_2) \cdot (G) + (\gamma_1 + \gamma_2) \cdot (B) \quad (3)$$

### 4.2.2. La Comisión Internacional de la Iluminación

La Comisión Internacional de la Iluminación, también conocida como CIE de su título francés, Commission Internationale de l'Eclairage - se dedica a la cooperación a nivel mundial y el intercambio de información sobre todos los asuntos relacionados con la ciencia y el arte de la luz y la iluminación, el color y visión, fotobiología y la tecnología de la imagen [22].

De esta forma, CIE es el organismo encargado de realizar normalizaciones relacionadas con el color.

En 1931, CIE estandariza tres luces “primarias” monocromáticas.

- R = 700 nm
- G = 546,1 nm
- B = 435,8 nm

#### 4.2.3. El Observador Patrón CIE (1931). El espacio 1931 CIE RGB

CIE realizó un experimento detallado para determinar las curvas de igualación de color. Estas curvas o funciones de igualación de color son las series de valores triestímulos espectrales de un determinado sistema de estímulos primarios (por ej. **RGB**).

En la figura 4.8. se muestra gráficamente el experimento de correspondencia de colores a partir de una mezcla aditiva.

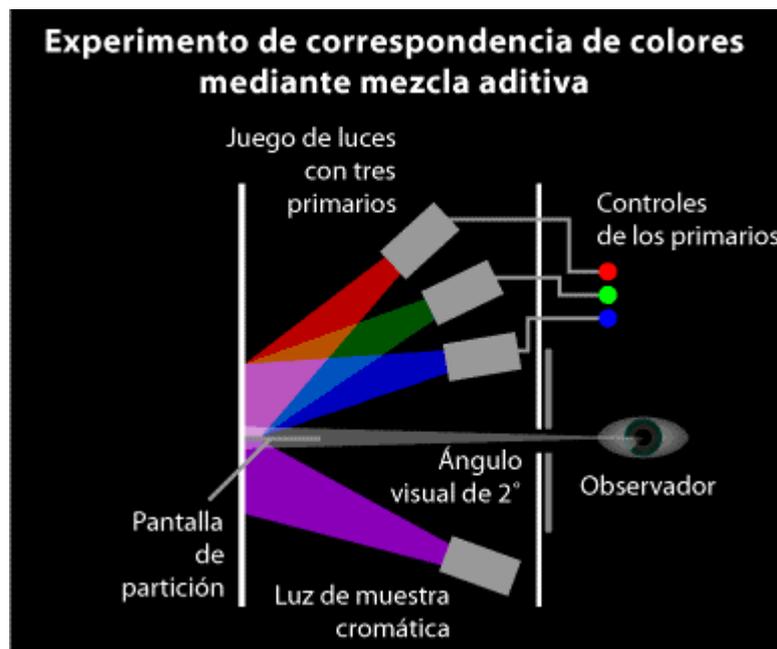


Figura 4. 8. Experimento de correspondencia de colores mediante mezcla aditiva.  
[26]

¿En qué consistía el experimento? El observador, regulando los controles de los tres primarios, tenía que conseguir la luz de referencia (otro monocromático). Se tabuló cada 5 nm.

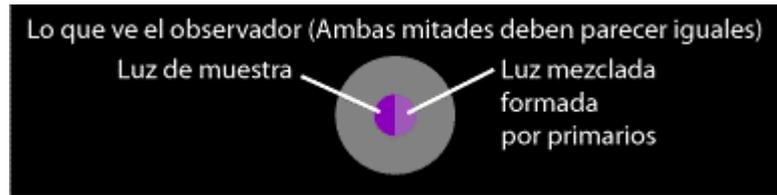


Figura 4. 9. Lo que ve el observador, durante el experimento CIE 1931 [26].

Una vez se conseguía igualar los dos colores, se registraban los valores de  $\alpha$ ,  $\beta$  y  $\gamma$ , para los cuales se produce la igualación.

$$\delta C(\lambda) = \alpha(R) + \beta(G) + \gamma(B) \quad (4)$$

Quien siga este procedimiento se encontrará de inmediato con un problema: sean cuales sean los primarios elegidos, algunos colores no se pueden igualar con ninguna combinación. Sin embargo, es posible soslayar el problema llevando la luz de uno o más de los primarios al otro campo; o sea, añadiéndola a la luz de referencia. Este procedimiento se justifica por el hecho de que añadir una luz a la luz de referencia es igual a restar esa luz de la mezcla de los tres primarios. Es lo mismo que añadir una cantidad negativa [28].

De este modo, cualquier color espectral se puede hacer corresponder con la síntesis aditiva de los tres primarios, permitiéndolo si fuera necesario añadir uno o dos primarios a ese color espectral. Formalmente se puede decir que cualquier color espectral se puede representar como una suma de los tres primarios y que alguno de ellos se puede expresar de forma negativa [28]. Si la igualación no era posible, se probaba cambiando de sitio una de las luces:

$$\delta C(\lambda) + \alpha(R) = \beta(G) + \gamma(B) \quad (5)$$

Despejando:

$$\delta C(\lambda) = -\alpha(R) + \beta(G) + \gamma(B) \quad (6)$$

Normalizando:

$$C(\lambda) = -\frac{\alpha}{\delta(R)} + \frac{\beta}{\delta(G)} + \frac{\gamma}{\delta(B)} \quad (7)$$

Si se expresa en función de la longitud de onda ( $\lambda$ ):

$$C(\lambda) = \bar{r}(\lambda)R + \bar{g}(\lambda)G + \bar{b}(\lambda)B \quad (8)$$

En la figura 4.10. se observan las funciones de igualación de color. A las frecuencias de los primarios no se necesitan otras luces. Algunas luces requieren de valores negativos de alguno de los primarios, como se explicó anteriormente.

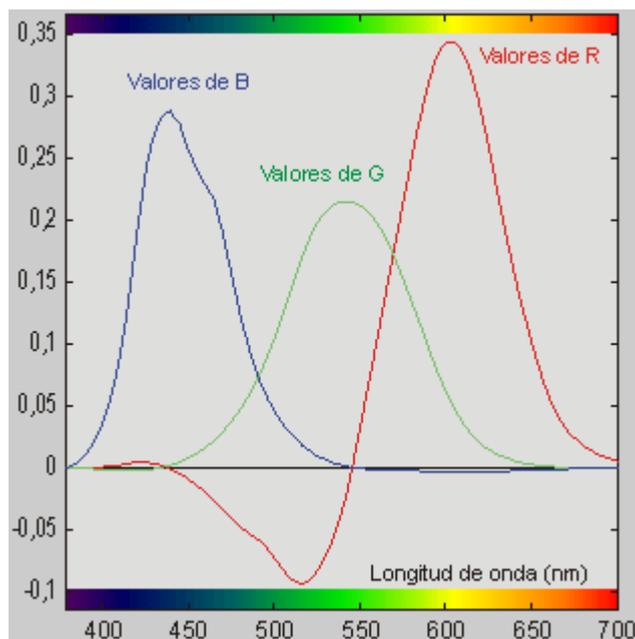


Figura 4. 10. Funciones de igualación de color [29]

Normalizando las coordenadas anteriores, podemos definir unas nuevas:

$$r(\lambda) = \frac{\bar{r}(\lambda)}{\bar{r}(\lambda) + \bar{g}(\lambda) + \bar{b}(\lambda)} \quad (9)$$

$$g(\lambda) = \frac{\bar{g}(\lambda)}{\bar{r}(\lambda) + \bar{g}(\lambda) + \bar{b}(\lambda)} \quad (10)$$

$$b(\lambda) = \frac{\bar{b}(\lambda)}{\bar{r}(\lambda) + \bar{g}(\lambda) + \bar{b}(\lambda)} \quad (11)$$

De esta manera,  $r(\lambda) + g(\lambda) + b(\lambda) = 1$  (12)

A los coeficientes  $r$ ,  $g$  y  $b$  se les denomina **coordenadas tricromáticas** de un color, en el espacio 1931 CIE RGB.

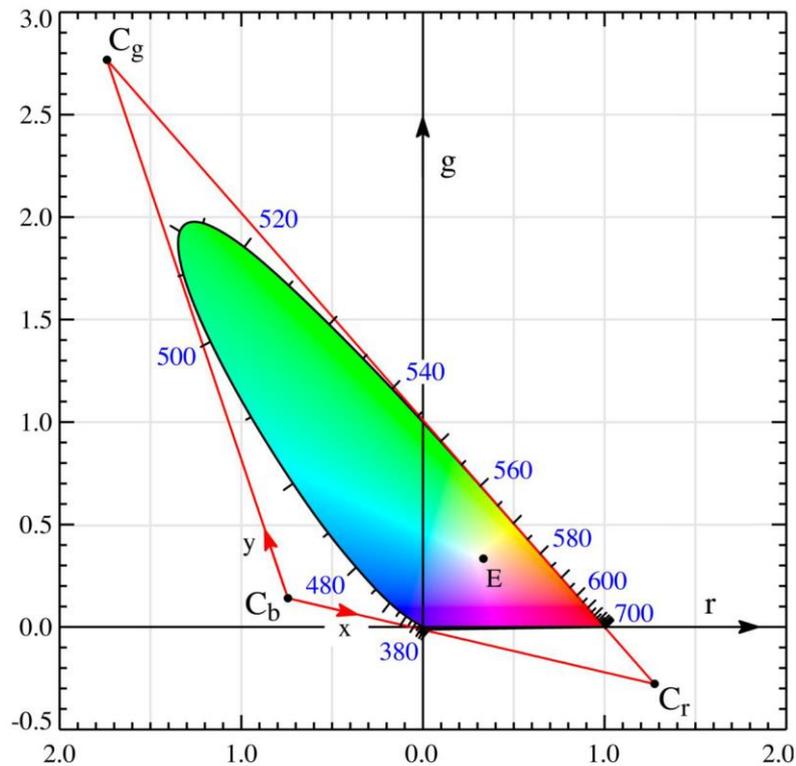


Figura 4. 11. Colores en el sistema RGB [26].

Así, el color rojo sería:  $r=1$ ,  $g=0$  y  $b=0$ ; el color verde:  $r=0$ ,  $g=1$  y  $b=0$  y el color azul:  $r=0$ ,  $g=0$  y  $b=1$ .

#### 4.2.4. Espacio 1931 CIE XYZ

La dificultad en el cálculo de los valores triestímulos de R, G y B según las ecuaciones básicas indujo a la CIE a la adopción de otro sistema tricromático. Este sistema se basa en los experimentos que se realizaron con observadores reales, en los que establecieron las magnitudes de los primarios que igualaban los colores espectrales. Mediante una transformación matricial, a partir de los primarios R, G

y B se definen los nuevos estímulos X, Y y Z. Se trata de estímulos artificiales y no igualables con los espectrales visibles, pero que aseguran que las coordenadas de cromaticidad  $x$ ,  $y$ ,  $z$ , no adopten valores negativos, cuyo significado físico podría resultar confuso en su aplicación [30].

Las condiciones para el nuevo sistema de coordenadas serán:

- Las nuevas funciones de igualación deberían ser positivas para todo  $\lambda$ .

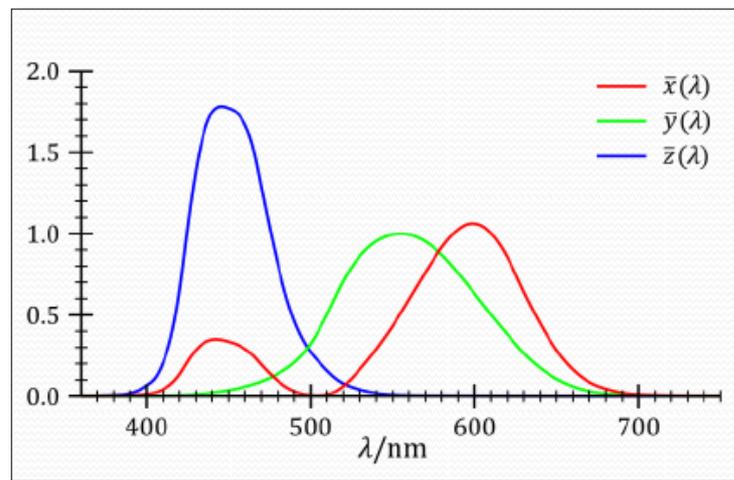


Figura 4. 12. Nuevas funciones de igualación de color (todos los coeficientes positivos) [26]

- El blanco deberá tener coordenadas  $(1/3, 1/3, 1/3)$
- La función de igualación  $\bar{y}(\lambda)$  deberá coincidir con la función de eficiencia luminosa espectral ( $\Phi_v(\lambda)$ ) en visión fotópica (la que se obtiene con los conos, visión diurna).

$$K(\lambda) = \frac{\Phi_v(\lambda)}{\Phi(\lambda)} \quad (13)$$

donde  $\Phi(\lambda)$  es el flujo radiante espectral y  $K(\lambda)$  es la sensibilidad espectral [26].

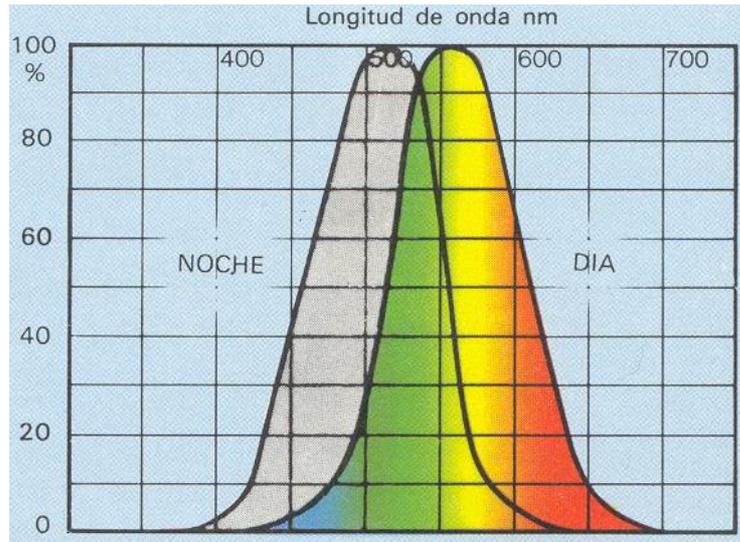


Figura 4. 13. Eficiencia luminosa espectral. [26]

- La gama cromática deberá ocupar un espacio máximo.

Una vez localizados los nuevos primarios, es posible representar los antiguos en función de los nuevos.

$$\begin{bmatrix} x(\lambda) \\ y(\lambda) \\ z(\lambda) \end{bmatrix} = \begin{pmatrix} 0.49 & 0.31 & 0.20 \\ 0.18 & 0.81 & 0.01 \\ 0.00 & 0.01 & 0.99 \end{pmatrix} \begin{bmatrix} \bar{r}(\lambda) \\ \bar{g}(\lambda) \\ \bar{b}(\lambda) \end{bmatrix} \quad (14)$$

Este sistema de ecuaciones es para las funciones de igualación de color. También se puede aplicar la misma ecuación para los valores triestímulos X, Y y Z.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{pmatrix} 0.49 & 0.31 & 0.20 \\ 0.18 & 0.81 & 0.01 \\ 0.00 & 0.01 & 0.99 \end{pmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (15)$$

A continuación se muestran los valores triestímulos expresados a partir de las funciones de igualación del color:

$$X = k \cdot \int P_{\lambda} \cdot \bar{x}(\lambda) \cdot d\lambda \quad (16)$$

$$Y = k \cdot \int P_{\lambda} \cdot \bar{y}(\lambda) \cdot d\lambda \quad (17)$$

$$Z = k \cdot \int P_{\lambda} \cdot \bar{z}(\lambda) \cdot d\lambda \quad (18)$$

donde  $k$  es un factor normalizante y  $P_\lambda$  corresponde al componente monocromático de longitud de onda  $\lambda$ , en el estímulo del color que corresponda [30].

Por último, las coordenadas de cromaticidad, expresadas en función de los valores triestímulos son:

$$x = \frac{X}{X+Y+Z} \quad (19)$$

$$y = \frac{Y}{X+Y+Z} \quad (20)$$

$$z = \frac{Z}{X+Y+Z} \quad (21)$$

En 1931 se pensaba que los conos se concentraban en la región de la fovea. Posteriormente se supo que los conos se extendían más allá de esta región, por lo que se decidió volver a repetir las pruebas del Observador Patrón CIE 1931, de 2°, resultando de ellas el Observador Patrón 1964 CIE 10° [26].

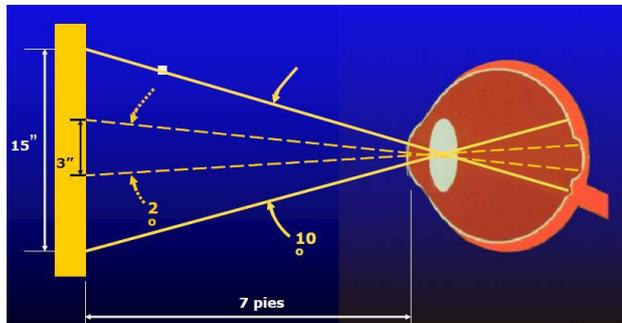


Figura 4. 14. Aumento del ángulo visual para el experimento del observador CIE 1964. [26]

#### 4.2.5. Escala Uniforme UCS 1960

Hasta los años sesenta se habían propuesto diversos espacios de color, a partir de la idea de transformar proyectivamente el espacio CIE (Judd, 1935), que fueron considerados por el Comité de Colorimetría CIE con el fin de conseguir espacios uniformes en los que las diferencias de color estuviesen correlacionadas con la apreciación visual, es decir, donde los colores con iguales diferencias observables puedan ser representados por puntos equidistantes [30].

Éstos dieron lugar a la recomendación de la Escala de Cromaticidad Uniforme CIE 1960 (UCS), propuesta por MacAdam (1937; 1942a; 1944), que es una transformación proyectiva del Diagrama de Cromaticidad CIE 1931 (x,y). Se definieron las nuevas coordenadas u, v, a partir de las siguientes expresiones [30]:

$$u = \frac{4x}{-2x + 12y + 3} \quad (22) \quad u = \frac{4X}{X + 15Y + 3Z} \quad (23)$$

$$v = \frac{6y}{-2x + 12y + 3} \quad (24) \quad v = \frac{6Y}{X + 15Y + 3Z} \quad (25)$$

En las que x, y, X, Y y Z son las coordenadas de cromaticidad y valores triestímulos, respectivamente, según el Observador Patrón CIE 1931 [30].

A continuación, en la figura 4.15., está representado el sistema UCS en un diagrama de cromaticidad [30].

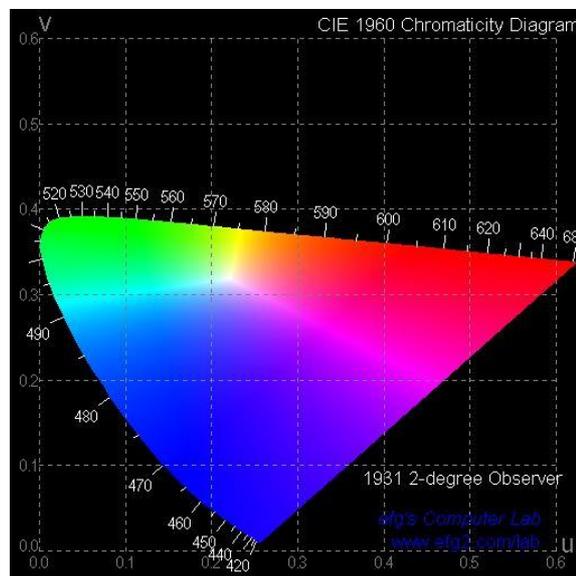


Figura 4. 15. CIE 1960 Diagrama de Cromaticidad UCS [31]

#### 4.2.6. Espacio $U^*V^*W^*$

A partir del nuevo diagrama de cromaticidad UCS 1960, y basándose en el trabajo de Wyszecki (1963), la CIE considera, un año más tarde, una modificación tridimensional del mismo. Se trata del Sistema CIE 1964 ( $U^*V^*W^*$ ), en el que se incluyen los índices de cromaticidad  $U^*$  y  $V^*$ , y de luminosidad  $W^*$ , los cuales se definen según las ecuaciones [30]:

$$W^* = 25 \cdot \sqrt[3]{Y} - 17 \quad (26)$$

$$U^* = 13W^*(u - u_o) \quad (27)$$

$$V^* = 13W^*(v - v_o) \quad (28)$$

donde  $Y$  es el valor triestímulo CIE 1931;  $u, v$ , las coordenadas de cromaticidad CIE 1960 (UCS), correspondientes al estímulo coloreado en cuestión, y  $u_o$  y  $v_o$ , las del estímulo acromático relacionado con el iluminante de referencia. Para el caso del Iluminante C, que es un iluminante definido por CIE que se asimila con la luz diurna media (tradicionalmente luz de cielo nublado), y el observador Estándar CIE 1931, estos valores son [30]:

$$u_o(C) = 0,2009 \text{ y } v_o(C) = 0,3073 \quad (29)$$

Se propone, además, una fórmula para las diferencias de color que considera la influencia de la luminosidad en la cromaticidad:

$$\Delta E_{U^*V^*W^*} = \sqrt{(\Delta U^*)^2 + (\Delta V^*)^2 + (\Delta W^*)^2} \quad (30)$$

que es una extensión tridimensional del Teorema de Pitágoras para la distancia entre dos puntos del diagrama.

#### 4.2.7. Espacio CIE LUV

Se utiliza para mostrar las diferencias de color con mayor comodidad. El espacio CIELUV es especialmente útil para mezclas de aditivos de luces, debido a sus propiedades adición lineal [32].

El espacio CIELUV es una modificación del sistema CIE 1964 ( $U^*V^*W^*$ ). Este espacio de color incorpora una nueva Escala Uniforme de Color, CIE 1976 UCS (MacAdam, 1974; 1978; Nickerson, 1975), representada por el Diagrama de Cromaticidad ( $u', v'$ ) (Fig. 17) y

directamente relacionado con el Diagrama de Cromaticidad (u,v) de 1960 [30]:

$$u' = \frac{4X}{X + 15Y + 3Z} \quad v' = \frac{9X}{X + 15Y + 3Z} \quad (31)$$

donde  $u' = u$  y  $v' = 1,5 \cdot v$ .

El espacio CIELUV viene determinado por la respuesta tridimensional en  $L^*$ , y cromaticidad  $u^*$ ,  $v^*$ . Se define por las expresiones [30]:

$$L^* = \left\{ \begin{array}{ll} 116 \sqrt[3]{\frac{Y}{Y_n}} - 16, & \text{si } \frac{Y}{Y_n} > 0.008856 \\ 903,3 \left(\frac{Y}{Y_n}\right) & \text{si } \frac{Y}{Y_n} \leq 0.008856 \end{array} \right\} \quad (32)$$

$$u^* = 13L^*(u' - u'_n) \quad (33)$$

$$v^* = 13L^*(v' - v'_n) \quad (34)$$

donde  $u'$ ,  $v'$  representan la cromaticidad de un estímulo coloreado;  $u'_n$  y  $v'_n$  la del estímulo blanco correspondiente al iluminante de referencia;  $Y$  e  $Y_n$  son los valores triestímulos CIE 1931, para el estímulo considerado y el estímulo blanco, respectivamente [30].

En el caso del Iluminante C y el Observador Estándar CIE 1931,  $u'_n$  y  $v'_n$  toman los valores:

$$u'_n(C) = u_o(C) = 0.2009 \quad (35)$$

$$v'_n(C) = 1.5v_o(C) = 0.4610 \quad (36)$$

En este sistema, la fórmula para diferencias de color propuesta es análoga a la anterior, y también considera conjuntamente la luminancia y cromaticidad [30]:

$$\Delta E^*_{uv} = \sqrt{(\Delta L^*)^2 + (\Delta u^*)^2 + (\Delta v^*)^2} \quad (37)$$

#### 4.2.8. Espacio CIE LAB

La intención de CIE LAB (o Lab) es construir un espacio de color uniforme de forma más perceptiva que los espacios de color anteriores. [33]. ¿Qué significa que sea lineal? Todas las diferencias de color igualmente percibidas deben representarse en tal espacio uniforme por las mismas distancias.

El espacio de color CIE LAB es un sistema coordenado cartesiano definido por tres coordenadas colorimétricas  $L^*$ ,  $a^*$  y  $b^*$ , magnitudes adimensionales que se calculan por las fórmulas siguientes:

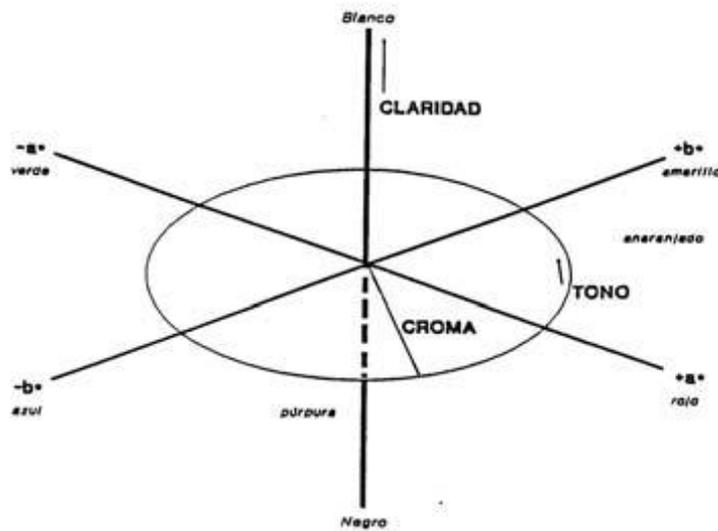


Figura 4. 16. Coordenadas cartesianas y cilíndricas del Espacio de Color CIE LAB [30]

La **Luminancia  $L^*$** , que se define igual que el sistema CIELUV:

$$L^* = \left\{ \begin{array}{ll} 116 \sqrt[3]{\frac{Y}{Y_n}} - 16, & \text{si } \frac{Y}{Y_n} > 0.008856 \\ 903,3 \left(\frac{Y}{Y_n}\right), & \text{si } \frac{Y}{Y_n} \leq 0.008856 \end{array} \right\} \quad (38)$$

La **Cromaticidad  $a^*$ ,  $b^*$** :

$$a^* = 500 \left[ f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right] \quad (39)$$

$$b^* = 200 \left[ f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right] \quad (40)$$

siendo:

$$f\left(\frac{X}{X_n}\right) = \begin{cases} \sqrt[3]{\frac{X}{X_n}}, & \text{para } \frac{X}{X_n} > 0.008856 \\ 7.787\left(\frac{X}{X_n}\right) + \frac{16}{116}, & \text{para } \frac{X}{X_n} \leq 0.008856 \end{cases} \quad (41)$$

$$f\left(\frac{Y}{Y_n}\right) = \begin{cases} \sqrt[3]{\frac{Y}{Y_n}}, & \text{para } \frac{Y}{Y_n} > 0.008856 \\ 7.787\left(\frac{Y}{Y_n}\right) + \frac{16}{116}, & \text{para } \frac{Y}{Y_n} \leq 0.008856 \end{cases} \quad (42)$$

$$f\left(\frac{Z}{Z_n}\right) = \begin{cases} \sqrt[3]{\frac{Z}{Z_n}}, & \text{para } \frac{Z}{Z_n} > 0.008856 \\ 7.787\left(\frac{Z}{Z_n}\right) + \frac{16}{116}, & \text{para } \frac{Z}{Z_n} \leq 0.008856 \end{cases} \quad (43)$$

Los valores  $X_n$ ,  $Y_n$ ,  $Z_n$  corresponden al estímulo considerado como blanco. Para el iluminante C y el Observador Estándar CIE 1931, [30].

$$X_n = 98,041 \quad Y_n = 100 \quad Z_n = 118,103$$

La diferencia de color queda definida por:

$$\Delta E^*_{ab} = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} \quad (44)$$

#### 4.2.9. Familia HSL

Su nombre proviene del inglés (Hue, Saturation, Lightness): Matiz, Saturación y Luminosidad. Define un modelo mejor adaptado a la descripción e interpretación humana de los colores. Son más intuitivos, pues utilizan las características con las que describimos los colores. Son espacios no uniformes. El modelo HSL se representa gráficamente como un bicono. Los dos vértices en el modelo HSL son el color blanco y el negro, el ángulo se corresponde con el matiz, la distancia al eje con la saturación y la distancia al eje blanco-negro define la luminancia. [34]

Dentro de la familia HSL encontramos el modelo HSI y el modelo HSV,

que son deformaciones no lineales del espacio de color RGB. [34]

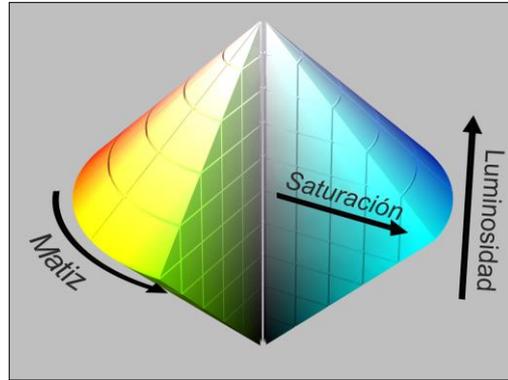


Figura 4. 17. Bicono del modelo HSL [34]

A continuación, se detallan las ecuaciones para el sistema HSI (Hue, Saturation, Intensity), partiendo de RGB.

$$H = \begin{cases} \theta, & \text{si } B \leq G \\ 360 - \theta, & \text{si } B > G \end{cases} \quad (45)$$

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[R - G] + (R - B)}{[R - G]^2 + (R - B)^2 + (G - B)^2}^{1/2} \right\} \quad (46)$$

$$S = 1 - \frac{3}{R + G + B} [\min(R, G, B)] \quad (47)$$

$$I = \frac{1}{3}(R + G + B) \quad (48)$$

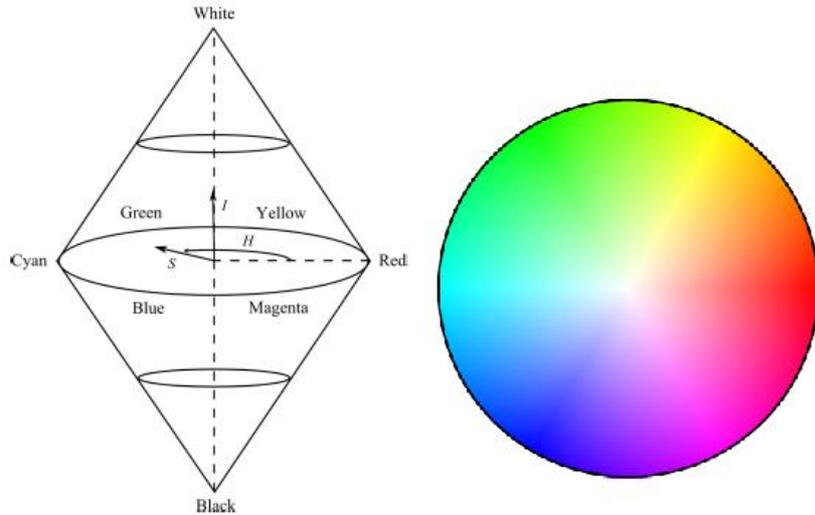


Figura 4. 18. *Espacio HSI y plano tono-saturación para el máximo de intensidad.*

El espacio de color HSV se basa en los términos usados por los artistas: matiz (hue), sombra (shadow) y valor (value). La sombra se incrementa añadiendo negro a un color puro. Esto equivale a decrementar V. El matiz se incrementa añadiendo blanco a un color puro. Esto equivale a decrementar S sin tocar V. Se modela con una pirámide hexagonal invertida.

