



Universidad
de La Laguna

ESTUDIO DE LA APLICABILIDAD DE LOS MÉTODOS MÁS UTILIZADOS EN PROCESAMIENTO DE RETINOGRAFÍAS SOBRE RETINOGRAFÍAS COMPASS

**TRABAJO FIN DE GRADO
GRADO EN INGENIERÍA ELECTRÓNICA INDUSTRIAL Y
AUTOMÁTICA**

Alumna: María Armas López de Vergara

Tutora: Silvia Alayón Miranda

Julio 2017

ÍNDICE

RESUMEN.....	3
1. INTRODUCCIÓN	4
2. OBJETIVOS Y PLANIFICACIÓN	6
3. DESCRIPCIÓN DEL PROBLEMA MÉDICO	7
3.1. EL GLAUCOMA	7
3.2. TÉCNICAS ACTUALES PARA EL DIAGNÓSTICO DE GLAUCOMA.....	8
3.3. RETINOGRAFÍAS ANALIZADAS EN ESTE TFG	9
4. ESTADO DEL ARTE.....	12
5. ESTUDIO DE APLICABILIDAD DE LOS MÉTODOS SELECCIONADOS.....	20
5.1 “GLAUCOMA DETECTION THROUGH OPTIC DISC AND CUP SEGMENTATION USING K-MEANS CLUSTERING” (Ayub et al., 2016) [10]	20
5.1.1 EXPLICACIÓN DEL MÉTODO.....	20
5.1.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO	21
5.1.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS.....	22
5.1.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS.....	23
5.2 “FUZZY C-MEANS (FCM) FOR OPTIC CUP AND DISC SEGMENTATION WITH MORPHOLOGICAL OPERATION” (Khalid et al., 2014) [13]	24
5.2.1 EXPLICACIÓN DEL MÉTODO.....	24
5.2.2 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS.....	25
5.2.3 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS.....	25
5.3 “SUPERPIXEL CLASSIFICATION BASED OPTIC DISC AND OPTIC CUP SEGMENTATION FOR GLAUCOMA SCREENING” (Cheng et al., 2013) [17]	26
5.3.1 EXPLICACIÓN DEL MÉTODO.....	26
5.3.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO	29
5.3.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS (CONJUNTO DE ENTRENAMIENTO: UNA IMAGEN).....	29
5.3.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS (CONJUNTO DE ENTRENAMIENTO: UNA IMAGEN).....	30
5.3.5 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS (CONJUNTO DE ENTRENAMIENTO: 3 IMÁGENES)	31
5.3.6 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS (CONJUNTO DE ENTRENAMIENTO: TRES IMÁGENES)	32
5.4 “AUTOMATIC MEASUREMENT OF CUP TO DISC RATIO BASED ON LINE PROFILE ANALYSIS IN RETINAL IMAGES” (Hatanaka et al., 2011) [28].....	33
5.4.1 EXPLICACIÓN DEL MÉTODO.....	33

5.4.2	PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO	35
5.4.3	RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS.....	35
5.4.4	RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS.....	36
5.5	“DETECTION OF GLAUCOMA USING RETINAL FUNDUS IMAGES” (Ahmad et al., 2014) [30]	37
5.5.1	EXPLICACIÓN DEL MÉTODO.....	37
5.5.2	PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO	38
5.5.3	RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS.....	38
5.5.4	RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS.....	39
5.6	“SEGMENTATION OF THE OPTIC DISK AND OPTIC CUP USING HISTOGRAM FEATURE-BASED ADAPTIVE THRESHOLD FOR CUP TO DISK RATIO” (Nugraha et al., 2016) [31]	40
5.6.1	EXPLICACIÓN DEL MÉTODO.....	40
5.6.2	RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS.....	42
5.6.3	RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS.....	42
5.7	“SEGMENTATION OF THE OPTIC DISK IN COLOR EYE FUNDUS IMAGES USING AN ADAPTIVE MORPHOLOGICAL APPROACH” (Welfer et al., 2009) [36]	43
5.7.1	EXPLICACIÓN DEL MÉTODO.....	43
5.7.2	PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO	45
5.7.3	RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS.....	45
5.7.4	RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS.....	46
5.8	“BLOOD VESSEL INPAINTING BASED TECHNIQUE FOR EFFICIENT LOCALIZATION ANDSEGMENTATION OF OPTIC DISK IN DIGITAL FUNDUS IMAGES” (Sarathi et al., 2016) [34]	47
5.8.1	EXPLICACIÓN DEL MÉTODO.....	47
5.8.2	PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO	48
5.8.3	RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS.....	49
5.8.4	RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS.....	50
6.	ANÁLISIS DE RESULTADOS EXPERIMENTALES	52
7.	CONCLUSIONES Y LÍNEAS ABIERTAS.....	56
8.	REFERENCIAS	59
	ANEXO I TÉCNICAS DE PROCESAMIENTO DE IMÁGENES UTILIZADAS EN ESTE TRABAJO FIN DE GRADO.....	63
	ANEXO II IMÁGENES UTILIZADAS EN ESTE TRABAJO FIN DE GRADO (HORUS Y COMPASS)	79
	ANEXO III RESULTADOS EXPERIMENTALES DE LOS MÉTODOS REPLICADOS EN ESTE TFG SOBRE LAS IMÁGENES HORUS Y COMPASS	84

RESUMEN

En este Trabajo Fin de Grado (TFG) se realiza un estudio de aplicabilidad de los métodos de segmentación automáticos más recientes sobre imágenes de retinografías Compass.

Los métodos publicados en la literatura científica están diseñados para trabajar con retinografías convencionales, y se desea investigar si son aplicables a este nuevo tipo de retinografías confocales.

Las estructuras de interés a segmentar en estas imágenes son la cabeza del nervio óptico – CNO (o disco óptico) y la excavación (o copa), debido a que son las más influyentes en el diagnóstico del Glaucoma.

Se seleccionarán diferentes trabajos publicados, se reproducirán y se aplicarán sobre un conjunto de imágenes de prueba (convencionales y confocales). Finalmente, se analizarán los resultados experimentales obtenidos y se obtendrán conclusiones sobre la aplicabilidad de cada método.

ABSTRACT

The main purpose of this End of Degree Work (EDW) is to study the applicability of most recently automatically segmentation methods for Compass retinographies.

The published scientific literature methods are focused on conventional retinographies. Our interest is to research if they are applicable to the new type of confocal ones.

The structures of interest in the segmentation process of these images are the optic nerve head and the optic cup, due to their influence in the glaucoma diagnosis.

A selection of different publications will be carried out in order to reproduce and apply them to an image collection (with common and confocal retinographies). Finally, the experimental results will be analysed and some conclusions of the applicability of each method will be extracted.

1. INTRODUCCIÓN

Los sistemas de ayuda al diagnóstico, concretamente por medio de imágenes, están sufriendo un gran avance en los últimos años gracias al desarrollo de los sistemas de visión por computador. Esto es extensible al campo de la Oftalmología, abordado en el presente Trabajo Fin de Grado (TFG).

En la práctica oftalmológica es muy habitual que el especialista realice su diagnóstico con unas imágenes denominadas *retinografías*, que son imágenes del fondo del ojo adquiridas con unas cámaras especiales (*retinógrafos*). El análisis visual de estas retinografías permite la detección de diversas enfermedades oculares, como por ejemplo la Retinopatía Diabética y el Glaucoma, por medio del estudio de algunas de las estructuras presentes en dichas imágenes. En la figura 1.1 se muestra una retinografía convencional con algunas de sus partes señalizadas.

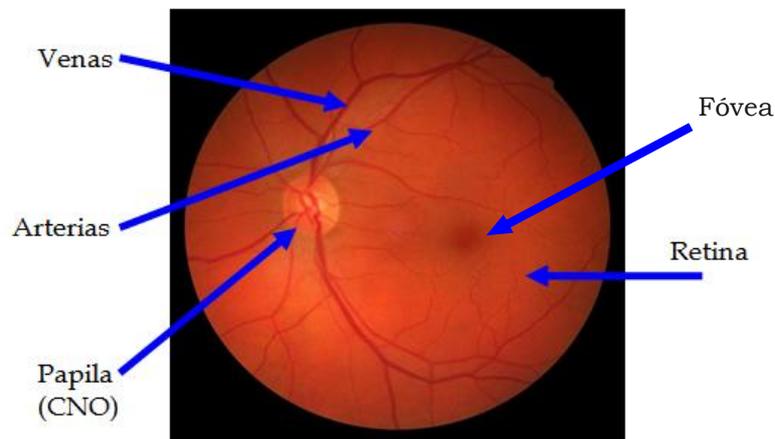


Figura1.1. Retinografía convencional y partes observables del ojo en la misma.

La mayoría de los sistemas actuales de ayuda al diagnóstico de enfermedades del ojo basados en el análisis de retinografías son semi-automáticos, requiriendo la intervención del usuario en alguna etapa del análisis para obtener resultados fiables, como el trazado manual o semi-automático del contorno de la papila y de otras estructuras de la cabeza del nervio óptico. Sin embargo, en el campo de la investigación están comenzando a aparecer sistemas que tratan de minimizar la intervención humana en el proceso de segmentar e identificar las diferentes estructuras presentes en las retinografías. Estos últimos métodos son los que nos interesa analizar en el presente TFG.

Todos los trabajos publicados hasta la fecha se han aplicado sobre retinografías adquiridas con "retinógrafos convencionales" (ver figura 1.2). En estas retinografías la retina tiene una apariencia rojiza, los vasos y la fóvea son las zonas más oscuras, y el disco óptico suele ser la zona elíptica más clara del interior de la retina. Por lo tanto, las técnicas de segmentación existentes se basan en el análisis de la información del color y de la intensidad de la imagen.

El perfeccionamiento de la tecnología médica supone un constante desafío. En el campo de la Oftalmología es destacable el desarrollo de un nuevo equipo retinógrafo, denominado Compass [1] que presenta numerosas ventajas como, por ejemplo, permitir la realización de varias pruebas diagnósticas a la vez sobre un paciente. En concreto, este aparato permite adquirir retinografías mientras el paciente se somete a un estudio perimétrico. Como desventaja, las imágenes obtenidas con él son confocales, y por lo tanto su apariencia es totalmente diferente a las retinografías hasta ahora consideradas convencionales. En la figura 1.2 se puede observar la diferencia entre una imagen convencional y una Compass.

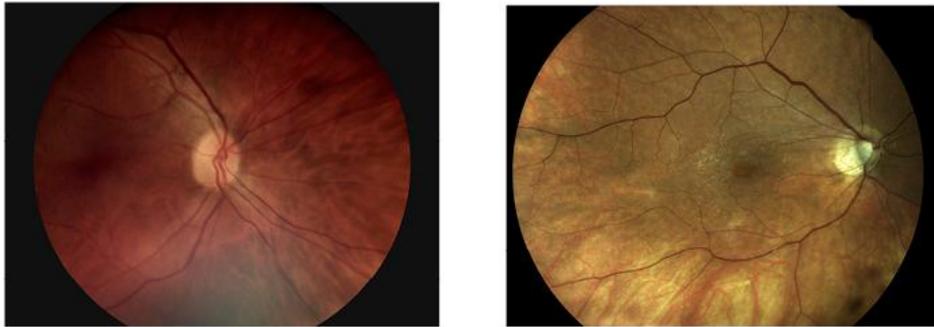


Figura 1.2. Retinografías convencional (izquierda) y Compass (derecha).

En las imágenes Compass la información de color y luminosidad ya no es fiable, debido a la gran variabilidad que presentan las estructuras de interés en cada retinografía. No hay un patrón único que permita diferenciar la zona del disco óptico del resto de la imagen. Por lo tanto, los métodos hasta ahora publicados en la literatura científica sobre la segmentación automática de esta región podrían no ser aplicables en este nuevo tipo de imágenes.

Precisamente, éste es el principal interés de este TFG: estudiar la aplicabilidad de los métodos de segmentación automáticos más utilizados en el procesamiento de retinografías convencionales sobre estas nuevas retinografías de la máquina Compass.

La presente memoria se estructura como sigue: se comienza describiendo los objetivos del TFG y los fundamentos del problema médico abordado. Como en el TFG se plantea un estudio de los métodos de segmentación de retinografías más actuales, se presenta, a continuación, un estado detallado del arte. Algunos de los métodos analizados serán explicados y replicados en el siguiente capítulo. Por último, tras realizar un análisis de los resultados experimentales obtenidos, se ofrecen las conclusiones y líneas abiertas.

2. OBJETIVOS Y PLANIFICACIÓN

Como se ha indicado en la introducción, el **principal objetivo** del presente Trabajo Final de Grado es estudiar la aplicabilidad de los métodos de segmentación automáticos más utilizados en el procesamiento de retinografías convencionales sobre las nuevas retinografías de la máquina Compass. En concreto, los métodos enfocados a la segmentación automática del disco óptico y de la excavación.

Como los métodos de segmentación diseñados para las retinografías convencionales suelen estar basados en el análisis de la información del color y luminancia, información no significativa en las imágenes Compass, partimos de la **hipótesis** de que probablemente estos métodos no serán aplicables sobre estas nuevas imágenes. Pero es objeto de este TFG verificar esta hipótesis.

Como **objetivo secundario**, es importante destacar que este TFG pretende ser una introducción a la investigación para la alumna que lo desarrolla. Concretamente, en el procesamiento de imágenes médicas, área en el que ella desea especializarse y continuar su formación de postgrado.

Para conseguir alcanzar los objetivos del TFG será necesario realizar las siguientes tareas de investigación y desarrollo:

1. Estudiar el problema médico abordado: en concreto, los fundamentos de la enfermedad del Glaucoma, y cómo se realiza su diagnóstico con retinografías.
2. Estudiar las técnicas de procesamiento de imagen más comunes: dado que no existe una asignatura específica sobre procesamiento de imágenes en el Grado en Ingeniería Electrónica Industrial y Automática, esta labor es imprescindible en las etapas iniciales del TFG.
3. Realizar una recopilación de los trabajos más recientes que abordan el problema de la segmentación automática del disco óptico y la excavación, por ser estas estructuras las analizadas en el diagnóstico del Glaucoma. Esta tarea implicará el manejo de bases de datos y de literatura científica, para la correcta documentación del estado del arte actual.
4. Selección de los trabajos publicados que se intentarán reproducir. El estudio del trabajo de otros autores no es una tarea sencilla, no siempre se ofrecen suficientes detalles que permitan la total reproducibilidad de los métodos propuestos.
5. Selección de un conjunto de imágenes para validar los métodos reproducidos. En este caso, se usarán 30 retinografías convencionales (adquiridas con la cámara Horus de la empresa Miis) y 30 retinografías Compass. Estas imágenes han sido cedidas por especialistas del Hospital Universitario de Canarias.
6. Estudiar la herramienta Matlab y su librería de procesamiento de imágenes, ya que será el entorno de implementación del presente TFG.
7. Analizar los resultados de segmentación obtenidos con los distintos métodos estudiados e implementados para los dos grupos de imágenes, y extraer conclusiones sobre la aplicabilidad de dichos métodos.

3. DESCRIPCIÓN DEL PROBLEMA MÉDICO

3.1. EL GLAUCOMA

El Glaucoma es una enfermedad que produce una lesión irreparable en el nervio óptico que suele estar provocada por un aumento de la presión intraocular. Esta enfermedad causa una pérdida progresiva de la visión que comienza, generalmente, en el campo visual periférico y avanza de forma más o menos progresiva hacia el central, por lo que muchos pacientes no son conscientes de ella hasta que el proceso se encuentra muy avanzado. Según la Organización Mundial de la Salud, constituye la segunda causa principal de ceguera en el mundo [2]. De forma más específica, se estima que esta afección degenerativa afecta a unas 46.242 personas en Canarias [3], es decir, aproximadamente al 22% de los habitantes de las islas.

Para poder explicar de manera más detallada la enfermedad ocular del glaucoma, es necesario describir previamente a grandes rasgos cómo funciona el ojo humano. En la figura 3.1 se pueden observar las partes más importantes del mismo.

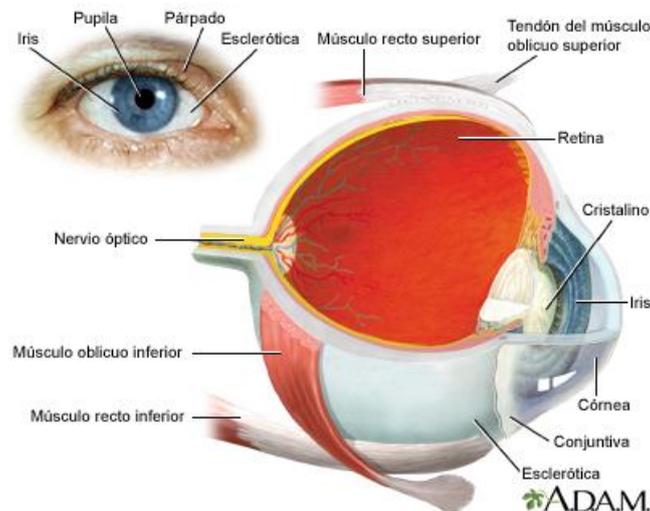


Figura 3.1. Esquema del interior del ojo. Extraído de [4].

Como se puede apreciar, el ojo está recubierto por una capa protectora de color blanco que se llama esclerótica y tiene como función salvaguardar a los elementos internos. En la parte delantera del ojo se encuentra la córnea, que es transparente y permite que entre la luz. Además, el iris es la parte de color en el ojo que se contrae y se expande para que la pupila deje entrar la cantidad adecuada de luz. Esta se dirige al cristalino que, a su vez, enfoca la luz sobre la retina. Las fibras nerviosas de la retina llevan, de este modo, la luz y las imágenes al cerebro por medio del nervio óptico.

La presión interna del ojo depende de la cantidad de fluido que se encuentre dentro del mismo. Si el sistema de drenaje del ojo funciona correctamente, el fluido saldrá libremente sin acumularse. En la mayoría de los tipos de glaucoma, el sistema de drenaje del ojo se bloquea y el fluido intraocular no puede drenar. Al acumularse, causa un aumento de presión en el interior del ojo que daña al nervio óptico.

No obstante, aunque la presión intraocular alta es uno de los factores conocidos que influye en la aparición de glaucoma, no se puede afirmar que exista una correlación exacta entre glaucoma y presión intraocular, pues algunas personas pueden desarrollar la enfermedad con cifras de presión intraocular consideradas normales y, sin embargo, en otras ocasiones existen cifras altas sin que se produzca ninguna repercusión ocular [5].

3.2. TÉCNICAS ACTUALES PARA EL DIAGNÓSTICO DE GLAUCOMA

La importancia del diagnóstico temprano de esta enfermedad, así como de su avance, reside en la incapacidad de regeneración del nervio óptico y, por lo tanto, en la imposibilidad de recuperación visual [6], [7].

Con este propósito se ha invertido un gran esfuerzo en el desarrollo de técnicas de examen. En la actualidad existen numerosos aparatos médicos para estudiar y diagnosticar las enfermedades oculares. En el caso del glaucoma, existen dos tipos de pruebas bien diferenciadas:

1. *Pruebas funcionales*: estudian los defectos funcionales del ojo, entendiendo como defecto funcional un fallo en la capacidad visual del paciente. Para esto se utilizan **perímetros**, que son aparatos que permiten analizar el campo visual.
2. *Pruebas morfológicas*: realizan mediciones de las estructuras internas del ojo para estimar el daño morfológico. Requieren el uso de equipos sofisticados y costosos, como la **Tomografía de Coherencia Óptica** (OCT) y el **Tomógrafo Retinal de Heidelberg** (HRT).

Los dos métodos de diagnóstico (funcional y morfológico) son útiles y complementarios, ya que el daño glaucomatoso da lugar a cambios morfológicos en la capa de fibras nerviosas y a una pérdida funcional del área correspondiente.

Pero, sin duda, una herramienta de diagnóstico que se usa en la práctica clínica diaria es la retinografía, imagen del fondo de ojo adquirida con un **retinógrafo**. Los retinógrafos son cámaras económicas y sencillas de manejar, disponibles hoy en día en todas las consultas oftalmológicas y en los centros de salud. Las imágenes que se obtienen con esta cámara permiten alertar inicialmente al especialista de la presencia de Glaucoma. Un ejemplo de retinografía se mostró anteriormente en la figura 1.2.

Un aspecto que se estudia en el diagnóstico del glaucoma con retinografías es la presencia de una papila muy excavada [8]. La **papila**, o **cabeza del nervio óptico (CNO)** es una estructura visible en las retinografías, que presenta un hundimiento o depresión central, denominada **excavación fisiológica**, correspondiente al volumen no ocupado por tejido neural. En los pacientes de glaucoma esta excavación es mayor que en los sujetos sanos. En una papila sana (figura 3.2 izquierda) la excavación debe medir 0.3 mm o menos, y no haber una diferencia de 0.2 mm entre un ojo y otro. En cambio, en una papila glaucomatosa (figura 3.2, derecha) se puede observar un aumento concéntrico de la excavación, lo que implica una pérdida localizada de tejido.

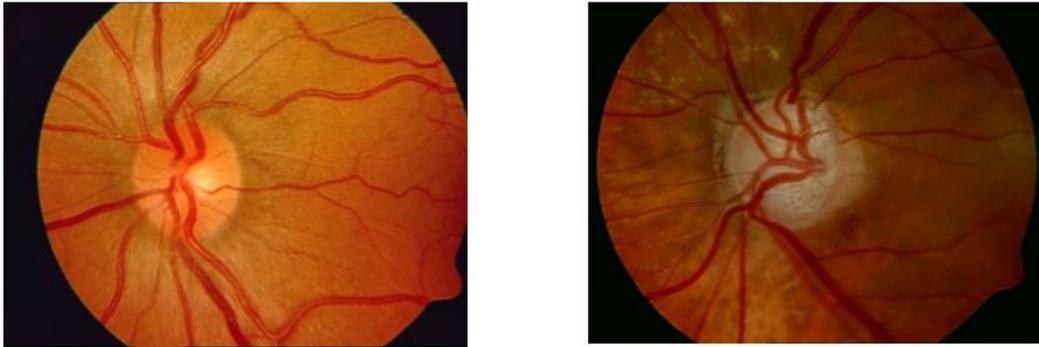


Figura 3.2. Izquierda: papila sana. Derecha: papila glaucomatosa.

Por lo tanto, para el diagnóstico del Glaucoma, la aplicación de técnicas de procesamiento de imagen sobre imágenes retinográficas tiene como objetivo principal la segmentación de la CNO y de la excavación, y la medición de sus tamaños.

3.3. RETINOGRAFÍAS ANALIZADAS EN ESTE TFG

En este Trabajo Fin de Grado se han utilizado retinografías adquiridas con dos retinógrafos diferentes:

1. Retinografías de la cámara Horus (Miis): retinografías convencionales, tomadas con la cámara no midriática manual Horus [9]. En la figura 3.3 se muestra esta cámara, y en la figura 3.4 algunas de las retinografías obtenidas con ella. Se puede observar que en estas retinografías la retina es de un tono rojizo, los vasos y la fovea se corresponden con las partes más oscuras de la imagen, y el disco óptico generalmente es la zona elíptica más clara que se aprecia en la retina. Por lo tanto, presentan la apariencia más común en este tipo de imágenes.



Figura 3.3. Cámara Horus (Miis).

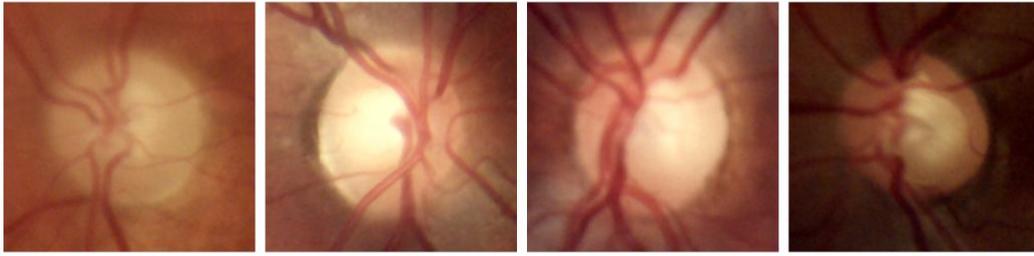


Figura 3.4. Retinografías convencionales.

2. Retinografías de la cámara Compass (Centervue): retinografías no convencionales, tomadas con la cámara Compass [1]. Esta cámara es especial porque, además de permitir la adquisición de retinografías, permite la realización simultánea de perimetrías (ver figura 3.5).



Figura 3.5. Cámara Compass. Primer perímetro-retinógrafo capaz de realizar perimetrías y adquirir retinografías confocales a la vez.

En esta máquina la adquisición de las imágenes se realiza de manera confocal. Una cámara confocal utiliza iluminación puntual, utiliza un colimador de orificio delimitante, y elimina la información que está fuera del plano focal. Como se puede observar en la figura 3.6, las imágenes obtenidas con Compass son muy diferentes de las retinografías clásicas: ni la retina aparece siempre en tono rojizo, ni la CNO es necesariamente la zona más iluminada de la imagen. La distribución del color en estas imágenes es mucho más aleatoria, y no existe un patrón regular que permita una identificación sencilla de la zona de la CNO.

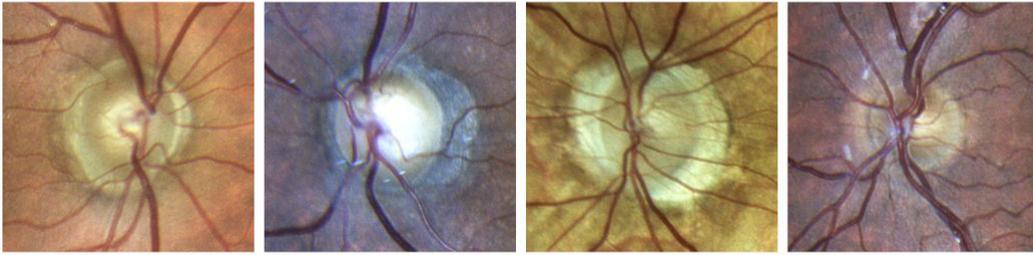


Figura 3.6. Retinografías Compass.

Todas las imágenes con las que se trabaja en el presente TFG han sido proporcionadas por oftalmólogos del Hospital Universitario de Canarias. Entre todas las imágenes cedidas, se han elegido 30 de cada tipo (30 imágenes Miis y 30 imágenes Compass). Como punto de partida, se trabaja con las imágenes con la zona de la CNO ya localizada, recortadas manualmente por un experto médico.

Se ha intentado que estas 60 imágenes reflejen la mayor variedad posible, dentro de cada categoría. En el anexo II se pueden observar las imágenes finalmente seleccionadas.

4. ESTADO DEL ARTE

En este Trabajo Fin de Grado se ha realizado una recopilación de los artículos científicos más recientes cuyo objetivo es la detección automática de las estructuras de mayor interés para el diagnóstico del glaucoma en retinografías: la cabeza del nervio óptico (CNO) o disco óptico, y la excavación (o copa).

Es importante destacar que todos estos métodos han sido diseñados para su aplicación sobre retinografías convencionales, obtenidas con retinógrafos midriáticos o no midriáticos. La retinografía confocal es una técnica muy reciente, y no se han encontrado trabajos que aborden la segmentación totalmente automática sobre este tipo de retinografías.

En total se han estudiado en profundidad 30 artículos. A continuación, se ofrece una breve descripción de cada trabajo. Los métodos implementados en el presente TFG están extraídos de esta colección.

Comenzaremos comentando los trabajos que han abordado el problema utilizando **clasificadores** en alguna etapa del procesamiento, tanto supervisados como no supervisados. Estos últimos emplean algoritmos de agrupamiento de datos (*clustering*) para determinar qué píxeles se corresponden al fondo, al disco óptico y/o a la excavación fisiológica, como parte del proceso de segmentación.

Por ejemplo, en [10] se proponen dos métodos independientes para segmentar disco y copa. Ambos métodos comienzan aplicando operaciones morfológicas para atenuar los vasos presentes en la CNO, y utilizan filtros y ecualización sobre distintas componentes de color según el caso (disco o copa). Sobre las imágenes resultado se aplica el clasificador k-means. Los resultados de aplicabilidad de este método se ofrecen en la sección 5.1.

En [11] se comparan cuatro métodos diferentes para segmentar la CNO:

- 1) Umbralización con Otsu.
- 2) Método de crecimiento de regiones sobre la imagen con los vasos eliminados.
- 3) K-means en el espacio de color Lab.
- 4) Fuzzy c-means sobre la componente R de la imagen original.

Pero en el artículo no se explica bien cómo se elige la solución final de manera automática, ni se ofrece información básica sobre algunos de los métodos propuestos: cómo es el método de crecimiento de regiones que usan y cómo se obtiene la imagen con vasos eliminados sobre la que se aplica este método, cómo se determina el número de centros para los algoritmos k-means y fuzzy c-means, etc.

Con respecto a la segmentación de la copa, se propone un método que “parece” un ecualizado de la componente L seguido de un umbralizado, pero es difícil de asegurar, teniendo en cuenta que lo que se dice en el texto no se corresponde con el esquema gráfico del método que aparece en el artículo.

Además, los resultados experimentales gráficos no parecen coherentes con los métodos que dicen los autores haber seguido en algunos casos, tal y como se puede apreciar en la única figura que los muestra (figura 4.1).

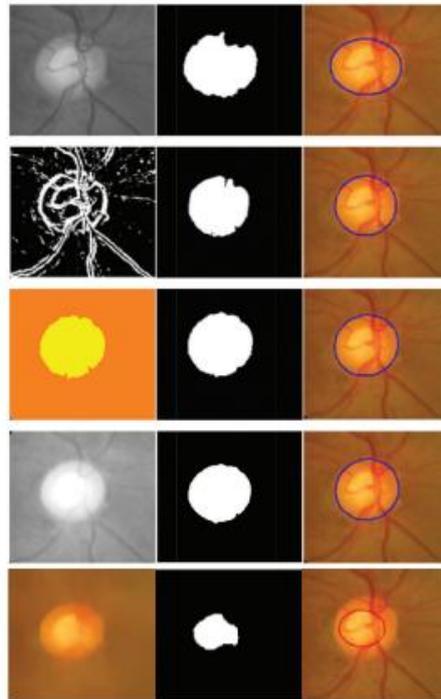


Figure 7. Result of fundus image analysis.

Row 1 Result of otsu method

Row 2 Result of region growing algorithm

Row 3 Result of hill climbing algorithm

Row 4 Result of fuzzy c-means algorithm

Row 5 Result of optic cup segmentation method

Figura 4.1. Resultados gráficos de las cuatro segmentaciones del disco y de la segmentación de la copa extraídos del trabajo [11].

Otro inconveniente es que los métodos propuestos en este trabajo han sido aplicados, según los autores, sólo sobre 12 retinografías, lo que parece insuficiente para asegurar que el método es robusto. Por todos estos motivos, este método ha sido descartado del estudio de aplicabilidad realizado en este TFG.

En la propuesta de [12] se propone un método para la localización de la zona de la CNO que aplica los siguientes pasos: Análisis Discriminante Lineal sobre la imagen original, ecualizado adaptativo, filtrado y umbralizado para la detección de vasos, borrado de la red de vasos, aplicación de k-means, y aplicación de operadores morfológicos (apertura-cierre). Este proceso está esquematizado en la figura 4.2 (izquierda), extraída del propio artículo. Posteriormente, en la zona localizada como CNO, sobre la componente G de la imagen, se aplica un procedimiento para detectar la excavación basado en la transformada watershed.

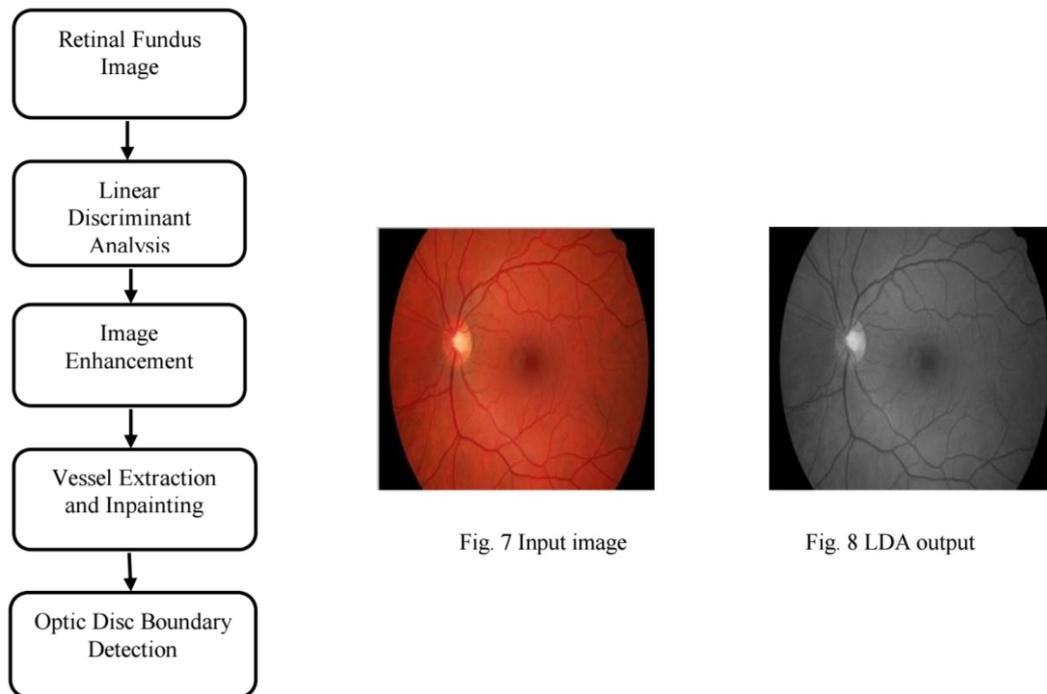


Figura 4.2. Detección de la CNO propuesta por [12] (izquierda). Resultado de aplicar análisis lineal discriminante sobre la imagen original (derecha).

Este método se ha intentado reproducir, pero finalmente no se ha considerado en el presente estudio de aplicabilidad por varios motivos:

- 1) No se comprende muy bien la utilidad de la aplicación del análisis discriminante lineal sobre la imagen original. La imagen resultante es prácticamente igual que la imagen original en escala de grises (ver figura 4.2 derecha).
- 2) No se comprende el paso de borrado de los vasos, porque en los pasos siguientes no se utiliza la información de los mismos en ningún momento.
- 3) La aplicación del clasificador k-means no está bien explicada ni documentada. El artículo se limita a resumir en qué consiste este clasificador, pero no comenta cómo lo aplica ni qué hace con la imagen resultante. De hecho, ni siquiera contempla este paso en el esquema del método (figura 4.2 izquierda).
- 4) La operación de apertura y cierre parece que se aplica sobre la imagen en escala de grises, no sobre ninguna imagen resultante de un paso anterior.
- 5) El artículo menciona que el método propuesto se ha aplicado sobre 50 imágenes, y que ha dado buenos resultados en 48, pero no muestra ni una sola imagen de estos resultados de segmentación.

El proceso propuesto por [13] tiene como objetivo la detección automática y simultánea del disco y de la excavación. Procesa inicialmente la imagen con operaciones morfológicas para reducir el efecto de los vasos en la zona de la CNO, y la imagen resultante es la entrada del clasificador fuzzy c-means. Los resultados de aplicabilidad de este método se ofrecen en la sección 5.2.

Por otra parte, en [14] se comienza localizando la zona de la CNO con un método basado en el Análisis de Componentes Principales (*Principal Component Analysis – PCA*). Una vez localizada esta zona, se aplica un clasificador fuzzy c-means para detectar la excavación, y un modelo de contornos activos para segmentar la CNO. Finalmente, sobre los resultados obtenidos con ambos métodos, se realizan una serie de mediciones indicativas de la presencia de Glaucoma (relación copa-disco, ancho mínimo del anillo neuro-retiniano, etc). El esquema del método se muestra en la figura 4.3.

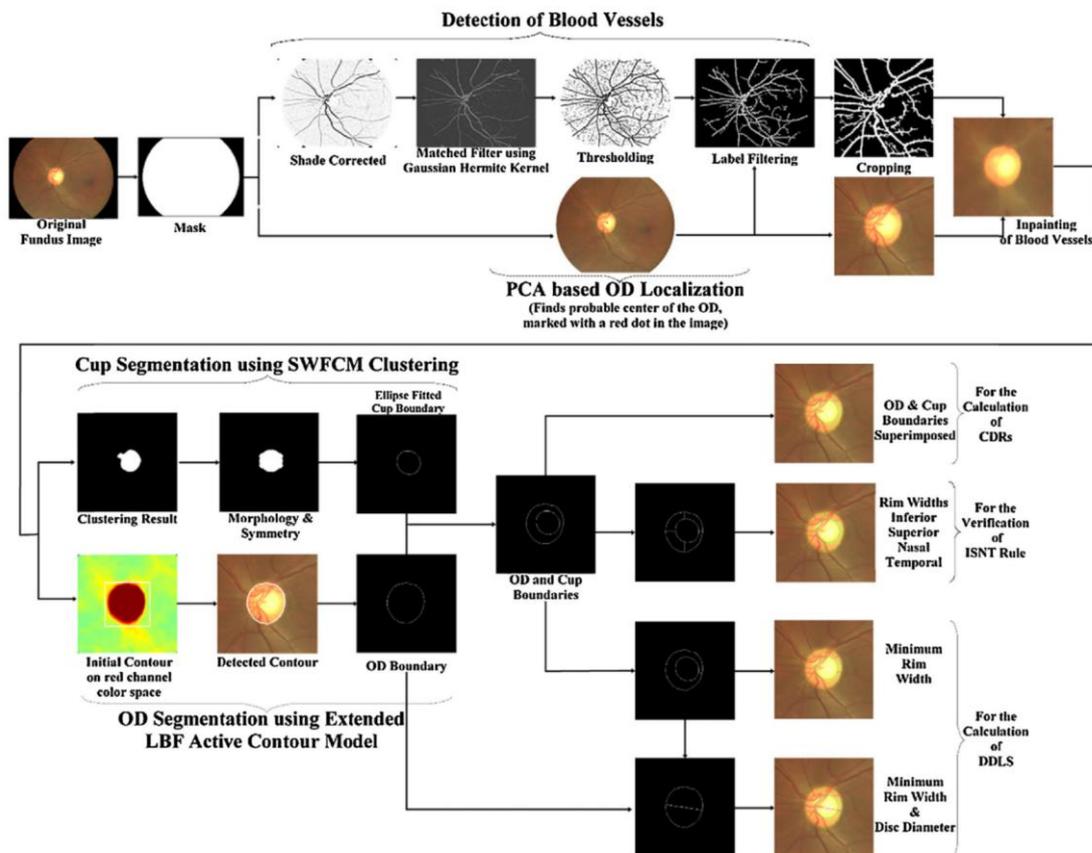


Figura 4.3. Esquema del método propuesto por [14].

El método está bien explicado en sus partes principales, aunque muchas de las etapas intermedias que aparecen en el esquema del mismo no aparecen detalladas. Ha sido validado sobre un conjunto amplio de imágenes, concretamente sobre 40 imágenes de cedidas por un hospital local, 9 imágenes de la base de retinografías RIMONE [15] (desarrollada por investigadores de la ULL), y 10 imágenes de la base DIARETDB0 [16], y los resultados experimentales se muestran adecuadamente. A pesar de que presenta mayor rigor científico que los trabajos descritos anteriormente, no ha sido reproducido en el presente TFG por falta de tiempo.

Continuamos este estado del arte analizando los trabajos que han aplicado **técnicas de segmentación basadas en superpíxeles** en alguna etapa del procesamiento. El primer trabajo que mencionaremos será el de [17], que aplica sobre la imagen original una técnica de generación de superpíxeles denominada *Simple Linear Iterative Clustering* (SLIC). Sobre estas regiones se realizan una serie de medidas que compondrán dos vectores de características diferentes, uno representativo de la zona de la CNO y otro

de la excavación. Posteriormente, se aplica un clasificador de Máquina de Vectores Soporte (*Support Vector Machine – SVM*) a cada grupo de vectores de características por separado, para delimitar cada una de estas regiones. El esquema del método, extraído del propio artículo, se presenta en la figura 4.4.

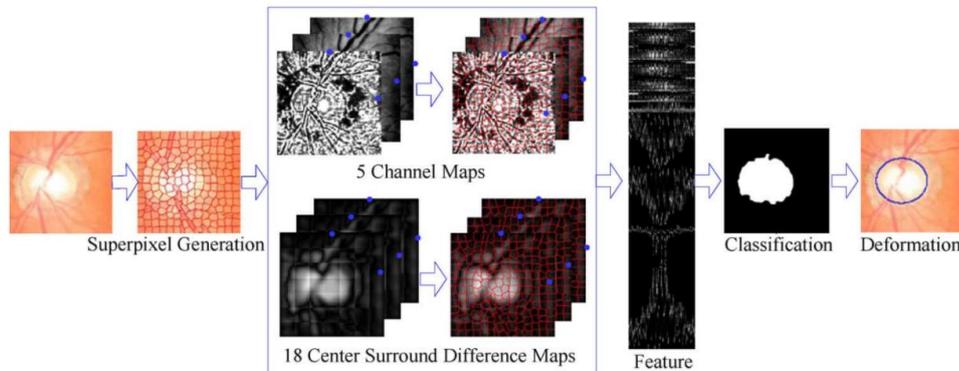


Figura 4.4. Esquema gráfico del método propuesto por [17].

El método está bien explicado, lo que ha permitido su reproducción para el presente estudio de aplicabilidad. Todos los detalles de este estudio se presentan en la sección 5.3.

Llegados a este punto, es importante comentar que se han encontrado 9 trabajos más relacionados con la generación de superpíxeles que se han tratado de estudiar y reproducir [18]–[26]. Esta tarea ha sido imposible en todos los casos, debido a la falta de especificación de los autores en sus explicaciones.

Por ejemplo, en [18] se describen los pasos de un algoritmo que denominan *One Fold Pixel Grouping*, como si fuera algo novedoso propuesto por ellos, cuando en realidad se trata de una vaga explicación del SLIC.

En todos estos 9 trabajos se menciona que se aplica un clasificador: en [18] no se llega a mencionar cuál exactamente, en [19] se utilizan los clasificadores SVM, K-means y K vecinos más cercanos (*K-Nearest Neighbours – KNN*), en [20], [24] y [21] se emplea el K-means, etc. Y sobre las características que se extraen para realizar esta etapa de clasificación, todos coinciden en que son características extraídas de las regiones generadas por el SLIC, pero nombran características posibles en general, sin llegar en ningún momento a decir cuáles han sido las empleadas exactamente.