Sea “max” el valor máximo de los componentes R, G y B y “min” el valor mínimo de esos mismos valores. Las ecuaciones de transformación de RGB a HSV son:

$$H = \begin{cases} \text{no definido,} & \text{si } \max = \min \\ 60^\circ \frac{G-B}{\max - \min} + 0^\circ, & \text{si } \max = R \text{ y } G \geq B \\ 60^\circ \frac{G-B}{\max - \min} + 36^\circ & \text{si } \max = R \text{ y } G < B \\ 60^\circ \frac{B-R}{\max - \min} + 120^\circ, & \text{si } \max = G \\ 60^\circ \frac{R-G}{\max - \min} + 240^\circ, & \text{si } \max = B \end{cases} \quad (49)$$

$$S = \begin{cases} 0, & \text{si } \max = 0 \\ 1 - \frac{\min}{\max}, & \text{en otro caso} \end{cases} \quad (50)$$

$$V = \max \quad (51)$$

#### 4.2.10. Modelo de apariencia de color CIECAM 02

Existen otros espacios basados en modelos de apariencia de color, por ejemplo el espacio de color CIECAM 02 (modelo de apariencia de color adoptado por CIE en 2002).

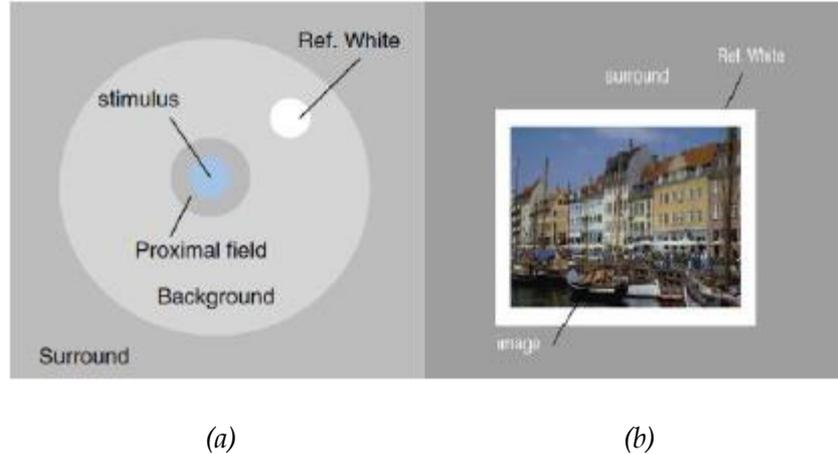


Figura 4.19. Espacio de color CIECAM 02

(a) Parámetros usados en CIECAM 02. (b) Parámetros en una imagen. [35]

Observando la figura 4.19 se puede decir que el estímulo (*stimulus*) es el objeto principal de la imagen. El campo próximo (*proximal field*) es el entorno más cercano al estímulo considerado. El fondo (*background*), es definido como el entorno que rodea al campo próximo y, finalmente, el campo externo (*surround*) es el campo más lejano. Para usarlo correctamente es importante entender los parámetros de entrada y salida del modelo. En la figura 4.20. se muestran estos parámetros.

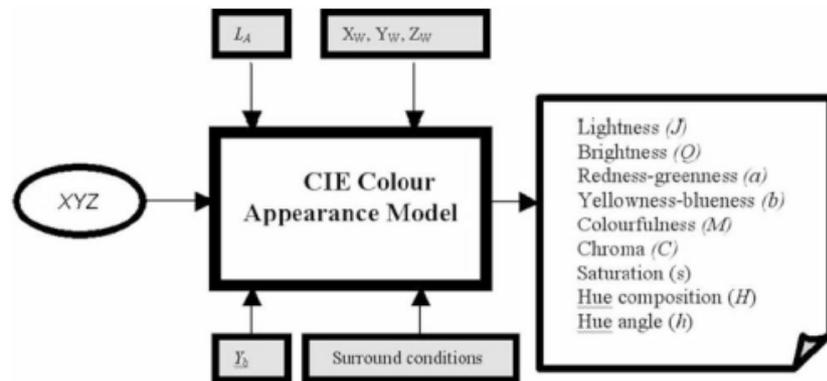


Figura 4.20. Esquemático modelo CIECAM 02

Las salidas del modelo de apariencia de color CIECAM 02 que se obtienen son varios términos o dimensiones que forman el modelo de color. Con 3 coordenadas de este modelo se obtiene el espacio de color

$JCh$ . Donde  $J$  es la luminancia,  $C$  la chroma y  $h$  el tono. El espacio de color  $JCh$  es uniforme y es el más objetivo debido al uso de condiciones de visualización para su cálculo.

Los resultados que se obtengan de este trabajo, serán comparados con este espacio de color  $JCh$ .

#### 4.2.11. Resumen de espacios de color

ESPACIOS DE COLOR	
NO UNIFORMES	UNIFORMES
RGB	$U^*V^*W^*$
XYZ	CIE LUV
HSI	CIE LAB
HSV	JCh (de CIECAM 02)

Tabla 1. Resumen Espacios de Color

### 4.3. Distancias de color

Si un espacio de color es uniforme y sus dimensiones ortogonales, entonces la diferencia entre dos colores se puede representar como la Distancia Euclídea entre sus coordenadas [36].

Los espacios de color CIELAB y CIELUV (CIE, 1976) están destinados a proporcionar únicamente un espacio de color uniforme a través de la transformación de los triestímulos XYZ. De esta manera, se consigue salvar los problemas que presentan los espacios no uniformes en cuanto a parecido con la percepción humana [36].

Las ecuaciones (37) y (44) mostradas en apartados anteriores definen las distancias de color CIELUV y CIELAB.

Estas distancias de color son ampliamente utilizadas, pero son

inadecuadas en ciertas aplicaciones como aquellas donde se requiere un único valor para definir la tolerancia en todo el espacio de color. Los mayores problemas que se han encontrado usando estas diferencias de color [36]:

- Uniformidad de los componentes de la diferencia de color: Chroma, Hue y Lightness.
- Condiciones de visión: Los instrumentos que se encargan de medir color, como el espectrómetro simple, recogen el estímulo que se le presenta sin tener en cuenta las condiciones bajo las cuales se están tomando las muestras.
- Superficie de características: Las características de los medios tales como el brillo y la textura son conocidos por inducir cambios de tal forma que por muy pequeñas que sean las variaciones de color, estas son percibidas.

Los problemas identificados arriba se pueden resolver de dos formas [36]:

1. El espacio de color puede ser modificado de manera que su uniformidad perceptual sea adecuada.
2. Ponderación de las ecuaciones de diferencias de color de manera que se corrijan las principales causas principales de no uniformidad.

A continuación se presentan algunas diferencias de color [36], derivadas de transformaciones en las coordenadas de CIELAB, que se han creado para resolver los problemas anteriores.

- **CMC**. Adoptada por el Colour Measurement Committee (CMC). Derivó de una considerable cantidad de datos experimentales acerca de la aceptabilidad de las muestras de color en la industria textil y parece que dio una uniformidad sustancialmente mejor a CIELAB para pequeñas diferencias de color.

$$\Delta E_{CMC} = \left[ \left( \frac{\Delta L^*}{l \cdot S_L} \right)^2 + \left( \frac{\Delta C_{ab}^*}{c \cdot S_C} \right)^2 + \left( \frac{\Delta H_{ab}^*}{S_H} \right)^2 \right]^{1/2} \quad (52)$$

- **BFD.** Una serie de conjuntos de datos experimentales que incluían tanto resultados de aceptabilidad como de perceptibilidad, fueron combinados para derivar en la distancia de color BFD.

$$\Delta E(\text{BFD}) = \left\{ \left[ \frac{\Delta L(\text{BFD})}{l} \right]^2 + \left[ \frac{\Delta C_{ab}^*}{cD_c} \right]^2 + \left[ \frac{\Delta H_{ab}^*}{D_H} \right]^2 + R_T \left( \frac{\Delta C_{ab}^*}{D_c} \right) \left( \frac{\Delta H_{ab}^*}{D_H} \right) \right\}^2 \quad (53)$$

La ecuación de la distancia de color BFD introduce una relación hue-chroma que mejora el ajuste con los datos experimentales. El término  $R_T$  controla la rotación de las elipses de tolerancia con su efecto máximo en las muestras de azul de croma alto.

- **CIE94.** Un comité técnico de CIE creado para hacer un estudio de evaluación de las diferencias de color en la industria, publicó su recomendación como CIE Technical Report, en 1995 [37]. La nueva ecuación fue conocida como CIE94. El artículo propuso una nueva ecuación de diferencia de color cuya estructura es similar a CMC:

$$\Delta E_{94}^* = \sqrt{\left( \left( \frac{\Delta L^*2}{k_L S_L} \right) + \left( \frac{\Delta C_{ab}^*2}{k_C S_C} \right) + \left( \frac{\Delta H^*2}{k_H S_H} \right) \right)} \quad (54)$$

donde  $S_L = 1, S_C = 1 + 0.045C_{ab}^*, S_H = 1 + 0.015C_{ab}^*$ .

El papel de los factores paramétricos es permitir que la ecuación sea sensible al ajuste de las componentes de luminosidad, croma y brillo para permitir que sus pruebas de evaluación difieran de las condiciones básicas por la cual se creó CIE94.

Estos parámetros se muestran en la Tabla 2, de la página siguiente.

- **CIEDE2000:** CIE propuso la primera revisión importante de CIE94 en 2001, donde se introdujo la interacción de los términos hue-chroma, similares a los de la ecuación de distancias de color de BFD, y también ajustes a las funciones de ponderación  $S_L$  y  $S_H$ . La ecuación de la distancia de color es la siguiente:

Iluminación	D65
Illuminance	1000lux
Background	Uniform neutral gray, L*=50
Sample size	Angular subtense greater tan 4°
Sample separation	Direct contact
Sample structure	Visually homogeneous
Magnitude of colour difference	$\Delta E_{ab} \leq 5.0$

Tabla 2. Condiciones de referencia adoptadas en CIE94.

$$\Delta E_{00} = \left\{ \left[ \frac{\Delta L'}{k_L S_L} \right]^2 + \left[ \frac{\Delta C'_{ab}}{k_C S_C} \right]^2 + \left[ \frac{\Delta H'_{ab}}{k_H S_H} \right]^2 + R_T \left( \frac{\Delta C'_{ab}}{k_C S_C} \right) \left( \frac{\Delta H'_{ab}}{k_H S_H} \right) \right\}^{\frac{1}{2}} \quad (55)$$

Las ecuaciones detalladas de las distancias de color nombradas arriba se encuentran en el libro Colour Engineering [36].

DISTANCIAS DE COLOR		
Derivadas de Distancia Euclídea:	CIE LAB	
	CIE LUV	
Derivadas de CIE LAB y CIE LUV:	CMC	CIE94 (a partir de CMC)
	BFD	CIEDE2000 (a partir de BFD.

Tabla 3. Resumen Distancias de color.



# 5. CLASIFICADORES

---

El objetivo de un clasificador es obtener un sistema que sea capaz de predecir un tipo de clase a partir de un conjunto de muestras conocidas. En nuestro caso las muestras serán píxeles. Existen dos tipos de clasificadores: los supervisados y los no supervisados. En el entrenamiento de los clasificadores supervisados es necesario indicar de qué clase es cada vector de características, mientras que los no supervisados lo hacen por sí mismos. Este capítulo se centrará en los supervisados.

En general, para la creación del clasificador es necesario tener un conjunto de píxeles para entrenamiento con sus respectivas etiquetas de clase (o verdad de referencia), y otro conjunto para clasificación. Ningún píxel del conjunto de entrenamiento puede estar presente en el conjunto de clasificación y viceversa. Además, se recomienda que todos los píxeles estén normalizados.

Así, una proporción de píxeles se utiliza para enseñar al clasificador, y el restante, para comprobar la fiabilidad del mismo. Si el clasificador tiene un porcentaje de acierto aceptable, en un futuro, será capaz de clasificar píxeles de los cuales se desconoce su clase con una fiabilidad significativa.

A continuación se explicarán los clasificadores más importantes.

## 5.1. K-Nearest Neighbor

k-NN [38] es un método de clasificación que estima la probabilidad a posteriori de que un elemento  $x$  pertenezca a la clase  $C$ , a partir de la información proporcionada por el conjunto de entrenamiento.

Sea el vector de características, con  $p$  atributos, perteneciente a la muestra  $i$  del conjunto  $N$ :

$$x_i = (x_{1i}, x_{2i}, \dots, x_{pi}) \quad i = 1, \dots, N. \quad (56)$$

Entonces se toma cada vector de características como las coordenadas de un espacio de dimensión  $N$ . Si deseamos clasificar una nueva muestra entre los  $k$  vecinos más cercanos, se posiciona y se cuantifican el número de elementos de las distintas clases que le rodean.

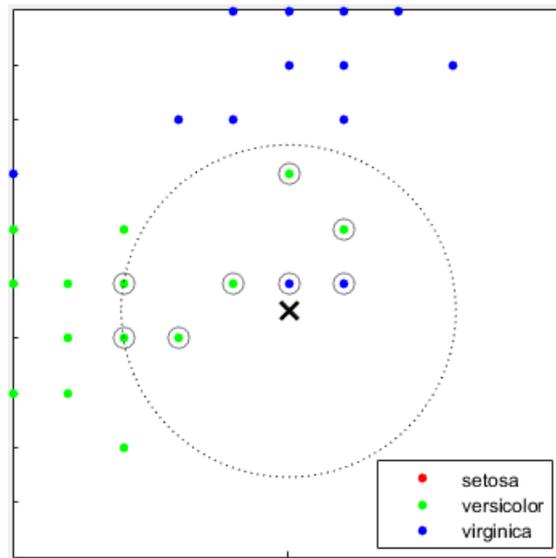


Figura 5. 1. Ejemplo espacio de muestras  $k$ -NN [39].

En ejemplo que se muestra en la figura 5.1., con  $k=8$ , se determinaría que la nueva muestra es *versicolor* ya que existen seis muestras *versicolor* y dos *virginica*. Si deseásemos clasificar con  $k=3$  la predicción sería *virginica* ya que existe dos muestras *virginica* y una muestra *versicolor*.

La selección del tipo de distancia del vecino más cercano puede variar la toma de decisión [39]:

1. Distancia euclídea:

$$d_{ij} = \sqrt{\sum_{r=1}^p (x_{ri} - y_{rj})^2} \quad (57)$$

donde  $x_{ri}$  son las coordenadas del píxel e  $y_{rj}$  las coordenadas del vecino en  $(r,j)$ .

2. Distancia ponderada: se da mayor peso a los vecinos más cercanos. Así luego no hay riesgo de permitir a un vecino muy lejano (aunque perteneciente al conjunto  $k$ ) contribuir a la clasificación de  $x$ .

$$d_{ij} = \sqrt{\sum_{r=1}^P w_i (x_{ri} - y_{rj})} \quad (58)$$

donde  $w_i$  representa el vector de pesos inverso.

3. Distancia de Minkowski:

$$d_{ij} = \sqrt[P]{\sum_{r=1}^N |x_{ri} - y_{rj}|^P} \quad (59)$$

Casos especiales:

- a)  $P=1$ , entonces  $d_{ij}$  es la distancia de City Block.
- b)  $P=2$ , entonces  $d_{ij}$  es la distancia euclídea.
- c)  $P= \infty$ , entonces  $d_{ij}$  es la distancia de Chebychev.

4. Distancia del coseno:

$$d_{ij} = \left( 1 - \frac{x_i y'_j}{\sqrt{(x_i x'_i) \cdot (y_i y'_j)}} \right) \quad (60)$$

donde  $x$  es el vector de coordenadas del píxel e  $y$  el vector de coordenadas vecino que se toma la distancia.

La influencia de la distancia reside en la elección de las muestras que se usan para tomar una decisión. Es posible que entre dos tipos de distancias, se seleccionen muestras que tengan clases distintas y, por tanto, cambie la decisión que toma el clasificador.

## 5.2. Redes Neuronales

Las redes neuronales artificiales (RNA) son una familia de modelos inspirados en las redes neuronales biológicas. Su objetivo es simular las tareas cognitivas del ser humano mediante un algoritmo.

Están formadas por un conjunto de unidades, llamadas neuronas, que están interconectadas entre sí:

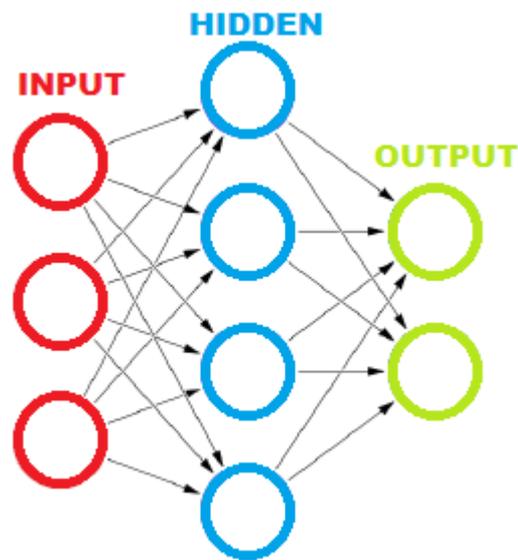


Figura 5. 2. Red Neuronal. [40]

En cualquier red neuronal con  $i$  neuronas, existen 3 elementos [41]:

- **Función o regla de propagación:** permite obtener a partir de las entradas y los pesos, el valor potencial postsináptico  $h_i(t)$  de la neurona.

$$h_i(t) = \sum_j w_{ij}x_j \quad (61)$$

donde  $w_{ij}$  representa el peso de la unión  $(i, j)$ ,  $x_j$  el valor de la neurona presináptica  $j$ . Dada una entrada positiva, y si el peso es positivo, el sistema excitará a la neurona postsináptica, y si es negativo tenderá a inhibirla.

- **Función de activación:** proporciona el estado de activación actual  $a_i(t)$  a partir del potencial postsináptico  $h_i(t)$  y del estado de activación anterior  $a_i(t - 1)$ :

$$a_i(t) = f_i(a_i(t - 1), h_i(t)) \quad (62)$$

En ocasiones, se determina que el estado anterior no afecta al estado de activación, dependiendo así, solamente del potencial postsináptico.

Entre las funciones de activación  $f_i$  habituales puede seleccionarse: la identidad, el escalón, funciones sigmoideas, gaussianas o sinusoidales.

- **Función de salida:** proporciona la salida de la neurona en función de su estado de activación actual. Normalmente, la función de salida es la identidad, de modo que el estado de activación de la neurona se considera la propia salida.

Durante la fase de entrenamiento, la red neuronal aprende mediante la actualización de los pesos que caracterizan a las conexiones. Los pesos se adaptan de acuerdo a la información extraída de las características de las muestras. Normalmente, se eligen los pesos optimizando cierta función de energía.

Posteriormente, una vez fijados los pesos de la red neuronal, se prueba la capacidad que tiene la red de dar una respuesta correcta ante patrones que no han sido empleados en su entrenamiento.

### 5.3. Support Vector Machine (SVM)

Support Vector Machine (SVM) es un clasificador supervisado desarrollado por V. Vapnik en 1995 [42]. El objetivo de SVM es dividir un espacio de muestras, linealmente separables según su clase, mediante un hiperplano.

Durante la clasificación, las muestras que están a un lado del hiperplano se etiquetaran como una clase, y las que están al otro como otra.

Sea el vector de características, con P atributos, perteneciente a la muestra i del conjunto N:

$$x_i = (x_{1i}, x_{2i}, \dots, x_{pi}) \quad i = 1, \dots, N. \quad (63)$$

Se toma cada vector de características como las coordenadas de un espacio de dimensión N, denominando los vectores de soporte. Así, SVM clasifica la información de entrada encontrando el mejor hiperplano que separa los puntos de una clase de otra.

El mejor es aquel que tiene la mayor distancia, perpendicular al hiperplano, entre dos vectores soporte de clases distintas sin que ningún otro vector soporte pertenezca a ella.

Debido a la dificultad de separabilidad de los datos, en ocasiones se define un margen *suave*, que permite que cierto número de muestras pertenezcan al margen.

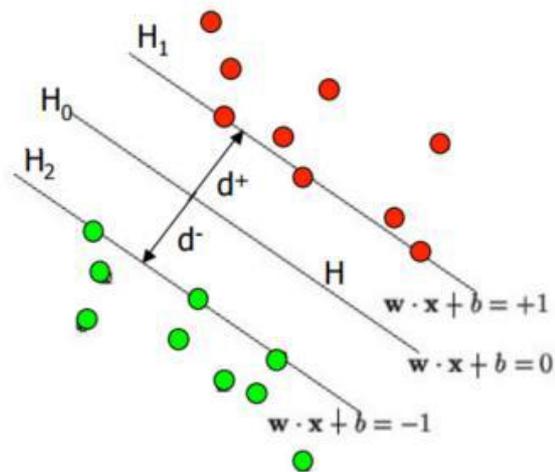


Figura 5. 3. Hiperplano y margen caso 2D [43].

Definiendo el hiperplano H tal que [43]:

$$w \cdot x_i + b \geq 1 \quad \text{cuando } y_i = 1 \quad (64)$$

$$w \cdot x_i + b \geq -1 \quad \text{cuando } y_i = -1 \quad (65)$$

Donde  $w$  denota el vector normal al hiperplano,  $b$  el término independiente y  $x$  e  $y$  coordenadas en el espacio. Entonces los planos  $H_1$  y  $H_2$  se definen como:

$$w \cdot x_i + b = 1 \quad (66)$$

$$w \cdot x_i + b = -1 \quad (67)$$

Si el conjunto de entrenamiento es linealmente separable podemos seleccionar dos hiperplanos en el borde de los conjuntos de vectores de soporte maximizando su distancia.

La distancia entre  $H_0$  y  $H_1$  es por tanto:

$$\frac{|w \cdot x + b|}{\|w\|} = \frac{1}{\|w\|} \quad (68)$$

Para maximizar el margen, debemos minimizar  $\|w\|$ . Desarrollando por el método Lagrange el problema a resolver es:

$$\min \frac{1}{2} \|w\|^2 - \sum_i a_i y_i (x_i \cdot w + b) + \sum_i a_i \quad (69)$$

donde los términos  $a_i$  constituyen una representación del vector de pesos en el conjunto de entrenamiento.

Analizando el problema primal y dual encontramos que la ecuación del plano es:

$$w = \sum_i a_i y_i x_i \quad (70)$$

donde los términos  $a_i$  constituyen una representación del vector de pesos en el conjunto de entrenamiento.

En la mayoría de los casos, el problema de separación no es lineal. Para ello, se definen unas funciones o kernels que transforman el espacio de entrada en un espacio que sea separable linealmente.

Existen multitud de kernels además del lineal: cuadrático, cubico, gaussiano o con bases radiales. Dependiendo de la forma que muestre el espacio de muestras, habrá que seleccionar el kernel que mejor se adapte para obtener una separabilidad clara.

#### 5.4. Árboles de decisión

El objetivo de los árboles de decisión es crear un modelo que prediga el valor de una variable de salida en función de diversas variables de entrada. Cada hoja es un valor de la variable de salida y cada rama representa la conjunción de características o condiciones que conducen a ese valor de la variable de salida. Si la variable de salida toma valores continuos, se le denomina árboles de regresión.

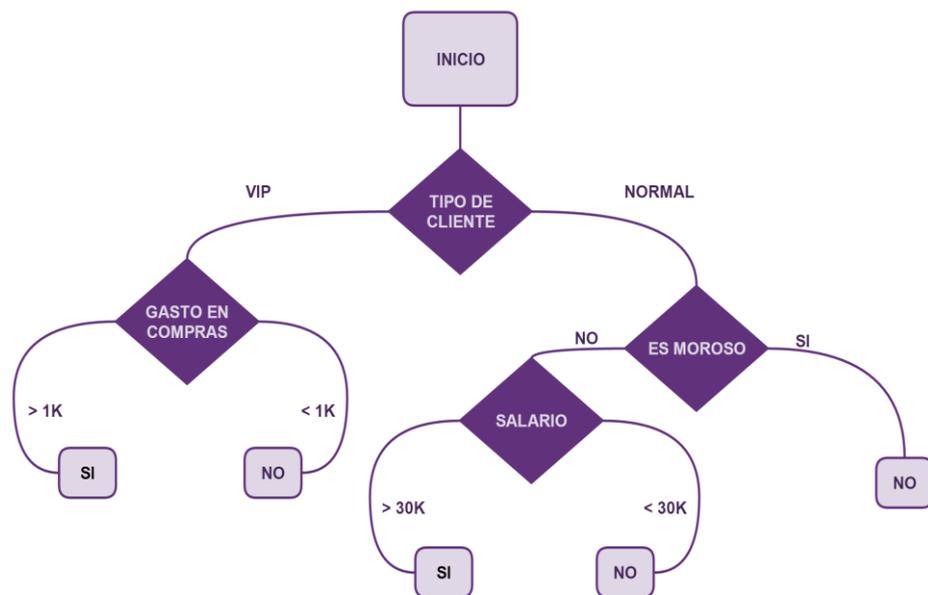


Figura 5. 4. Árbol de decisión. ¿Ofertar producto al cliente? [40]

Particularmente, en la clasificación de píxeles, cada hoja del árbol representa un tipo de clase, y cada rama, un conjunto de características.

Los clasificadores de un solo árbol de decisión que se utilizarán para desarrollar este trabajo son los siguientes [44]:

**Simple Tree:** Es un árbol de decisión simple con algunas hojas que hacen unas distinciones bastante menos finas, debido a su número máximo de divisiones que es 4.

**Medium Tree:** Es un árbol de decisión de mediana complejidad con menos hojas. El número máximo de divisiones es 20.

**Complex Tree:** Es un árbol de decisión con muchas hojas que hace una distinción muy fina entre clases. El número máximo de divisiones es 100.