Algunos de estos métodos además comparten otras etapas de procesamiento (aplicación de la transformada Hough, filtros Gabor, operadores morfológicos, ...). En ningún caso entran a describir en demasiado detalle estas etapas, y las figuras que ofrecen no parecen representar lo que se menciona en el texto. Finalmente, se ha observado que en todos estos trabajos aparecen figuras copiadas del trabajo presentado en [17], por lo que creemos que se tratan de plagios del mismo, y por este motivo han sido finalmente descartados.

La **técnica de contornos activos** ha sido aplicada por varios autores en el problema de segmentación abordado. Un ejemplo de esto es el trabajo anteriormente comentado de [14].

El mayor inconveniente de los modelos de contornos activos (o *snakes*) es el gran número de parámetros involucrados que se deben fijar a priori y la alta dependencia del resultado de la correcta elección del contorno inicial.

Por ejemplo, en [27] se generan distintas imágenes a partir de la imagen original, resultado de la aplicación de operadores morfológicos en diferentes direcciones. Sobre el valor máximo de todas estas imágenes, se aplica una serie de filtros y se segmenta el disco óptico mediante la aplicación de los contornos activos sobre la imagen resultante. Para segmentar la copa, se localizan los puntos correspondientes a las dobleces de los vasos sanguíneos y se realiza una interpolación entre ellos que determina el contorno de la excavación. Esta técnica fue estudiada en profundidad y se intentó replicar en este TFG, pero finalmente se descartó debido a que fue imposible aplicar de manera eficiente el modelo de contorno activos en las imágenes obtenidas con el procesamiento descrito.

Otro tipo de métodos intentan abordar el problema basándose únicamente en la aplicación de **operadores morfológicos y filtros**, sin combinarlos con ningún otro tipo de procesamiento.

Las dos propuestas [28], [29] son parecidas. En la primera de ellas [21], se eliminan los vasos de la zona de la CNO y se realiza una detección de bordes (operador de Canny) para detectar el borde del disco. Para segmentar la excavación se aplica el modelo de contornos activos. El contorno inicial se construye con 36 puntos que se extraen del trazado de varios perfiles sobre la imagen en diferentes direcciones pasando siempre por el centro del disco segmentado anteriormente. La segunda propuesta [22] supone una modificación de la anterior que tiene en cuenta las dobleces de los vasos para construir el contorno inicial. El primer trabajo de estos autores, [21], ha sido reproducido en este TFG. Los resultados se muestran en la sección 5.4.

En la propuesta de [30] se intenta segmentar el disco y la copa por separado. En ambos casos se modifica el espacio de color, se realiza un umbralizado, se aplican operadores morfológicos sobre el resultado y, en último lugar, se utiliza un filtro gaussiano. Sin embargo, para el disco y la copa se realiza este proceso sobre distintas componentes de color, en las que cada una de estas estructuras se aprecia mejor, según el criterio de los autores. Este método se ha incluido en el estudio de aplicabilidad realizado en este TFG, y sus resultados se muestran en la sección 5.5.

En [31] se aplica el mismo proceso para las dos estructuras de la retinografía que se desea segmentar. Se ecualiza la componente R de la retinografía y se aplican operadores morfológicos. El procesamiento finaliza con una umbralización, fijándose dos umbrales diferentes para segmentar disco y copa. Los resultados de la aplicabilidad de este método sobre las imágenes estudiadas en este TFG se muestran en la sección 5.6.

En [32] se propone un método que sólo detecta el disco óptico. Se comienza ecualizando la imagen que contiene la zona más próxima a la CNO. Mediante una umbralización y la aplicación de operadores morfológicos se calcula el radio aproximado del disco. Con esta información se dibuja una circunferencia, para posteriormente buscar los puntos de corte con la CNO y obtener así una segmentación del disco más precisa. En [33] se aplican operadores morfológicos sobre la imagen original, se selecciona una componente de color distinta para la copa y el disco, y se ecualizan y umbralizan para obtener ambas estructuras por separado. Estos dos últimos métodos no se han incluido en el estudio de aplicabilidad de este TFG, por ser muy parecido a los anteriores.

Por último, [34] presenta un método para segmentar el disco óptico. En primer lugar, localiza aproximadamente la posición del nervio óptico mediante el uso de una ventana de káiser. A continuación, detecta los vasos utilizando información morfológica, y propone una técnica para que visualmente no sean apreciables en la zona de la CNO. Sobre el resultado ecualizado, se realiza una umbralización. La elección del umbral tiene en cuenta las intensidades mínimas y máximas a lo largo del eje horizontal del centro del disco. El método se ha reproducido, y se puede consultar en detalle en la sección 5.8.

La **transformada Watershed**, técnica muy utilizada en la segmentación de imágenes naturales, ha sido también aplicada sobre retinografías. El principal problema de esta transformada es que suele generar imágenes sobresegmentadas. Para corregir esta sobresegmentación se han propuesto diversas estrategias.

En [35] se propone un método basado en el uso de esta transformada para segmentar el disco óptico. Se comienza trabajando sobre una imagen en escala de grises generada con PCA, sobre la que se realizan algunas operaciones morfológicas. Se calcula el gradiente de la imagen resultante y se determina una función de probabilidad de densidad con la que se fijan unos marcadores (*markers*) internos. Como marcador externo, se considera una circunferencia que contenga la cabeza del nervio óptico. Partiendo de estos marcadores, se aplica la transformada watershed. Finalmente, se unen las regiones para formar el contorno del disco óptico y corregir la sobresegmentación que, a pesar de la selección de marcadores, sigue existiendo. Este método se ha intentado replicar en este TFG, pero finalmente no se ha incluido en el estudio de aplicabilidad porque los resultados obtenidos son muy diferentes de los mostrados por los autores. Posiblemente sea debido a que no hemos sabido reproducir correctamente el método.

Otro método que utiliza la transformada watershed para segmentar el disco óptico es [36]. En este trabajo también se intentan seleccionar unos markers adecuados para evitar la sobresegmentación. El procesamiento comienza detectando los vasos y localizando el centro aproximado de la cabeza del nervio óptico. Se eligen aleatoriamente 20 puntos diferentes dentro de los vasos y cercanos al centro de la CNO. La transformada watershed se aplica 20 veces, cambiando en cada aplicación los marcadores. En cada aplicación se considera como marcador interno uno de los 20 puntos de los vasos elegidos anteriormente, y como marcador externo una circunferencia de radio mayor que el disco. Para cada resultado obtenido, se escoge la

región central y se calcula su compactación. La región más compacta se establece como nuevo marcador interno, y como marcador externo se considera una nueva circunferencia centrada en esta región. Aplicando una última vez la transformada watershed con estos nuevos markers, se obtiene como resultado el disco óptico segmentado. Esta técnica se ha reproducido en este TFG, y sus resultados se muestran en la sección 5.7.

Para terminar este capítulo dedicado al estado del arte, comentar que se han estudiado otro tipo de métodos, como [37], [38] o [39], que utilizan técnicas diferentes a las ya comentadas (técnicas de crecimiento de regiones, algoritmos genéticos, redes neuronales, etc.), pero que no se han podido reproducir en su totalidad por falta de tiempo.

5. ESTUDIO DE APLICABILIDAD DE LOS MÉTODOS SELECCIONADOS

Se han elegido algunos de los métodos presentados en el capítulo anterior para realizar el estudio de aplicabilidad objeto del presente TFG. En esta memoria se incluye una explicación de todas las técnicas de procesamiento de imágenes involucradas en estos métodos, en el anexo I por motivos de orden y claridad.

Para su implementación se ha utilizado Matlab, que incluye una librería específica de procesamiento de imágenes (*Image Processing Toolbox*) [40].

Los métodos reproducidos se han aplicado sobre las 30 imágenes Horus (retinografías convencionales) y sobre las 30 imágenes Compass (retinografías confocales) seleccionadas para este estudio. En ambos conjuntos de imágenes se incluyen casos de glaucoma y ojos sanos. Además, se han escogido imágenes con iluminación variada (iluminación baja, media y alta) para analizar la robustez de los métodos considerados. Todas estas imágenes han sido recortadas previamente de forma que la zona de la CNO se encuentra en el espacio central de la imagen. Cada imagen tiene un tamaño de 741 x 741 píxeles y se encuentra en formato PNG.

A continuación, se presenta una breve descripción de cada método, aunque más detallada que en el apartado anterior, los problemas que se han presentado (si procede) a la hora de reproducir cada propuesta, y las estadísticas con los resultados obtenidos. Cabe destacar que los resultados han sido evaluados de forma cualitativa y subjetiva, sin un exhaustivo rigor técnico, puesto que no se ha considerado necesario en vista de los resultados de segmentación obtenidos.

5.1 “GLAUCOMA DETECTION THROUGH OPTIC DISC AND CUP SEGMENTATION USING K-MEANS CLUSTERING” (Ayub et al., 2016) [10]

5.1.1 EXPLICACIÓN DEL MÉTODO

El objetivo de este trabajo es la segmentación automática de disco y copa, por separado. Para ello, proponen utilizar operadores morfológicos, espacios de color y técnicas de clasificación, concretamente, el clasificador k-means.

Un esquema del procesamiento que se aplica para obtener el disco óptico y la excavación se muestra en la figura 5.1. Básicamente, en los dos casos se eliminan los vasos sanguíneos mediante operaciones morfológicas de apertura y cierre, se cambia del espacio de color RGB a HSV y se emplean métodos de ecualizado o filtrado. Con la imagen obtenida al final de cada proceso se emplea un clasificador k-means que segmenta el disco y la copa, respectivamente.

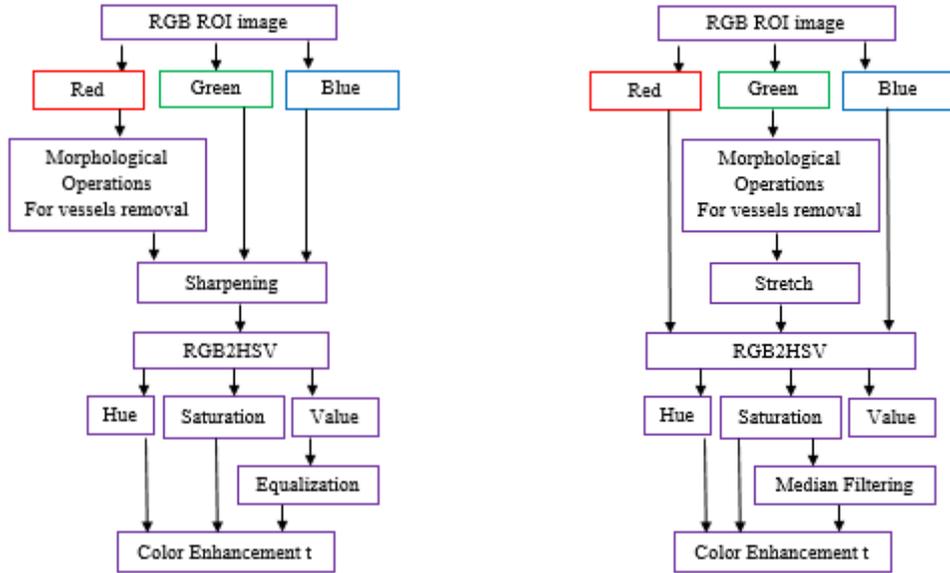


Figura 5.1. Pasos para la detección de la CNO (izquierda) y la excavación (derecha).
Extraído de [10].

El método ha sido probado en 100 retinografías no disponibles públicamente, y algunos de los resultados obtenidos se pueden observar en la figura 5.2.

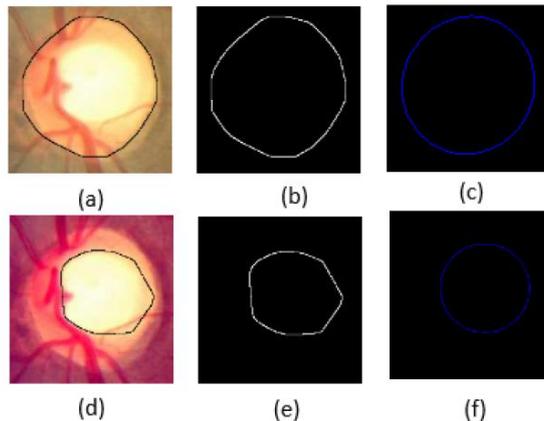


Figura 5.2. Resultados experimentales. Extraído de [10].

5.1.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO

En el artículo no se especifica en qué consiste el paso de *sharpening*, presente en el método propuesto para la segmentación del disco. Por otra parte, en ambos procesamientos se menciona que realiza una mejora del color (*color enhancement*), pero tampoco de este paso se dan detalles.

Para la etapa de *sharpening* se aplicó un filtro paso-alto con el objetivo de realzar las formas de la imagen. Y la etapa denominada *color enhancement* fue implementada haciendo una conversión de HSV a RGB. Estas decisiones fueron tomadas analizando las imágenes ofrecidas por los autores en el artículo, y suponiendo que son los pasos que más se asemejan a la realidad.

Además, después de realizar varias pruebas, se observó que el proceso propuesto para segmentar la copa era capaz de detectar copa y disco a la vez ofreciendo mejores resultados incluso que el método diseñado específicamente solo para el disco. Por este motivo, se decidió prescindir del primer método propuesto para la segmentación de la CNO y trabajar únicamente con el diseñado para la copa.

5.1.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.1. Se puede observar que el método propuesto por estos autores funciona correctamente para el 33.33% de las imágenes analizadas. En la figura 5.3 se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	10	0	8	12
Porcentaje (%)	33,33	0	26,67	40

Tabla 5.1. Resultados cualitativos del método [10] sobre imágenes Horus.

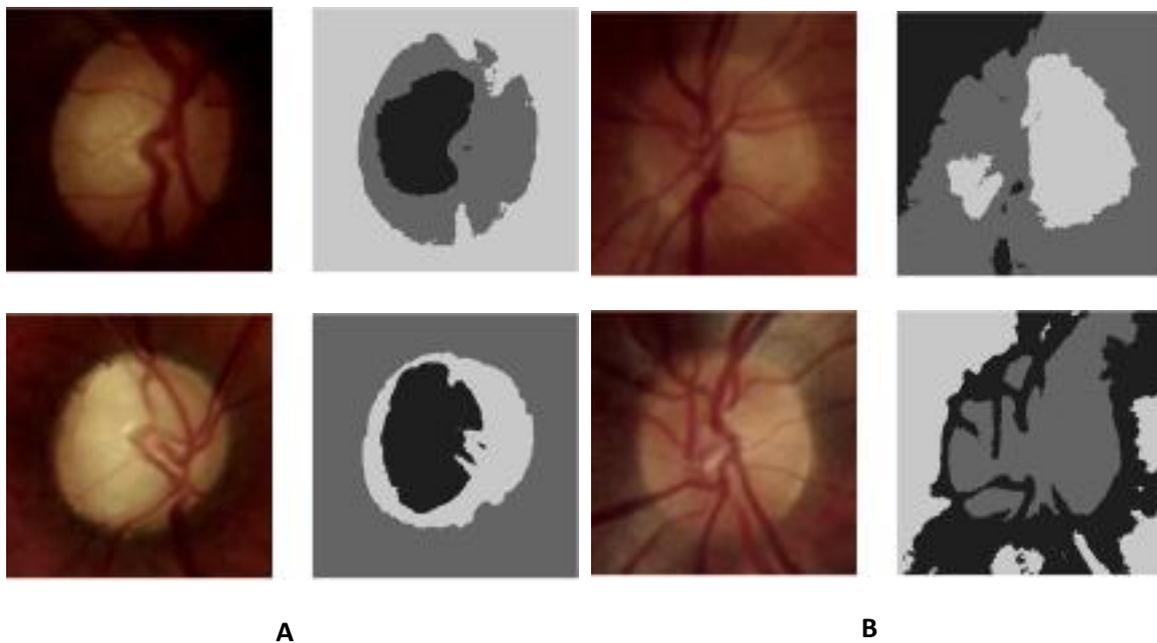


Figura 5.3. Resultados de segmentación de disco y copa correcta (A) e incorrecta (B) (imágenes Horus, método [10]).

5.1.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.2. Se puede observar que el método propuesto por estos autores funciona correctamente para el 0% de las imágenes analizadas. No obstante, se detectó la copa correctamente en el 33.33% de las retinografías Compass. En la figura 5.4 se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	0	10	20
Porcentaje (%)	0	0	33,33	66,67

Tabla 5.2. Resultados cualitativos del método [10] sobre imágenes Compass.

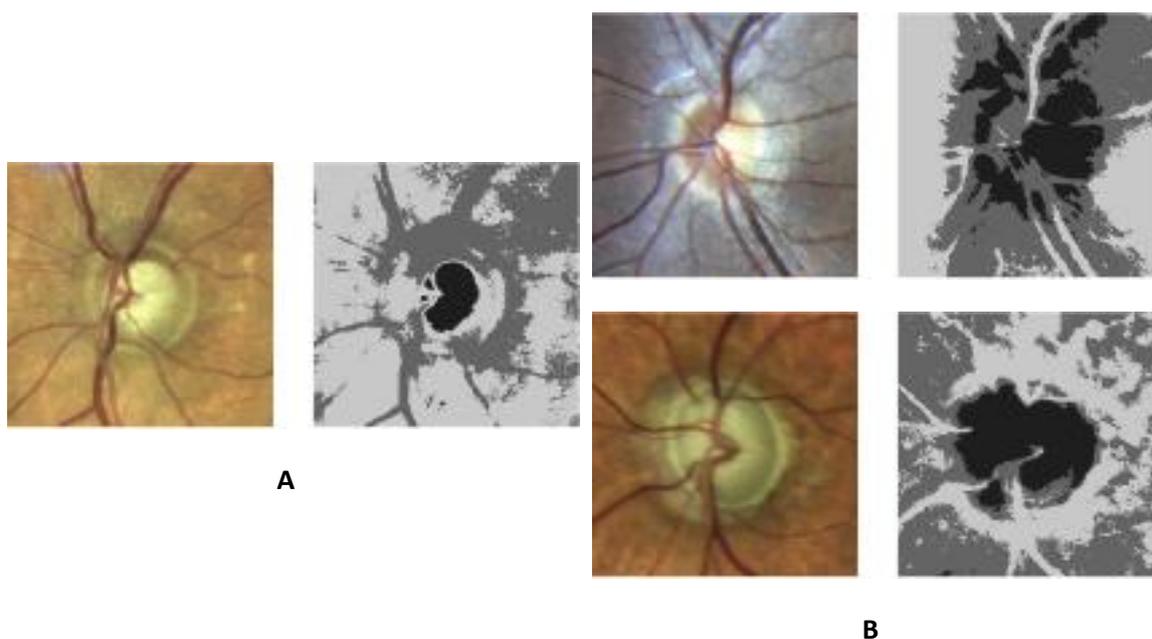


Figura 5.4. Resultado de segmentación correcta solo de la copa (A) y de segmentación incorrecta (B) (imágenes Compass, método [10]).

5.2 “FUZZY C-MEANS (FCM) FOR OPTIC CUP AND DISC SEGMENTATION WITH MORPHOLOGICAL OPERATION” (Khalid et al., 2014) [13]

5.2.1 EXPLICACIÓN DEL MÉTODO

El principal objetivo de este método es la segmentación automática y simultánea del disco y la excavación. Con este propósito, se procesa la imagen con operaciones morfológicas, y posteriormente se aplica el clasificador fuzzy c-means.

El proceso que se sigue en esta propuesta se resume en la figura 5.5. En concreto, el paso de “operación morfológica” consiste en la aplicación de operadores de dilatación y erosión (o lo que es lo mismo, de cierre) sobre la componente G de la imagen en el espacio de color RGB. Con el clasificador fuzzy c-means sobre los píxeles de la imagen resultante se obtiene el disco y la copa segmentados.

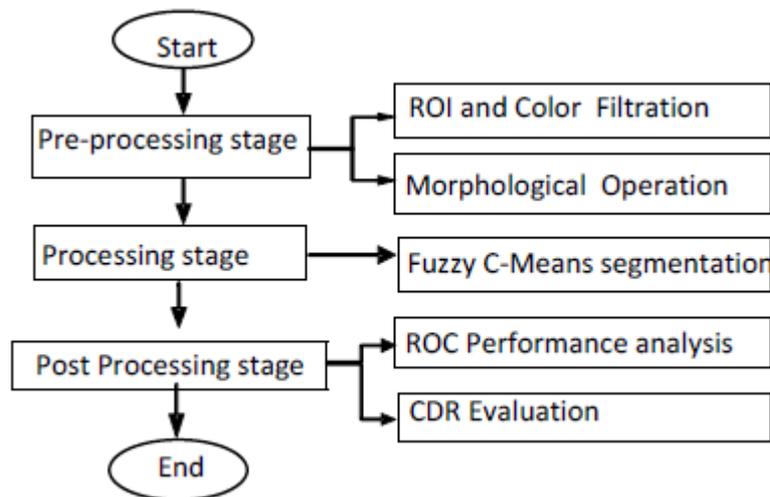


Figura 5.5. Pasos para la detección de la CNO y la excavación. Extraído de [13].

El método ha sido probado en 27 retinografías, aunque no se especifica la base de datos de donde estas imágenes han sido obtenidas. Algunos de los resultados se pueden observar en la figura 5.6.

Features	FCM with Morphological Operation	FCM Without Morphological Operation
Optic Cup		
Optic Disc		

Figura 5.6. Resultados experimentales. Extraído de [13].

5.2.2 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.3. Se puede observar que el método propuesto por estos autores funciona correctamente para el 20% de las imágenes analizadas. En la figura 5.7 se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	6	0	12	12
Porcentaje (%)	20	0	40	40

Tabla 5.3. Resultados cualitativos del método [13] sobre imágenes Horus.

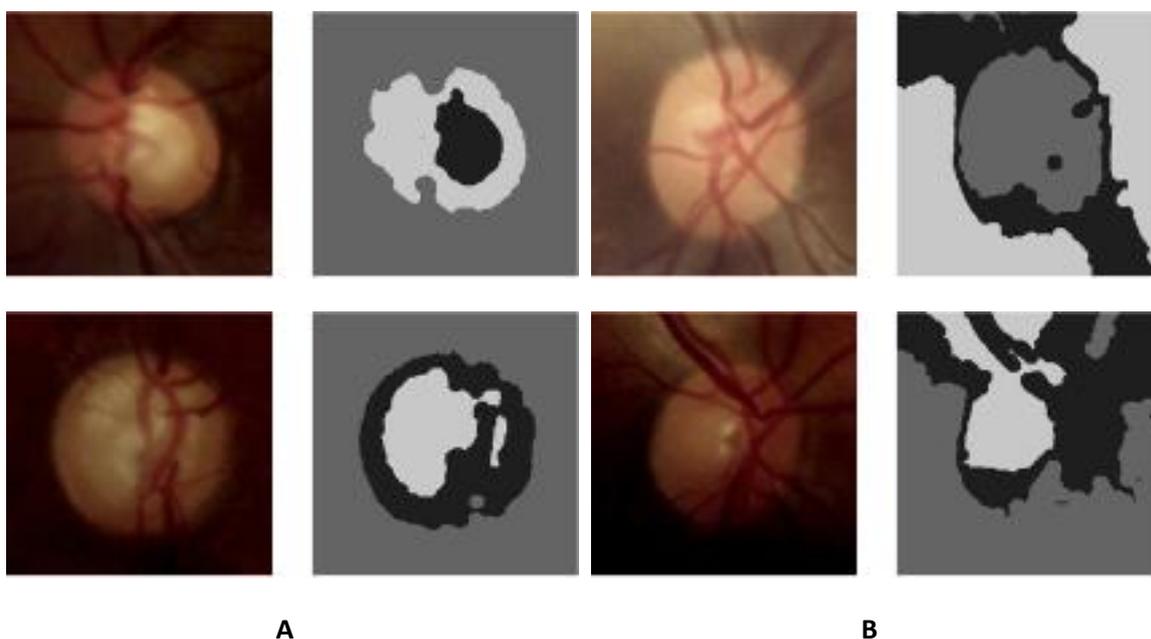


Figura 5.7. Resultados de segmentación correcta (A) e incorrecta (B) de disco y copa (imágenes Horus, método [13]).

5.2.3 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.4. Se puede observar que el método propuesto por estos autores funciona correctamente para el 0% de las imágenes analizadas. Aunque, por otra parte, la detección de la copa se logra de forma aproximada en el 20% de las mismas.

En la figura 5.8 se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	0	6	24
Porcentaje (%)	0	0	20	80

Tabla 5.4. Resultados cualitativos del método [13] sobre imágenes Compass.

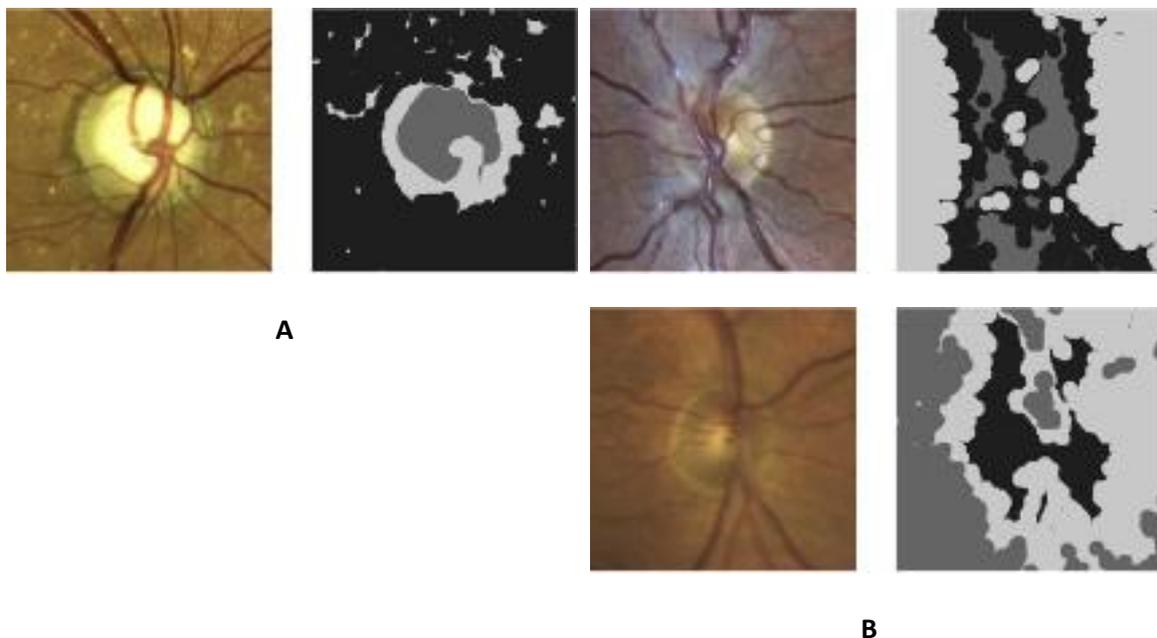


Figura 5.8. Resultado de segmentación correcta solo de la copa (A) y de segmentación incorrecta (B) (imágenes Compass, método [13]).

5.3 “SUPERPIXEL CLASSIFICATION BASED OPTIC DISC AND OPTIC CUP SEGMENTATION FOR GLAUCOMA SCREENING” (Cheng et al., 2013) [17]

5.3.1 EXPLICACIÓN DEL MÉTODO

En este trabajo se presenta un método para segmentar disco y copa por separado, aunque ambos procedimientos son muy parecidos. En líneas generales, el método propuesto aplica sobre la imagen original una técnica de generación de superpíxeles denominada *Simple Linear Iterative Clustering* (SLIC). Sobre las regiones obtenidas se

realizan una serie de medidas que compondrán dos vectores de características diferentes, uno representativo de la zona de la CNO y otro de la excavación. Posteriormente, se aplica un clasificador de Máquina de Vectores Soporte (*Support Vector Machine – SVM*) a cada grupo de vectores de características por separado, para delimitar cada una de estas regiones. El esquema del método, extraído del propio artículo, se presenta en la figura 5.9.

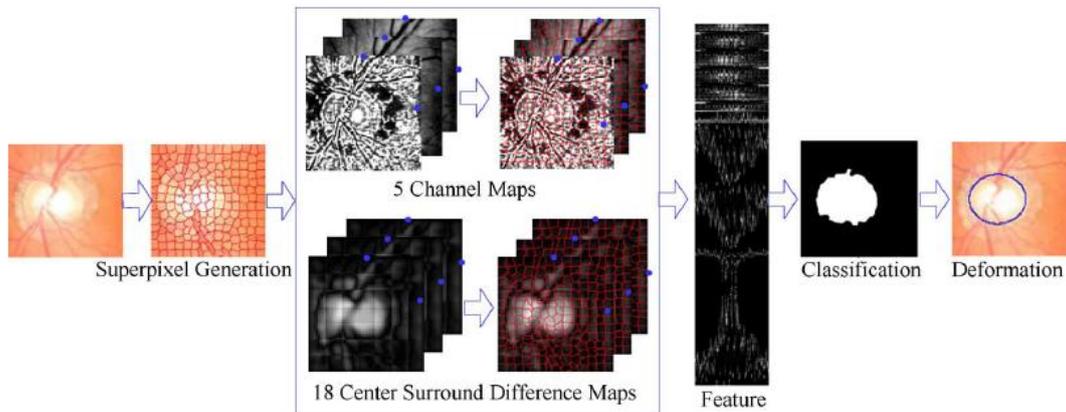


Figura 5.9. Pasos para la detección de la CNO. Extraído de [17].

Con respecto a la etapa de extracción de características, es importante aclarar que el vector final representativo de cada región superpíxel se compone de las siguientes medidas:

1. 5 histogramas, de los canales R, G y B ecualizados (del espacio RGB), y de los canales H y S (del espacio HSV) sin ecualizar, para diferenciar la zona de la CNO del fondo.
2. 18 medidas estadísticas de textura, para diferenciar la CNO de posibles atrofas alrededor de la papila.

Para realizar estas medidas estadísticas, se aplica un análisis multiescalar a cada canal RGB de la imagen original: un filtrado gaussiano iterativo sobre la misma imagen (9 iteraciones), que permite analizar las diferencias de los valores medios y la varianza de cada región superpíxel entre escalas, y espacialmente con sus regiones vecinas adyacentes.

Los vectores de características así construidos son la entrada de un clasificador de Máquina de Vectores Soporte (*Support Vector Machine – SVM*) con kernel lineal. Este clasificador etiqueta cada superpíxel como perteneciente o no al disco óptico. El resultado final se suaviza y se umbraliza, para conseguir una máscara de la CNO.

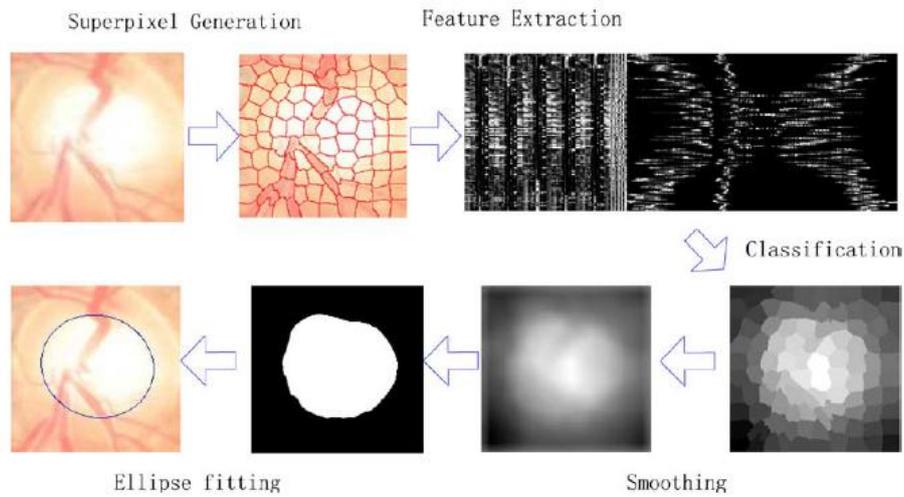


Figura 5.10. Pasos para la detección de la excavación. Extraído de [17]

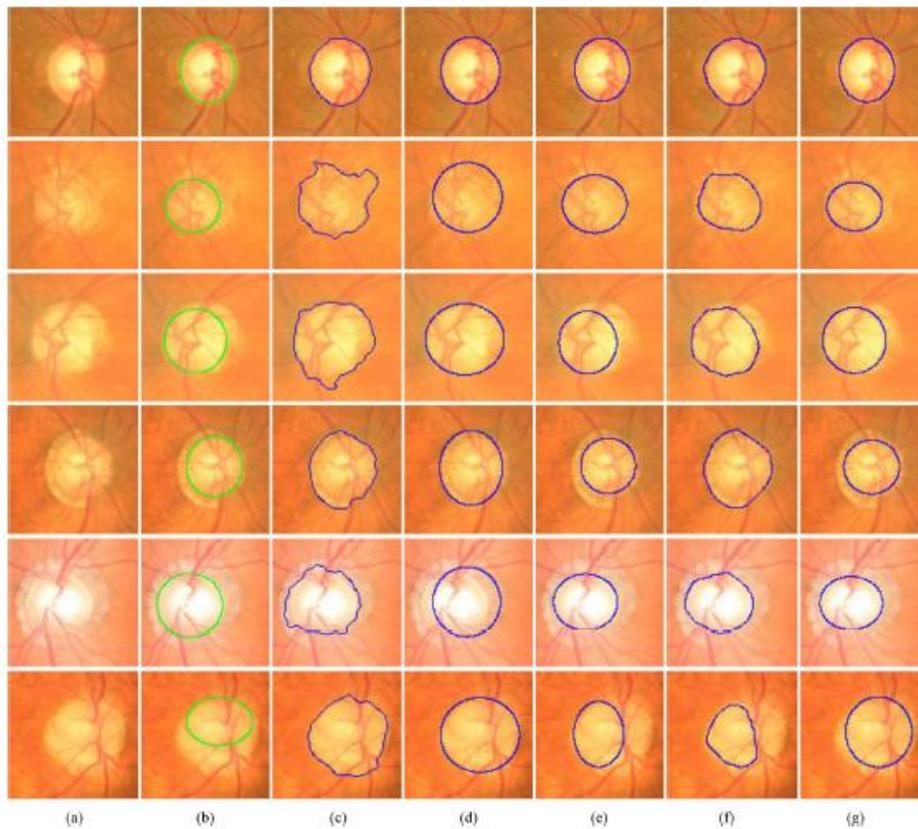


Figura 5.11. Resultados experimentales. Columna (a): imagen original, columna (b): ground-thruth manual, columnas (c)-(f): resultados de otros métodos, columna (g): resultado del método propuesto. Extraído de [17].

La forma de hallar la excavación es bastante similar, tal y como se puede apreciar en la figura 5.10. Sobre las regiones superpíxel generadas con SLIC, se realizan una serie de medidas para construir un vector de características representativo de cada una. En este caso, se incluyen 4 histogramas y 12 medidas estadísticas (las mismas

características que en el caso anterior, exceptuando el histograma y las medidas del canal R). La parte final del procedimiento (aplicación de SVM y obtención de la máscara de la CNO) coincide con la del disco.

El método ha sido probado sobre 2326 retinografías de las que 650 son del Singapore Malay Eye Study (SiMES) [41] y 1676 del Singapore Chinese Eye Study (SCES) [42]. Algunos de los resultados obtenidos se pueden observar en la figura 5.11.

5.3.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO

Es importante tener en cuenta que el clasificador SVM es un clasificador supervisado, por lo que es necesario ajustarlo previamente con un conjunto de entrenamiento. El modo en que los autores han entrenado el clasificador no se especifica en el artículo, por lo que se ha probado el método con distintos conjuntos de entrenamiento.

Para las imágenes Horus (retinografías convencionales) se construyeron, en primer lugar, conjuntos de entrenamiento etiquetando manualmente los superpíxeles de una retinografía con iluminación media (“pertenece a CNO”, “pertenece a fondo”). Del mismo modo, se etiquetaron los superpíxeles para el proceso de clasificación cuyo objetivo es detectar la excavación. Los resultados no fueron satisfactorios, debido seguramente a que este conjunto no era representativo de las imágenes con iluminación media y baja.

Por lo tanto, en una segunda aproximación, se construyeron conjuntos de entrenamiento etiquetando los superpíxeles de tres retinografías (con iluminación baja, media y alta, respectivamente). Los resultados mejoraron con estos nuevos conjuntos de entrenamiento.

Del mismo modo, se hicieron pruebas de clasificación sobre las imágenes Compass (retinografías confocales) con un conjunto de entrenamiento que recogía los superpíxeles etiquetados de una sola imagen y con un conjunto de entrenamiento que consideraba superpíxeles de tres imágenes diferentes.

Los resultados experimentales de todas estas pruebas se presentan en las siguientes secciones.

5.3.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS (CONJUNTO DE ENTRENAMIENTO: UNA IMAGEN)

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.5. Se puede observar que el método propuesto por estos autores funciona correctamente para el 0% de las imágenes analizadas. Aunque cabe destacar que el borde del disco se detecta con bastante precisión en el 23% de las imágenes. En la figura 5.12 Se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	7	0	23
Porcentaje (%)	0	23,33	0	76,67

Tabla 5.5. Resultados cualitativos del método [17] sobre imágenes Horus (conjunto de entrenamiento construido con una sola imagen)

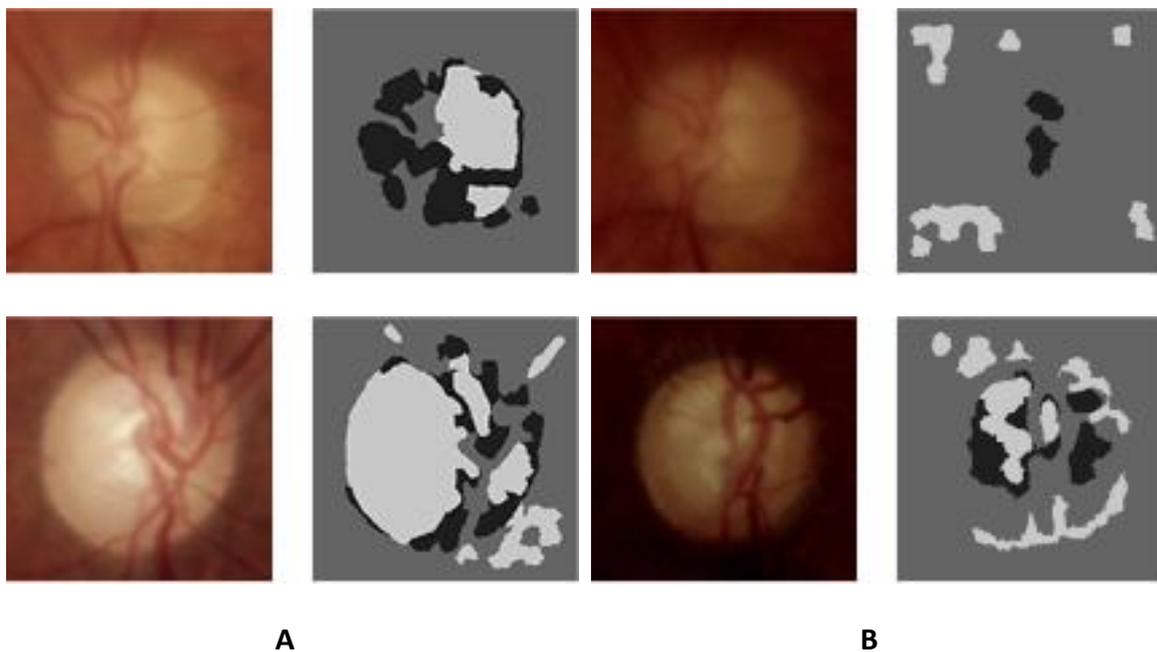


Figura 5.12. Resultados de segmentación correcta solo del disco (A) y segmentación incorrecta (B) (imágenes Horus, método [17], conjunto de entrenamiento construido con una imagen).

5.3.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS (CONJUNTO DE ENTRENAMIENTO: UNA IMAGEN)

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.6. Se puede observar que el método propuesto por estos autores funciona correctamente para el 0% de las imágenes analizadas. Únicamente en el 6,67% de los casos se puede intuir la forma del disco. En la figura 5.13 se pueden ver algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	2	0	28
Porcentaje (%)	0	6,67	0	93,33

Tabla 5.6. Resultados cualitativos del método [17] sobre imágenes Compass (conjunto de entrenamiento construido con una sola imagen).

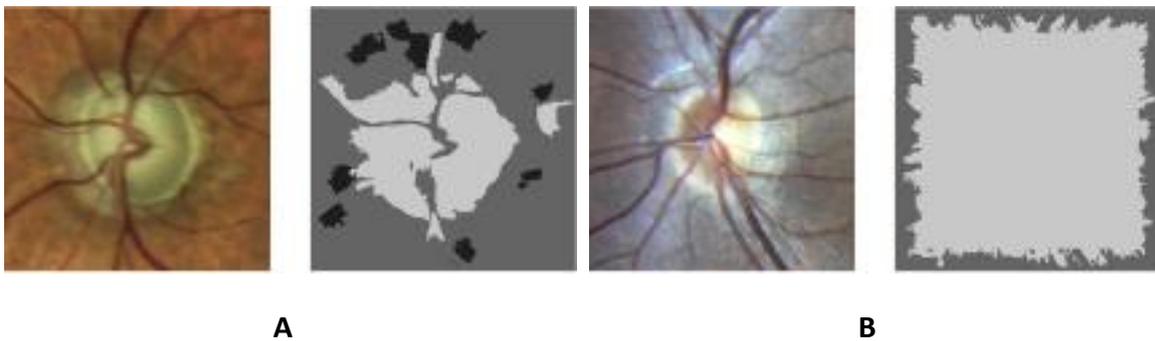


Figura 5.13. Resultado de segmentación aproximadamente correcta solo de la copa (A) y segmentación incorrecta (B) (imágenes Compass, método [17], conjunto de entrenamiento construido con una imagen).