Algunas técnicas construyen clasificadores con más de un árbol de decisión. Este el caso de los métodos:

**Bagging** (Breiman, 1996) [45]: construye varios árboles de decisión de gran tamaño muestreando repetidamente la información de entrenamiento y los promedia para obtener el clasificador. Finalmente, clasifica según la clase que más se repita.

**Boosting** (Freund & Shapire, 1996) [46]: clasificador que crea varios árboles de decisión utilizando todos los datos de entrenamiento. Para los casos que fueron erróneamente clasificados, se les aplica un peso para que los siguientes árboles mejoren su respuesta. Existen versiones como AdaBoost [46] (Adaptative Boosting) y LogiBoost [47] (Logistic Adaptation): ambas intentan asignar adaptativamente los pesos de los árboles de decisión para mejorar la respuesta del clasificador.

Como tabla resumen de los clasificadores se tiene la que se muestra en la página siguiente:

Tipos de Clasificadores				
K-NN	SVM	Decision Tree		R. Neuronales
-Fine -Medium	-Linear -Cuadratic -Cubic	<b>Un árbol</b> -Complex Tree -Medium Tree -Simple Tree	<b>Varios</b> -Bagger -AdaBoost	

## 6. ALGORITMO IMPLEMENTADO

---

Una vez hecho el estudio previo, se procede a explicar detalladamente el algoritmo implementado para la formación del clasificador. En la siguiente figura (Figura 6.1) se muestra una visión general del proceso, dividido en bloques:



*Figura 6. 1. Esquema general del algoritmo del clasificador*

El objetivo del clasificador es obtener un sistema que sea capaz de

segmentar la región perteneciente a la excavación del nervio óptico en imágenes de retinografías. Se hará una clasificación a nivel de píxel. Para ello definiremos 3 clases, que serán:

- Clase 1: El píxel no pertenece ni al borde del disco óptico, ni al borde del excavación.
- Clase 2: El píxel pertenece al borde del disco óptico.
- Clase 3: El píxel pertenece al borde del excavación.

Es importante añadir que el conjunto de retinografías seleccionadas para la clasificación no puede contener ninguna que haya sido usada previamente para realizar el entrenamiento. Además, se recomienda que las imágenes estén ajustadas para que tengan el mismo tamaño, formato y condiciones de iluminación.

En este caso no ha sido posible conseguir que las condiciones de iluminación sean las mismas, por lo que más adelante se explicará cómo se ha solucionado el problema.

A cada imagen se le calculará una matriz de características, donde cada fila será un vector que contendrá las características de un píxel y, como último elemento de la fila, se le asignará la correspondiente verdad de referencia o etiqueta (ver capítulo 5).

En el apartado 6.4. se entrenará al clasificador, y posteriormente, en el apartado 6.5. se clasificará el resto de muestras para conocer la fiabilidad del mismo.

A lo largo de los siguientes apartados se desarrollaran las pruebas y los resultados del algoritmo.

## 6.1. Selección de imágenes de retinografías

Las bases de datos de las que se ha partido para realizar el algoritmo de clasificación se han escogido a conciencia, porque:

- Son **públicas**: Hasta ahora no existía ninguna base pública de retinografías dedicada a glaucoma, es decir, la verdad de referencia que existía se correspondía con vasos sanguíneos del disco óptico y microaneurismas. Las imágenes que existían eran privadas y entonces no se podía verificar que su fuente era fiable. Se necesitan imágenes públicas de bases de datos que puedan proporcionar toda la información de adquisición, de iluminación, tamaño de las imágenes, que sean de distintos pacientes, etc.
- Son de **fuentes variadas**. Esto hace que tengan diferencias de iluminación, de forma de adquisición, etc. Así, encontrar un algoritmo que funcione, será más difícil y, en el caso de hallarlo, tendrá una mayor robustez.
- Tienen **diversas enfermedades**, como degeneración macular, retinopatía diabética, glaucoma e, incluso, algunas son de personas **sanas**. Esto hace el problema aún más realista y difícil.

Por tanto, se han elegido imágenes de 6 bases de datos, que son:

1. **Messidor** [48], es una base de datos que ha sido establecida para facilitar los estudios sobre diagnósticos asistidos de forma computacional de la retinopatía diabética. El uso para el que se desarrolló esta base fue para detectar el grado de retinopatía y el riesgo de edema macular. La base de datos proviene del Ministerio de Investigación y Defensa francés dentro del programa TECHNO -VISION 2004.

Cuenta con 1200 imágenes con las siguientes características:

- Formato: TIFF
- Tamaño: 900x600
- Dispositivo de adquisición: Retinógrafo Topcon TRC NW6 con cámara de video 3CCD en color y ángulo de visión 45°.
- Condiciones de iluminación: No disponible.

2. **Erlangen** [49], base de datos que proviene del Laboratorio de reconocimiento de Patrones (CS5), del Departamento de Oftalmología de la Universidad de Friedrich-Alexander de Erlangen-Numembert (Alemania) y la Universidad Tecnológica de Brno (República Checa), en la Facultad de Ingeniería Eléctrica y Comunicaciones, dentro del Departamento de Ingeniería Biomédica. Esta base de datos contiene 15 imágenes de pacientes sanos, 15 imágenes de pacientes con retinopatía diabética y 15 pacientes con glaucoma, con las siguientes características:

- Formato: JPEG
- Tamaño: 900x600
- Dispositivo de adquisición: Retinógrafo con cámara Canon CR-1 y ángulo de visión 45° y diferentes ajustes de adquisición.
- Condiciones de iluminación: No disponible.

3. **DRIVE** [50], o Digital Retinal Images for Vessel Extraction. Esta base de datos se ha desarrollado para hacer posibles estudios comparativos sobre la segmentación de los vasos sanguíneos en la retina. Las imágenes se obtuvieron gracias a un programa de selección de imágenes de retinopatía diabética que se realizó en los Países Bajos. El rango de edad de los 400 pacientes diabéticos se encontraba entre los 25 y los 90 años.

- Nº de retinografías: 40
- Formato: TIFF
- Tamaño: 565x584
- Dispositivo de Adquisición: Retinógrafo Canon CR5 no midriático con cámara de video 3CCD en color y ángulo de visión 45°.

- Condiciones de iluminación: No disponible.
4. **HEI-MED (DMED)** [37], o Hamilton Eye Institute Macular Eye Dataset, es una colección de 169 retinografías recogidas como parte de una red de telemedicina para diagnóstico de retinopatía diabética desarrollado por el Instituto del Ojo de Hamilton y el Grupo de Visión Artificial y Ciencia de la Imagen en ORNL (Oak Ridge National Laboratory), con la colaboración de la Universidad de Borgoña (Francia).
- Formato: JPEG
  - Tamaño: 781x600
  - Dispositivo de Adquisición: No disponible
  - Condiciones de iluminación: No disponible
5. **STARE** [38], o STructured Analysis of de REtina, es un proyecto de la Universidad de California (San Diego). Las imágenes que se utilizan en este trabajo, son las que se usaron en el proyecto STARE y fueron proporcionadas por el Centro Oftalmológico Shiley de la Universidad de California y por el Veterans Administration Medical Center, en San Diego.
- Nº de retinografías: 400
  - Formato: JPG
  - Tamaño: 700x605
  - Dispositivo de Adquisición: No disponible
  - Condiciones de iluminación: No disponible
6. **Aria DataSet** [39], o Automated Retinal Image Analysis, en la que han contribuido en el desarrollo tres hospitales: Hospital Universitario de Canarias (Isla de Gran Canaria, España), Hospital Clínico San Carlos (Madrid, España) y Hospital Universitario Miguel Servet (Zaragoza, España).
- Nº de Retinografías: 105
  - Formato: JPEG
  - Tamaño: 768x576
  - Dispositivo de adquisición: No disponible
  - Condiciones de iluminación: No disponible

A continuación, se muestra una tabla resumen de todas las bases de datos que se van a utilizar:

	FORMATO	TAMAÑO	ADQUISICIÓN	Nº TOTAL
MESSIDOR	TIFF	900x600	Retinógrafo Topcon TRC NW6	1200
ERLANGEN	JPEG	900x600	Retinógrafo Canon CR-1	45
DRIVE	TIFF	565x584	Retinógrafo Canon CR-5	40
DMED	JPEG	781x600	No disponible	169
STARE	JPG	700x605	No disponible	400
ARIA	JPEG	768x576	No disponible	105

*Tabla 4. Resumen de las bases de datos escogidas.*

De todas estas bases, se ha hecho una selección de 80 retinografías, teniendo en cuenta que ésta debía contar con:

- Retinografías en las que, a simple vista, se viera la excavación bien diferenciada.
- Retinografías en las que la excavación estuviera difusa.
- Retinografías que contuvieran vasos sanguíneos dentro de la excavación y también otras que contuvieran vasos fuera.

El fin de seleccionar las imágenes de esta forma es darle más fiabilidad al algoritmo, de manera que no sólo detecta la excavación que es más clara, sino también la que es más difusa y, por tanto, no se diferencia bien del resto del disco óptico. En las siguientes Figuras (6.2. - 6.14.) , se muestran algunas de estas retinografías:



*Figura 6. 2. Retinografía de Erlangen DataBase (I)  
con vasos sanguíneos dentro del excavación y excavación claramente diferenciable*



*Figura 6. 3. Retinografía de Erlangen DataBase (II)  
con vasos sanguíneos en el borde del excavación y claramente diferenciable.*



*Figura 6. 4. Retinografía de Aria DataSet (I)  
con excavación muy pequeño, vasos en el borde y claramente diferenciable.*

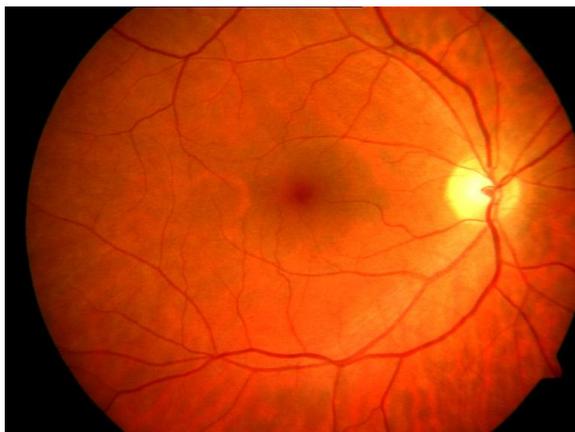


Figura 6. 5. Retinografía de Aria DataSet (II). Excavación difuso.



Figura 6. 6. Retinografía de STARE DataBase (I). Excavación diferenciable.



Figura 6. 7. Retinografía de STARE DataBase (II). Excavación diferenciable.

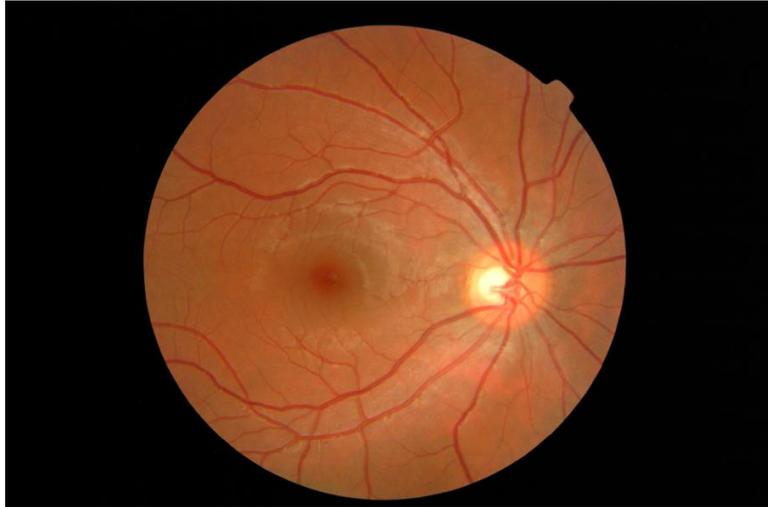


Figura 6. 8. *Retinografía de Medissor DataBase (I).*  
*Excavación claramente diferenciable*

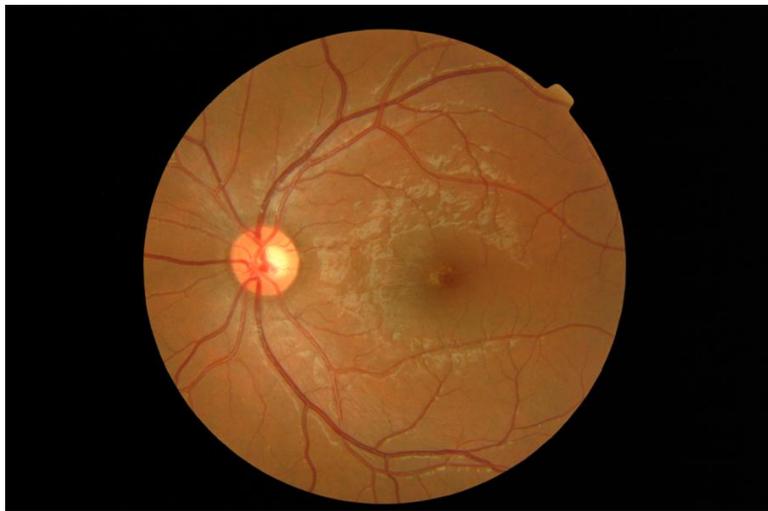


Figura 6. 9. *Retinografía de Medissor DataBase (II)*



Figura 6. 10. *Retinografía de Drive DataBase (I).* *Excavación diferenciable.*



Figura 6. 11. *Retinografía de Drive DataBase (II).  
Excavación diferenciable. Vasos que cruzan el excavación.*



Figura 6. 12. *Retinografía de DMED (I). Excavación difuso.*

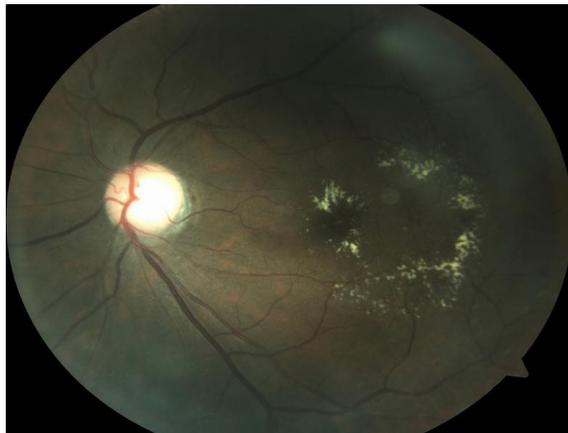


Figura 6. 13. *Retinografía de DMED (II). Excavación difuso.*

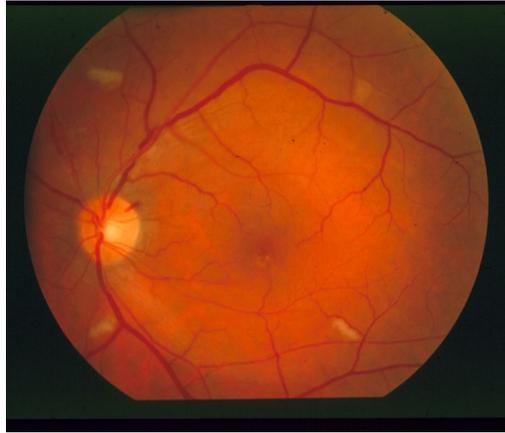


Figura 6. 14. Retinografía de STARE Database (III).  
Excavación difuso y pequeño.

## 6.1. Pre-procesado

Para conseguir una buena clasificación es necesario hacer una serie de cambios y extraer cierta información a las imágenes. El conjunto de modificaciones previas a la clasificación es lo que entendemos por pre-procesado. Podemos dividir el pre-procesado en dos módulos que se realizan en paralelo, es decir, que son independientes.

- Pre-procesado sobre las retinografías originales:



Figura 6. 15. Esquema Pre-Procesado.

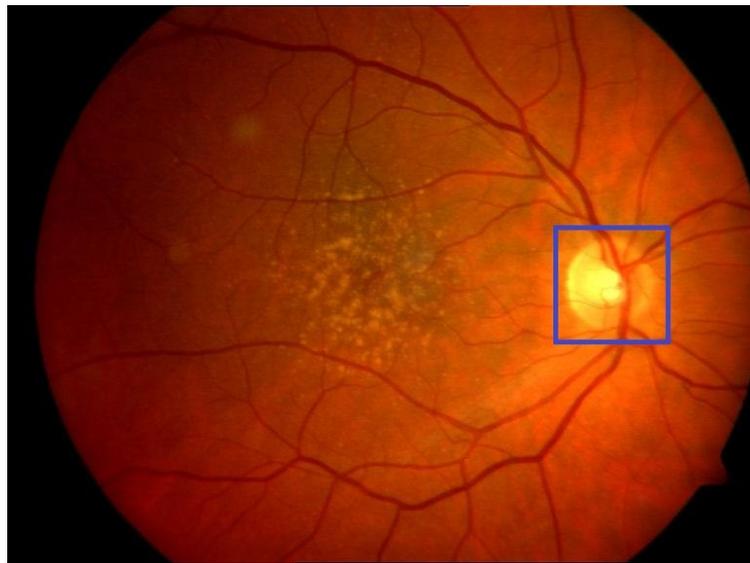
- Construcción de la Verdad de Referencia:



Figura 6. 16. Esquema Verdad Referencia.

De las retinografías que se han seleccionado para segmentar la excavación, sólo interesa la zona donde se encuentra el disco óptico, llamada ROI (del inglés, Region Of Interest).

El primer paso a realizar será seleccionar la zona y recortarla. Al limitar el análisis a esta ROI se logra reducir considerablemente los recursos computacionales. Como se dijo anteriormente, es importante que todas las imágenes tengan el mismo tamaño. Esta selección se realiza localizando el centro del disco óptico [51] y trazando un área cuadrada centrada en él con una superficie del 7% de la imagen total del fondo de ojo. Esta restricción es generalmente adoptada para ser utilizada en otros algoritmos, como podemos ver en [9].



*Figura 6. 17. Selección de la ROI sobre la retinografía.*



*Figura 6. 18. Resultado del recorte de la ROI.*

El siguiente paso, una vez tenemos todas las ROI recortadas, es calcular el gradiente (derivada) de color de cada imagen y por píxel, en 360 grados, con pasos de 15 grados.

Se han propuesto varios detectores de bordes de color que determinan las derivadas direccionales en dos direcciones, la mayoría de ellos utilizan la distancia euclídea en el espacio de color seleccionado para medir las diferencias de color.

Se ha seleccionado la distancia de color CIE94, que es eficiente para el cómputo de derivadas direccionales. Se utiliza, entonces, una máscara Sobel, en el espacio de color Lab y con CIE94, basándose en en [1].

A pesar del hecho de que CIEDE2000 fue desarrollado para corregir CIE Lab más allá que CIE94, algunos autores afirman que esta es una fórmula para las pequeñas diferencias de color [52], y que, aunque la ecuación CIEDE2000 ciertamente se comporta mejor que CIE94 para algunos conjuntos de datos, su complejidad añadida, probablemente, no está justificada en determinadas aplicaciones prácticas [53]. Además, "Melgosa et al." [54] encontraron que la mejora de CIE94 sobre CIE Lab era considerablemente mayor que la de CIEDE2000 sobre CIE94.

Se consideran las coordenadas de un píxel de la imagen  $(x, y)$  denotadas como:

$$a(x, y) = [L^*(x, y), a^*(x, y), b^*(x, y)] \quad (71)$$

Las derivadas pueden obtenerse restando dos vectores, el primero que contiene los coeficientes positivos de la máscara,  $V^+$ , y el otro con los coeficientes negativos  $V^-$ . Se presenta un ejemplo para el caso de  $0^\circ$  y para el caso de  $45^\circ$ .

$a_1$	$a_2$	$a_3$
$a_4$	$a_4$	$a_5$
$a_6$	$a_7$	$a_7$

PARA  $0^\circ$

1	2	1
0	0	0
-1	-2	-1

PARA  $45^\circ$

-2	-1	0
-1	0	1
0	1	2

$$V^+ = a_1 + 2a_2 + a_3 \quad (72)$$

$$V^- = -a_7 - 2a_8 - a_9 \quad (73)$$

$$V^+ = a_6 + a_8 + 2a_9 \quad (74)$$

$$V^- = -2a_1 - a_2 - a_4 \quad (75)$$

La distancia se obtiene como  $v = ||\Delta E_{94}(V^+, V^-)||$ , donde  $v$  es el valor

de la norma de las diferencias de color de la imagen en el píxel en cuestión y  $\Delta E_{94}(V+, V-)$  es la distancia de color CIE94 entre ambos vectores.

La explicación de por qué se calcula el gradiente en 360 grados es debido a que los píxeles del borde de la excavación tienen un color distinto a los píxeles del disco óptico colindantes. Esta variación del color es lo que se pretende medir con el cálculo de los gradientes.

Así, en el caso de las retinografías, se obtienen 25 imágenes por cada ROI, en las que se pueden ver las diferencias de color. A continuación, se muestra un ejemplo de una ROI y sus 25 imágenes de gradiente. (Figuras 6.20-6.45).

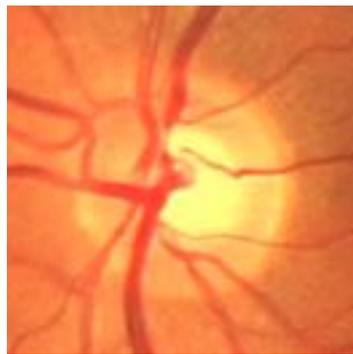


Figura 6. 19. ROI original

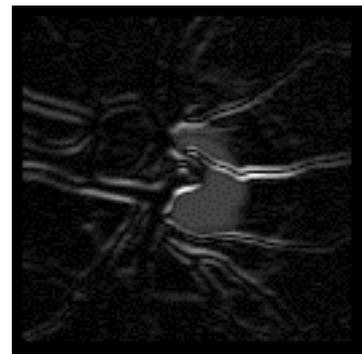


Figura 6. 20. M ( $\theta=0^\circ$ )

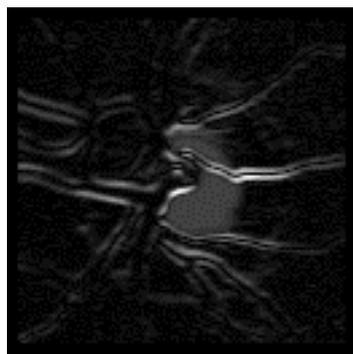


Figura 6. 21. M ( $\theta=15^\circ$ )

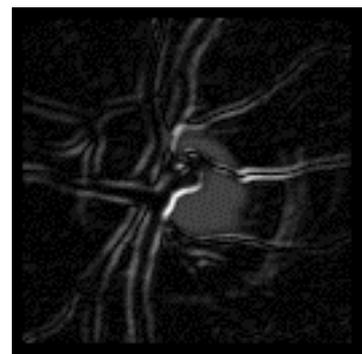


Figura 6. 22. M ( $\theta=30^\circ$ )

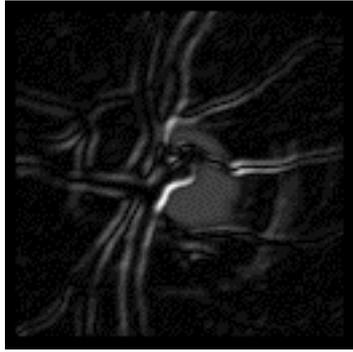


Figura 6. 23.  $M$  ( $\theta=45^\circ$ )

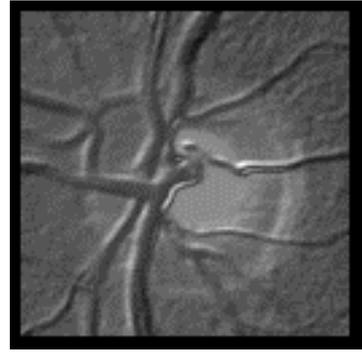


Figura 6. 24.  $M$  ( $\theta=60^\circ$ )

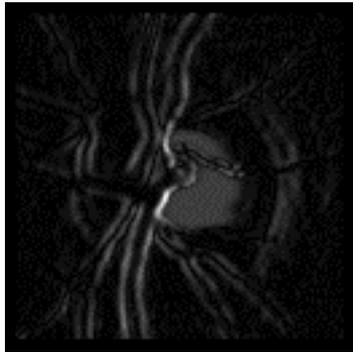


Figura 6. 25.  $M$  ( $\theta=75^\circ$ )

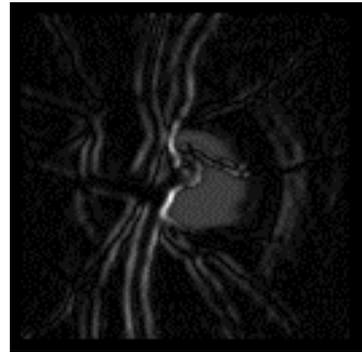


Figura 6. 26.  $M$  ( $\theta=90^\circ$ )

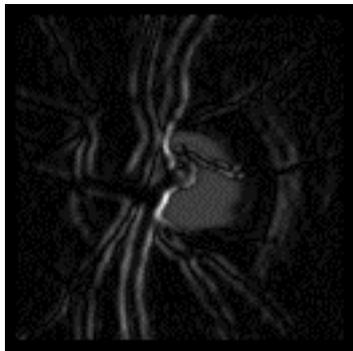


Figura 6. 27.  $M$  ( $\theta=105^\circ$ )

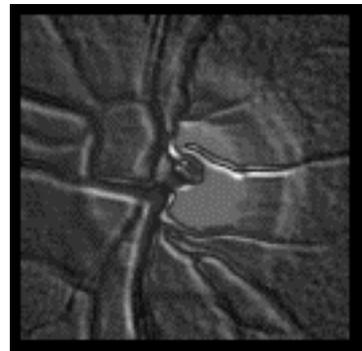


Figura 6. 28.  $M$  ( $\theta=120^\circ$ )

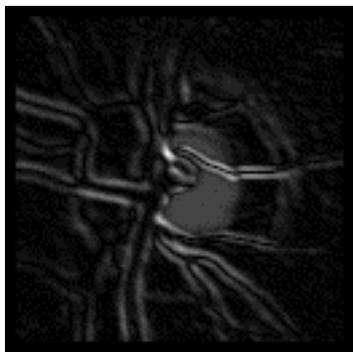


Figura 6. 29.  $M$  ( $\theta=135^\circ$ )

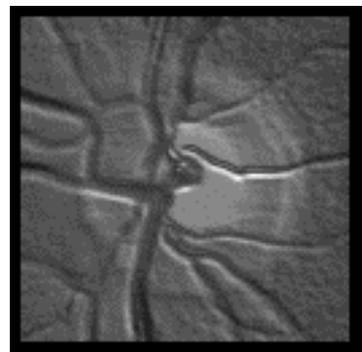


Figura 6. 30.  $M$  ( $\theta=150^\circ$ )

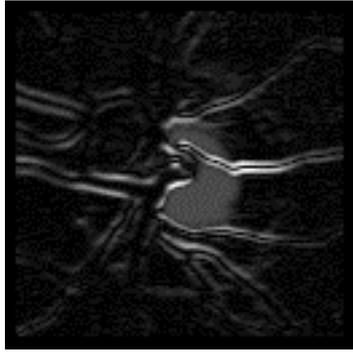


Figura 6. 31.  $M (\theta=165^\circ)$

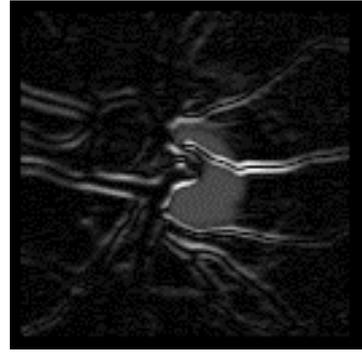


Figura 6. 32.  $M (\theta=180^\circ)$

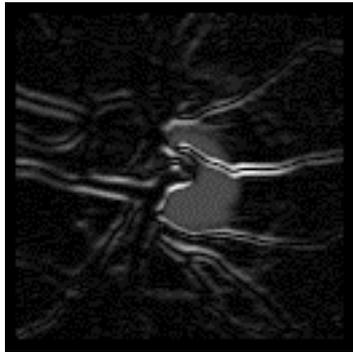


Figura 6. 33.  $M (\theta=195^\circ)$

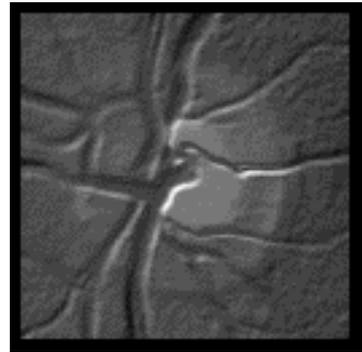


Figura 6. 34.  $M (\theta=210^\circ)$

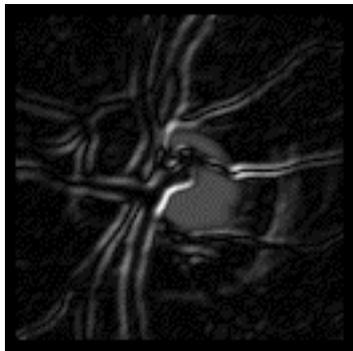


Figura 6. 35.  $M (\theta=225^\circ)$

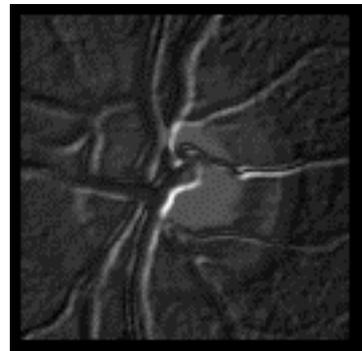


Figura 6. 36.  $M (\theta=240^\circ)$

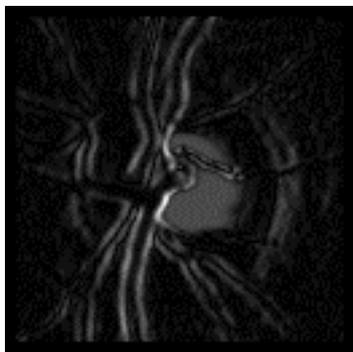


Figura 6. 37.  $M (\theta=255^\circ)$

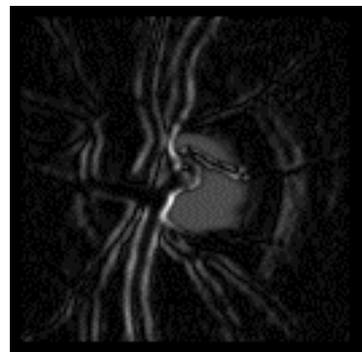


Figura 6. 38.  $M (\theta=270^\circ)$

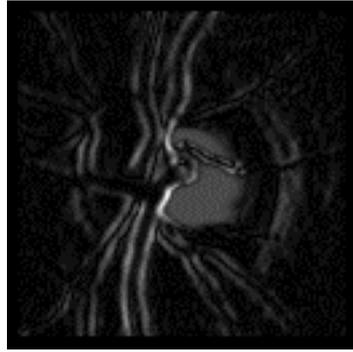


Figura 6. 39.  $M (\theta=285^\circ)$

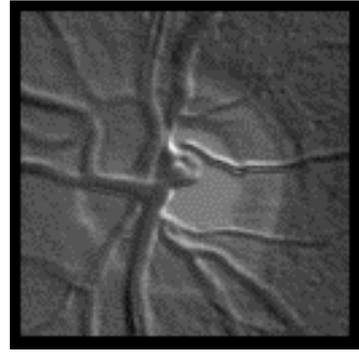


Figura 6. 40.  $M (\theta=300^\circ)$

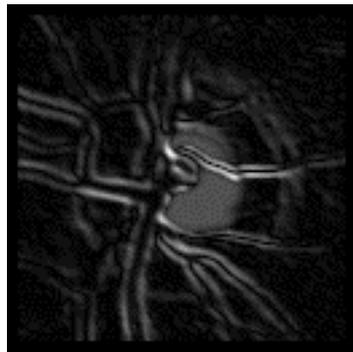


Figura 6. 41.  $M (\theta=315^\circ)$

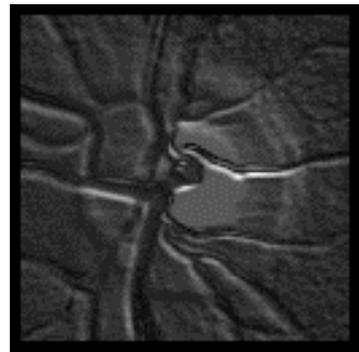


Figura 6. 42.  $M (\theta=330^\circ)$

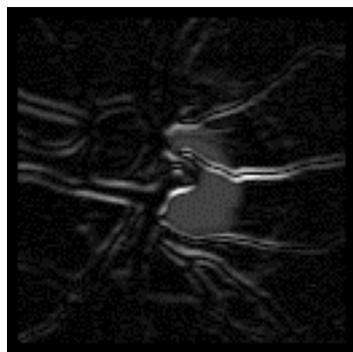


Figura 6. 43.  $M (\theta=345^\circ)$

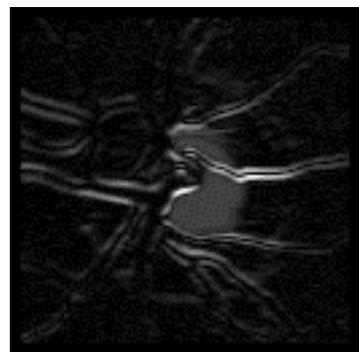


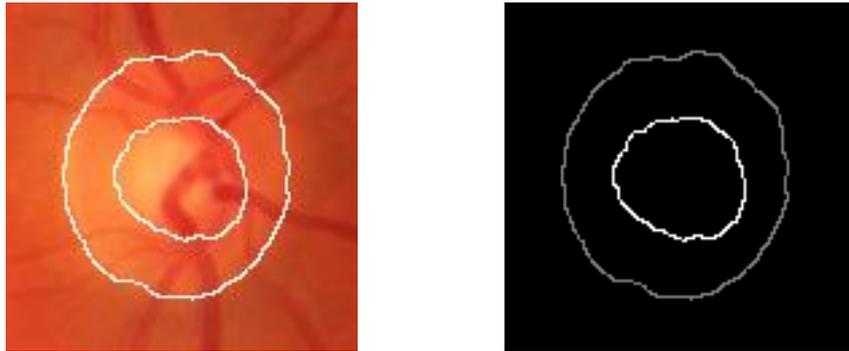
Figura 6. 44.  $M (\theta=360^\circ)$

Observando las imágenes resultantes de calcular los gradientes de color, se aprecian puntos de grandes cambios de color (las zonas más brillantes) en las regiones donde se encuentran los vasos sanguíneos dentro de la excavación. Esto se traduce en que, calculando los gradientes, no es necesario añadir la información de curvatura de los vasos, como se ha venido haciendo en otros métodos anteriormente [17] [19]. Como se detalla en estos artículos, detectar la curvatura de los vasos es un proceso muy complejo y, de esta manera, se está incluyendo la información de curvatura y color en un mismo procedimiento, lo que da una mayor eficiencia a este método.

Al no tener la verdad de referencia de las retinografías para la segmentación de la excavación, se ha tenido que construir una para poder realizar el entrenamiento y, posteriormente, verificar la robustez del clasificador.

Se parte de la imagen ROI y se selecciona la zona que corresponde con el borde de la excavación y la que corresponde con el borde del disco óptico, de forma manual.

Una vez tenemos diferenciada la excavación del resto, creamos una imagen con 3 valores de gris: que sea 0 (negro) si no es borde de excavación ni borde de disco óptico, 127(gris) si es borde de disco óptico y 255 (blanco) si es borde de excavación.



*Figura 6. 45. Construcción Verdad de Referencia*

*A la izda, selección del borde del excavación y disco óptico. A la derecha, máscara creada a partir de la selección.*

Al observar la Figura 6.47. parece extraño el hecho de no utilizar esta verdad para segmentar también el disco óptico. El motivo de construir la verdad de referencia de esta manera no es más que conseguir tener más fronteras decisión para que el clasificador aprenda mejor. Si no aparecen los píxeles del disco óptico como otra clase, habría demasiados píxeles de “No excavación” y muy pocos píxeles de “Si excavación”.

## 6.2. Extracción de características

Como bien indica el título de este trabajo, la segmentación de la excavación está basada en gradientes de color. Así, las imágenes de gradiente obtenidas en el pre-procesado servirán para formar la matriz de características. Esta matriz contendrá las características de las imágenes preparadas para entrenamiento del clasificador. En el apartado anterior, se muestran ejemplos de imágenes de gradiente de color.

Para entender bien cómo se forma dicha matriz, hay que recalcar, tal y como se comentó al comienzo del capítulo, que cada fila corresponde a un vector de características y cada elemento del vector será una característica del píxel.

Además de las imágenes de gradientes, también se incluirán las componentes de color  $L$ ,  $a$  y  $b$ . Como se ha mencionado anteriormente, se ha elegido el espacio de color CIELAB para emular el diagnóstico hecho por un médico experto y, por tanto, la información de color debe estar correlacionada con la percepción humana de los colores y las diferencias entre ellos.

Otros datos importantes que incluir como características son la distancia y el ángulo del píxel en cuestión, respecto al centro de la excavación. Las ecuaciones usadas para el cálculo de la distancia y el ángulo son:

$$d = \sqrt{(i - \text{centrox})^2 + (j - \text{centroy})^2} \quad (76)$$

$$\theta = \arctan\left(\frac{\text{centroy} - j}{i - \text{centrox}}\right) \quad (77)$$

Siendo  $d$  la distancia al centro,  $\theta$  el ángulo y  $(\text{centrox}, \text{centroy})$  los valores de la posición  $(i, j)$  de la ROI en la que se encuentra el centro de la excavación. Por último, se incluirá la información de la posición  $(i, j)$  del píxel en la imagen y la clase a la que pertenece.

Con toda esta información acerca del píxel, se construye un vector con 33 características (de tamaño 1 x 33):

- 25 valores de gradiente de color (1 por cada ángulo).
- 3 valores de color: L, a y b.
- 1 valor de distancia al centro.
- 1 valor del ángulo con respecto al centro.
- 2 valores de la posición (i, j) del píxel.
- 1 valor de la verdad de referencia (clase 1,2 ó 3).

En la siguiente figura se explica de forma gráfica la construcción de la matriz de características:

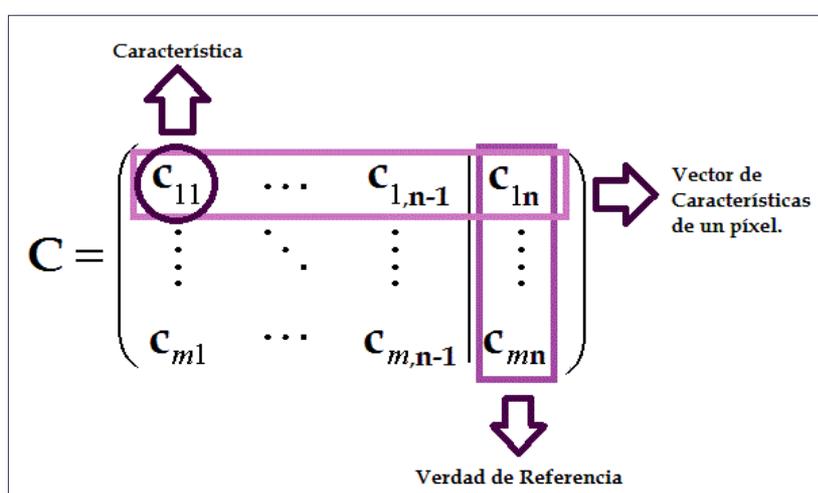


Figura 6. 46. Estructura de la matriz de características

donde  $m = n^\circ$  total de píxeles de todas las imágenes de entrenamiento y  $n=33$  (32 características + verdad referencia)

Una vez se ha extraído la información de todos los píxeles de cada imagen, y de todas las imágenes de entrenamiento, ya está lista la matriz C para comenzar el entrenamiento.

### 6.3. Entrenamiento

Inicialmente, el clasificador no tiene ningún conocimiento y es necesario que aprenda a clasificar entre las diferentes clases.

Para ello, hay que introducirle la matriz de características y una

columna que se corresponde con la verdad de referencia, como se ha visto en la Figura 6.47. que servirá para indicar al clasificador si el píxel es “No excavación, No disco óptico” (clase 1, negro), “Si disco óptico, No excavación” (clase 2, gris) o “Si excavación, No disco óptico” (clase 3, blanco).

Internamente, el clasificador analiza el conjunto de datos y reconoce los patrones, asumiendo la clase a la que pertenece cada píxel. Entre los clasificadores estudiados en el capítulo 5, finalmente se ha hecho uso de los siguientes:

- K-Nearest Neighbor (KNN) Fine
- Support Vector Machine (SVM) Linear
- Simplex Tree, Medium Tree, Complex Tree (un solo árbol de decisión).
- Bagged Tree
- AdaBoost Tree

En las primeras pruebas de entrenamiento y en su posterior test, se detectó una mala clasificación. Su origen provenía de la construcción de la matriz de características.

Teniendo en cuenta que se está trabajando a nivel de píxel y que se tienen 30 imágenes de entrenamiento de tamaño 131x131, el tamaño de la matriz es muy elevado. Como las imágenes de gradiente presentan un borde de 5x5 alrededor de la imagen, lo eliminamos de todas ellas. Así, las imágenes ahora son de 121x121. Una imagen de este tamaño tiene 14641 píxeles, que multiplicado por las 30 imágenes resulta la cantidad de 439230 píxeles.

De los todos los píxeles,

- 422987 son de la Clase 1.
- 10487 son de la Clase 2.
- 5756 son de la Clase 3.

Esto presentó un problema, debido a que había una clase con un número de muestras mucho mayor que el resto y el entrenador no aprendía correctamente. Una vez hecho el entrenamiento, clasificaba todos los píxeles como pertenecientes a la Clase 1. Las muestras del resto de clases eran insignificantes con respecto a las de la primera clase.

Fue entonces cuando se pensó que, al estar trabajando a nivel de píxel, lo importante no era incluir todos los que tiene una imagen, sino incluir píxeles pertenecientes a los tres tipos de clases, con independencia de la retinografía.

Se hicieron, por tanto, regiones que se situaran en la zona conflictiva, que contuvieran píxeles pertenecientes a los tres tipos de clases. Estas regiones se utilizarán para tomar la información de los píxeles que pertenezcan a la Clase 1, que es la clase conflictiva.

En las siguientes figuras, se muestra un ejemplo de extracción de algunas características de una de las regiones mencionadas anteriormente.



Figura 6. 47. "L"  
de una región de ROI.

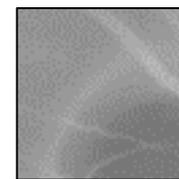


Figura 6. 48. "a"  
de una región de ROI.



Figura 6. 49. "b"  
de una región de ROI

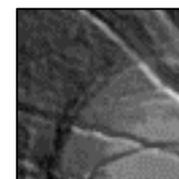


Figura 6. 50. Módulo gradiente  
(ángulo 30°)

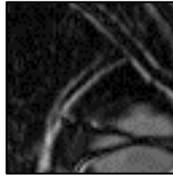


Figura 6. 51. *Módulo gradiente*  
(ángulo 345°)



Figura 6. 52. *Verdad de referencia*

Este procedimiento se ha repetido con 5 imágenes, que pertenecen a las imágenes de entrenamiento.

La idea, a la hora de montar la matriz de características, es:

1. Incluir todos los vectores de características de los píxeles que estén etiquetados como excavación (Clase 3), de las 30 imágenes de entrenamiento.
2. Incluir todos vectores de características de los píxeles que estén etiquetados como disco óptico (Clase 2), de las 30 imágenes de entrenamiento.
3. Incluir todos los vectores de características de los píxeles que estén etiquetados como "ni excavación, ni disco" (Clase 1), de las 5 regiones seleccionadas de entre las 30 imágenes de entrenamiento.

Ahora contamos, en total, con 31923 píxeles, de los cuales:

- 15680 de la Clase 1.
- 10487 de la Clase 2.
- 5756 de la Clase 3.

Sigue habiendo diferencia entre el número de elementos de cada clase, pero la diferencia es mucho menor y esto mejorará notablemente la clasificación.

## 6.4. Clasificación

Una vez terminado el entrenamiento tenemos que clasificar las imágenes que se habían destinado para ello, es decir, tenemos que comprobar la eficiencia de nuestro algoritmo.

Se clasificarán 50 imágenes y, posteriormente, se hará un post-procesado para comparar los resultados con la verdad de referencia y, así, ver claramente la efectividad del algoritmo.

Como resultado el clasificador se obtiene una matriz de probabilidades ( $m \times 3$ ), donde cada columna de la matriz es un vector de probabilidad entre 0 y 1 y "m" es el número total de píxeles clasificados. En base a la publicación [1], se hallará la zona a segmentar mediante las probabilidades de que los píxeles pertenezcan a la Clase 3, es decir, se extraerá la información que contiene la matriz en su tercera columna.

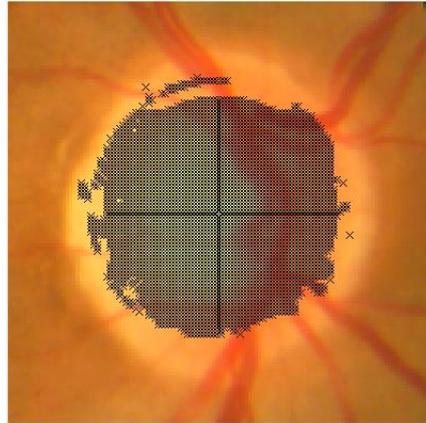
## 6.5. Post-Procesado

Tras realizar la clasificación, hay que realizar una serie de tareas para una mejor presentación de los resultados. A continuación, se muestra una visión general de estas tareas (Figura 6.53.)

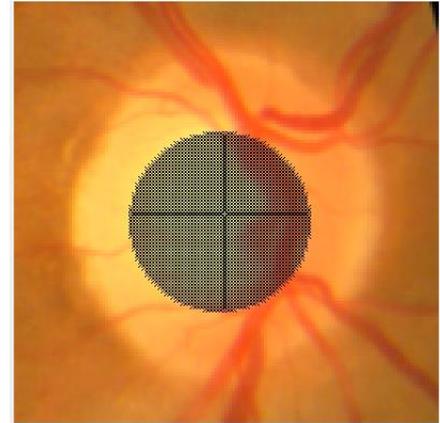


*Figura 6. 53. Visión general del post-procesado*

Una vez tenemos todos esos píxeles, que comprenden una nube alrededor del centro de la excavación, se observa que hay algunos puntos erróneos, que surgen tras la clasificación, alrededor de la excavación del disco óptico. Este problema se solventa, eliminando los puntos más alejados del centro. En la figura 6.54. se muestra un ejemplo de esta nube de puntos.



(a)



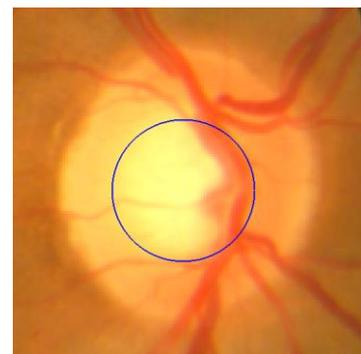
(b)

Figura 6. 54. Nube de puntos resultado de clasificación (a) y corrección (b)

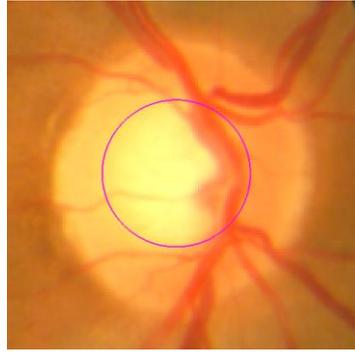
A continuación, se hallará la distancia media desde cada píxel al centro de la excavación. Posteriormente, se descartarán todos los píxeles que no cumplan que:  $\text{Distancia\_centro} \geq \text{Distancia\_media}$ . Los puntos resultantes se aproximan por una circunferencia, debido a que es mucho más interesante para calcular el CDR. Finalmente, se representarán los píxeles resultantes sobre la ROI original. En la siguiente figura se puede ver el resultado final de una de las retinografías.



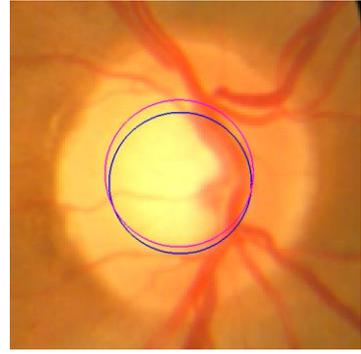
(a)



(b)



(c)



(d)

*Figura 6. 55. Resultados Post-procesado.*

*(a) Imagen original. (b) Resultado clasificación EXCAVACIÓN. (c) Verdad de referencia en forma circular. (d) Comparativa entre (b) y (c).*



## 7. RESULTADOS

Para la valoración de los resultados se hará uso de tablas de confusión. Las tablas de confusión recogen información acerca de las predicciones de la siguiente forma:

True Class	Clase 1 (0)	Bien Clasificado (%)	Es clase 1 y se clasifica como 2 (%)	Es clase 1 y se clasifica como 3 (%)	TPR FNR
	Clase 2 (127)	Es clase 2 y se clasifica como 1 (%)	Bien Clasificado (%)	Es clase 2 y se clasifica como 3 (%)	TPR FNR
	Clase 3 (255)	Es clase 3 y se clasifica como 1 (%)	Es clase 3 y se clasifica como 2 (%)	Bien Clasificado (%)	TPR FNR
		Clase 1 (0)	Clase 2 (127)	Clase 3 (255)	
		Predict Class			

Figura 7. 1. Modelo tabla de confusión.

Los términos que se usarán en este capítulo irán todos referidos a la Clase 3, puesto que es la zona que se pretende segmentar en la retinografía. Estos términos son:

- **TP (Verdaderos Positivos):** Es Clase 3 y el clasificador lo identifica como tal.

- **FP (Falsos Positivos):** No es Clase 3 y el clasificador lo identifica como tal.
- **FN (Falsos Negativos):** No es Clase 3 y no se identifica como Clase 3.
- **TN (Verdaderos Negativos):** Es Clase 3 y el clasificador no lo identifica como tal.
- **TPR (Sensibilidad o True Positive Rate):** es la relación entre el número de píxeles segmentados por el algoritmo que, también son segmentados por el experto y la cantidad total de píxeles segmentados por el experto.

$$TPR = \frac{TP}{TP + FN} \quad (78)$$

- **Accuracy (Precisión):** Representa el número de píxeles (%) correctamente identificados.

$$ACC = \frac{TP + TN}{TP + FP + TN + FN} \quad (79)$$

- **TNR (Especificidad o True Negative Rate):** Porcentaje de negativos correctamente identificados, respecto a los negativos de la imagen segmentada por un experto.

$$TNR = \frac{TN}{TN + FP} \quad (80)$$

- **PPV (Positive Predictive Value):** mide la sobre-segmentación calculando la relación entre los píxeles segmentados por el algoritmo que también son segmentados por los expertos y la cantidad de píxeles segmentados.

$$PPV = \frac{TP}{TP + FP} \quad (81)$$

- **NPV (Negative Predictive Value):** Es la proporción entre los valores negativos indicados por un experto frente a la suma de falsos negativos detectados por el algoritmo y los valores negativos que indica el experto.

$$NPV = \frac{TN}{TN + FN} \quad (82)$$

Se mostrarán los resultados de haber entrenado con los distintos clasificadores y, posteriormente, se optará por la elección de uno de ellos. Se elegirá el clasificador que mejor se adapte al algoritmo, que sea más eficaz y que se ejecute en el menor tiempo posible. Recordar que hemos hecho un tratamiento por píxel, por tanto los porcentajes hacen referencia al número de píxeles acertados/errados.

### 7.1. Resultado del entrenamiento

**Matriz de confusión SVM Linear:** Ofrece una probabilidad de acierto del 49,1%. No hace una buena clasificación de las clases por lo que descartamos automáticamente su uso para usarlo como clasificador del algoritmo.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	10487 100%	0 0.0%	0 0.0%	0.0% 100%
	255	5756 100%	0 0.0%	0 0.0%	0.0% 100%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 5. Matriz de Confusión SVM Linear

**Matriz de confusión SVM Cuadrático:** Se obtienen exactamente los mismos resultados que en SVM Linear. La probabilidad de acierto es,

también, 49,1%. Descartamos también su uso.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	10487 100%	0 0.0%	0 0.0%	0.0% 100%
	255	5756 100%	0 0.0%	0 0.0%	0.0% 100%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 6. Matriz de Confusión SVM Cuadrático

**Matriz de Confusión de SVM Cúbico:** Se obtienen los mismos resultados que anteriormente. Probabilidad de acierto: 49,1%.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	10487 100%	0 0.0%	0 0.0%	0.0% 100%
	255	5756 100%	0 0.0%	0 0.0%	0.0% 100%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 7. Matriz de Confusión SVM Cúbico

Con estos resultados se concluye que el clasificador SVM no es apropiado para clasificar estos píxeles.

**Matriz de Confusión de KNN Fine:** La probabilidad de acierto es de un 95.5%. Es un porcentaje muy bueno, pero hay numerosos píxeles que no están siendo bien clasificados. Este podría ser un candidato para elegirlo como clasificador definitivo.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	0 0.0%	9876 94.2%	611 5.8%	94.2% 5.8%
	255	0 0.0%	811 14.1%	4945 85.9%	85.9% 14.1%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 8. Matriz de Confusión KNN Fine

**Matriz de Confusión de KNN Medium:** Clasifica peor que KNN Fine, aumentando los píxeles mal clasificados. La probabilidad de acierto es de un 93.1%. Se considera también un buen clasificador.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	0 0.0%	10065 96.0%	422 4.0%	96.0% 4.0%
	255	0 0.0%	1775 30.8%	3981 69.2%	69.2% 30.8%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 9. Matriz de Confusión KNN Medium

**Matriz de Confusión de Complex Tree:** La probabilidad de acierto es 99.1%. El porcentaje de fallo es muy pequeño. Sería un buen candidato para ser el clasificador utilizado definitivamente.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	0 0.0%	10344 98.6%	143 1.4%	98.6% 1.4%
	255	0 0.0%	155 2.7%	5601 97.3%	97.3% 2.7%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 10. Matriz de Confusión Complez Tree

**Matriz de Confusión de Medium Tree:** La probabilidad de acierto es 98.0%. Su calidad es inferior a Complex Tree. Es buen candidato, aunque ya se ha encontrado alguno que es mejor.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	0 0.0%	10223 97.5%	264 2.5%	97.5% 2.5%
	255	0 0.0%	370 6.4%	5386 93.6%	93.6% 6.4%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 11. Matriz de Confusión Medium Tree

**Matriz de Confusión de Simple Tree:** El porcentaje de acierto es 96%. Empeora con respecto a Complex Tree y Medium Tree.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	0 0.0%	9889 94.3%	598 5.7%	94.3% 5.7%
	255	0 0.0%	682 11.8%	5074 88.2%	88.2% 11.8%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 12. Matriz de Confusión Simple Tree

Se puede concluir que de los tres clasificadores de árbol de decisión el mejor sería Complex Tree, con una probabilidad de acierto de 99.2%.

**Matriz de Confusión de Bagger Tree:** Es el clasificador que muestra mayor probabilidad de acierto: 100%.

True Class	0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
	127	0 0.0%	10473 100%	14 0.1%	100% 0.1%
	255	0 0.0%	64 1.1%	5692 98.9%	98.9% 1.1%
		0	127	255	TPR/FNR
		Predicted Class			

Tabla 13. Matriz de Confusión Tree Bagger

Este sería el clasificador ideal en cuanto al nivel de acierto, aunque se explicará porqué no se elige finalmente.

**Matriz de Confusión de AdaBoost Tree:** La probabilidad de acierto es menor que en el clasificador Bagger Tree, siendo ambos varios árboles de decisión. La probabilidad de acierto es del 95.5%.

0	15680 100%	0 0.0%	0 0.0%	100% 0.0%
127	0 0.0%	10040 95.7%	447 4.3%	95.7% 4.3%
255	0 0.0%	996 17.3%	4760 82.7%	82.7% 17.3%
	0	127	255	TPR/FNR
	Predicted Class			

Tabla 14. Matriz de Confusión AdaBoost Tree

Finalmente se escoge el clasificador Complex Tree. Su elección se debe a que:

- La probabilidad de acierto es del 99.1%.
- La rapidez del clasificador es muy alta (del orden de 0.5 segundos por ejecución).
- El clasificador Bagger Tree tenía un 100% de probabilidad de acierto, pero su tiempo de ejecución es mucho mayor (entre 3 y 5 minutos), por lo que retrasaría mucho el diagnóstico.

Así, se compensa el 0.9% de error entre Bagger Tree y Complex Tree, con la rapidez a la que trabaja el segundo.

A continuación se muestra la curva ROC (Receiver Operating Characteristic), para cada clase según el clasificador Complex Tree:

Para la Clase 1, se considera esta como clase positiva, y las otras dos (Clase 2 y Clase 3) se consideran clases negativas.