5.3.5 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS (CONJUNTO DE ENTRENAMIENTO: 3 IMÁGENES)

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.7. Se puede observar que aumentando el tamaño del conjunto de entrenamiento se puede detectar aproximadamente el disco y la copa en el 20% de las retinografías. Además, se puede apreciar solo el disco en el 13,33% y solo la copa en el 16,67% de los casos. En la figura 5.14 se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	6	4	5	15
Porcentaje (%)	20	13,33	16,67	50

Tabla 5.7. Resultados cualitativos del método [17] sobre imágenes Horus (conjunto de entrenamiento construido con tres imágenes).

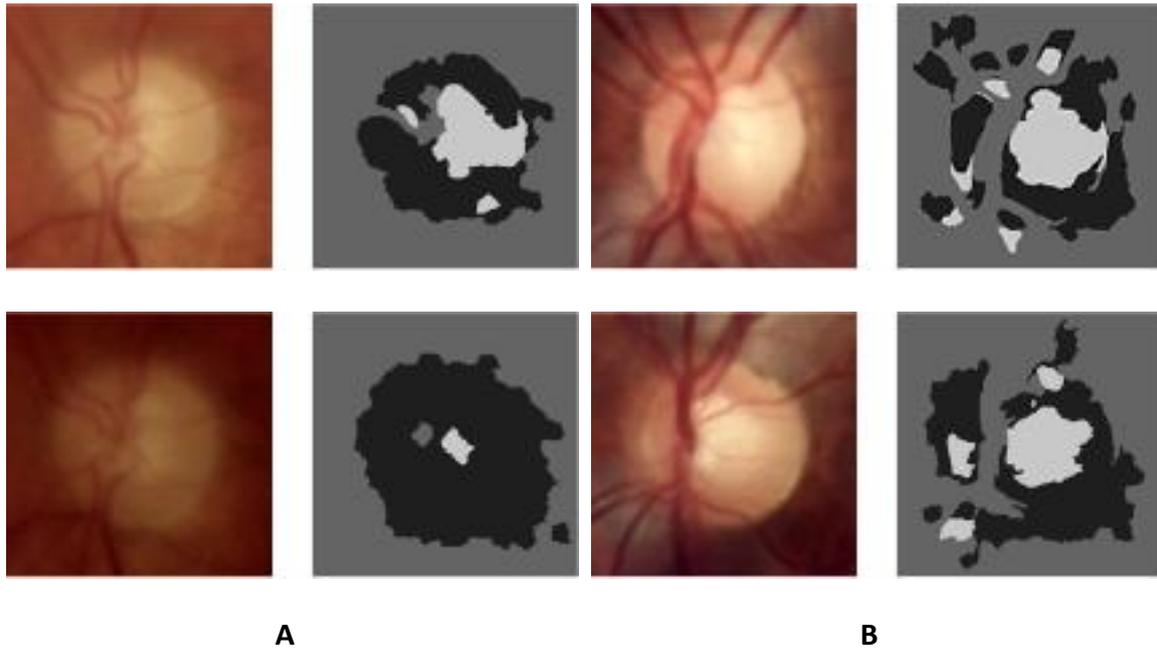


Figura 5.14. Resultados de la segmentación aproximadamente correcta de disco y copa (A), y de segmentación incorrecta (B) (imágenes Horus, método [17], conjunto de entrenamiento construido con tres imágenes).

5.3.6 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS (CONJUNTO DE ENTRENAMIENTO: TRES IMÁGENES)

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.8. Se puede observar que el método propuesto por estos autores funciona correctamente para el 0% de las imágenes analizadas. Sin embargo, se puede apreciar el disco, aunque mezclado con otras partes, en el 16,67% de las imágenes, y la copa también en el 16,67% de las retinografías. En la figura 5.15 se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	5	5	20
Porcentaje (%)	0	16,67	16,67	66,66

Tabla 5.8. Resultados cualitativos del método [17] sobre imágenes Compass (conjunto de entrenamiento construido con tres imágenes).

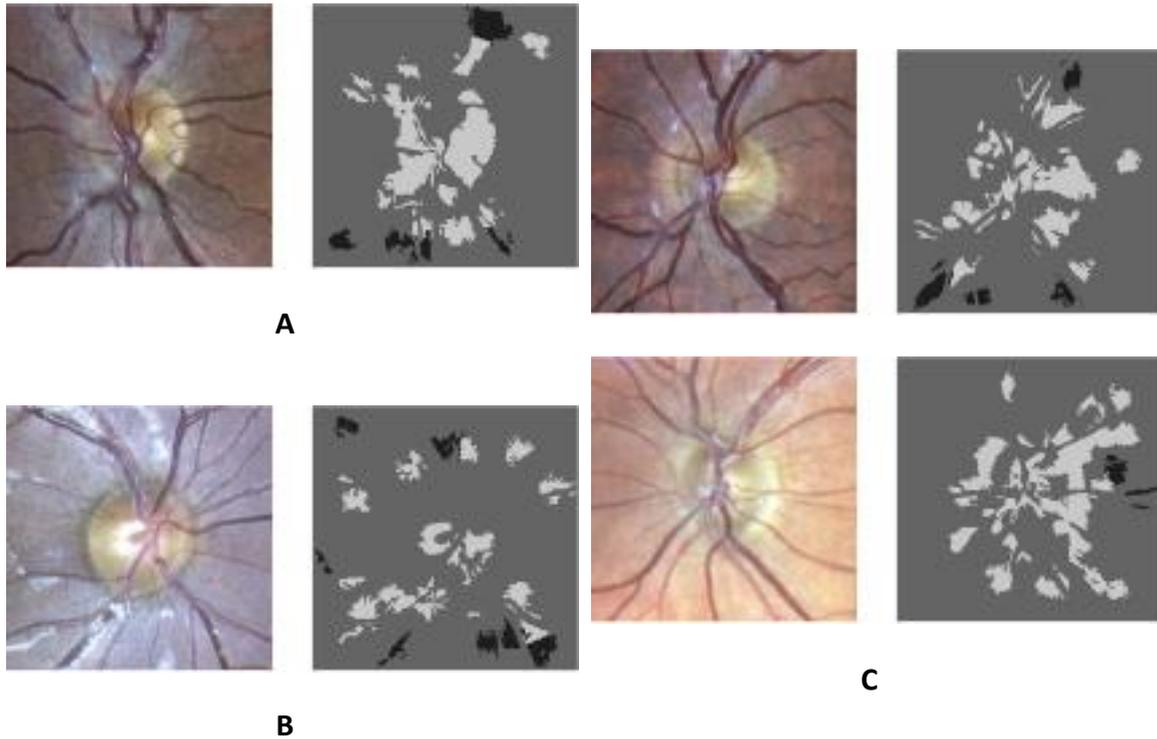


Figura 5.15. Resultado de segmentación aproximadamente correcta sólo del disco (A), resultado de segmentación en la que se aprecia la copa (B), y resultado de segmentación incorrecto (C) (imágenes Compass, método [17], conjunto de entrenamiento construido con tres imágenes).

5.4 “AUTOMATIC MEASUREMENT OF CUP TO DISC RATIO BASED ON LINE PROFILE ANALYSIS IN RETINAL IMAGES” (Hatanaka et al., 2011) [28]

5.4.1 EXPLICACIÓN DEL MÉTODO

Este método segmenta automáticamente copa y disco con dos procedimientos diferentes, tal y como muestra el esquema de la figura 5.16. Pero ambos métodos parten de la misma imagen: la imagen original con los vasos detectados y eliminados.

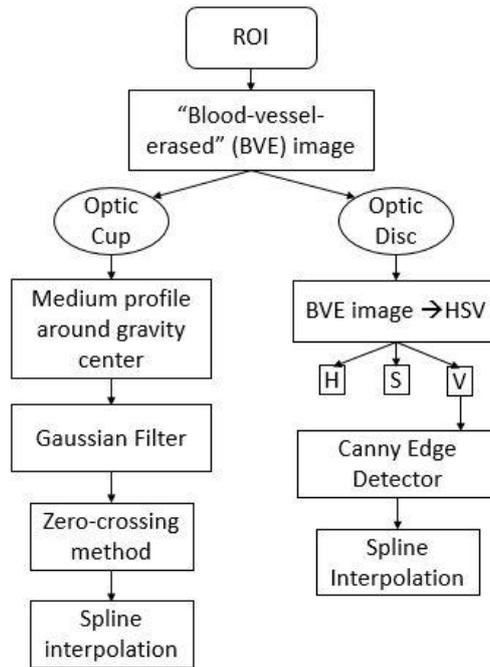


Figura 5.16. Detección de la CNO y la excavación propuesta en el método [28].

El proceso de borrado de los vasos es el propuesto en [43]. Comienza aplicando la transformada top-hat sobre cada componente R, G y B de la imagen. Esta transformada realza los detalles de la imagen, manteniendo en un segundo plano las zonas amplias y uniformes. Cada imagen resultante se umbraliza, obteniéndose de esta manera los píxeles que pertenecen a los vasos. Finalmente, el valor original de estos píxeles en las imágenes R, G y B se sustituye por el valor medio de cada componente de color.

Para la detección del disco se aplica un detector de bordes (operador de Canny) sobre la componente V de la imagen de vasos borrados (en el espacio de color HSV). El disco final se obtiene aproximando el resultado con una elipse.

Para la detección de la excavación se emplea el canal B de la imagen sin vasos. Sobre esta imagen se trazan diez perfiles en torno al centro de gravedad del disco, en 36 direcciones diferentes, con una diferencia de 10 grados entre ellos. Tras obtener la media de los perfiles y aplicar un filtro gaussiano, se hallan 10 puntos por medio del método zero-crossing que se supone que pertenecen a la frontera de la copa. Interpolando estos puntos se aproxima dicha frontera.

El método ha sido probado sobre 45 retinografías, de las que 23 pertenecen a personas con glaucoma, y no están disponibles públicamente. Algunos de los resultados obtenidos se pueden observar en la figura 5.17.

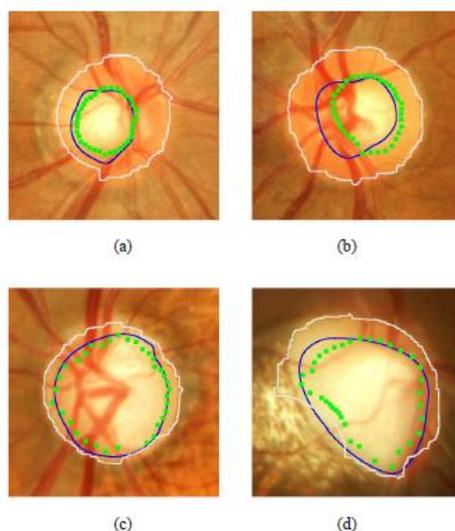


Figura 5.17. Resultados experimentales. Las líneas blancas y verdes muestran el resultado de la segmentación del disco y la copa con el método propuesto. La línea azul es la segmentación manual realizada por un experto. Extraído de [28].

5.4.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO

Como no se especifica el tipo de interpolación que se emplea en la última fase de la detección tanto de la CNO como de la copa, se ha hecho uso de la técnica de contornos activos en ambos casos.

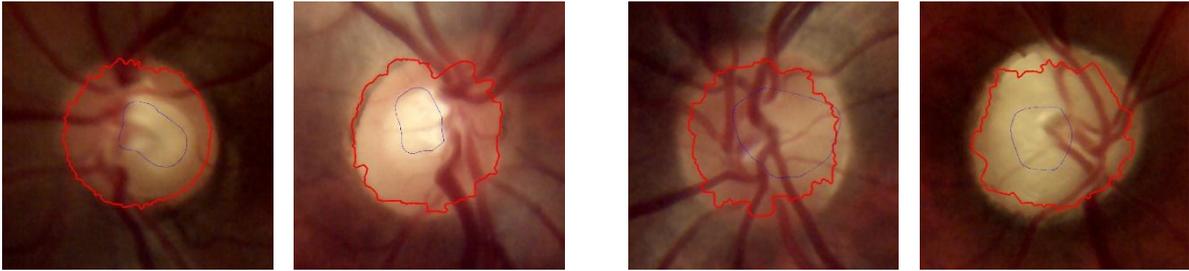
Tampoco se explica con qué criterio emplear el método zero-crossing en el procesamiento de la excavación, por lo que se ha decidido tomar los puntos del perfil correspondientes al 80% del área situada bajo la curva de la gráfica. Estas decisiones se han contrastado de forma experimental para poder ser lo más fieles posibles a la propuesta de los autores de este método.

5.4.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.9. Se puede observar que el método propuesto por estos autores funciona correctamente para el 36,67% de las imágenes analizadas. En la figura 5.18 se exponen algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	11	6	9	4
Porcentaje (%)	36,67	20	30	13,33

Tabla 5.9. Resultados cualitativos del método[28] sobre imágenes Horus.



A

B

Figura 5.18. Resultados de segmentación correcta (A) e incorrecta (B) de disco y copa (imágenes Horus, método [28]).

5.4.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.10. Se puede observar que el método propuesto por estos autores funciona de forma aproximada para el 46,67% de las imágenes analizadas. En la figura 5.19 se exponen algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	14	4	6	6
Porcentaje (%)	46,67	13,33	20	20

Tabla 5.10. Resultados cualitativos del método [28] sobre imágenes Compass.



A

B

Figura 5.19. Resultados de segmentación correcta (A) e incorrecta (B) de disco y copa (imágenes Compass, método [28]).

5.5 “DETECTION OF GLAUCOMA USING RETINAL FUNDUS IMAGES” (Ahmad et al., 2014) [30]

5.5.1 EXPLICACIÓN DEL MÉTODO

El objetivo de este trabajo es segmentar automáticamente la CNO y la copa, por separado. Con este propósito se emplea información de distintos espacios de color, técnicas de umbralización, operadores morfológicos y filtros gaussianos.

En la figura 5.20 se pueden observar las etapas propuestas para la segmentación de cada estructura. Para detectar la copa se parte del canal G de la imagen RGB, que se umbraliza con un valor entre 0.4 y 0.57 para obtener la imagen binaria. Luego se aplican las operaciones morfológicas de dilatación y erosión, y finalmente se suaviza el resultado con un filtro gaussiano.

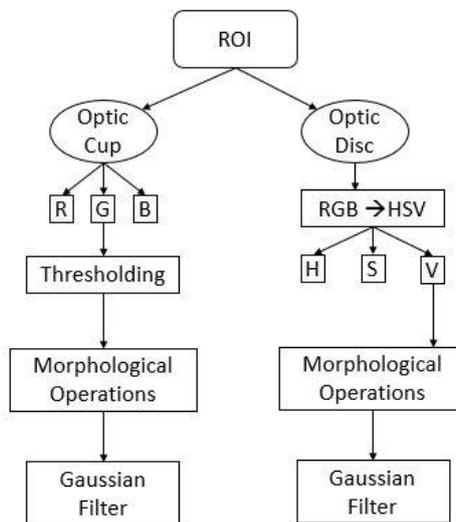


Figura 5.20. Pasos para la detección de la CNO y la excavación según [30].

Por otro lado, para segmentar el disco se trabaja en el espacio de color HSV y se umbraliza el canal V. Al igual que con la copa, se emplea la operación de cierre sobre este canal y un filtro gaussiano para obtener la CNO.

El método ha sido probado en 80 retinografías extraídas de las bases de datos DMED [44], FAU [45] y MESSIDOR [46]. Algunos de los resultados experimentales mostrados por los autores se pueden observar en la figura 5.21.

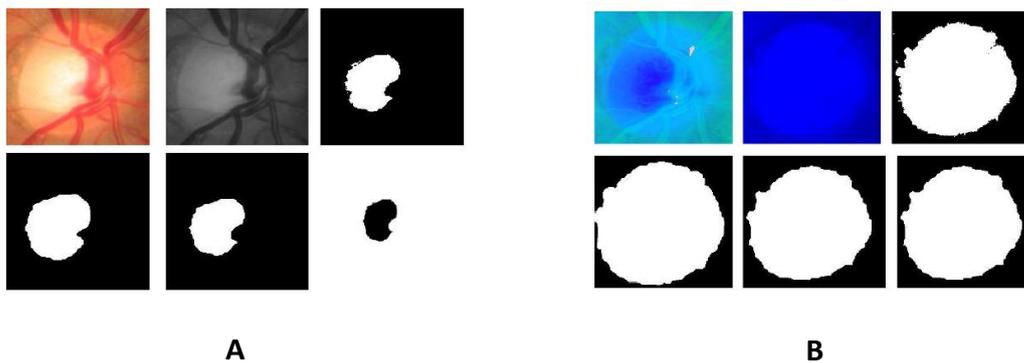


Figura 5.21. Resultados experimentales para la copa (A) y para el disco (B). Extraído de [30].

5.5.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO

Para obtener el valor de umbralización de forma automática, puesto que el objetivo especificado es detectar automáticamente la CNO y la excavación, en lugar de elegir el valor entre el rango establecido empíricamente en [30], se ha empleado el método de Otsu.

5.5.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.11. Se puede observar que el método propuesto por estos autores funciona correctamente para el 26,67% de las imágenes analizadas. En la figura 5.22 se presentan algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	8	0	9	13
Porcentaje (%)	26,67	0	30	43,33

Tabla 5.11. Resultados cualitativos del método [30] sobre imágenes Horus.

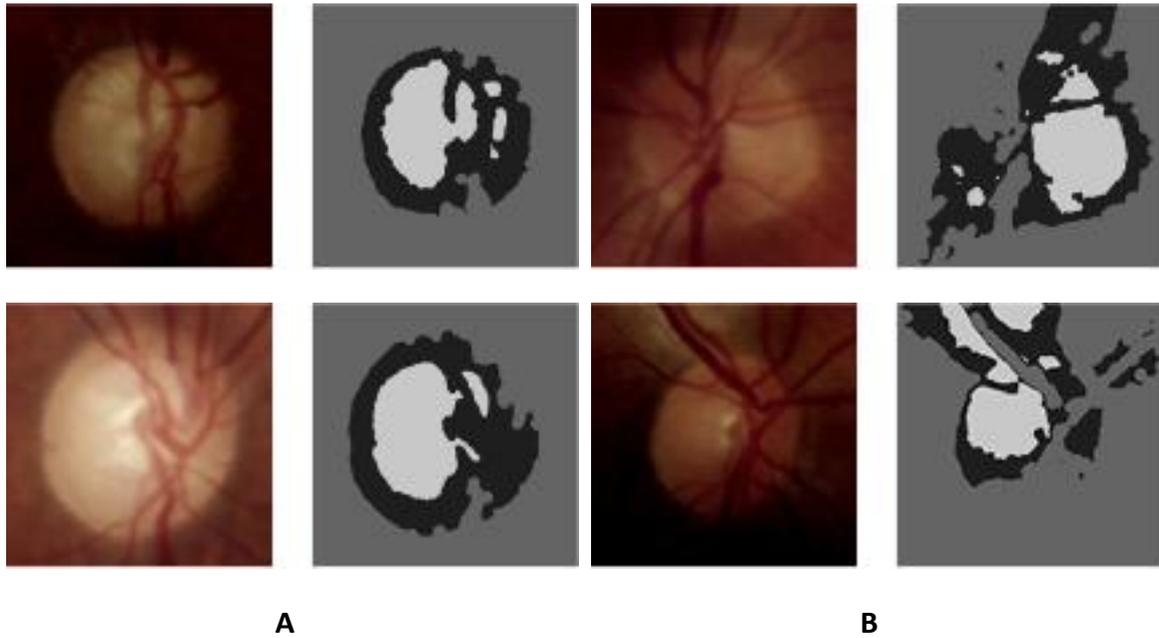


Figura 5.22. Resultados de la segmentación correcta (A) e incorrecta (B) de disco y copa. (imágenes Horus, método [30]).

5.5.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.12. Se puede observar que el método propuesto por estos autores funciona correctamente para el 0% de las imágenes analizadas. Se puede distinguir cualitativamente la copa óptica en el 30% de las retinografías. En la figura 5.23 se ofrecen algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	0	9	21
Porcentaje (%)	0	0	30	70

Tabla 5.12. Resultados cualitativos del método [30] sobre imágenes Compass.

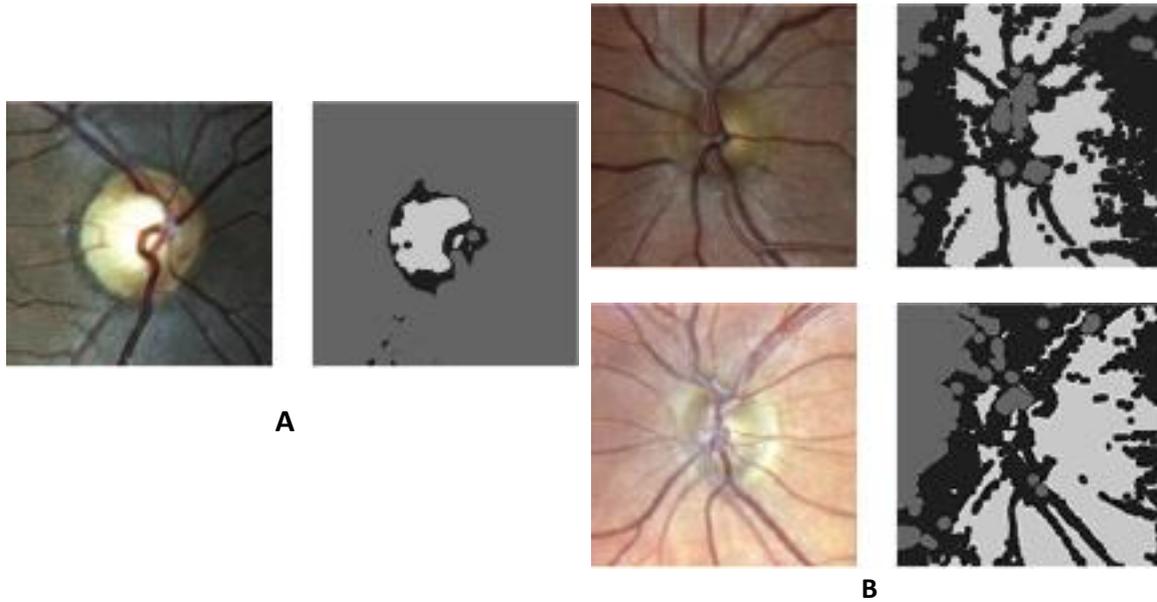


Figura 5.23. Resultados de segmentación correcta solo de la copa (A) y de segmentación incorrecta (B). (imágenes Compass, método [30]).