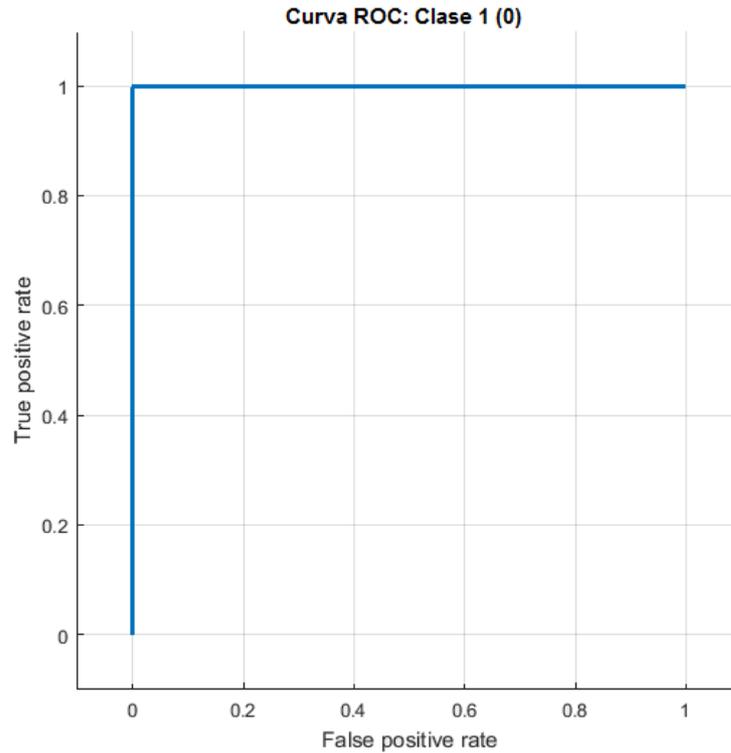


Tabla 15. Curva ROC para la Clase 1

Para la Clase 2, se considera ésta como clase positiva, y las otras dos (Clase 1 y Clase 3) se consideran clases negativas. La gráfica se muestra en la página siguiente

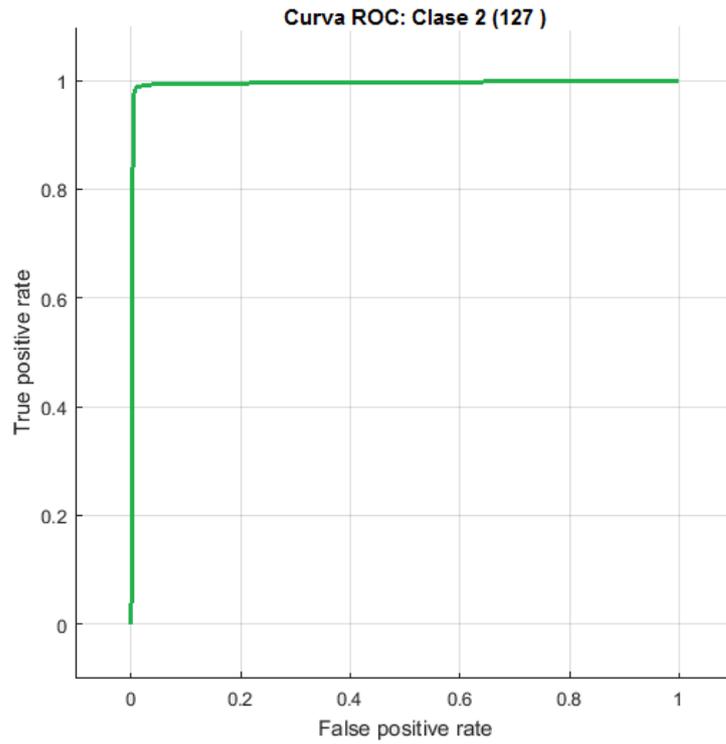


Tabla 16. Curva ROC de la Clase 2.

Para la Clase 3, se considera esta como clase positiva, y las otras dos (Clase 1 y Clase 2) se consideran clases negativas.

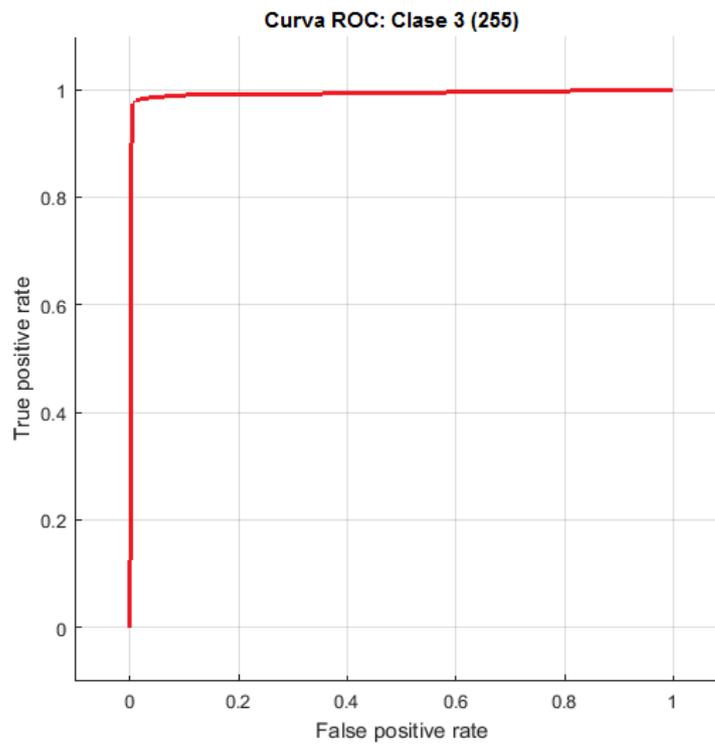


Tabla 17. Curva ROC para la Clase 3.

## 7.2. Resultado de la clasificación

Los promedios obtenidos como resultado de la clasificación de todas las imágenes con Complex Tree son los siguientes. La definición de cada uno de estos resultados se encuentra en el apartado 7.1.

VALOR ESTADÍSTICO	(%)
Especificidad (TNR)	98.43%
Valor predictivo positivo (PPV)	88.37%
Valor predictivo negativo (NPV)	98.45%
Precisión (ACC)	97.25%
Sensibilidad (TPR)	90.65%

En las páginas 103-112, se muestra una tabla detallada de todos los resultados obtenidos, por cada imagen.



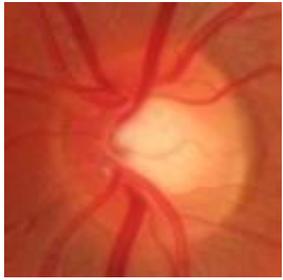
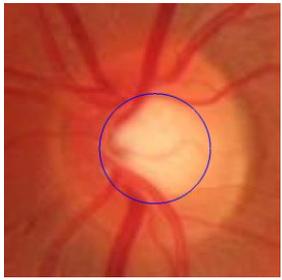
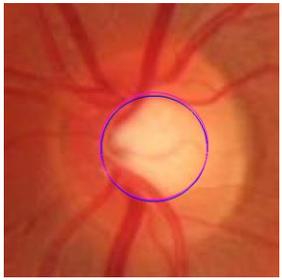
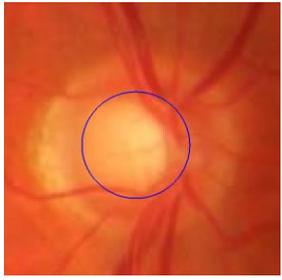
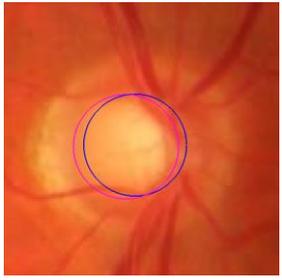
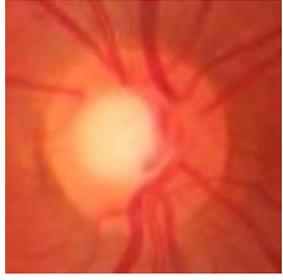
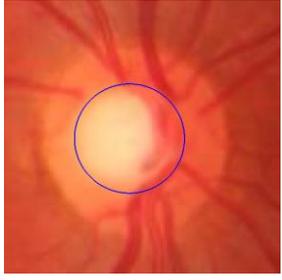
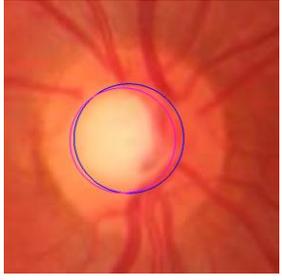
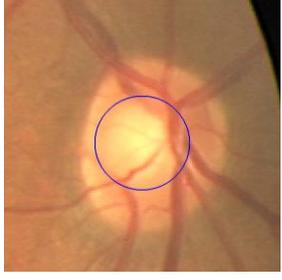
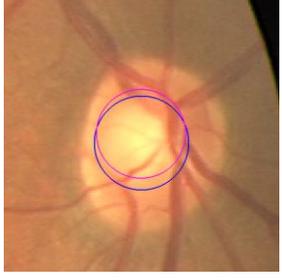
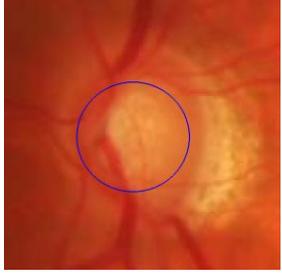
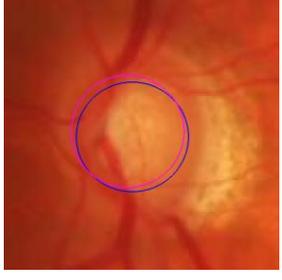
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			TPR = 95,69% TNR = 98,35% PPV = 88,53% NPV = 99,42% ACC = 98,04% <b>Promedio: 96,01%</b>
			TPR = 99,00% TNR = 99,18% PPV = 94,41% NPV = 99,86% ACC = 99,16% <b>Promedio: 98,32%</b>
			TPR = 99,00% TNR = 99,18% PPV = 94,41% NPV = 99,86% ACC = 99,16% <b>Promedio: 98,32%</b>
			TPR = 90,76% TNR = 98,23% PPV = 87,14% NPV = 98,77% ACC = 97,36% <b>Promedio: 94,45%</b>
			TPR = 90,35% TNR = 98,96% PPV = 93,07% NPV = 98,52% ACC = 97,81% <b>Promedio: 95,74%</b>

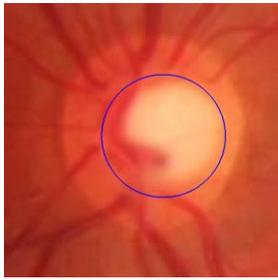
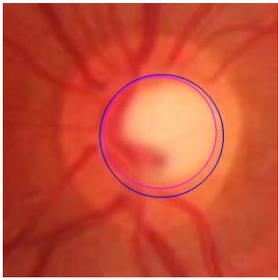
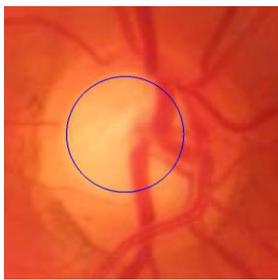
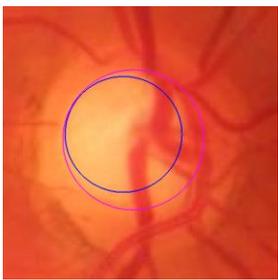
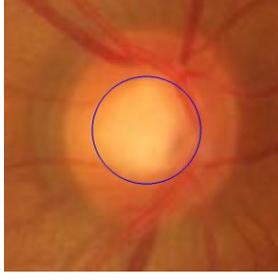
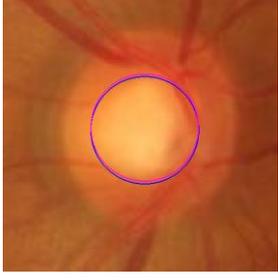
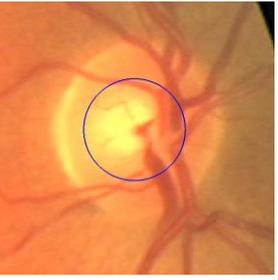
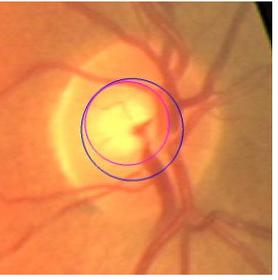
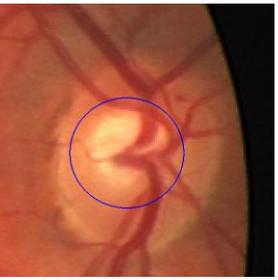
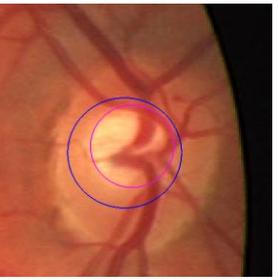
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			TPR = 100% TNR = 96,87% PPV = 82,97% NPV = 100% ACC = 97,28% <b>Promedio: 95,42%</b>
			TPR = 68,59% TNR = 100% PPV = 100% NPV = 92,35% ACC = 93,44% <b>Promedio: 90,88%</b>
			TPR = 97,30% TNR = 99,53% PPV = 96,60% NPV = 99,63% ACC = 99,26% <b>Promedio: 98,46%</b>
			TPR = 100% TNR = 96,22% PPV = 68,05% NPV = 100% ACC = 96,50% <b>Promedio: 92,15%</b>
			TPR = 100% TNR = 93,56% PPV = 54,97% NPV = 100,00% ACC = 94,03% <b>Promedio: 88,51%</b>

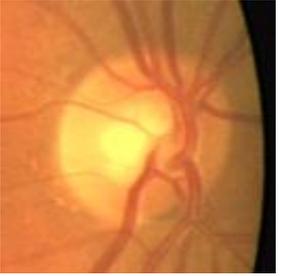
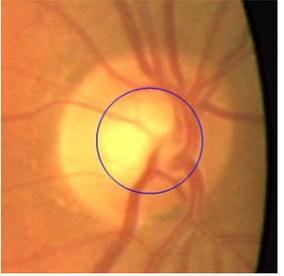
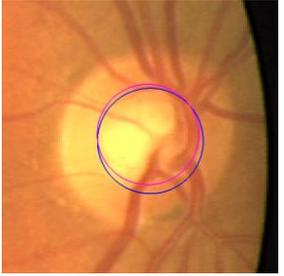
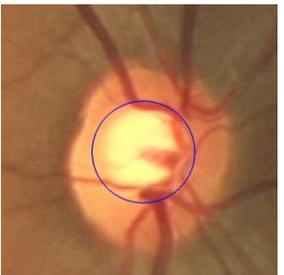
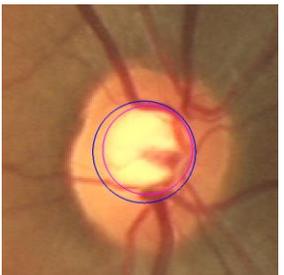
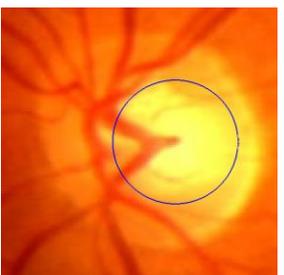
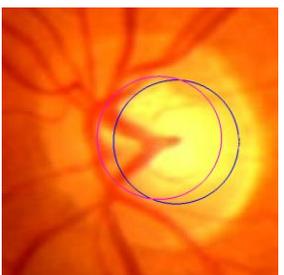
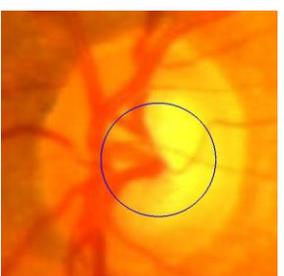
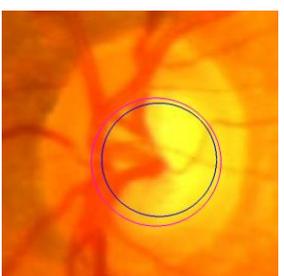
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			<p>TPR = 95,39%</p> <p>TNR = 98,35%</p> <p>PPV = 87,56%</p> <p>NPV = 99,43%</p> <p>ACC = 98,03%</p> <p><b>Promedio: 95,76%</b></p>
			<p>TPR = 99,09%</p> <p>TNR = 98,62%</p> <p>PPV = 77,43%</p> <p>NPV = 99,96%</p> <p>ACC = 98,64%</p> <p><b>Promedio: 94,75%</b></p>
			<p>TPR = 100%</p> <p>TNR = 97,17%</p> <p>PPV = 76,47%</p> <p>NPV = 100%</p> <p>ACC = 97,41%</p> <p><b>Promedio: 94,21%</b></p>
			<p>TPR = 83,07%</p> <p>TNR = 96,47%</p> <p>PPV = 81,89%</p> <p>NPV = 96,74%</p> <p>ACC = 94,31%</p> <p><b>Promedio: 90,49%</b></p>
			<p>TPR = 78,64%</p> <p>TNR = 100%</p> <p>PPV = 100%</p> <p>NPV = 95,67%</p> <p>ACC = 96,26%</p> <p><b>Promedio: 94,11%</b></p>

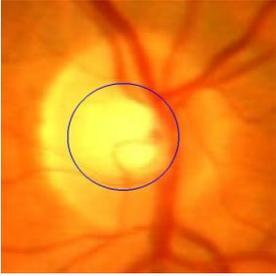
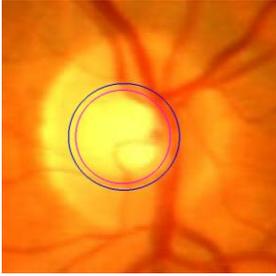
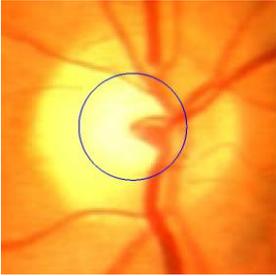
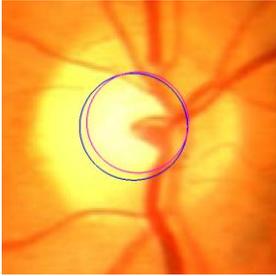
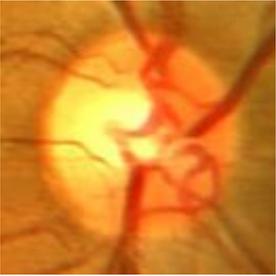
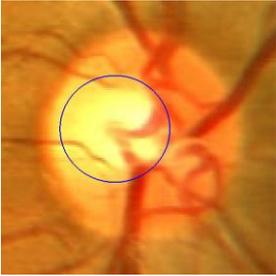
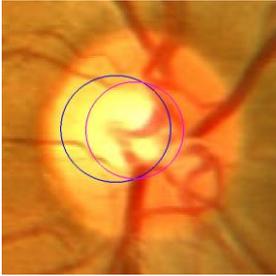
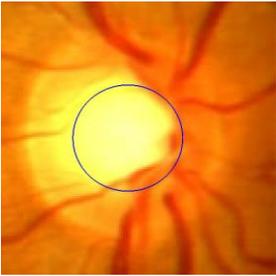
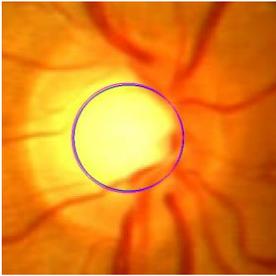
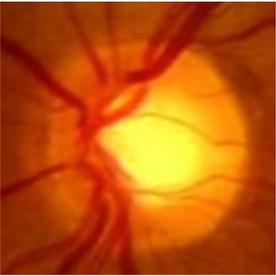
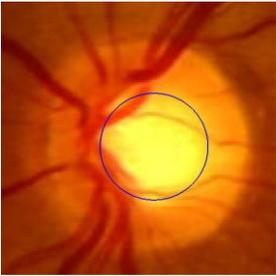
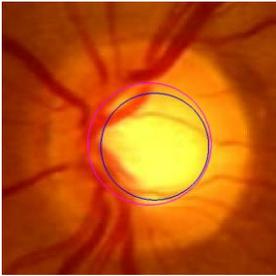
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			TPR = 100% TNR = 96,53% PPV = 74,88% NPV = 100% ACC = 96,85% <b>Promedio: 93,65%</b>
			TPR = 97,42% TNR = 98,21% PPV = 86,83% NPV = 99,68% ACC = 98,12% <b>Promedio: 96,05%</b>
			TPR = 85,17% TNR = 95,73% PPV = 68,85% NPV = 98,31% ACC = 94,68% <b>Promedio: 88,55%</b>
			TPR = 95,98% TNR = 99,94% PPV = 99,56% NPV = 99,41% ACC = 99,43% <b>Promedio: 98,87%</b>
			TPR = 76,75% TNR = 100% PPV = 100% NPV = 95,80% ACC = 96,31% <b>Promedio: 93,77%</b>

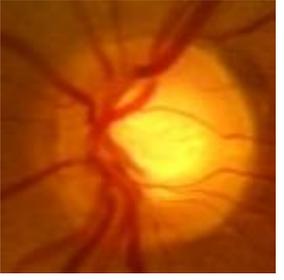
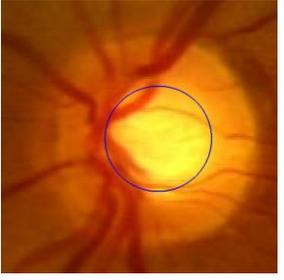
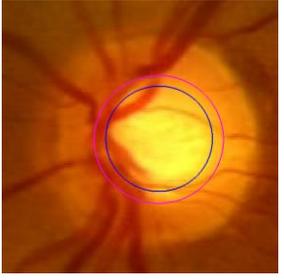
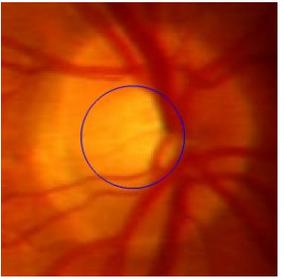
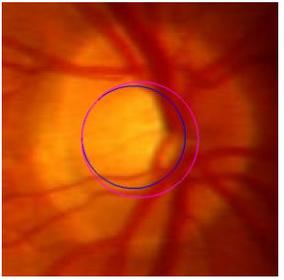
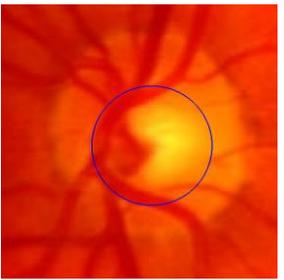
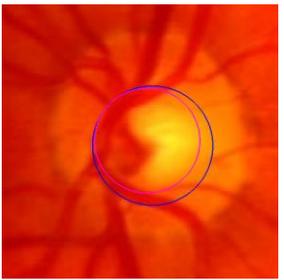
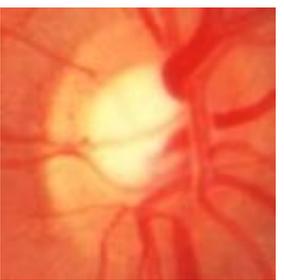
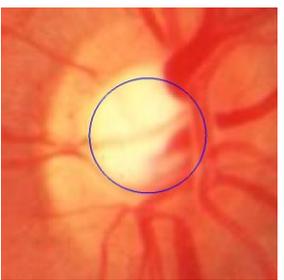
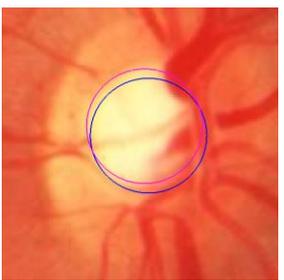
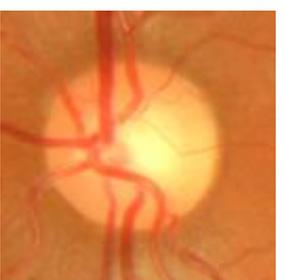
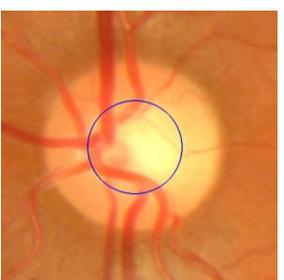
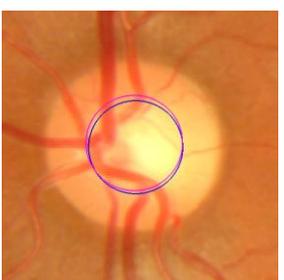
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			<p>TPR = 68,14%</p> <p>TNR = 100%</p> <p>PPV = 100%</p> <p>NPV = 93,70%</p> <p>ACC = 94,45%</p> <p><b>Promedio: 91,26%</b></p>
			<p>TPR = 78,65%</p> <p>TNR = 99,99%</p> <p>PPV = 99,94%</p> <p>NPV = 96,60%</p> <p>ACC = 96,97%</p> <p><b>Promedio: 94,43%</b></p>
			<p>TPR = 99,96%</p> <p>TNR = 96,07%</p> <p>PPV = 76,98%</p> <p>NPV = 99,99%</p> <p>ACC = 96,52%</p> <p><b>Promedio: 93,91%</b></p>
			<p>TPR = 88,99%</p> <p>TNR = 98,12%</p> <p>PPV = 88,56%</p> <p>NPV = 98,20%</p> <p>ACC = 96,84%</p> <p><b>Promedio: 94,14%</b></p>
			<p>TPR = 91,68%</p> <p>TNR = 99,60%</p> <p>PPV = 96,12%</p> <p>NPV = 99,10%</p> <p>ACC = 98,83%</p> <p><b>Promedio: 97,07%</b></p>

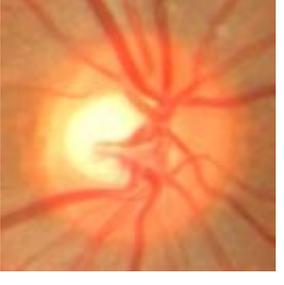
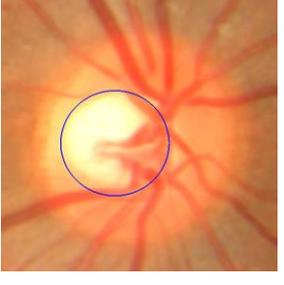
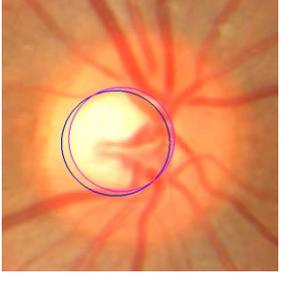
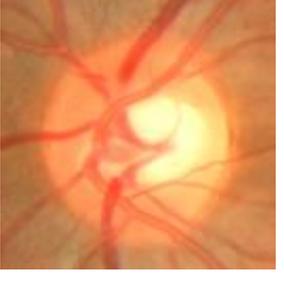
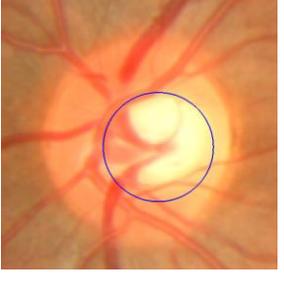
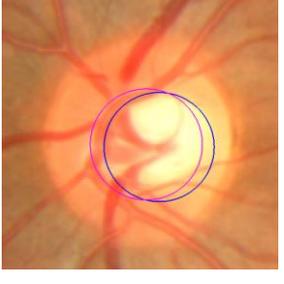
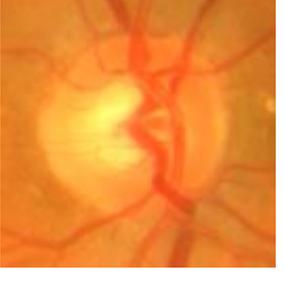
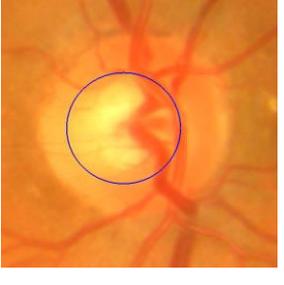
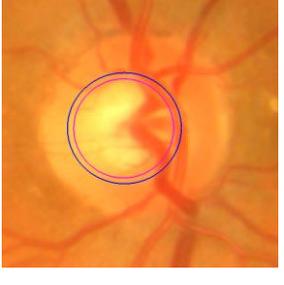
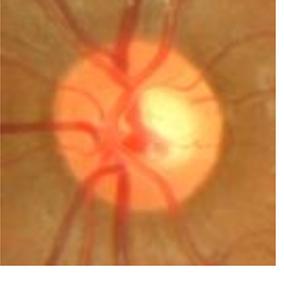
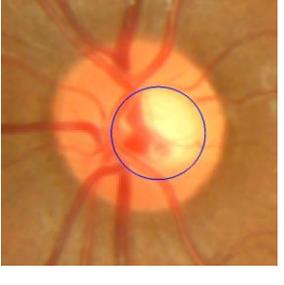
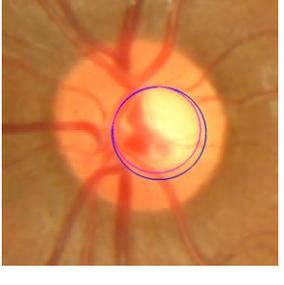
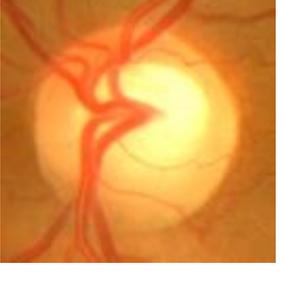
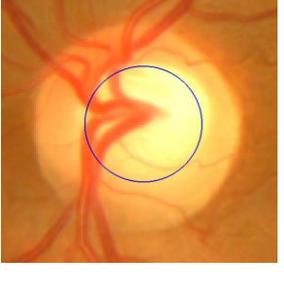
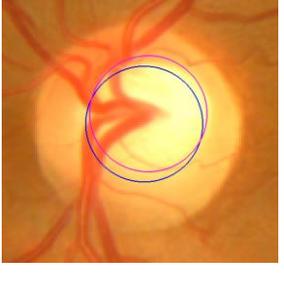
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			<p>TPR = 93,36%</p> <p>TNR = 98,66%</p> <p>PPV = 90,15%</p> <p>NPV = 99,12%</p> <p>ACC = 98,04%</p> <p><b>Promedio: 95,87%</b></p>
			<p>TPR = 83,71%</p> <p>TNR = 98,05%</p> <p>PPV = 86,63%</p> <p>NPV = 97,55%</p> <p>ACC = 96,17%</p> <p><b>Promedio: 92,42%</b></p>
			<p>TPR = 100%</p> <p>TNR = 96,80%</p> <p>PPV = 78,48%</p> <p>NPV = 100%</p> <p>ACC = 97,14%</p> <p><b>Promedio: 94,48%</b></p>
			<p>TPR = 99,34%</p> <p>TNR = 98,60%</p> <p>PPV = 86,08%</p> <p>NPV = 99,94%</p> <p>ACC = 98,66%</p> <p><b>Promedio: 96,53%</b></p>
			<p>TPR = 87,63%</p> <p>TNR = 98,03%</p> <p>PPV = 88,18%</p> <p>NPV = 97,93%</p> <p>ACC = 96,53%</p> <p><b>Promedio: 93,66%</b></p>