5.6 “SEGMENTATION OF THE OPTIC DISC AND OPTIC CUP USING HISTOGRAM FEATURE-BASED ADAPTIVE THRESHOLD FOR CUP TO DISK RATIO” (Nugraha et al., 2016) [31]

5.6.1 EXPLICACIÓN DEL MÉTODO

El objetivo principal de este trabajo es detectar automáticamente la CNO y la excavación a la vez en las imágenes retinográficas. Para ello básicamente se realiza a una ecualización del histograma, se umbraliza la imagen y se aplican operaciones morfológicas.

En la figura 5.24 queda reflejada la estructura de este proceso. En primer lugar, se parte de la componente roja del espacio RGB, a la que se le calcula la media y la desviación estándar. Una vez hecho esto, se ecualiza su histograma y se umbraliza con distintos valores, el primero para obtener el disco (ecuación 5.1) y el segundo para la copa (ecuación 5.2), según las ecuaciones:

$$T_{disc} = mean + 2 * std \quad (5.1)$$

$$T_{cup} = mean + 4 * std \quad (5.2)$$

Una vez que se ha umbralizado la imagen se realizan las operaciones de apertura y cierre para obtener el resultado final.

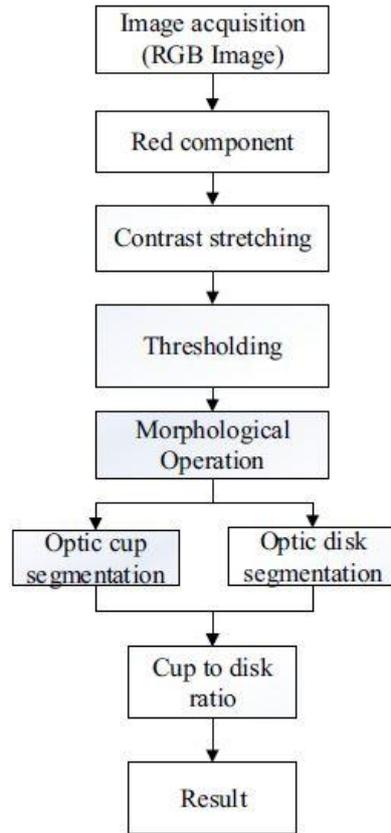


Figura 5.24. Pasos para la detección de la CNO y la excavación.
Extraído de [31].

De las 100 retinografías sobre las que se ha probado el método, 50 son de DRISTHIGS [47] y 50 de RIM-ONE [15]. Algunos de los resultados obtenidos se pueden observar en la figura 5.25.

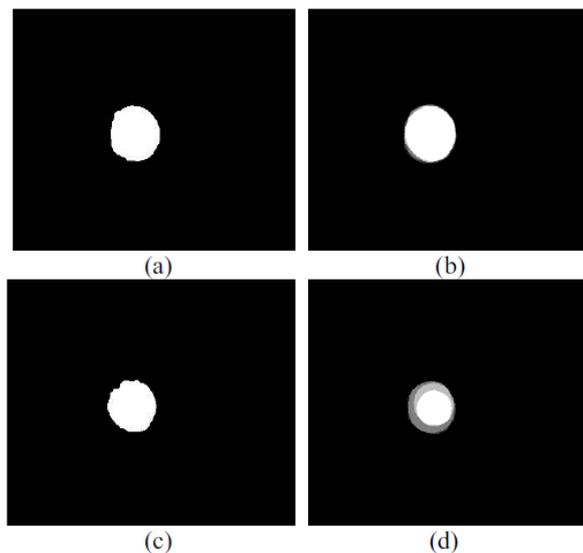


Figura 5.25. Resultados experimentales. Extraído de [31].

5.6.2 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.13. Se puede observar que el método propuesto por estos autores funciona correctamente para el 13,33% de las imágenes analizadas. Por otra parte se puede distinguir cualitativamente la CNO en el 36,67% de las retinografías. En la figura 5.26 se proporcionan algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	4	11	0	15
Porcentaje (%)	13,33	36,67	0	50

Tabla 5.13. Resultados cualitativos del método [31] sobre imágenes Horus.

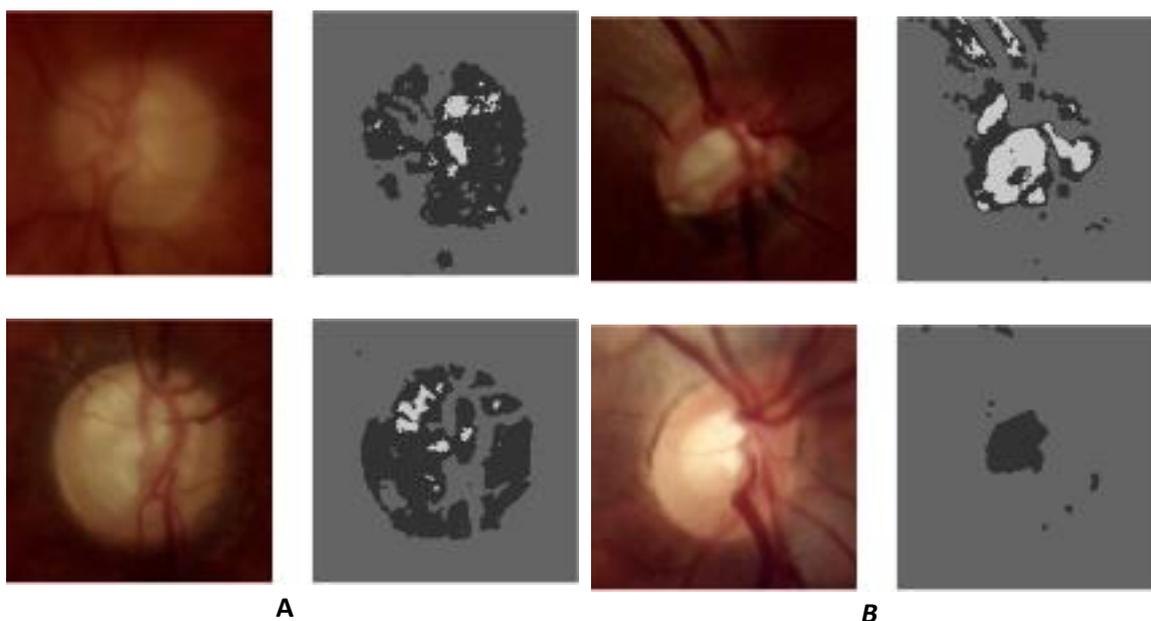


Figura 5.26. Resultados de la segmentación correcta (A) e incorrecta (B) de disco y copa (imágenes Horus, método [31]).

5.6.3 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.14. Se puede observar que el método propuesto por estos autores funciona correctamente para el 0% de las imágenes analizadas. Se puede distinguir la copa óptica, aunque mezclada con otras regiones, en el 20% de las retinografías. En la figura 5.27 se exponen algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	0	6	24
Porcentaje (%)	0	0	20	80

Tabla 5.14. Resultados cualitativos del método [31] sobre imágenes Compass

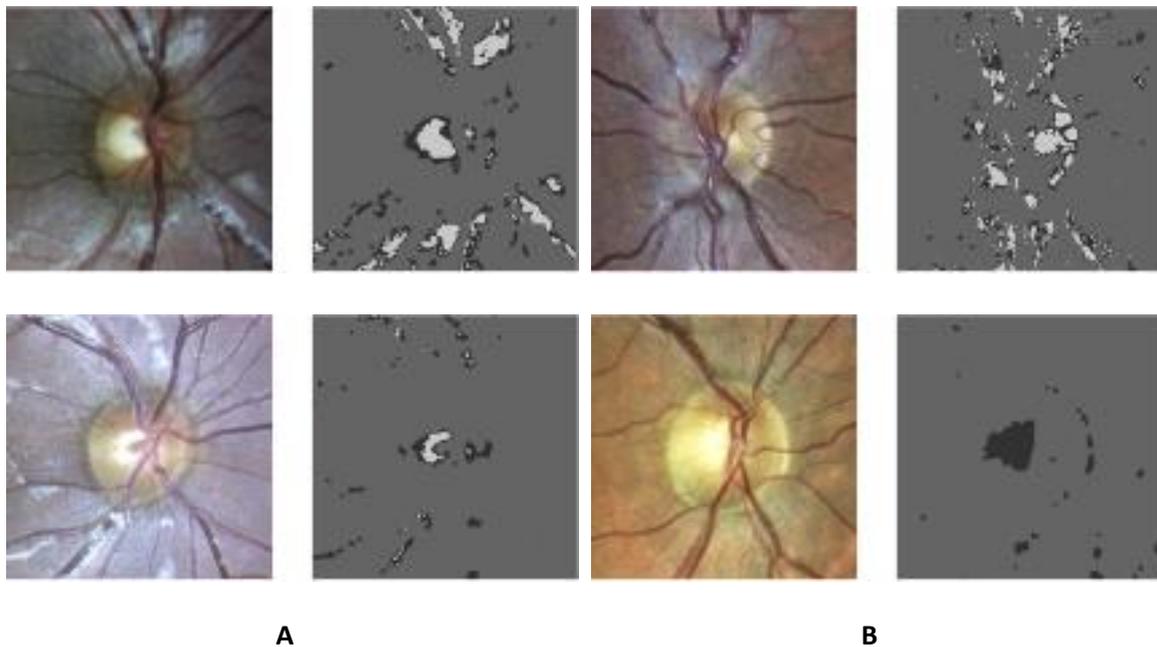


Figura 5.27. Resultados de segmentación aproximadamente correcta sólo de la copa (A) y resultados de segmentación incorrectos (B) (imágenes Compass, método [31]).

5.7 “SEGMENTATION OF THE OPTIC DISK IN COLOR EYE FUNDUS IMAGES USING AN ADAPTIVE MORPHOLOGICAL APPROACH” (Welfer et al., 2009) [36]

5.7.1 EXPLICACIÓN DEL MÉTODO

Este método tiene como finalidad la segmentación automática únicamente del disco óptico, centrándose en el uso de la transformada watershed.

En primer lugar, como se puede observar en la figura 5.28 se detectan los vasos sanguíneos de la imagen, y se seleccionan aleatoriamente 20 puntos que formen parte de estos vasos y que estén cerca del centro estimado de la CNO.

Se aplica la transformada watershed 20 veces sobre el gradiente de la imagen resultante de ejecutar una operación morfológica de apertura sobre la componente R. En cada uno de estas 20 aplicaciones de la transformada watershed, se establece uno

de los puntos seleccionados de los vasos como marcador interno, y una circunferencia centrada en este, capaz de abarcar a la cabeza del nervio óptico en su interior, como marcador externo.

De los 20 resultados obtenidos se analiza únicamente la región resultante que incluya el centro estimado de la CNO. De estas 20 regiones se escoge la que sea más compacta, y se le aplica erosión con un elemento estructurante en forma de diamante.

Para terminar, se vuelve a calcular la transformada watershed del gradiente, añadiéndole esta vez la forma resultante de la erosión como marcador interno, y la circunferencia correspondiente como marcador externo. El resultado final debe corresponderse con la CNO de la retinografía.

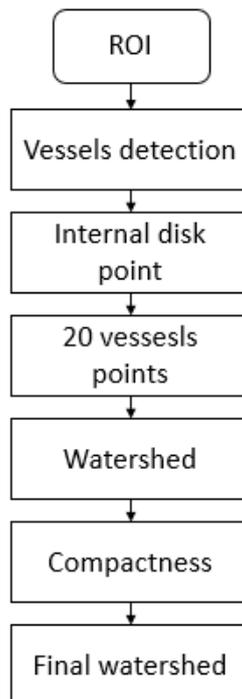


Figura 5.28. Pasos para la detección de la CNO según [36].

El método ha sido probado en 40 retinografías de la base de datos DRIVE [48] y 89 de la base de datos DIARETDB1 [49]. Algunos de los resultados obtenidos se pueden observar en la figura 5.29.

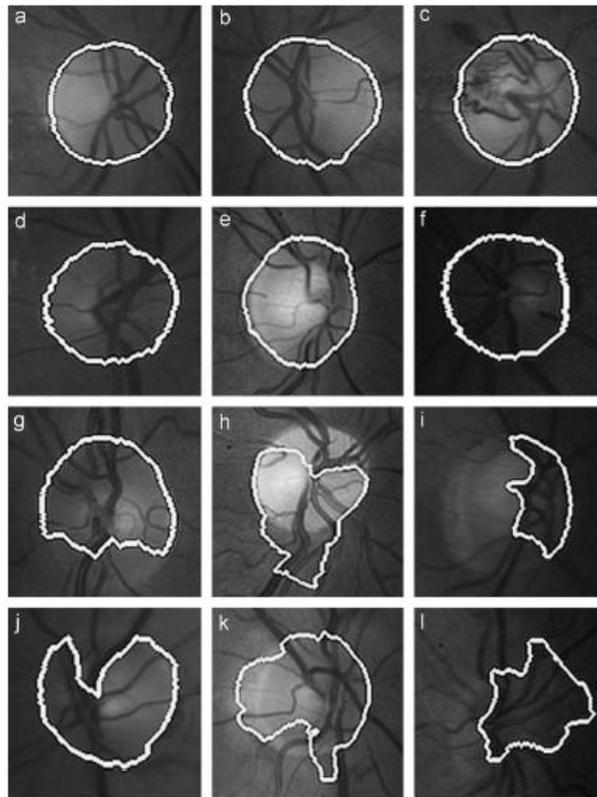


Figura 5.29. Resultados experimentales. Extraído de [36].

5.7.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO

Esta propuesta no pudo llevarse a cabo fielmente sobre el conjunto de 60 imágenes de prueba seleccionadas para este estudio de aplicabilidad, porque al estar ya recortadas y centradas en la CNO, las circunferencias que se creaban como marcadores externos sobresalían de la imagen. Es por esto por lo que en la mayoría de ocasiones las circunferencias usadas como marcadores externos no eran lo suficientemente grandes como para abarcar la CNO en su interior. Por lo tanto, como se puede observar en los resultados obtenidos con estas imágenes (anexo III), no se logra la segmentación completa del disco óptico.

Por este motivo se ha implementado este método sobre algunas retinografías Horus en su tamaño original. El número de imágenes no es representativo para sacar conclusiones estadísticas, pero sí es suficiente para observar el funcionamiento del método. Sobre las imágenes Compass sólo se ha podido probar en una de las imágenes, porque como la CNO suele estar cercana a los bordes en este tipo de retinografías, sigue estando presente el problema de la circunferencia que sobresale.

5.7.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS

Tal y como se comentó en el apartado anterior, debido a los problemas encontrados para reproducir el método no es coherente realizar unas estadísticas de aplicabilidad. Todos los resultados experimentales obtenidos se pueden consultar en el anexo III. En la figura 5.30 se ofrecen algunos a modo de ejemplo.

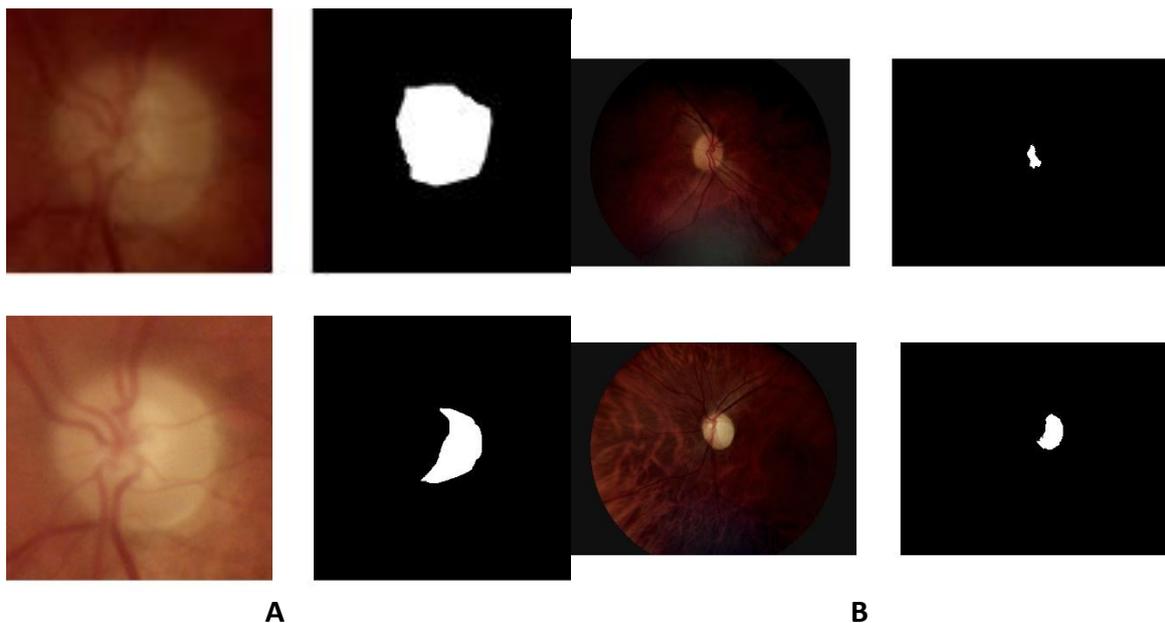


Figura 5.30. Resultados de segmentación incorrecta sobre imágenes del conjunto de prueba (A) y sobre imágenes en tamaño original (B) (imágenes Horus, método [36]).

5.7.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS

Tal y como se comentó en los problemas de reproducibilidad del método, tampoco sobre estas imágenes se ha podido realizar un análisis estadístico. En cualquier caso, en ninguna imagen se ha detectado correctamente el disco. Algunos resultados se ofrecen en la figura 5.31. Todos los resultados experimentales obtenidos se pueden consultar en el anexo III.

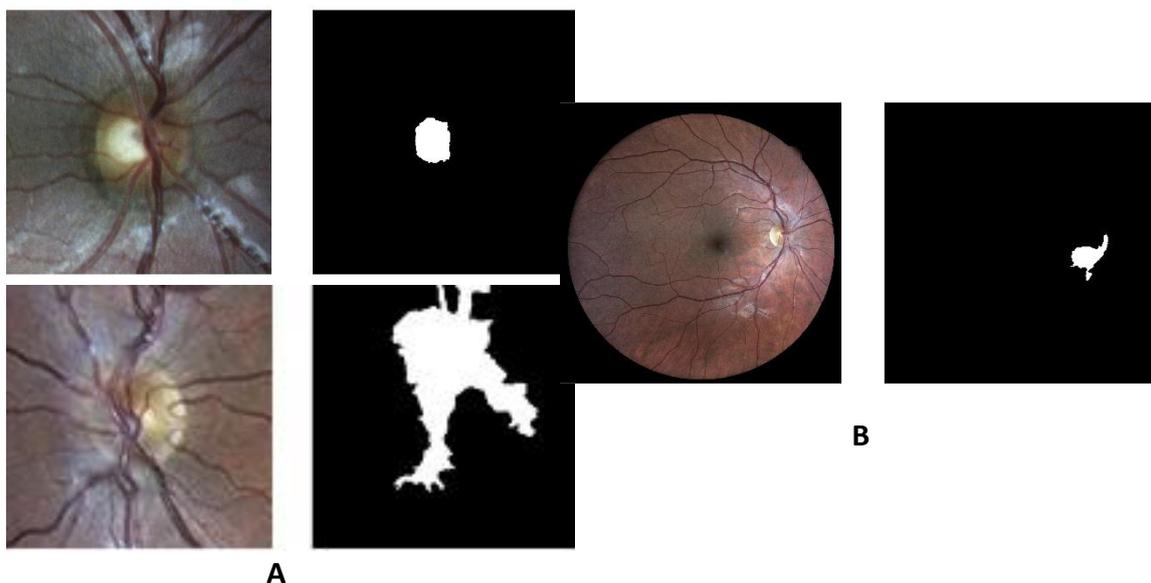


Figura 5.31. Resultados de segmentación incorrecta sobre imágenes del conjunto de prueba (A) y sobre una imagen en tamaño original (B) (imágenes Compass, método [36]).

5.8 “BLOOD VESSEL INPAINTING BASED TECHNIQUE FOR EFFICIENT LOCALIZATION AND SEGMENTATION OF OPTIC DISC IN DIGITAL FUNDUS IMAGES” (Sarathi et al., 2016) [34]

5.8.1 EXPLICACIÓN DEL MÉTODO

Este trabajo tiene por objetivo únicamente la segmentación del disco óptico. El método propuesto localiza la zona donde se encuentra la CNO, detecta los vasos y diseña una estrategia para borrarlos de la zona de la CNO, ecualiza y umbraliza la imagen resultante, y por último, aproxima

En la figura 5.32 se ofrece un esquema del proceso. Para empezar, se localiza el centro del nervio óptico mediante una ventana de Kaiser (*Stage A*).

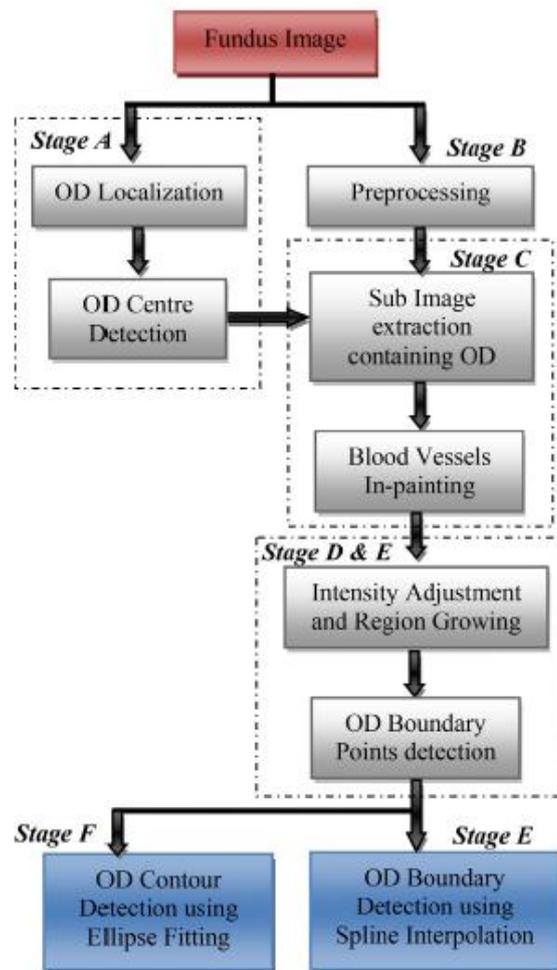


Figura 5.32. Pasos para la detección de la CNO. Extraído de [34].

Después, se separan las componentes RGB y se crea una imagen nueva formada por un 75% del canal rojo y un 25% del verde, con la que se continuará el procesamiento (*Stage B*).

Una vez que se genere esta imagen, para localizar y borrar los vasos sanguíneos se crea una circunferencia centrada en el punto hallado con la ventana de Kaiser. La circunferencia va aumentando de radio para recorrer todo el interior del disco óptico. Para cada radio se aplica la ecuación 5.3, siendo s los píxeles que forman la circunferencia:

$$\tau_1 = \min(s) \frac{\{\max(s) - \min(s)\}}{2} \quad (5.3)$$

Los valores que queden por debajo de τ_1 serán sustituidos por la media de s (*Stage C*).

A continuación, se realiza un ecualizado de la imagen para que el disco aparezca más brillante en la misma. Para detectar la frontera del disco, se emplea una técnica de crecimiento de regiones, utilizando el centro estimado de la CNO como semilla (*Stage D&E*).

Por último, se traza un perfil horizontal pasando por el centro, y el valor medio de estos valores se establece como umbral. Tras el umbralizado, se ajusta con una elipse la forma resultante. Esta elipse marcaría la frontera de la CNO (*Stage F*).

El método ha sido probado en retinografías proporcionadas por un hospital, y de las bases de datos MESSIDOR [46] y DRIVE [48]. Algunos de los resultados obtenidos se pueden observar en la figura 5.33.

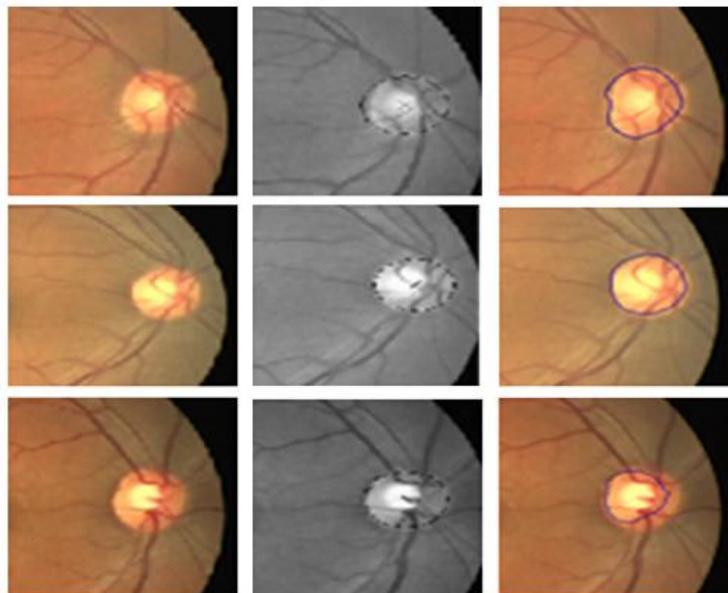


Figura 5.33. Resultados experimentales. Extraído de [34].

5.8.2 PROBLEMAS DE REPRODUCIBILIDAD DEL MÉTODO

Debido a la forma en la que están recortadas las imágenes de prueba, es más exacto considerar como punto central de la CNO el centro de la imagen que el obtenido mediante el uso de la ventana de Kaiser. En la figura 5.34 se muestra el proceso

seguido por los autores para localizar la zona de la CNO con este método. En nuestro caso, esta etapa es innecesaria.

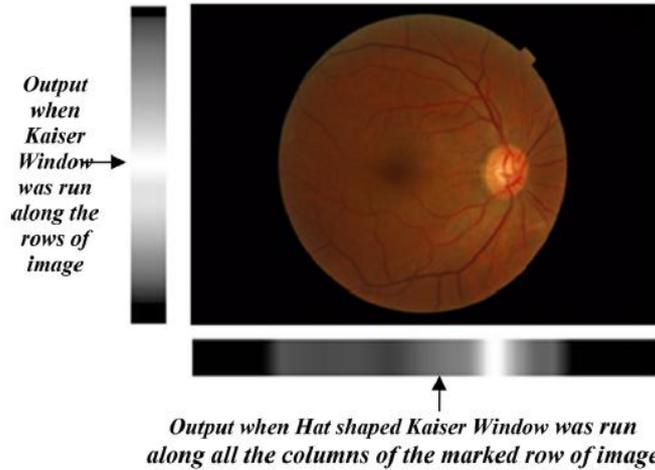


Figura 5.34. Resultado de la ventana Kaiser. Extraído de [34].

Se ha encontrado una errata en la ecuación 5.3 y se ha aplicado en su lugar la ecuación 5.4:

$$\tau_1 = \min(s) + \frac{\{\max(s) - \min(s)\}}{2} \quad (5.4)$$

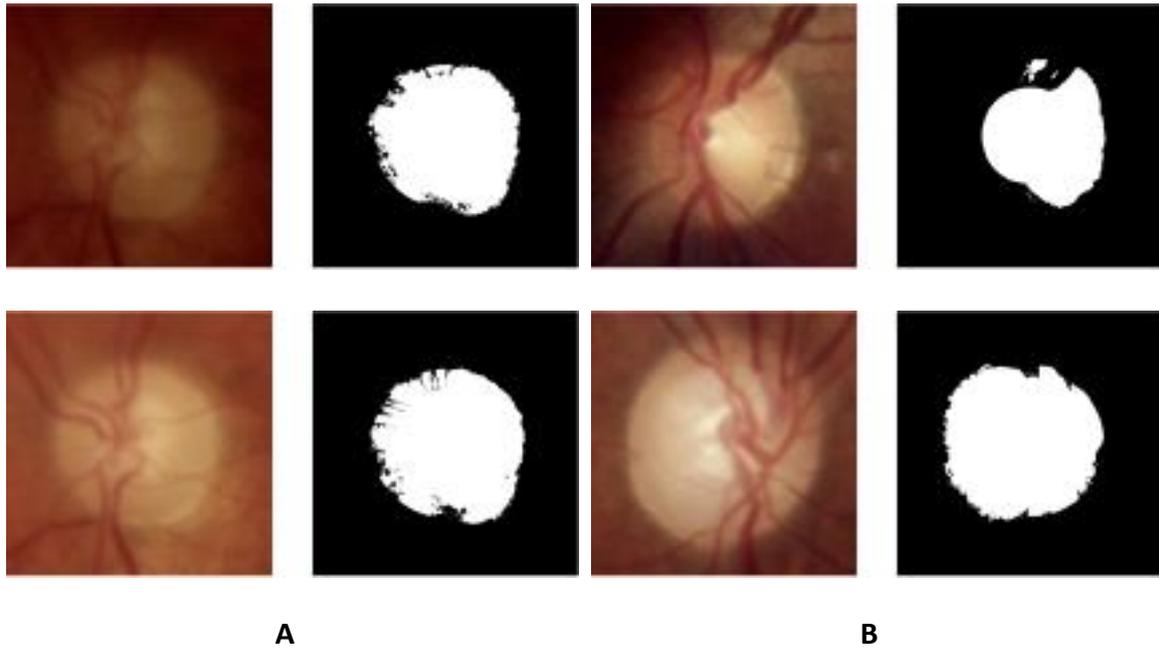
Finalmente, se ha comprobado experimentalmente que, si se ecualiza la imagen tal y como se propone en este método, los resultados obtenidos empeoran. Por tanto, se ha prescindido de este último paso.

5.8.3 RESULTADOS SOBRE LA BASE DE IMÁGENES HORUS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.15. Se puede observar que el método propuesto por estos autores funciona correctamente para el 50% de las imágenes analizadas. En la figura 5.35 se ofrecen algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	15	0	15
Porcentaje (%)	0	50	0	50

Tabla 5.15. Resultados cualitativos del método [34] sobre imágenes Horus.



. 5.35. Resultados de segmentación correcta (A) e incorrecta (B) del disco (imágenes Horus, método [34]).

5.8.4 RESULTADOS SOBRE LA BASE DE IMÁGENES COMPASS

Los resultados cualitativos de segmentación en estas 30 imágenes son los mostrados en la tabla 5.16. Se puede observar que el método propuesto por estos autores funciona detecta la zona aproximada del disco en el 43,33% de las imágenes analizadas. En la figura 5.36 se muestran algunos de los resultados experimentales obtenidos (que se recogen en su totalidad en el anexo III).

	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Número de imágenes	0	13	0	17
Porcentaje (%)	0	43,33	0	56,67

Tabla 5.16. Resultados cualitativos del método [34] sobre imágenes Compass.

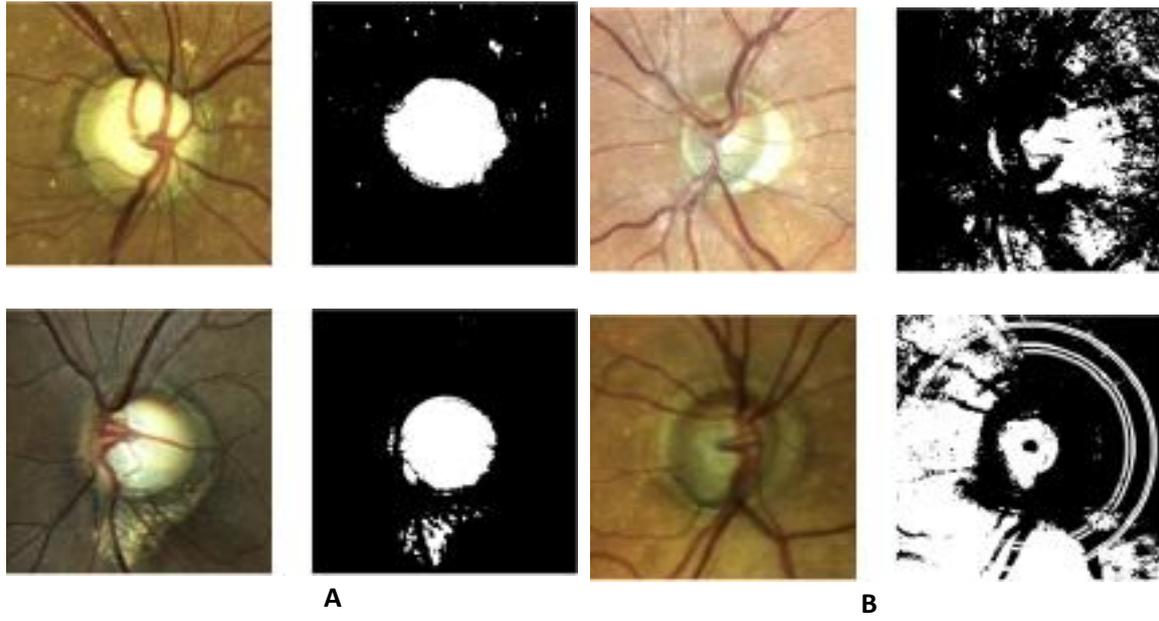


Figura 5.36. Resultados de segmentación aproximadamente correcta (A) e incorrecta (B) del disco (imágenes Compass, método [34]).

6. ANÁLISIS DE RESULTADOS EXPERIMENTALES

En total se han reproducido 8 métodos. Los resultados de las segmentaciones de disco y copa de cada uno de estos métodos sobre el conjunto de imágenes Horus y Compass se puede consultar en el anexo III. Para facilitar el análisis de estos resultados experimentales, en este capítulo nos centraremos en estudiar las estadísticas de cada método.

En la tabla 6.1 se recopilan los resultados de segmentación para 7 de los 8 métodos reproducidos. El método Welfer et al., 2009 [36] no se ha incluido en este análisis, ya que no se ha podido reproducir adecuadamente, y los resultados encontrados no son fiables.

En la tabla 6.1, para cada método analizado, se muestra el número/porcentaje de imágenes Horus y Compass en las que disco y copa han sido correctamente segmentados, sólo el disco o sólo la copa ha sido bien localizada, y finalmente, en las que disco y copa han sido incorrectamente segmentados.

El método que mejor se aproxima a la correcta detección de disco y copa es el de Hatanaka et al., 2011 [28], con un 36,67% de imágenes bien segmentadas para las imágenes Horus y un 46,67% para las Compass. Sin embargo, si se observan los resultados de segmentación mostrados en el anexo III, se puede apreciar que la detección de ambas estructuras no es precisa, por lo que no sería útil en un sistema de ayuda al diagnóstico de glaucoma.

El método que mejor detecta solamente el disco, tal y como se puede observar en la tabla 6.1, es el de Sarathi et al., 2016 [14]. En este caso se puede afirmar que el disco se aprecia cualitativamente en el 50% de los casos para las imágenes Horus y en el 43,33% para las Compass. Además, se ha observado que este método ofrece sus mejores resultados de segmentación en las imágenes muy iluminadas, lo que se puede comprobar en el anexo III.

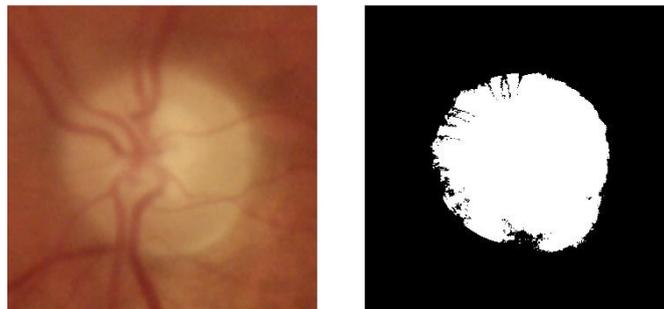


Figura 6.1. Resultado de segmentación de una imagen con alta iluminación con el método [14].

La detección automática solo de la copa, en el caso de las imágenes Horus, ha sido mejor resuelta por el método de Khalid et al., 2014 [13] (40% de copas correctamente segmentadas), mientras que con las imágenes Compass el mejor ha sido el método de Ahmad et al., 2014 [30] (30% de copas correctamente segmentadas).

Método	Retinografías	Correcta detección de disco y copa	Correcta detección solo de disco	Correcta detección solo de copa	Detección incorrecta en ambos casos
Ayub et al., 2016 [10]	Horus	10	0	8	12
		33,33	0	26,67	40
	Compass	0	0	10	20
		0	0	33,33	66,67
Khalid et al., 2014 [13]	Horus	6	0	12	12
		20	0	40	40
	Compass	0	0	6	24
		0	0	20	80
Cheng et al., 2013 [17] entrenamiento con una sola imagen	Horus	0	7	0	23
		0	23,33	0	76,67
	Compass	0	2	0	28
		0	6,67	0	93,33
Cheng et al., 2013 [17] entrenamiento con varias imágenes	Horus	6	4	5	15
		20	13,33	16,67	50
	Compass	0	5	5	20
		0	16,67	16,67	66,66
Hatanaka et al., 2011 [29]	Horus	11	6	9	4
		36,67	20	30	13,33
	Compass	14	4	6	6
		46,67	13,33	20	20
Ahmad et al., 2014 [30]	Horus	8	0	9	13
		26,67	0	30	43,33
	Compass	0	0	9	21
		0	0	30	70
Nugraha et al., 2016 [31]	Horus	4	11	0	15
		13,33	36,67	0	50
	Compass	0	0	6	24
		0	0	20	80
Sarathi et al., 2016 [34]	Horus	0	15	0	15
		0	50	0	50
	Compass	0	13	0	17
		0	43,33	0	56,67

Tabla 6.1. Resultados de segmentación de cada método. Filas azules: número de imágenes, filas blancas: porcentaje (%).

Por otro lado, el método que peores resultados proporciona es el de Cheng et al., 2013 [17], cuando el conjunto de entrenamiento se construye con una sola imagen, obteniendo un porcentaje del 76,67% y del 93,33% de detección incorrecta para las imágenes Horus y Compass, respectivamente. Es preciso destacar que estas cifras se reducen si ampliamos el conjunto de entrenamiento, teniendo un 50% y 66,66% de detección incorrecta en ambos casos, respectivamente. Por tanto, parece probable que si se aumentara el tamaño del conjunto de entrenamiento, los resultados de segmentación mejorarían.

Este método obtiene la frontera del disco de manera bastante exacta, en comparación con los demás métodos analizados (ver resultados del anexo III). Pero, al utilizar clasificadores supervisados, se necesita un trabajo manual a la hora de etiquetar las regiones que pertenecen al disco, al fondo o a la copa en el proceso de construcción de los conjuntos de entrenamiento. Este trabajo parece demasiado laborioso para los resultados de clasificación que ofrece.

En cuanto al método de Nugraha et al., 2016 [31], si se observan los resultados experimentales obtenidos en el anexo III, se puede observar que el valor empírico que los autores proponen para la umbralización de la imagen es válido para algunas retinografías, pero para otras ni siquiera es adecuado para detectar la copa.

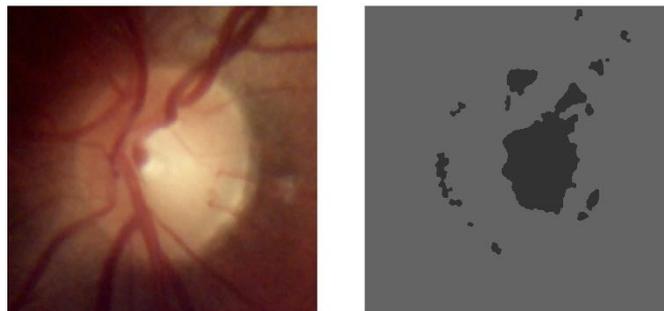


Figura 6.2. Resultado de segmentación con el método [31] con umbral no adecuado para detectar la copa.

El método de Welfer et al., 2009 [36], que no se contempla en las estadísticas por problemas de reproducibilidad (sección 5.7), en ningún caso detecta adecuadamente el disco, que es el objetivo principal del método. En las imágenes que se probaron en tamaño original se obtiene una región que en muchos casos contiene la copa o incluso la CNO pero que también abarca más zonas, lo que no permite una adecuada segmentación (ver resultados completos en el anexo III).

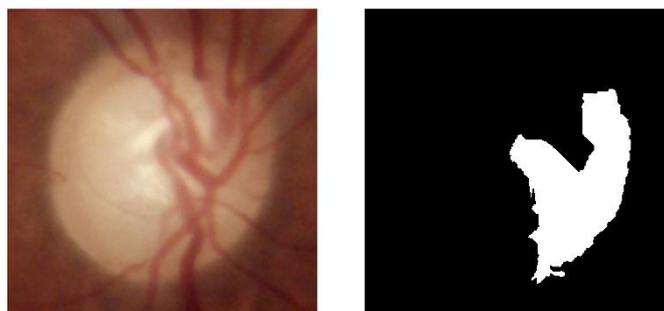


Figura 6.3. Resultado de segmentación con el método [36].

Si se observan todos los resultados obtenidos, se hace evidente que los métodos publicados hasta la fecha sobre la detección automática de la CNO y la excavación no son aplicables a las imágenes Compass. Esto es debido a que las características de estas retinografías difieren bastante de las convencionales, y los métodos estudiados se basan en estas últimas. El conocimiento sobre el que se suelen diseñar estos métodos no es fiable con las nuevas imágenes. Por ejemplo, la retina no está necesariamente en tono rojizo, la componente G ya no tiene por qué resaltar mejor el contorno de la CNO, y la afirmación de que la excavación suele ser la parte más clara de la retinografía ya no es cierta.