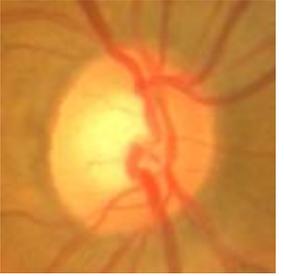
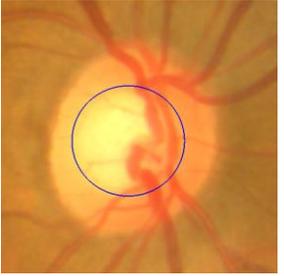
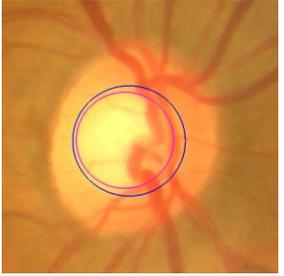
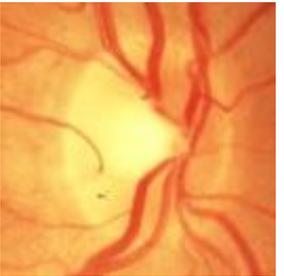
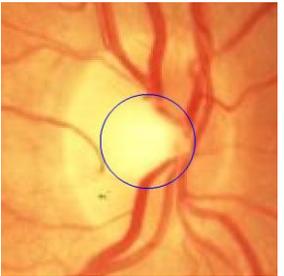
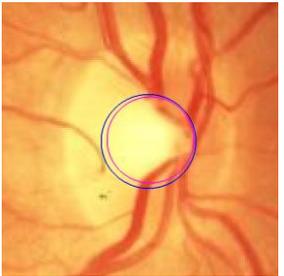
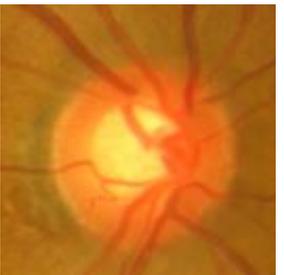
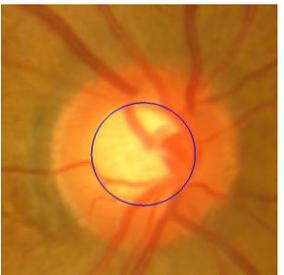
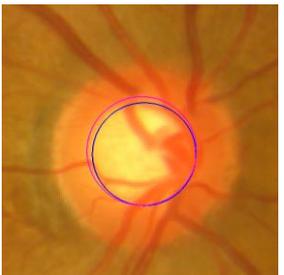
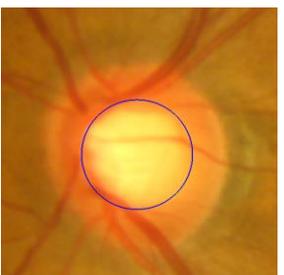
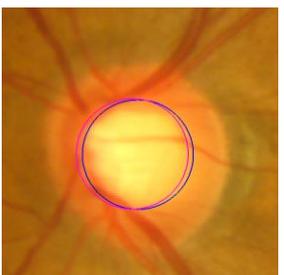
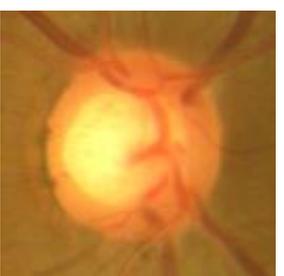
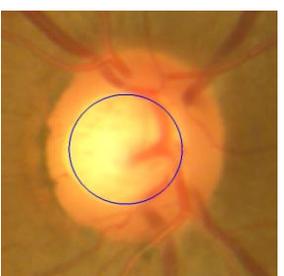
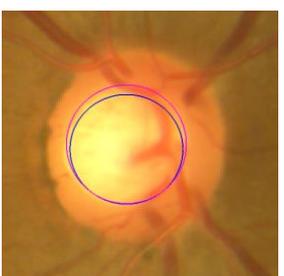
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			TPR = 100% TNR = 96,44% PPV = 75,57% NPV = 100% ACC = 96,80% <b>Promedio: 93,76%</b>
			TPR = 100% TNR = 84,13% PPV = 100% NPV = 100% ACC = 98,51% <b>Promedio: 96,21%</b>
			TPR = 89,02% TNR = 99,92% PPV = 99,38% NPV = 98,45% ACC = 98,55% <b>Promedio: 97,06%</b>
			TPR = 92,85% TNR = 99,17% PPV = 94,36% NPV = 98,93% ACC = 98,34% <b>Promedio: 96,73%</b>
			TPR = 87,02% TNR = 99,96% PPV = 99,72% NPV = 97,76% ACC = 98,02% <b>Promedio: 96,49%</b>

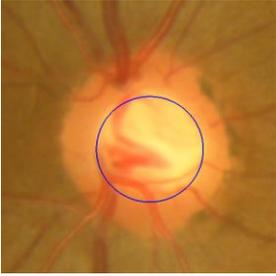
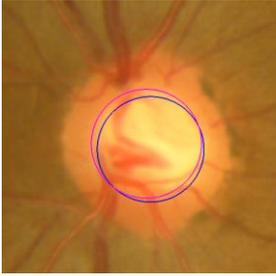
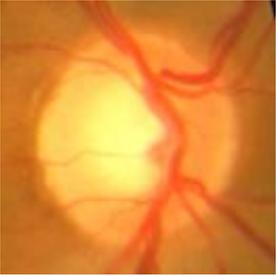
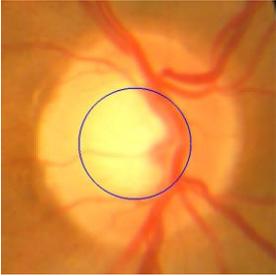
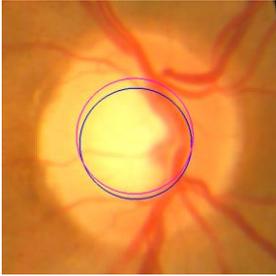
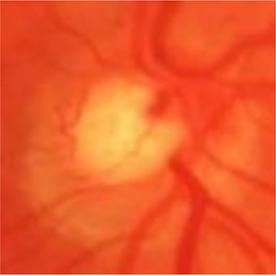
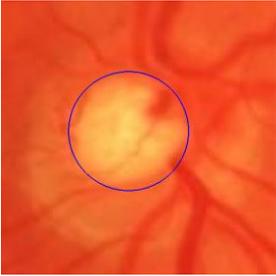
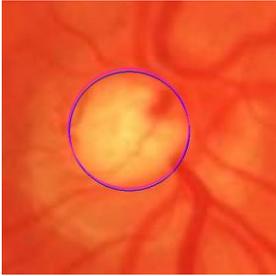
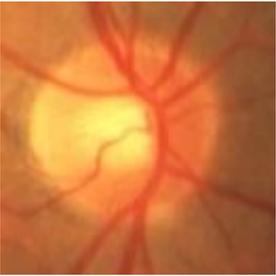
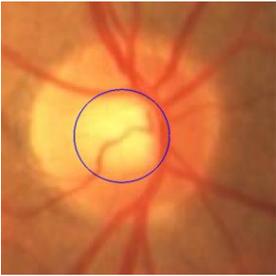
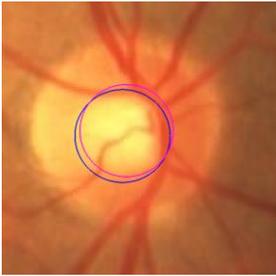
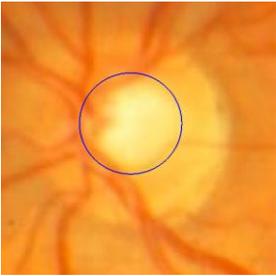
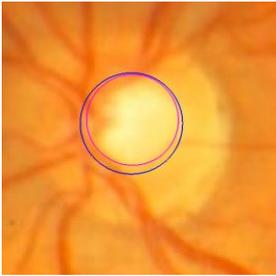
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			TPR = 88,72% TNR = 99,26% PPV = 94,61% NPV = 98,38% ACC = 97,93% <b>Promedio: 95,78%</b>
			TPR = 87,70% TNR = 99,23% PPV = 94,94% NPV = 98% ACC = 97,60% <b>Promedio: 95,5%</b>
			TPR = 96,24% TNR = 99,54% PPV = 97,42% NPV = 99,33% ACC = 99,04% <b>Promedio: 98,32%</b>
			TPR = 92,23% TNR = 98,94% PPV = 89,71% NPV = 99,22% ACC = 98,33% <b>Promedio: 95,69%</b>
			TPR = 100% TNR = 97,69% PPV = 80,74% NPV = 100% ACC = 97,89% <b>Promedio: 95,26%</b>

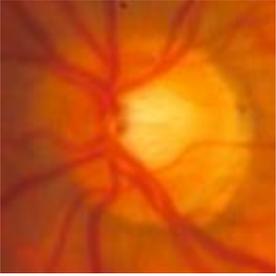
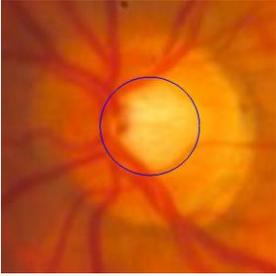
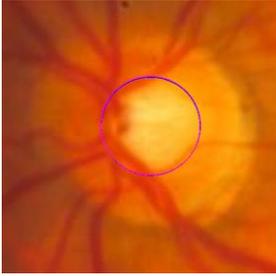
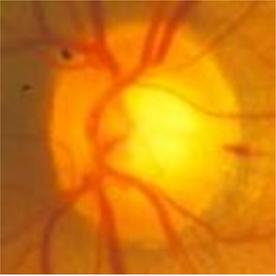
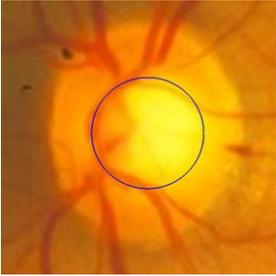
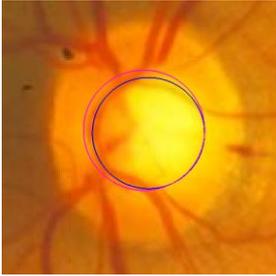
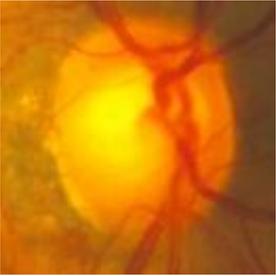
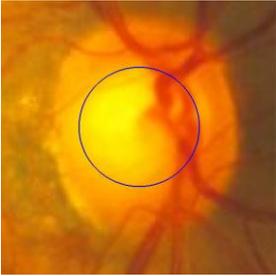
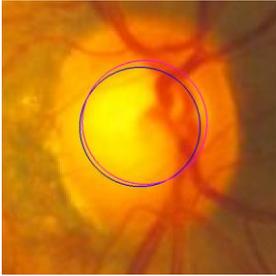
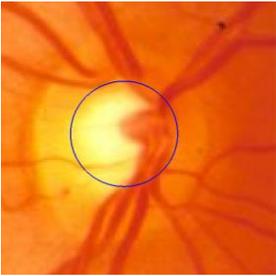
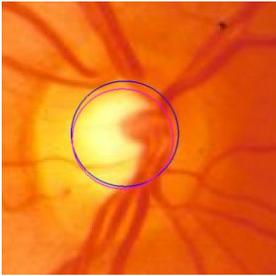
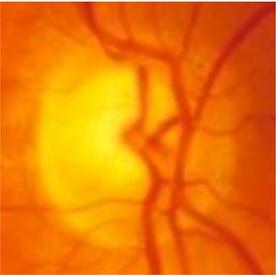
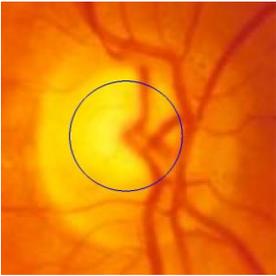
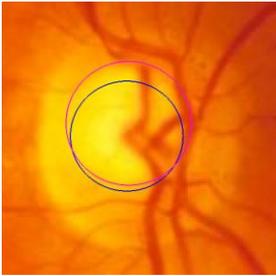
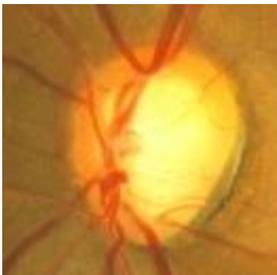
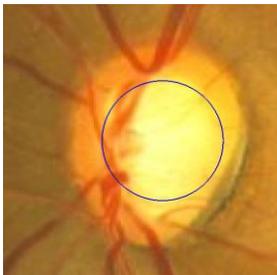
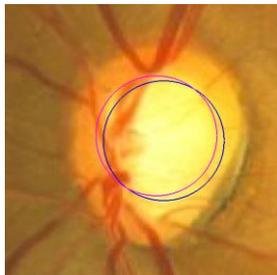
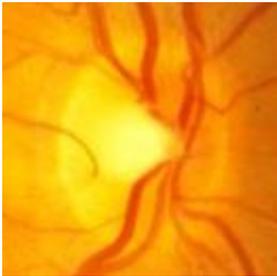
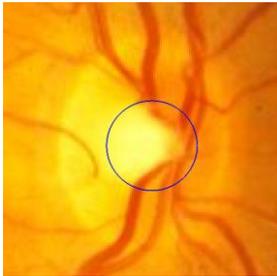
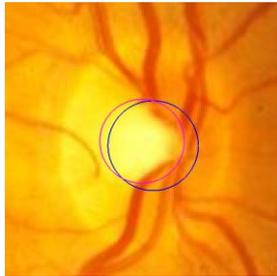
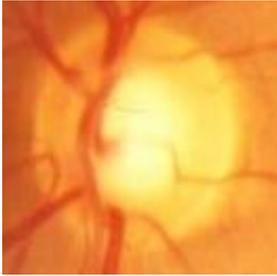
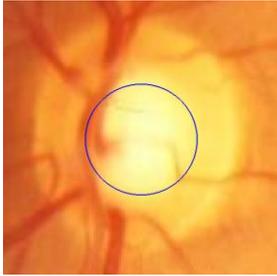
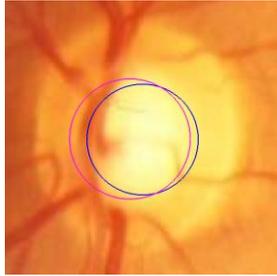
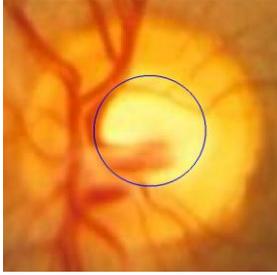
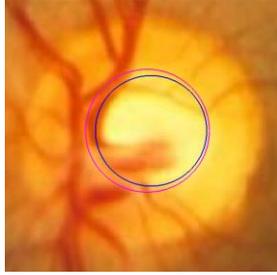
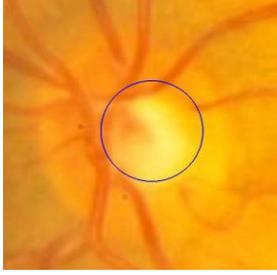
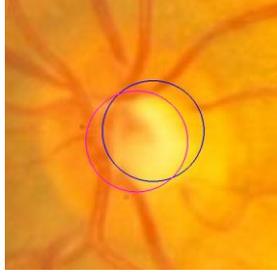
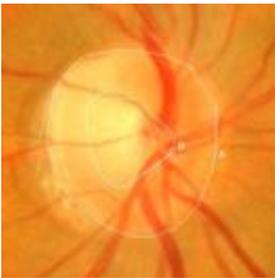
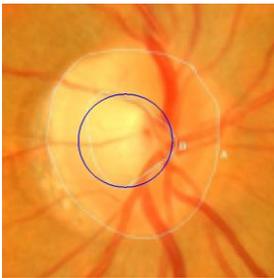
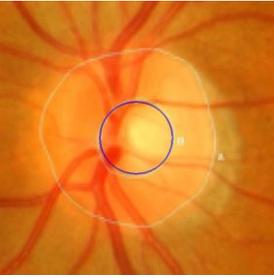
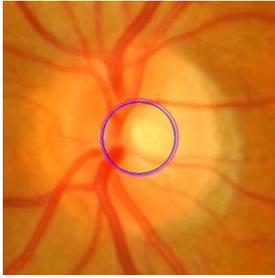
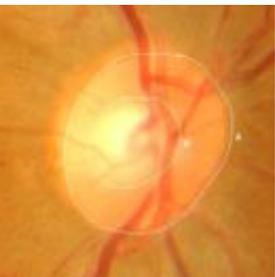
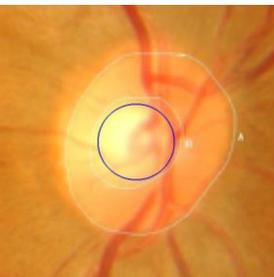
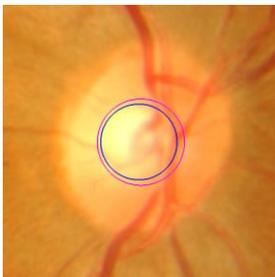
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			TPR = 98,75% TNR = 99,97% PPV = 99,78% NPV = 99,86% ACC = 99,85% <b>Promedio: 99,64%</b>
			TPR = 85,40% TNR = 99,96% PPV = 99,72% NPV = 97,43% ACC = 97,73% <b>Promedio: 96,04%</b>
			TPR = 89,61% TNR = 99,35% PPV = 96,38% NPV = 98,02% ACC = 97,77% <b>Promedio: 96,22%</b>
			TPR = 97,75% TNR = 98,32% PPV = 87,41% NPV = 99,73% ACC = 98,26% <b>Promedio: 96,29%</b>
			TPR = 75,95% TNR = 99,20% PPV = 94,91% NPV = 95,47% ACC = 95,39% <b>Promedio: 92,18%</b>

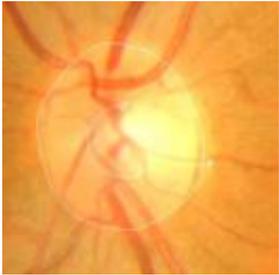
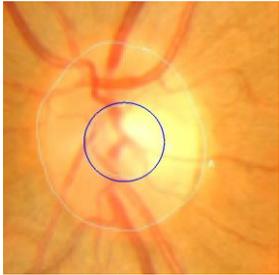
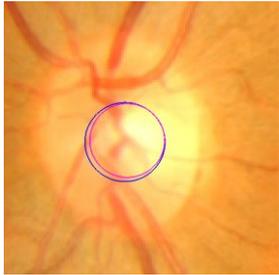
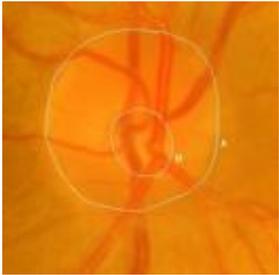
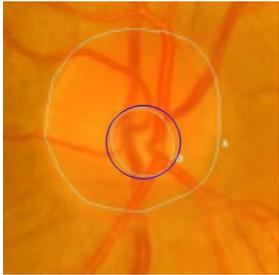
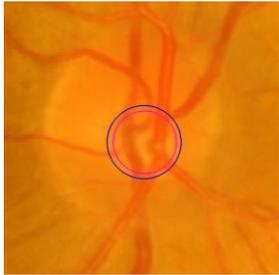
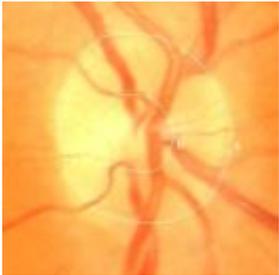
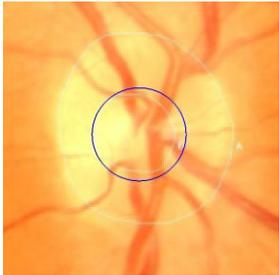
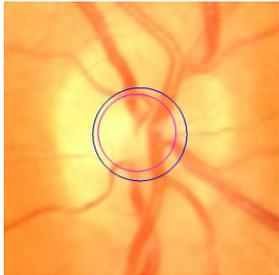
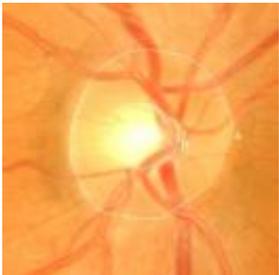
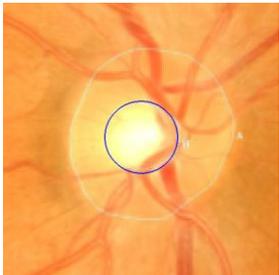
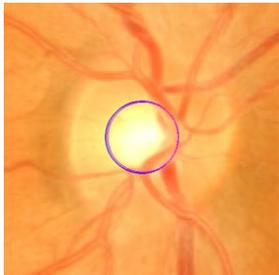
Imagen Original	Imagen Resultado	Resultado vs. VR	Resultados Obtenidos
			TPR = 90,67% TNR = 98,35% PPV = 90,86% NPV = 98,31% ACC = 97,17% <b>Promedio: 95,07%</b>
			TPR = 88,08% TNR = 97,88% PPV = 77,21% NPV = 99,02% ACC = 97,14% <b>Promedio: 91,87%</b>
			TPR = 78,87% TNR = 98,89% PPV = 92,80% NPV = 96,28% ACC = 95,83% <b>Promedio: 92,54%</b>
			TPR = 80,93% TNR = 100% PPV = 100% NPV = 96,47% ACC = 96,93% <b>Promedio: 94,87%</b>
			TPR = 76,06% TNR = 97,11% PPV = 76,27% NPV = 97,07% ACC = 94,81% <b>Promedio: 88,27%</b>

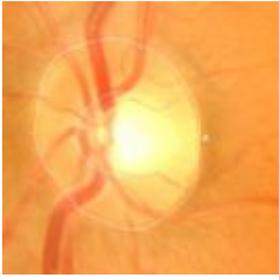
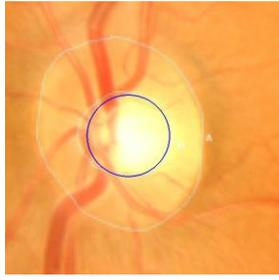
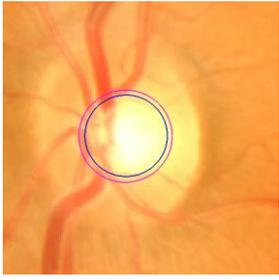
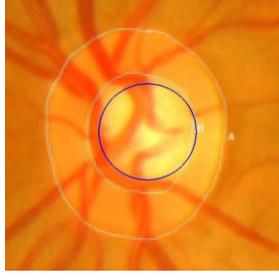
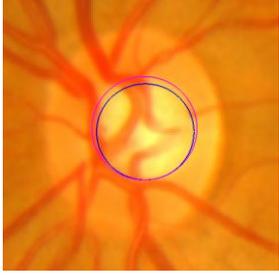
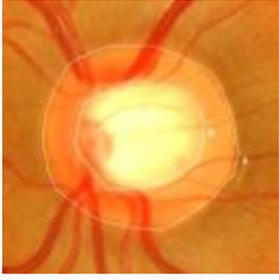
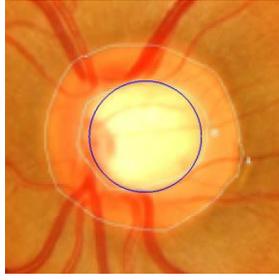
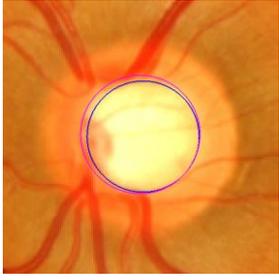
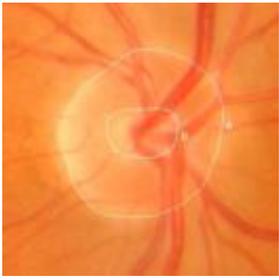
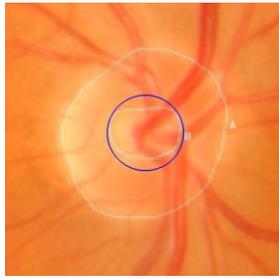
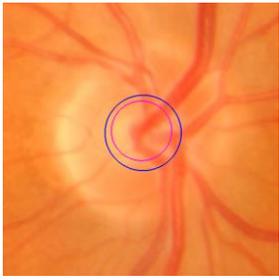
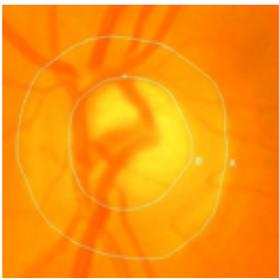
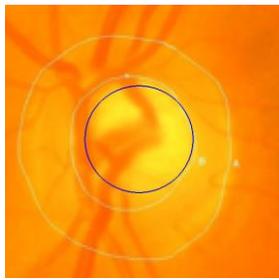
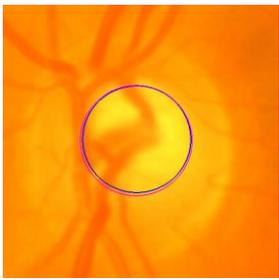
### 7.3. Estudio comparativo

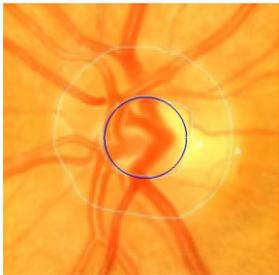
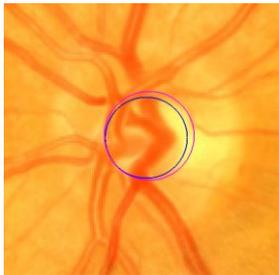
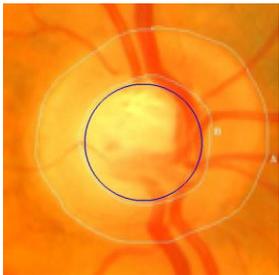
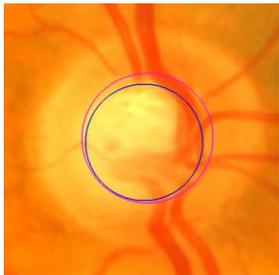
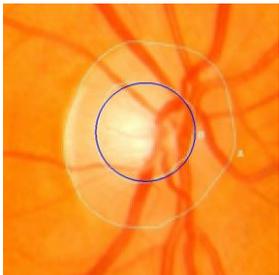
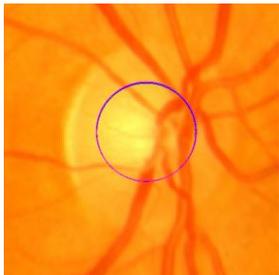
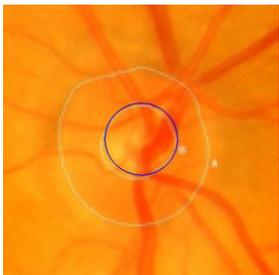
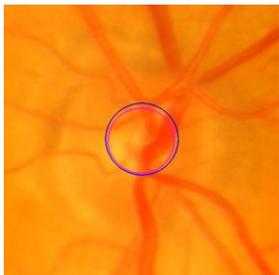
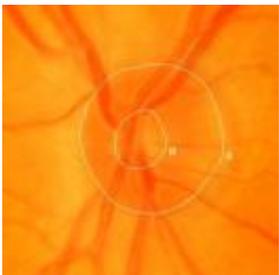
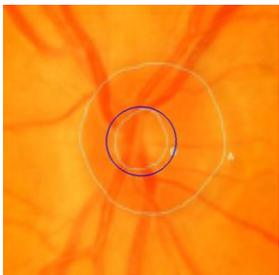
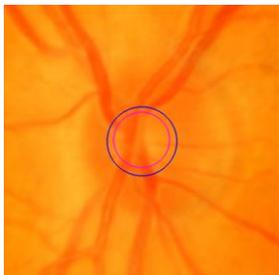
Tras realizar la clasificación de las imágenes seleccionadas y comprobar que se obtienen buenos resultados, se procede a realizar un estudio comparativo con las imágenes utilizadas para la publicación [19], donde se hace una segmentación de la excavación en retinografías basada en el espacio de color JCh y el clasificador Random Forest. Estas imágenes tienen la verdad de referencia marcada en color blanco por los especialistas en esta retinopatía.

Para ello se han seleccionado algunas de estas imágenes y se ha aplicado el mismo algoritmo detallado en el Capítulo 6. Los resultados de esta clasificación son los siguientes:

Original + VR	Resultado + VR	Resultado + VR circular	Resultados Obtenidos
			TPR = 96,85% TNR = 99,54% PPV = 95,48% NPV = 99,68% ACC = 99,30% <b>Promedio: 98,17%</b>
			TPR = 88,26% TNR = 100% PPV = 100% NPV = 99,22% ACC = 99,26% <b>Promedio: 97,35%</b>
			TPR = 77,10% TNR = 100% PPV = 100% NPV = 98,06% ACC = 98,18% <b>Promedio: 94,67%</b>

Original + VR	Resultado + VR	Resultado + VR circular	Resultados Obtenidos
			TPR = 99,93% TNR = 99,12% PPV = 87,61% NPV = 100% ACC = 99,16% <b>Promedio: 97,16%</b>
			TPR = 100% TNR = 98,37% PPV = 73,01% NPV = 100% ACC = 98,44% <b>Promedio: 93,97%</b>
			TPR = 100% TNR = 96,94% PPV = 68,96% NPV = 100% ACC = 97,14% <b>Promedio: 92,61%</b>
			TPR = 100% TNR = 97,75% PPV = 62,55% NPV = 100% ACC = 97,83% <b>Promedio: 91,62%</b>
			TPR = 99,87% TNR = 99,71% PPV = 95,06% NPV = 99,99% ACC = 99,72% <b>Promedio: 98,87%</b>

Original + VR	Resultado + VR	Resultado + VR circular	Resultados Obtenidos
			TPR = 78,17% TNR = 100% PPV = 100% NPV = 97,86% ACC = 98,01% <b>Promedio: 94,81%</b>
			TPR = 86,16% TNR = 100% PPV = 100% NPV = 98,23% ACC = 98,41% <b>Promedio: 96,56%</b>
			TPR = 88,29% TNR = 100% PPV = 100% NPV = 98% ACC = 98,26% <b>Promedio: 96,91%</b>
			TPR = 100% TNR = 97,64% PPV = 62,95% NPV = 100% ACC = 97,73% <b>Promedio: 91,67%</b>
			TPR = 93,76% TNR = 100% PPV = 100% NPV = 99,08% ACC = 99,19% <b>Promedio: 98,40%</b>

Original + VR	Resultado + VR	Resultado + VR circular	Resultados Obtenidos
			TPR = 83,57% TNR = 100% PPV = 100% NPV = 98,51% ACC = 98,61% <b>Promedio: 96,14%</b>
			TPR = 80,45% TNR = 100% PPV = 100% NPV = 95,92% ACC = 96,50% <b>Promedio: 94,57%</b>
			TPR = 97,97% TNR = 99,99% PPV = 99,91% NPV = 99,76% ACC = 99,78% <b>Promedio: 99,48%</b>
			TPR = 100% TNR = 98,99% PPV = 82,58% NPV = 100% ACC = 99,03% <b>Promedio: 96,12%</b>
			TPR = 100% TNR = 98,13% PPV = 64,76% NPV = 100% ACC = 98,19% <b>Promedio: 92,22%</b>

A continuación, se muestra una tabla donde se comparan los valores estadísticos de los resultados que se han obtenido con cada metodología:

	JCh	Lab
<b>Sensibilidad (TPR)</b>	86,95%	93,03%
<b>Especificidad (TNR)</b>	97,80%	99,24%
<b>Valor Predictivo Positivo (PPV)</b>	80,49%	89,05%
<b>Precisión (ACC)</b>	95,04%	98,53%

*Tabla 18. Tabla comparativa entre JCh y Lab*

Se puede observar claramente que el algoritmo implementado en este trabajo obtiene mejores resultados.



## 8. CONCLUSIONES Y LÍNEAS FUTURAS

---

Se puede considerar que el trabajo desarrollado tiene unos resultados muy positivos, más aún sabiendo la dificultad que ha tenido hasta ahora segmentar la excavación del disco óptico. Se ha modificado ligeramente un método ya implementado [1] para disco óptico y reutilizado para la excavación, comprobando que su utilidad también para este caso.

Los clasificadores que mejor resultado han obtenido y que, por tanto, han destacado más en la identificación correcta de los píxeles son los basados en Árboles de Decisión. Destacar también los buenos resultados que se han obtenido con los clasificadores basados en K-Nearest Neighbor.

Como líneas futuras se plantea:

- Implementar el algoritmo utilizando otros espacios de color, RGB, y escala de grises.
- Usar algún método de selección de características para comprobar si son necesarias todas ellas o se puede prescindir de alguna. Un ejemplo es PCA (Principal Component Analysis) [55].
- Diseñar una interfaz que permita a los especialistas utilizar el algoritmo para el diagnóstico de esta retinopatía.



## 9. REFERENCIAS

---

- [1] M. J. J. P. v. G. C. I. S. a. A. S. Irene Fondón, «Perceptually Adapted Method for Optic Disc Detection on Retinal Fundus,» Spain and The Netherlands, 2013.
- [2] R. G. a. R. Woods, Digital Image Processing, Addison Wesley, 1992.
- [3] V. G. Ruíz, «El Sistema Visual Humano,» 27 Septiembre 2014. [En línea]. Available: [https://encryptedtbn0.gstatic.com/images?q=tbn:ANd9GcQMj3\\_EnoIHo1\\_Kl\\_1rVkl1AVNYETv7\\_0zjSNqWzqaBdmUBoVVYOG](https://encryptedtbn0.gstatic.com/images?q=tbn:ANd9GcQMj3_EnoIHo1_Kl_1rVkl1AVNYETv7_0zjSNqWzqaBdmUBoVVYOG).
- [4] A. Piñero, Retina Caso a Caso, vol. 2, Barcelona, 2008.
- [5] «En Wikipedia: Definición de perfusión,» [En línea]. Available: <http://definicion.de/perfusion/>.
- [6] «En Wikipedia: Definición de Isquemia,» [En línea]. Available: <https://es.wikipedia.org/wiki/Isquemia>.
- [7] «En Wikipedia: Células Ganglionares,» [En línea]. Available: [https://es.wikipedia.org/wiki/C%C3%A9lulas\\_ganglionares\\_de\\_la\\_retina](https://es.wikipedia.org/wiki/C%C3%A9lulas_ganglionares_de_la_retina).
- [8] «Aver Clínica Oftalmológica,» [En línea]. Available: <http://www.clinica-aver.com/blog/que-es-la-retinografia/>.
- [9] L. J. L. J. T. N. Z. Z. L. S. L. H. T. M. C. K. a. W. T. Wong DW, «Intelligent fusion of cup-to-disc ratio determination methods for glaucoma detection in ARGALI,» de *Int. Conf. IEEE Eng. in Medicine and Biology Society*, Annu, 2009.
- [10] J. Liu, D. Wong, J. Lim, H. Li, N. Tan, Z. Zhang, T. Wong y R. Lavanya, «ARGALI: An Automatic Cup-to-Disc Ratio Measurement System for Glaucoma Analysis Using Level-set Image Processing,» *IFMBE Proceedings*, vol. 23, pp. 559-562.
- [11] J. GD, S. J y K. SR., «Optic disk and cup segmentation from monocular color retinal images for glaucoma assessment.,» *IEEE Trans Med Imaging.*, 2011.
- [12] F. N. M. T. S. J. P. A. Q. A. C. S. a. B. A. I. Fondón, «Automatic cup-to-disc ratio estimation using active contours and color clustering in fundus images for glaucoma diagnosis,» de *Lecture Notes in Computer Science 7325*, 2012.

- [13] G. D. Joshi, J. Sivaswamy y S. R. Krishnadas, «Depth Discontinuity-Based Cup Segmentation From Multiview Color Retinal Image,» *IEEE Trans. on Biomedical Eng.*, vol. 59, nº 6, pp. 1523-1531, 2012.
- [14] M. Madhusudhan, N. Malay y S. N. a. D. Samerendra, «Image processing techniques for glaucoma detection,» *Advances in Computing and Communications*, vol. 192, nº 3, pp. 365-373., 2011.
- [15] Y. Hatanaka, A. Noudo, C. Muramatsu, A. Sawada, T. Hara y T. a. F. H. Yamamoto, «Automatic measurement of cup to disc,» *Annu. Int. Conf. IEEE Eng. in Medicine and Biology Society*, pp. 3387-3390, 2011.
- [16] M. H. Tan, Y. Sun, S. H. Ong, J. Liu, M. Baskaran y T. A. a. T. Y. Wong, «Automatic Notch Detection in Retinal Images,» *IEEE 10th Int. Symp. on Biomedical Imaging: From Nano to Macro*, pp. 1440-1443, 2013.
- [17] G. Joshi, J. Sivaswamy, K. Karan y K. a. S. Krishnadas, «Vessel bend-based cup segmentation in retinal images,» *Int. Conf. Pattern Recognition*, pp. 2536-2539, 2010.
- [18] G. Joshi, K. J. Sivaswamy y K. a. S. K. Karan, «Optic disk and cup boundary detection using regional information,» *IEEE Int. Symp. on Biomedical Imaging: From Nano to Macro*, pp. 948-951, 2010.
- [19] J. F. V. A. S. Q. A. S. J. a. P. A. Irene Fondón, «Automatic Optic Cup Segmentation Algorithm for Retinal Fundus Images based on Random Forest Classifier,» de *EUROCONF*, Sevilla, España, 2015.
- [20] aulaClic S.L., «Aula-Clic. La luz y la Fotografía,» [En línea]. Available: [http://www.aula clic.es/fotografia-photoshop/t\\_4\\_7.htm](http://www.aula clic.es/fotografia-photoshop/t_4_7.htm).
- [21] «Real Academia Española,» 2015. [En línea]. Available: [www.rae.es](http://www.rae.es).
- [22] «International Commission on Illumination,» 2015. [En línea]. Available: <http://www.cie.co.at/>.
- [23] E. Liddell, «Blog de Percepcion Visual,» Mayo 2012. [En línea]. Available: <http://dieaugen.blogspot.com.es/p/percepcion-visual.html>.
- [24] «BLOG EDUCATIVO DEL AULA DIGITAL TELMEX DE LA ESC. PRIM "MELCHOR OCAMPO",» Marzo 2015. [En línea]. Available: [http://nuestroblogadtmelchor.blogspot.com.es/2015\\_03\\_01\\_archive.html](http://nuestroblogadtmelchor.blogspot.com.es/2015_03_01_archive.html).
- [25] «En Wikipedia: Definición de Daltonismo,» [En línea]. Available: <https://es.wikipedia.org/wiki/Daltonismo>.
- [26] J. R. Cerquides, *Apuntes: Luces, Colores y el Sistema Visual Humano*, Sevilla.
- [27] «En Wikipedia: Leyes de Grassmann,» [En línea]. Available: [https://es.wikipedia.org/wiki/Leyes\\_de\\_Grassmann](https://es.wikipedia.org/wiki/Leyes_de_Grassmann).
- [28] Blog de gusgsm, «Imagen Digital: Apuntes sobre diseño y artes gráficas,» [En línea]. Available: [http://www.gusgsm.com/triestimulos\\_colores\\_espectrales](http://www.gusgsm.com/triestimulos_colores_espectrales).

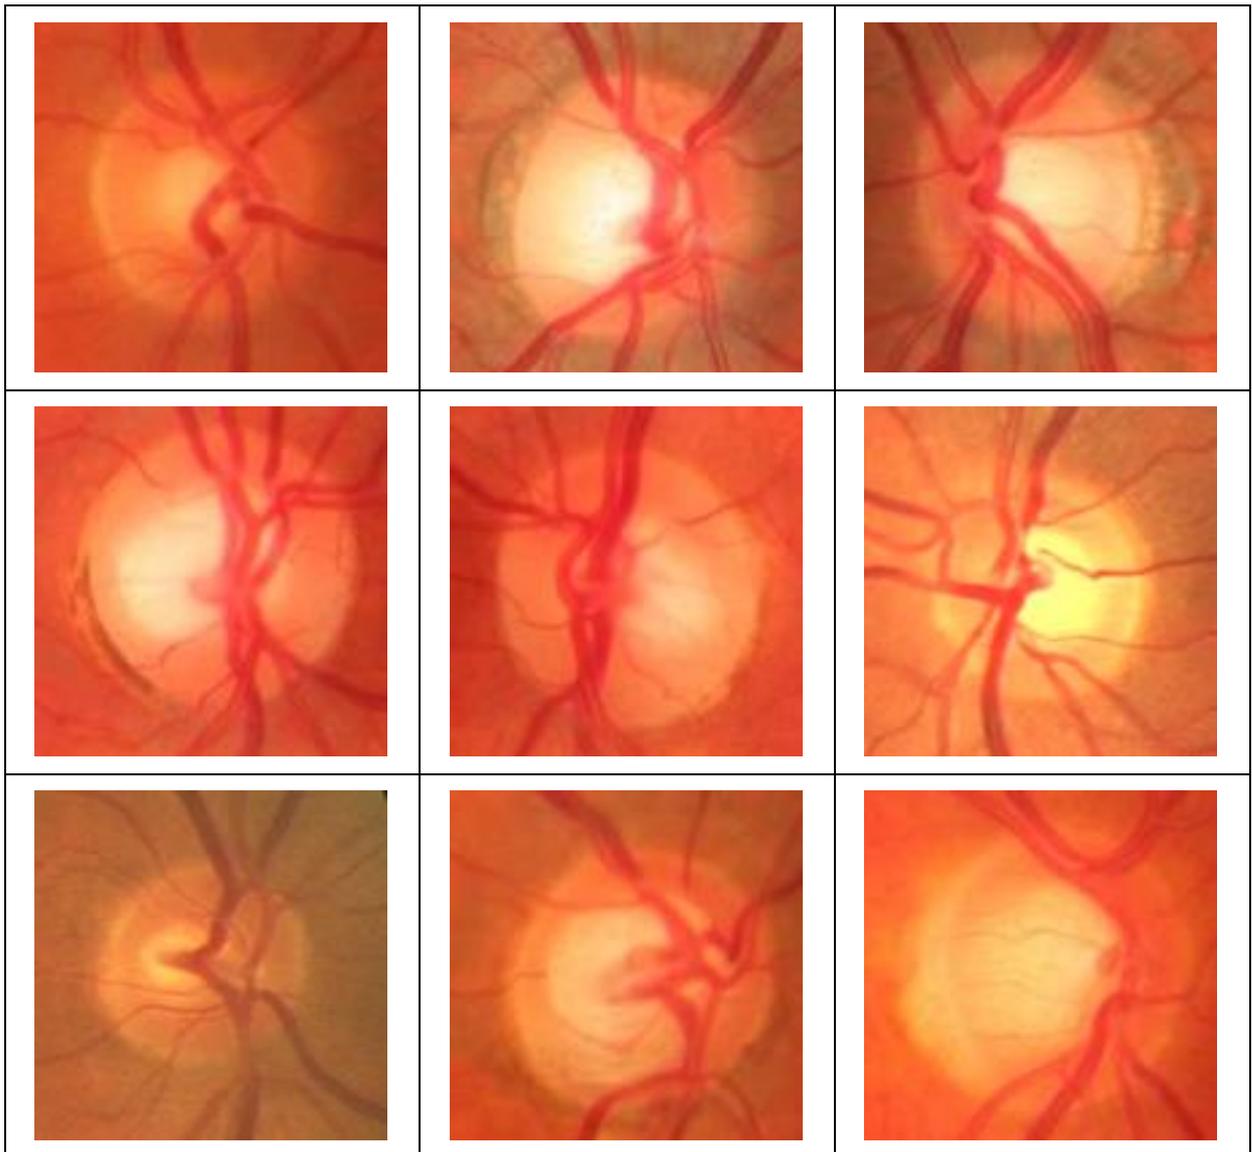
- [29] «LA GEOMETRÍA DE LOS DIAGRAMAS CROMÁTICOS,» [En línea].  
Available: <http://www.pauloport.com/Fotografia/cor/espacios3.htm>.
- [30] Grupo de Color y Calidad de Alimentos. Universidad de Sevilla,  
«El color: Fundamentos y Aplicaciones,» Sevilla.
- [31] «efg's Computer Lab Color,»  
[En línea]. Available: <http://www.efg2.com/Lab/Graphics/Colors/Chromaticity.htm>.
- [32] «En Wikipedia: CIELUV,» [En línea]. Available: <https://en.wikipedia.org/wiki/CIELUV>.
- [33] «En wikipedia: CIELAB,» [En línea]. Available: [https://en.wikipedia.org/wiki/Lab\\_color\\_space](https://en.wikipedia.org/wiki/Lab_color_space).
- [34] «En Wikipedia: HSL,» [En línea]. Available: [https://es.wikipedia.org/wiki/Modelo\\_de\\_color\\_HSL](https://es.wikipedia.org/wiki/Modelo_de_color_HSL).
- [35] Ming Ronniner Luo and Changjung Li, «CIECAM 02 and its recent developments,» [En línea].  
Available: [www.springer.com/.../9781441961891-c1.pdf?](http://www.springer.com/.../9781441961891-c1.pdf?).
- [36] P. G. a. L. MacDonald, Colour Engineering, John Wiley & Sons, LTD, 2003.
- [37] CIE Technical Report, «Industrial Colour Difference Evaluation.,» *CIE Publication*, nº 116, 1995.
- [38] «An introduction to kernel and nearest-neighbor nonparametric regression,» *The American Statistician*, nº 46, pp. 175-185, 1992.
- [39] MathWorks, *Classification Using Nearest Neighbors*.
- [40] A. I. G. Noguera, Elaboración propia., 2015.
- [41] N. Casillas, *Proyecto Final de Carrera: Sistema basado en redes neuronales para el reconocimiento de dígitos manuscritos*, Madrid, 2012.
- [42] V. V. a. C. Cortes, Support Vector Networks, AT&T Bell Labs (USA), 1995.
- [43] R. C. Berwick, *An idiot's guide to Support Vector Machines. Diapositivas. Última consulta el 14 de Julio de 2015.*
- [44] Mathworks, Classification Learner, 2015.
- [45] L. Breiman, «Bagging Predictors,» *Technical Report*, nº 421, 1994.
- [46] Y. F. a. R. Schapire, A short Introduction to Boosting. AT&T Labs - Research Shannon Laboratory, 1999.
- [47] T. H. a. R. T. J.H. Friedman, «Additive logistic regression: a statistical view of boosting.,» *The Annals of Statistics*, nº 28, pp. 337-407, 2000.
- [48] M. d. I. y. D. d. Francia, «Messidor Database,» [En línea]. Available: <http://messidor.crihan.fr/index-en.php>.

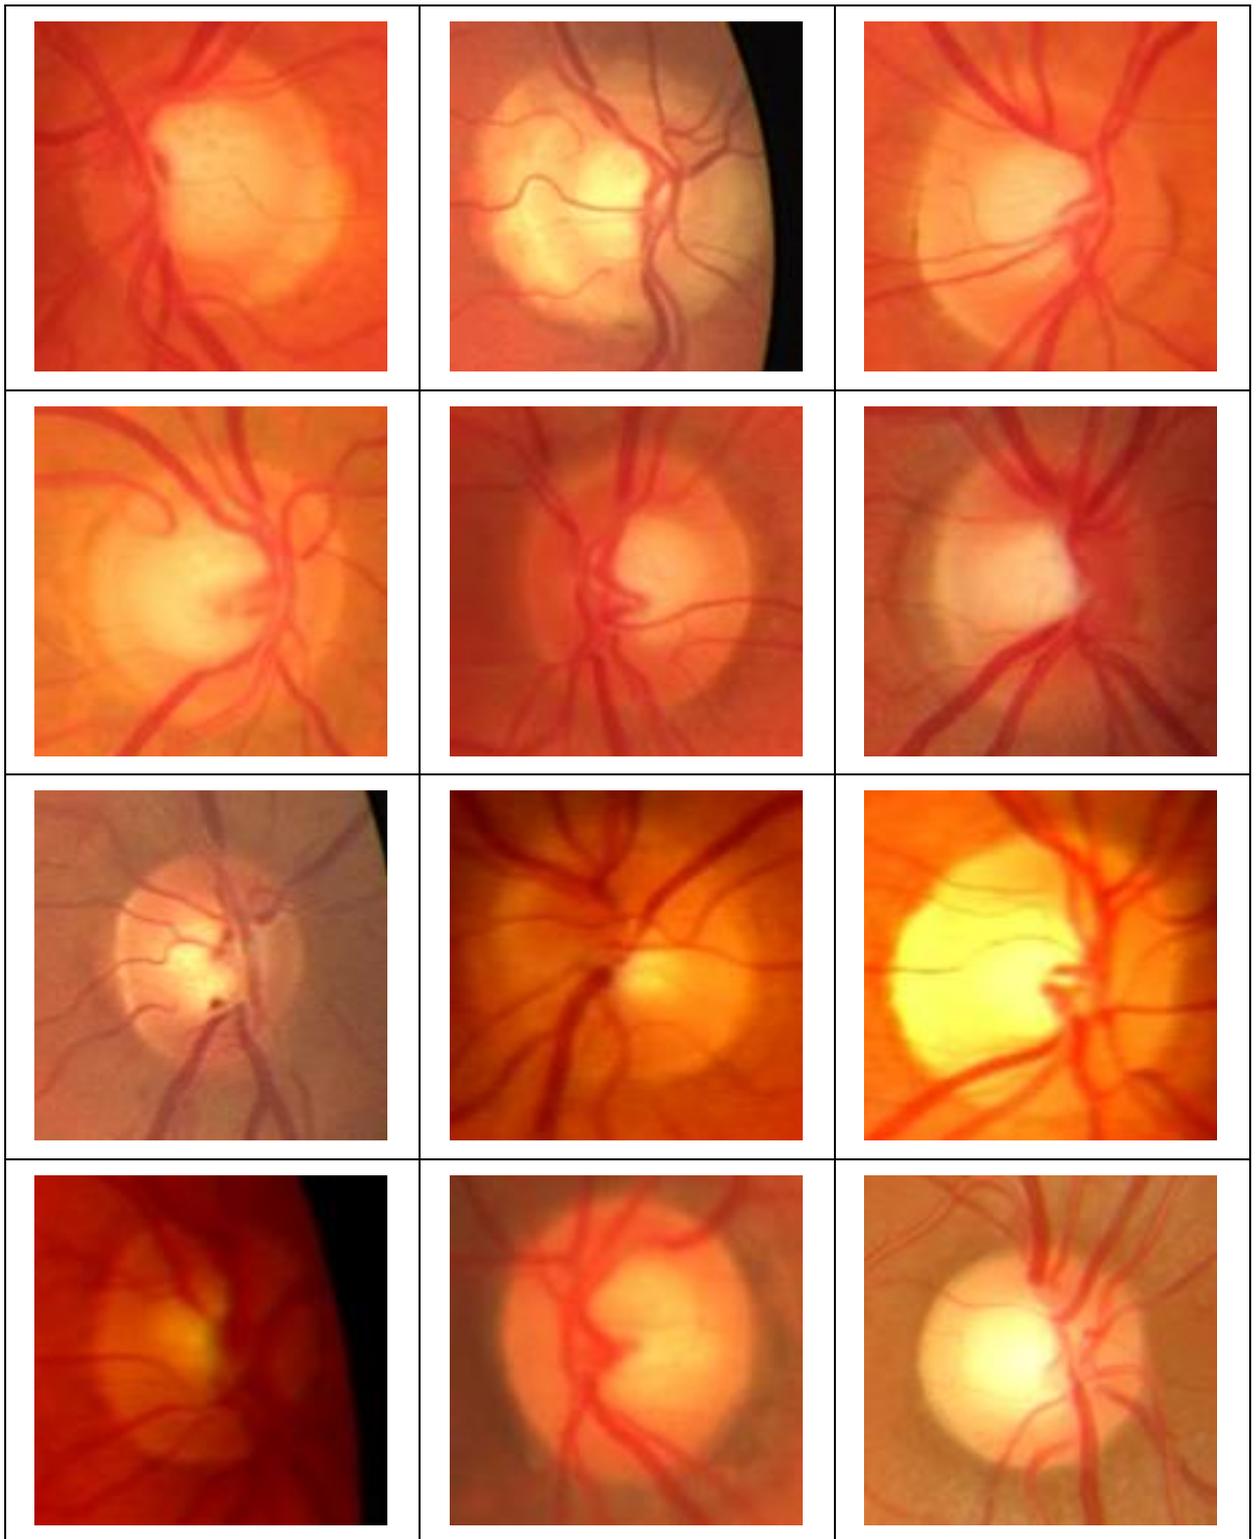
- [49] «High-Resolution Fundus (HRF) Image Database. Universität Erlangen-Nürnberg, Pattern Recognition Lab,» [En línea]. Available: <https://www5.cs.fau.de/research/data/fundus-images/>.
- [50] «DRIVE Database,» [En línea]. Available: <http://www.isi.uu.nl/Research/Databases/DRIVE/>.
- [51] P. t. M. Niemeijer, «Automatic Detection of diabetic retinopathy in digital fundus photographs,» [En línea]. Available: <http://igiturarchive.library.uu.nl/dissertations/2007-0102-200110/UUindex.html>. [Último acceso: 21 02 2013].
- [52] W. W. E. D. G. Sharma, «The CIEDE2000 color- difference formula: Implementation notes, supplementary test data, and mathematical observations,» *Color Res. Appl.* , n° 30, pp. 21-30, 2005.
- [53] M. Fairchild, *Color Appearance Models*, New Jersey: John Wiley & Sons, 2005.
- [54] M. Melgosa, R. Huertas y R. Berns, «Relative significance of the terms in the CIEDE200 and CIE94 color difference formulas,» *Journal of the J. Opt. Soc. Am A-Opt. Image Sci. Vis.*, n° 21, pp. 2269-2275, 2004.
- [55] Ingeniería de Sistemas y Automática. Universidad Miguel Hernández, «Transparencias sobre Selección y Extracción de Características,»  
[En línea]. Available: [http://isa.umh.es/asignaturas/iarp/transparencias/teoria\\_RP\\_EXTRAC%20-%201.pdf](http://isa.umh.es/asignaturas/iarp/transparencias/teoria_RP_EXTRAC%20-%201.pdf). [Último acceso: 07 09 2015].
- [56] «Hamilton Eye Institute Macular Edema Dataset,» [En línea].  
Available: <http://vibot.u-bourgogne.fr/luca/heimed.php>.
- [57] «Structured Analysis of the Retina Database,» [En línea].  
Available: <http://www.ces.clemson.edu/~ahoover/stare/>.
- [58] «Medical Image Analysis Group. Universidad de La Laguna, España,»  
[En línea]. Available: <http://medimrg.webs.ull.es/research/retinal-imaging/rim-one/>.
- [59] M. K. Dutta, A. K. Mourya, M. A. Singh, R. Parthasarathi y B. a. K. Riha, «Glaucoma Detection by Segmenting the Super Pixels from Fundus Colour Retinal Images,» *Int. Conf. Medical Imaging, m-Health and Emerging Communication Systems (MedCom)*, pp. 86-90, 2014.

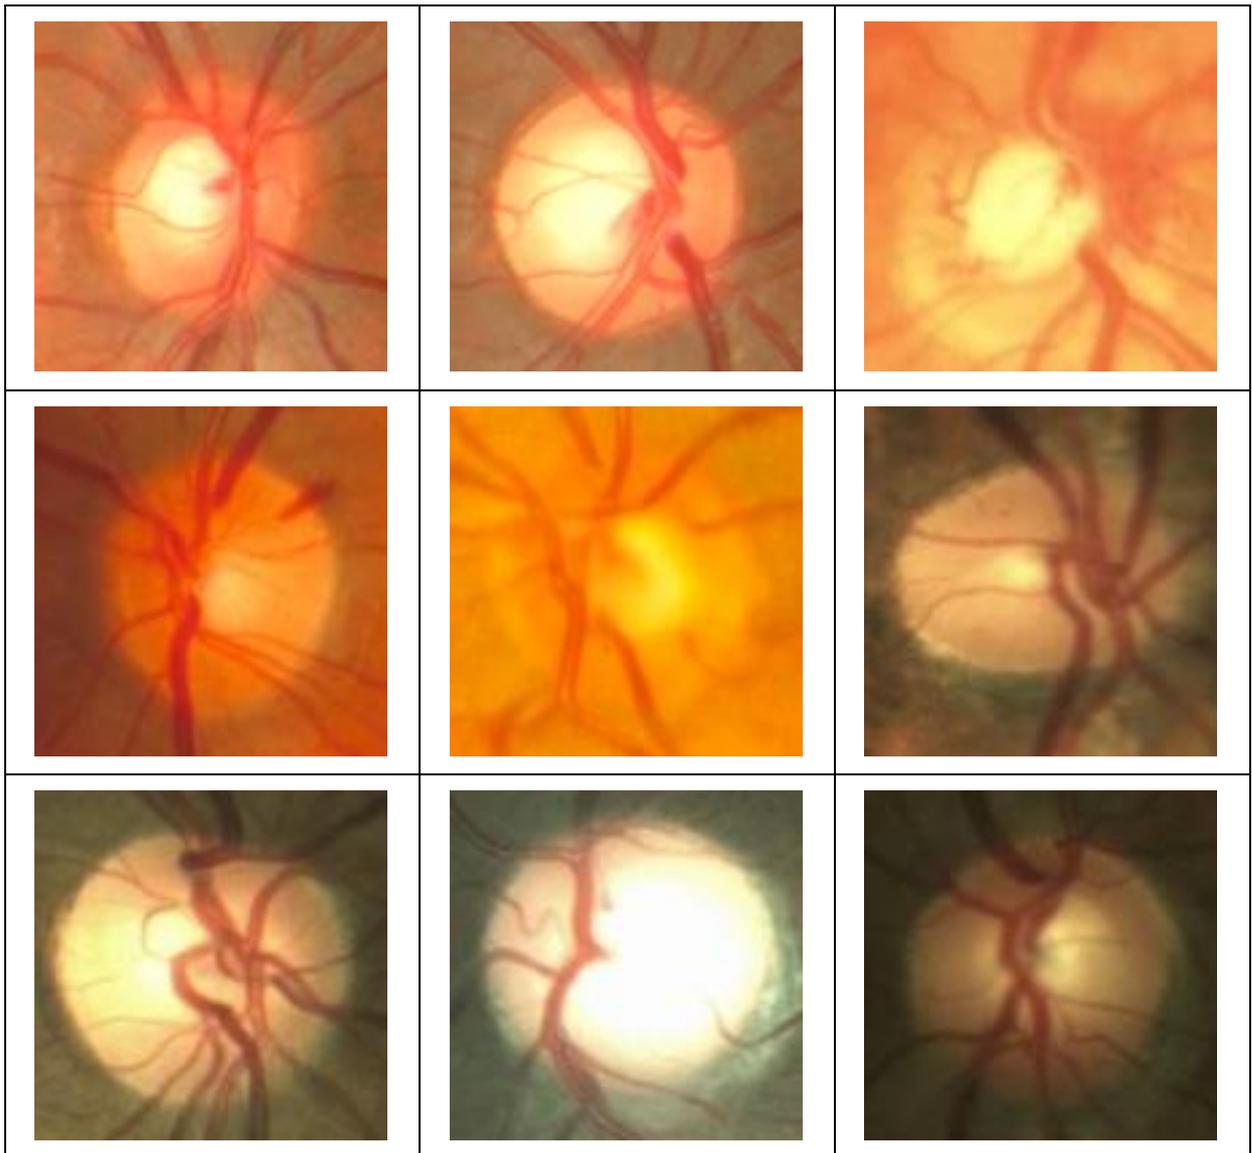
# 10. ANEXO I: ROI DE IMÁGENES ORIGINALES

---

1. ROI de las imágenes usadas para el entrenamiento:

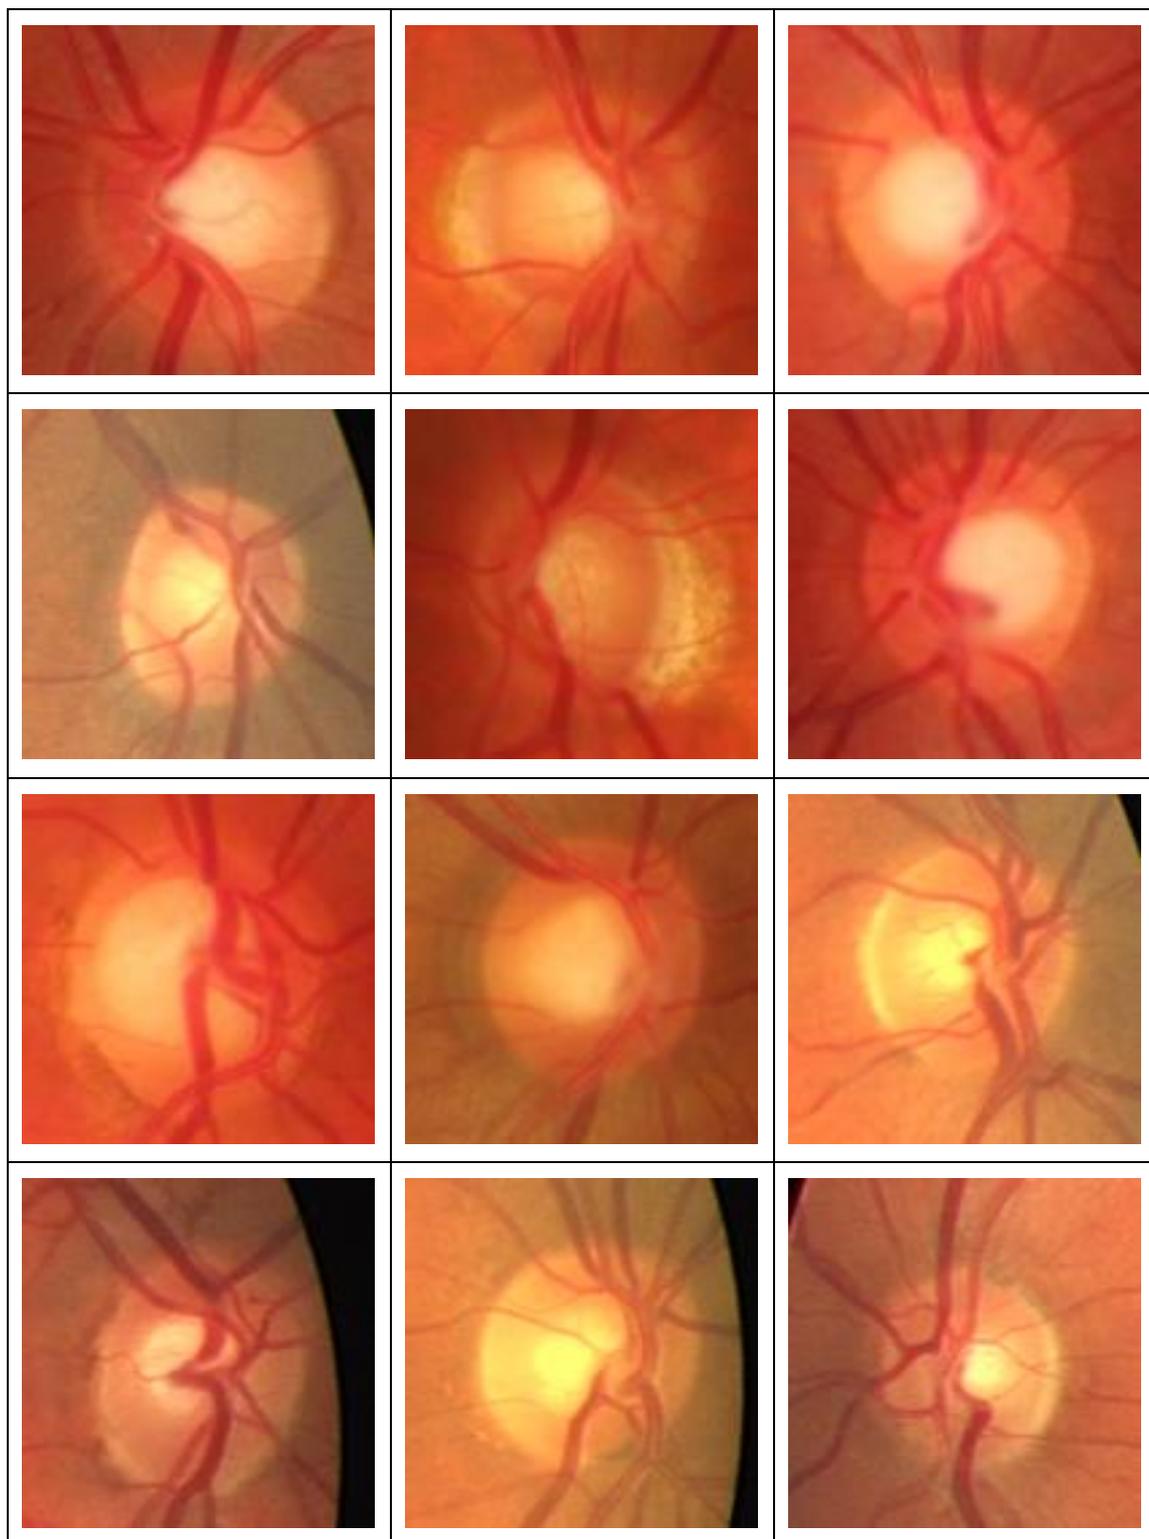


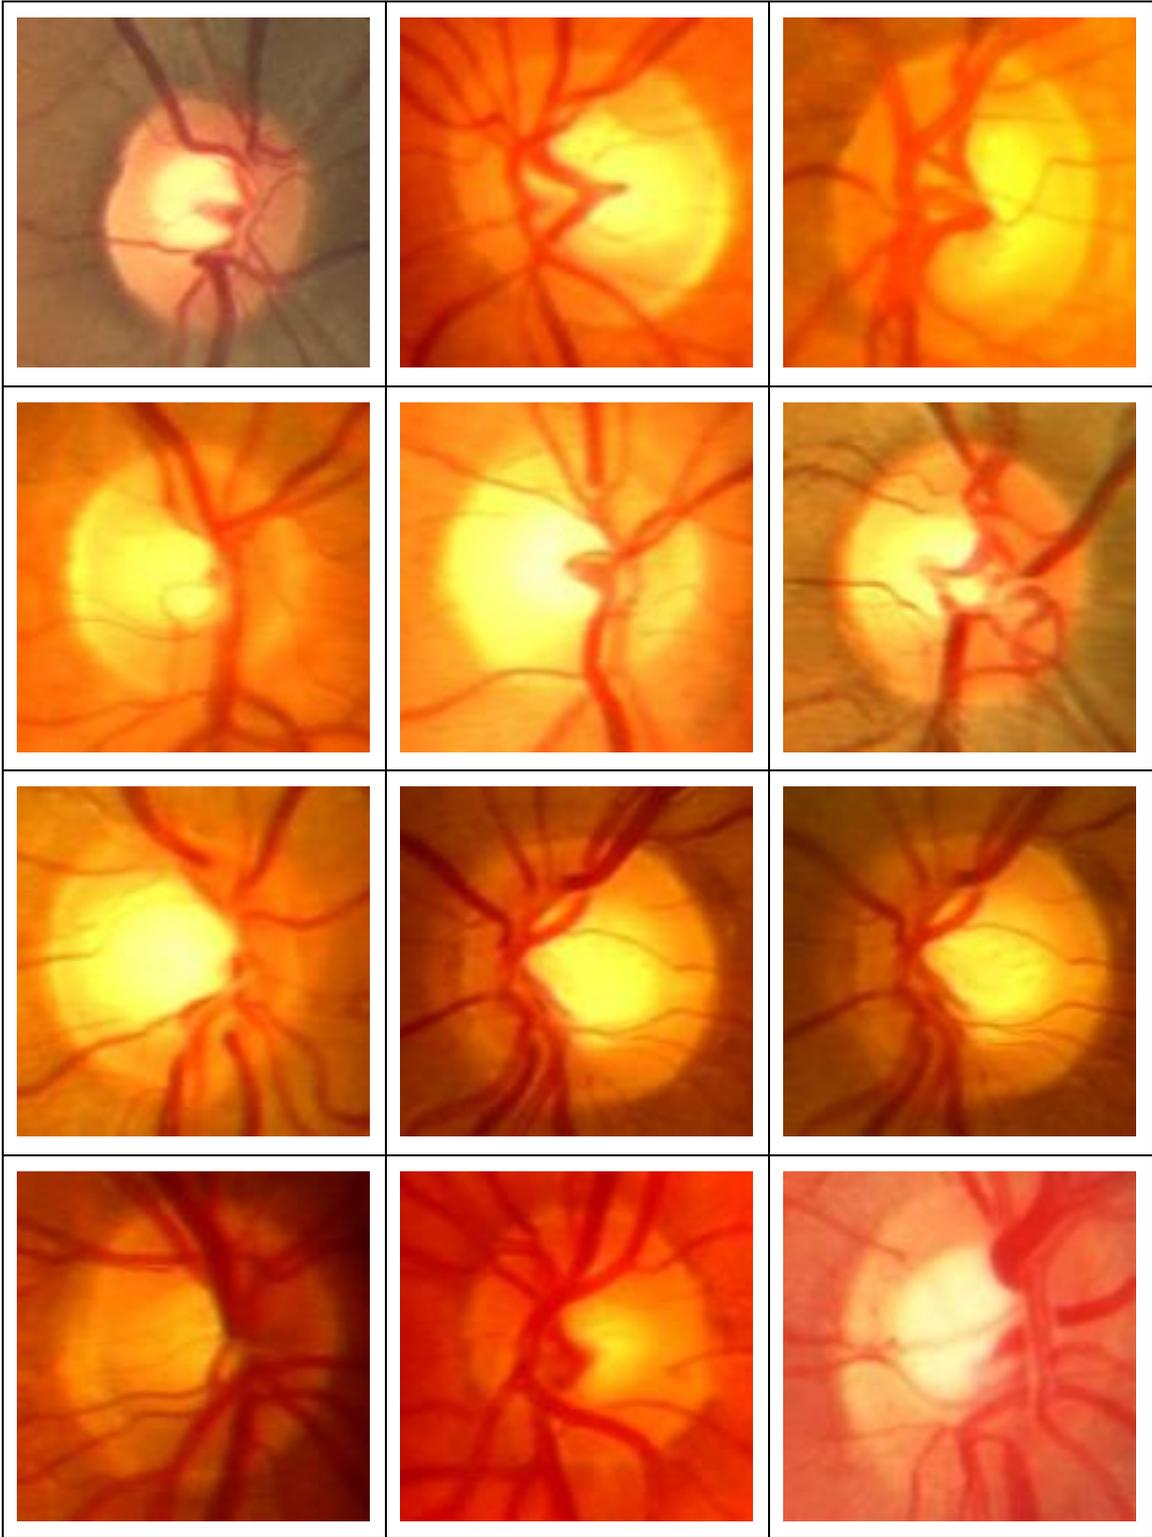


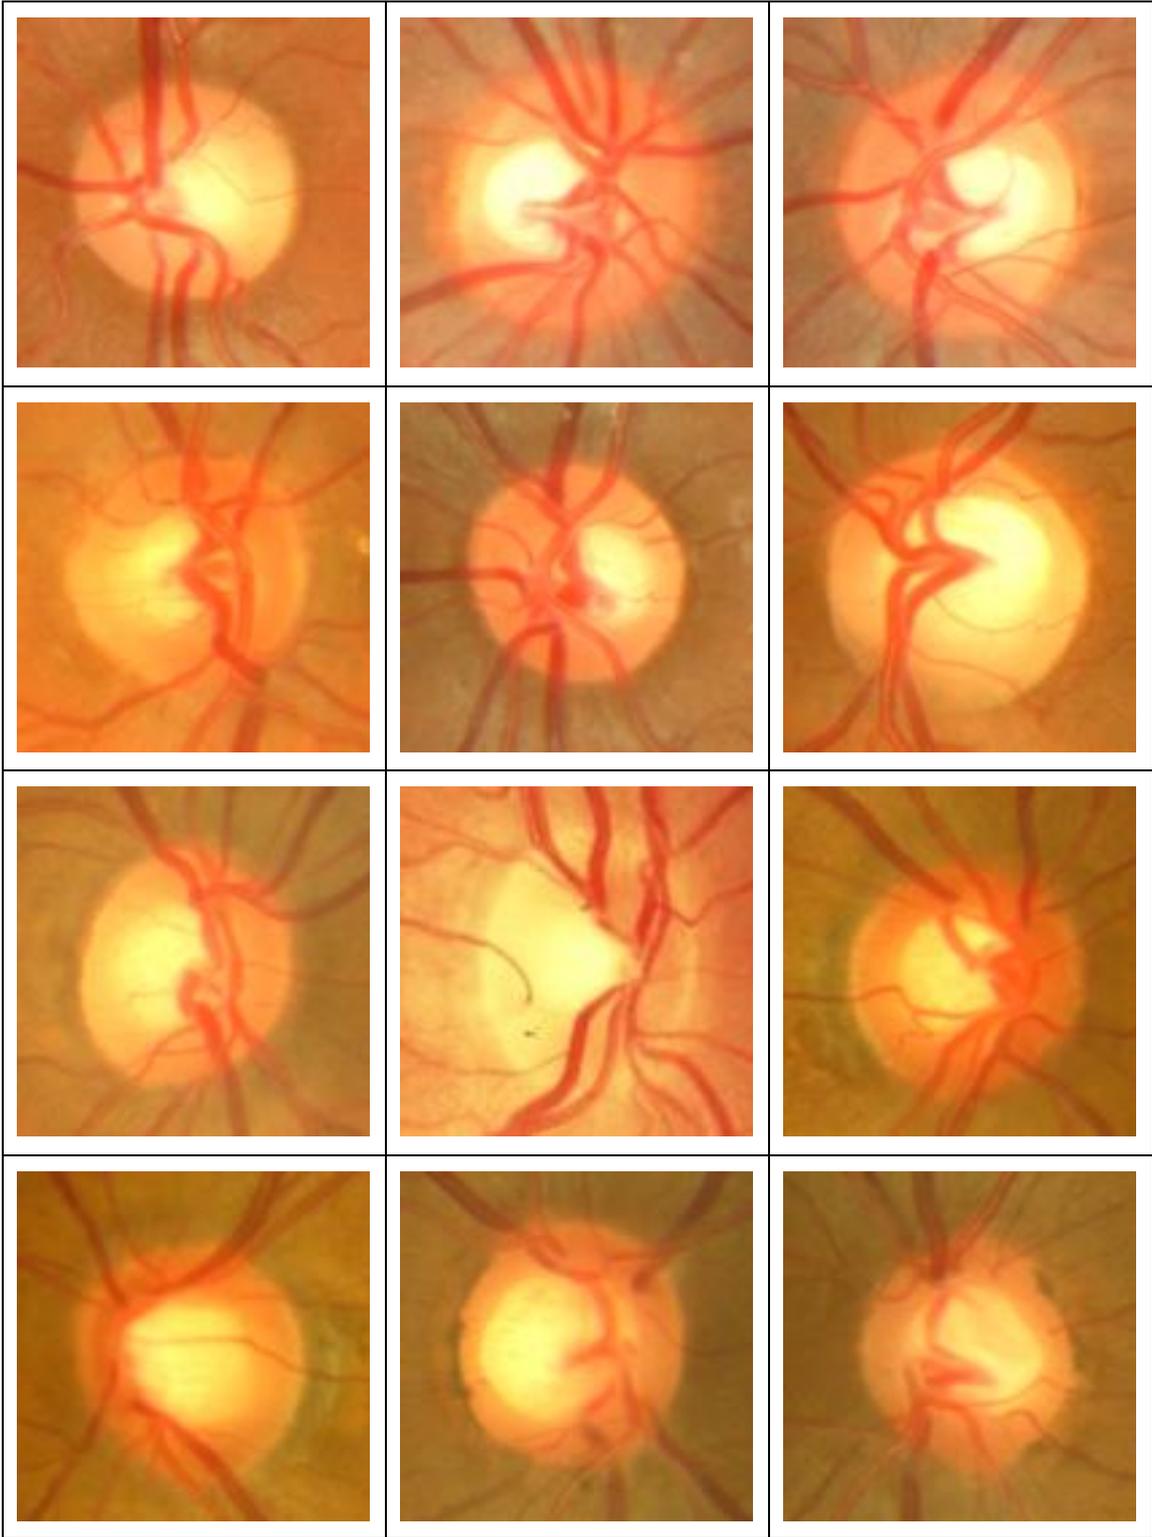


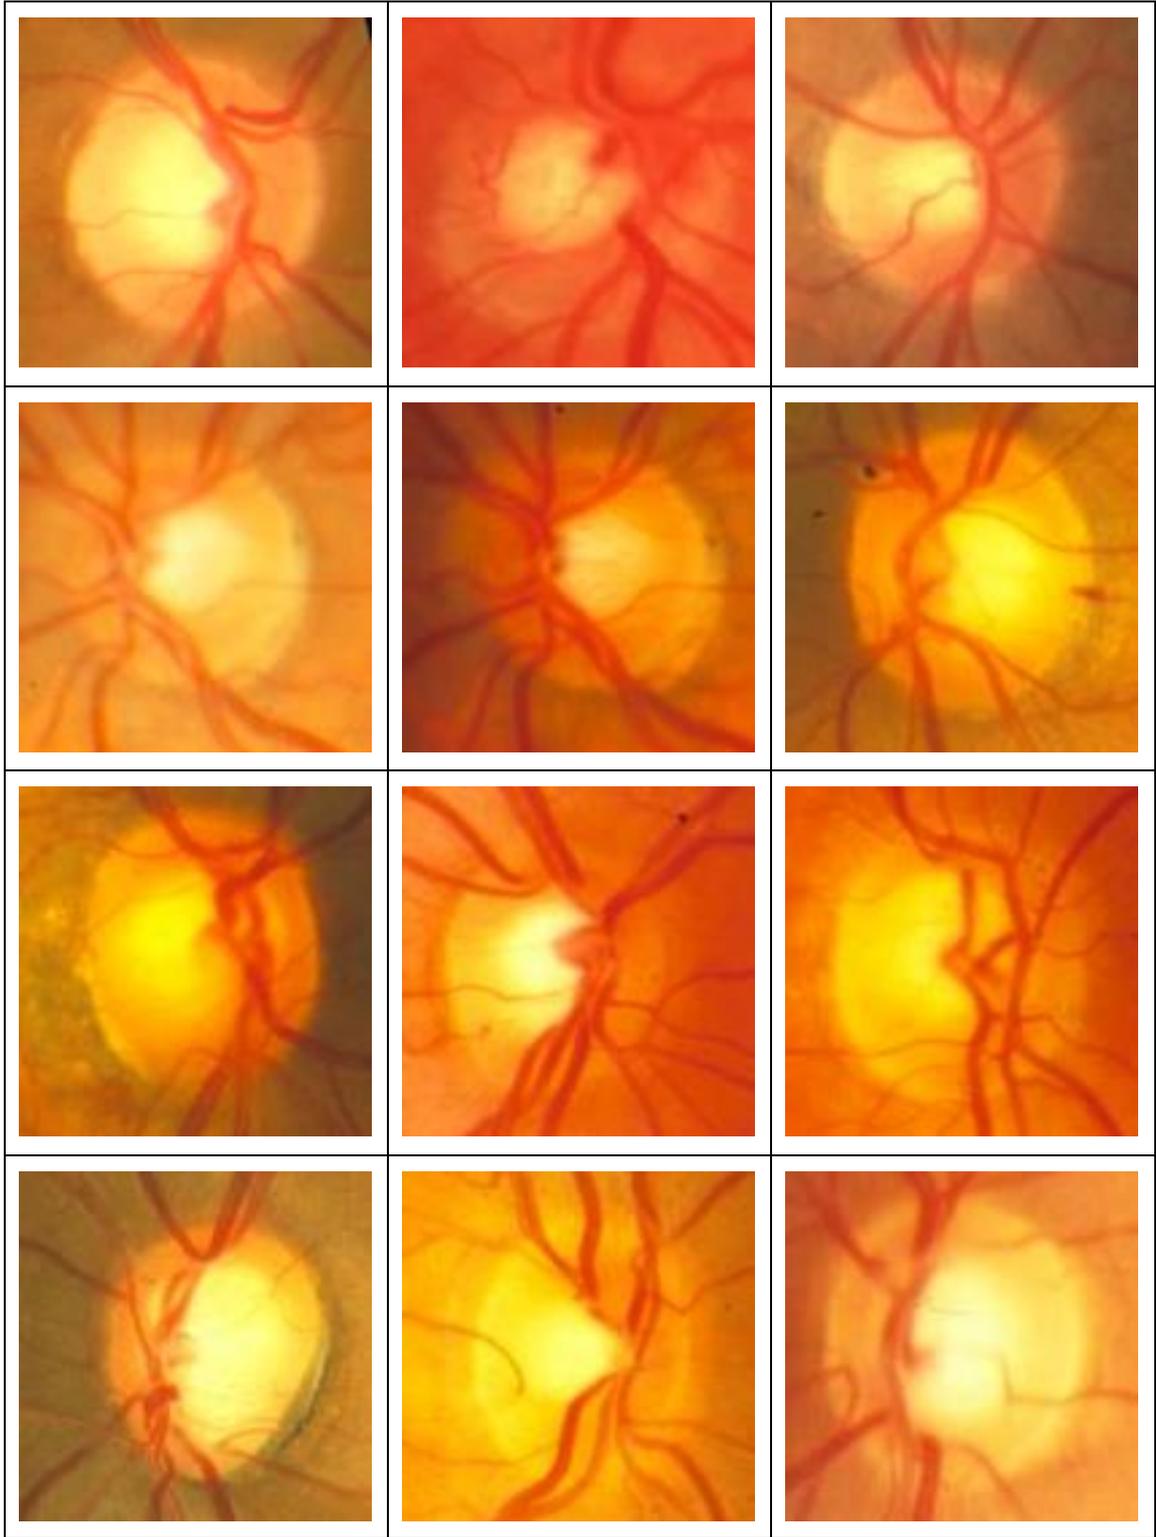


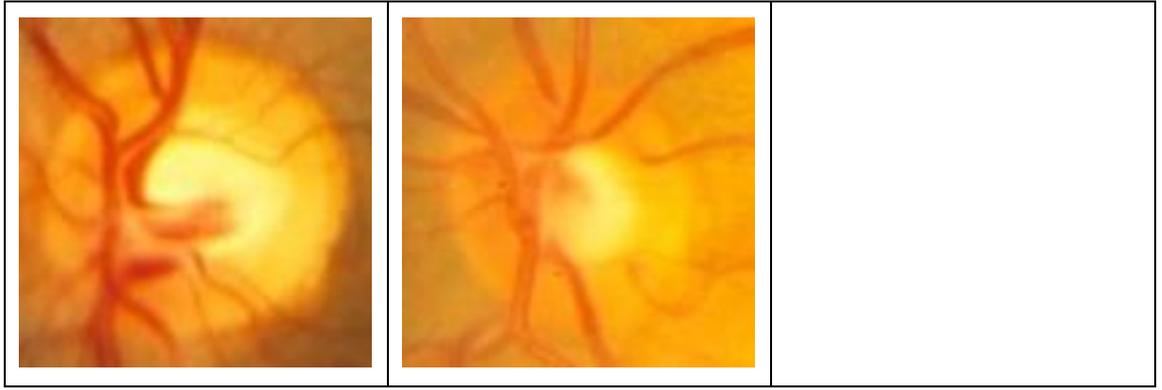
2. ROI de las imágenes usadas para el clasificador:













# 11 ANEXO II: ROI DE IMÁGENES RESULTADO COMPARADAS CON LA VERDAD DE REFERENCIA