Por tanto, se verifica la hipótesis inicial planteada en este TFG de que los métodos actualmente publicados no son válidos para las nuevas imágenes confocales Compass.

Sin embargo, los resultados obtenidos para las imágenes Horus (retinografías convencionales) nos han sorprendido bastante. Esperábamos mejores resultados de segmentación, puesto que todos estos métodos están diseñados específicamente para este tipo de imágenes. Los motivos de que esto haya ocurrido pueden ser variados: falta de rigor del método (en su explicación, o en su reproducción), validación con un número insuficiente de imágenes, métodos ad-hoc diseñados sólo para un tipo de imágenes demasiado ideales, etc.

Por último, es importante destacar que los resultados de segmentación han sido evaluados visualmente y, por tanto, de manera subjetiva. Para afirmar que un resultado de segmentación de una estructura es válido o no, el criterio es si se distingue esta estructura en la imagen, aunque su frontera no esté perfectamente delimitada. Esto es un criterio muy poco exigente y, aun así, ha dado lugar a estadísticas bastante negativas.

7. CONCLUSIONES Y LÍNEAS ABIERTAS

En este TFG se ha realizado un estudio de aplicabilidad de los métodos de segmentación automáticos de retinografías publicados más recientemente. Estos métodos han sido diseñados para trabajar sobre retinografías convencionales, pero en este TFG es de interés aplicarlos, además, sobre un nuevo tipo de imagen: la retinografía confocal. Se han seleccionado 30 imágenes Horus (convencionales) y 30 imágenes Compass (confocales) para el desarrollo experimental del estudio. Estas imágenes han sido cedidas por especialistas del Hospital Universitario de Canarias.

La segmentación de estas imágenes puede ser de gran utilidad para la ayuda al diagnóstico de una enfermedad ocular: el glaucoma. En concreto, el disco óptico y la excavación son las estructuras de interés para este problema médico, y sobre las que se ha centrado nuestro análisis de segmentación.

En el trabajo presentado en esta memoria se han estudiado en profundidad 30 artículos publicados en la literatura científica. Finalmente, 8 han podido ser reproducidos. Se han tratado de replicar más métodos, pero no en todos los casos los autores han ofrecido una explicación clara de sus propuestas: hay trabajos con desarrollos incompletos, con falta de información, resultados experimentales incomprensibles, e incluso, se han encontrado varios trabajos copiados.

En este TFG se ha partido de la hipótesis de que los métodos actualmente desarrollados para el procesamiento de retinografías convencionales no son aplicables sobre las nuevas retinografías consideradas. En una retinografía convencional la retina aparece en tono rojizo, los vasos y la fovea son las zonas más oscuras de la imagen, y el disco óptico la elipse más iluminada. Los métodos existentes se basan en todas estas características para operar. Sin embargo, en las nuevas imágenes confocales la distribución del color es mucho más aleatoria, de forma que la retina no tiene por qué ser roja; y la iluminación es totalmente distinta, lo que hace que la CNO no sea necesariamente la zona más clara de la imagen siempre. Por todo esto, las referencias que se tenían para la segmentación de las partes del nervio óptico de las imágenes convencionales no tienen por qué ser de utilidad para las confocales.

El presente TFG ha permitido la verificación de esta hipótesis. La principal conclusión que se puede extraer a partir de los resultados experimentales obtenidos en la reproducción de cada método, es que no son aplicables sobre las imágenes Compass. Por tanto, se pone de manifiesto la necesidad de elaborar nuevos métodos para el procesamiento de estas nuevas retinografías en futuras líneas de trabajo. Aunque, naturalmente, también se podría continuar analizando con mayor profundidad el estado del arte, e intentar reproducir más métodos.

La segunda conclusión importante es que los métodos estudiados tampoco parecen aplicables a nuestras imágenes convencionales. Esperábamos mejores resultados de segmentación, puesto que todos estos métodos están diseñados específicamente para este tipo de imágenes. Los motivos de que esto haya ocurrido pueden ser variados: falta de rigor del método (en su explicación, o en su reproducción), validación con un

número insuficiente de imágenes, métodos ad-hoc diseñados sólo para un tipo de imágenes demasiado ideales, etc.

Desde un punto de vista más personal, este TFG le ha permitido a la alumna familiarizarse con el entorno investigador: abordar un problema de investigación multidisciplinar, consultar bibliografía científica y bases de datos, ampliar el vocabulario técnico (sobre todo en inglés), manejar entornos de programación como el Matlab, redactar documentos científicos, etc.

Es importante destacar que este TFG ha aumentado sus conocimientos sobre procesamiento de imagen, ya que en su carrera no hay ninguna asignatura específica sobre esta materia (exceptuando “Ampliación de Sistemas Robotizados”, en la que se les da una introducción a técnicas de procesamiento básicas). Estos conocimientos son de especial relevancia para esta alumna, debido a que es su deseo especializarse en aplicaciones de la Ingeniería en Medicina. De hecho, planea continuar su formación el curso que viene en Madrid, realizando el Máster en Ingeniería Biomédica (UPM).

CONCLUSIONS AND FUTURE RESEARCH WORK

In this EDW we have carried out an applicability study of the most recently automatic segmentation methods for retinographies. These methods have been specifically designed for conventional retinographies, but in this EDW they have also been applied to confocal images. For the experimental study, 30 Horus images (conventional ones) and 30 Compass images (confocal ones) have been selected. All these images have been given by specialists of the Hospital Universitario de Canarias.

Retinography segmentation can be useful for helping glaucoma diagnostic. More specifically, the optic disk and cup are the structures of interest for this medical problem, and our applicability analysis has been focused on them.

In this report 30 scientific publications have been deeply studied. Finally, 8 of them have been reproduced. However, we have tried to replicate more methods, but it has not been possible due to the lack of precision in the explanations: there are some articles with incomplete developments, not enough information, misunderstanding experimental results, and some plagiarised publications.

In this EDW an initial hypothesis has been formulated: current methods for processing conventional retinographies are not useful for confocal ones. In a conventional retinography the retina has red colour, vessels and fovea are the darkest zones of the image, and the lightest elliptic part is the optic disc. Existing methods are based on these characteristics. But new confocal retinographies are characterized by a different and more randomly colour distribution. The retina is not always red, and the optic nerve head is not necessary the lighter region of the image. These are the reasons why conventional retinographies techniques could not work properly on confocal images.

The present EDW has allowed the verification of this hypothesis. The first conclusion extracted from the experimental results is that the analysed methods are not

applicable to Compass images. This fact evidences the necessity of developing new methods for processing these new retinographies in future research works. However, the applicability study could be also increased with new methods.

The second important conclusion is that the studied methods do not seem applicable to conventional images. We expected better segmentation results because these methods were specifically designed for conventional retinographies. Reasons of this finding could be the following ones: lack of strictness in the method (in its explanation or in its reproduction), validation with an insufficient number of images, ad-hoc methods planned only for ideal images, etc.

From a personal point of view, this EDW has allowed the student to familiarize with the research environment: tackle a multidisciplinary research problem, consult scientific bibliography and databases, improve her technical vocabulary (especially in English), manage tools as Matlab, redact scientific documents, etc.

It is important to highlight that this EDW has improved her knowledge about image processing. In her degree there is not any subject about this topic (only one, "Extension of Robotics Systems", offers an introduction). This knowledge is important for this student because she would like to specialize in the application of Engineering to Medicine. In fact, she will continue her formation in Madrid, in the Master in Biomedical Engineering (UPM).

8. REFERENCIAS

- [1] CenterVue. Disponible en: <https://www.centervue.com/products/compass/>.
- [2] Bull of the World Health Organ, "In focus: Glaucoma is second leading cause of blindness globally," p. 82 (11): 887, 2004.
- [3] Website de la Asociación de Glaucoma para afectados y familiares (AGAF). Disponible en: <http://www.asociaciondeglaucoma.es/>
- [4] "MedlinePlus." Disponible en: <https://medlineplus.gov/spanish/>.
- [5] J. García-Sánchez, J. García-Feijoó, "Glaucoma," *Editores Médicos S.A., Madrid*, 1999.
- [6] A. C. Viswanathana, F. W. Fitzkea, R. A. Hitchingsb, "Early detection of visual field progression in glaucoma: a comparison of PROGRESSOR and STATPAC 2," *Br. J. Ophthalmol*, vol. 81, pp. 1037–1042, 1997.
- [7] C. Bowd, Zangwill L. M., Medeiros F.A, Hao J., Chan K., Lee T.W., Sejnowski T.J., Goldbaum M.H., Sample P.A., Crowston J.G., Weinreb R.N., "Confocal scanning laser ophthalmoscopy classifiers and stereophotograph evaluation for prediction of visual field abnormalities in glaucoma-suspect eyes," *Invest. Ophthalmol*, vol. 45, pp. 2255–2262, 2004.
- [8] A. Arias-Puente, J. García-Sánchez, J. García-Feijoó, "Análisis de la excavación de la papila óptica. Capítulo del libro Técnicas diagnósticas y tratamiento del glaucoma," *Ediciones Universidad de Navarra, Pamplona. ISBN: 84-313-1587-3.*, 1998.
- [9] Website de Retinalyze. Disponible en: <http://www.retinalyze.es/> .
- [10] J. Ayub, J. Ahmad, J. Muhammad, L. Aziz, S. Ayub, U. Akram, I. Basit, "Glaucoma detection through optic disc and cup segmentation using K-mean clustering," *2016 International Conference on Computing, Electronic and Electrical Engineering, ICE Cube 2016 - Proceedings*, pp. 143–147, 2016.
- [11] R. Nithya, N. Venkateswaran, "Analysis of Segmentation Algorithms in Colour Fundus and OCT Images for Glaucoma Detection," *Indian Journal of Science and Technology*, vol. 8, no. September, pp. 326–332, 2015.
- [12] R. P. Rajaiah, R. J. Britto, "Optic Disc Boundary Detection and Cup Segmentation for Prediction of Glaucoma," vol. 3, no. 10, 2014.
- [13] N. E. A. Khalid, N. M. Noor, N. M. Ariff, "Fuzzy c-Means (FCM) for optic cup and disc segmentation with morphological operation," *Procedia Computer Science*, vol. 42, no. C, pp. 255–262, 2014.
- [14] P. S. Mittapalli, G. B. Kande, "Segmentation of optic disk and optic cup from digital fundus images for the assessment of glaucoma," *Biomedical Signal Processing and Control*, vol. 24, pp. 34–46, 2016.
- [15] "RIM-ONE." Disponible en: <http://medimrg.webs.ull.es/research/downloads/> .
- [16] "DIARETDB0." Disponible en: <http://www.it.lut.fi/project/imageret/diaretdb0/>.
- [17] J. Cheng, J. Liu, D. Tao, F. Yin, D. Wong, Y. Xu, T. Wong, "Superpixel classification based optic cup segmentation," *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, vol. 8151 LNCS, no. PART 3, pp. 421–428, 2013.
- [18] R. Deshpande, A. Kurmi, J. Yadav, P. Borole, "Identification of glaucoma disease using optic disk and cup segmentation from retinal images," vol. 5, no. 2, pp. 502–504, 2016.

- [19] P. Chaudhari, R. Nikhare, "OPTIC DISC AND OPTIC CUP SEGMENTATION FOR GLAUCOMA DETECTION," vol. X, no. ix, pp. 1–9, 2016.
- [20] K. Kavitha, M. Malathi, "Optic Disc and Optic Cup Segmentation for Glaucoma Classification," vol. 2, no. March, pp. 87–90, 2014.
- [21] V. Mahalakshmi, S. Karthikeyan, "Clustering Based Optic Disc and Optic Cup," pp. 3756–3761, 2014.
- [22] P. N. Maldhure, P. V. V Dixit, "Glaucoma Detection Using Optic Cup and Optic Disc Segmentation," *International Journal of Engineering Trends and Technology (IJETT)*, vol. 20, no. 2, pp. 52–55, 2015.
- [23] G. Sani, Y. Darvin, "Automatic Optic Disc and Cup Segmentation Based on Pca and Super Pixel Classification for," vol. 4, no. 3, pp. 69–75, 2014.
- [24] S. Thorat, S. Jadhav, "Optic disc and optic cup segmentation for glaucoma screening adopting superpixel classification," *International Journal of Innovations & Advancement in Computer Science*, vol. 4, no. Special Issue, 2015.
- [25] G. Veerasenthikumar, S. Vasuki, R. Rajkumar, "Artificial Intelligence and Evolutionary Algorithms in Engineering Systems," vol. 325, pp. 733–744, 2015.
- [26] B. B. Naik, R. Mariappan, "Classification of Eye Diseases Using Optic Cup Segmentation and Optic Disc Ratio," *IOSR Journal of Computer Engineering*, vol. 18, no. 5, pp. 87–94, 2016.
- [27] G. D. Joshi, J. Sivaswamy, S. R. Krishnadas, "Optic disk and cup segmentation from monocular color retinal images for glaucoma assessment," *IEEE Transactions on Medical Imaging*, vol. 30, no. 6, pp. 1192–1205, 2011.
- [28] Y. Hatanaka, Noudo A., Muramatsu C., Sawada A., Hara T., Yakamoto T., Fujita H., "Automatic measurement of cup to disc ratio based on line profile analysis in retinal images," *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, pp. 3387–3390, 2011.
- [29] Y. Hatanaka, Nagahata Y., Muramatsu C., Okumura S., Ogohara K., Sawada A., Ishida K., Yamamoto T., Fujita H., "Improved automated optic cup segmentation based on detection of blood vessel bends in retinal fundus images," *Conference proceedings: Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference*, vol. 2014, pp. 126–129, 2014.
- [30] H. Ahmad, A. Yamin, A. Shakeel, S. O. Gillani, U. Ansari, "Detection of glaucoma using retinal fundus images," *2014 International Conference on Robotics and Emerging Allied Technologies in Engineering, iCREATE 2014 - Proceedings*, no. August, pp. 321–324, 2014.
- [31] G. S. Nugraha, I. Soesanti, "Segmentation of the Optic Disc and Optic Cup Using Histogram Feature- Based Adaptive Threshold for Cup to Disk Ratio," vol. 5003, pp. 7–11, 2016.
- [32] S. M. K. Sherwani, M. I. Tiwana, N. H. Lovell, F. Ieee, "Automated Segmentation of Optic Disc Boundary and Diameter Calculation using Fundus Imagery," 2015.
- [33] C. Tulasigeri, M. Irulappan, "An adaptive threshold based algorithm for optic disc and cup segmentation in fundus images," *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, vol. 5, no. 6, 2016.
- [34] M. P. Sarathi, M. K. Dutta, A. Singh, C. M. Travieso, "Blood vessel inpainting based technique for efficient localization and segmentation of optic disc in

- digital fundus images," *Biomedical Signal Processing and Control*, vol. 25, pp. 108–117, 2016.
- [35] S. Morales, V. Naranjo, D. Pérez, A. Navea, M. Alcañiz, "AUTOMATIC DETECTION OF OPTIC DISC BASED ON PCA AND STOCHASTIC WATERSHED," in *20th European Signal Processing Conference (EUSIPCO 2012)*, 2012, pp. 2605–2609.
- [36] D. Welfer, J. Scharcanski, C. M. Kitamura, M. M. Dal Pizzol, L. W. B. Ludwig, D. R. Marinho, "Segmentation of the optic disk in color eye fundus images using an adaptive morphological approach," *Computers in Biology and Medicine*, vol. 40, no. 2, pp. 124–137, 2010.
- [37] S. Sedai, P. K. Roy, D. Mahapatra, R. Garnavi, "Segmentation of optic disc and optic cup in retinal fundus images using shape regression," *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, vol. 2016–Octob, pp. 3260–3264, 2016.
- [38] M. V. Wyawahare, P. M. Patil, "Performance Evaluation of Optic Disc Segmentation Algorithms in Retinal Fundus Images : an Empirical Investigation," vol. 69, pp. 19–32, 2014.
- [39] Y. Zheng, D. Stambolian, J. O'Brien, J. C. Gee, "Optic Disc and Cup Segmentation from Color Fundus Photograph Using Graph Cut with Priors," *Med Image Comput Comput Assist Interv.*, pp. 75–82, 2013.
- [40] MathWorks. Disponible en: <https://www.mathworks.com/>.
- [41] "The Singapore Malay Eye Study (SiMES)." Disponible en: <https://www.eyeworld.org/article-the-singapore-malay-eye-study--simes->.
- [42] M. Baskaran, C.F. Reuben, C. Cheng, A.K. Narayanaswamy, Y. Zheng, R. Wu, S. Saw, P.J. Foster, T. Wong, T. Aung, "The Prevalence and Types of Glaucoma in an Urban Chinese Population", *The Singapore Chinese Eye Study*, vol. 168751, no. 8, pp. 874–880, 2015.
- [43] T. Nakagawa, Y. Hayashi, Y. Hatanaka, A. Aoyama, Y. Mizukusa, A. Fujita, M. Kakogawa, T. Hara, H. Fujita, T. Yamamoto, "Recognition of optic nerve head using blood-vessel-erased image and its application to production of simulated stereogram in computer-aided diagnosis system for retinal images," *IEICE Trans. Information and Systems*, vol. J89–D, no. 11, pp. 2491–2501, 2006.
- [44] "DMED". Disponible en: <https://health.mil/Military-Health-Topics/Health-Readiness/Armed-Forces-Health-Surveillance-Branch/Data-Management-and-Technical-Support/Defense-Medical-Epidemiology-Database>.
- [45] "FAU." Disponible en: <https://www5.cs.fau.de/research/data/fundus-images/>.
- [46] "MESSIDOR techno-vision project France download images section," *MESSIDOR: Digital Retinal Images*. Disponible en: <http://messidor.crihan.fr/download-en.php%0A>.
- [47] "DRISTHI." Disponible en: <http://dristhi.com/>.
- [48] "DRIVE." Disponible en: <http://www.isi.uu.nl/Research/Databases/DRIVE/>.
- [49] "DIARETDB1." Disponible en: <http://www.it.lut.fi/project/imageret/diaretdb1/>.
- [50] A. de la Escalera Hueso, *VISIÓN POR COMPUTADOR. Fundamentos y métodos*. 2001.
- [51] J. Marrero, "Procesamiento automatizado de retinografías," *Proyecto Final de Carrera. Ingeniería Superior en Informática. Universidad de La Laguna.*, 2009.
- [52] R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, S. Sabine, "SLIC Superpixels Compared to State-of-the-art Superpixel Methods," vol. 6, no. 1, pp. 1–8, 2011.

- [53] K. M., A. Witkin, D. Terzopoulos, "Snakes: Active Contour Models," *International Journal of Computer Vision*, vol. 1(4), pp. 321–331, 1988.
- [54] M. Martín., "Contribuciones al análisis automático y semiautomático de ecografía fetal tridimensional mediante campos aleatorios de Markov y contornos activos. Ayudas al diagnóstico precoz de malformaciones. Tesis doctoral," *Universidad de Valladolid*, 2002.
- [55] R. Gonzalez y R. Woods, *Digital Image Processing*, 2008.

ANEXO I TÉCNICAS DE PROCESAMIENTO DE IMÁGENES UTILIZADAS EN ESTE TRABAJO FIN DE GRADO

1. Espacios de color
2. Histogramas
3. Umbralización
4. Operadores morfológicos
5. Detección de bordes
6. Filtrado de la imagen
7. Etiquetado
8. Clasificadores
9. Generación de superpíxeles
10. Transformada watershed
11. Técnicas de contornos activos

1. ESPACIOS DE COLOR

Las imágenes digitales se pueden representar de diferentes maneras para poder ser interpretadas por el ser humano o por otras tecnologías, con el objetivo de percibir el color de varias formas, según sea conveniente, o de facilitar su procesamiento a la hora de tratar la información digital. Estas formas de representación son llamadas espacios de color. En este TFG hemos utilizado las siguientes:

- **RGB:** está formado por tres componentes (*Red, Green, Blue* en la literatura anglosajona), de forma que cada color se establece según la proporción de rojo, de verde y de azul que contenga. Cada una de estas componentes puede adquirir valores que generalmente se expresan entre 0 y 255 para indicar la cantidad de cada una. Se trata, además, de un espacio de color ortogonal, es decir, no tiene en cuenta las partes cromáticas de las acromáticas del color a las que el ojo humano presenta distinta sensibilidad.
- **HSV:** es un espacio de color perceptual, esto es, con él es más sencillo asemejar los términos cromáticos a la percepción humana. Las componentes son el matiz (*hue*), en el que el tono varía de 0 a 1 y va de rojo a amarillo, verde, cian, azul, magenta y nuevamente al rojo; la saturación (*saturation*), en la que las tonalidades se encuentran desde insaturadas con valores cercanos a 0 (es decir, en tonos de gris) a totalmente saturadas (por lo que no tienen componente de blanco) cuando se alcanzan valores próximos a 1; y el brillo (*value*), en el que según se avance en el mismo rango de 0 a 1 los colores resultantes son más brillantes [40]. Por tanto, en el espacio HSV se hace una transformación no lineal del espacio RGB.
- **Escala de grises:** el porcentaje de blanco y de negro forman los distintos niveles de la escala de grises. Los valores pueden variar entre el valor mínimo (negro) y máximo (blanco).
- **Representación binaria:** los colores únicamente pueden ser blancos o negros, por lo que los píxeles solo pueden valer 0 o 1.

En la figura 1 se muestran varios ejemplos.

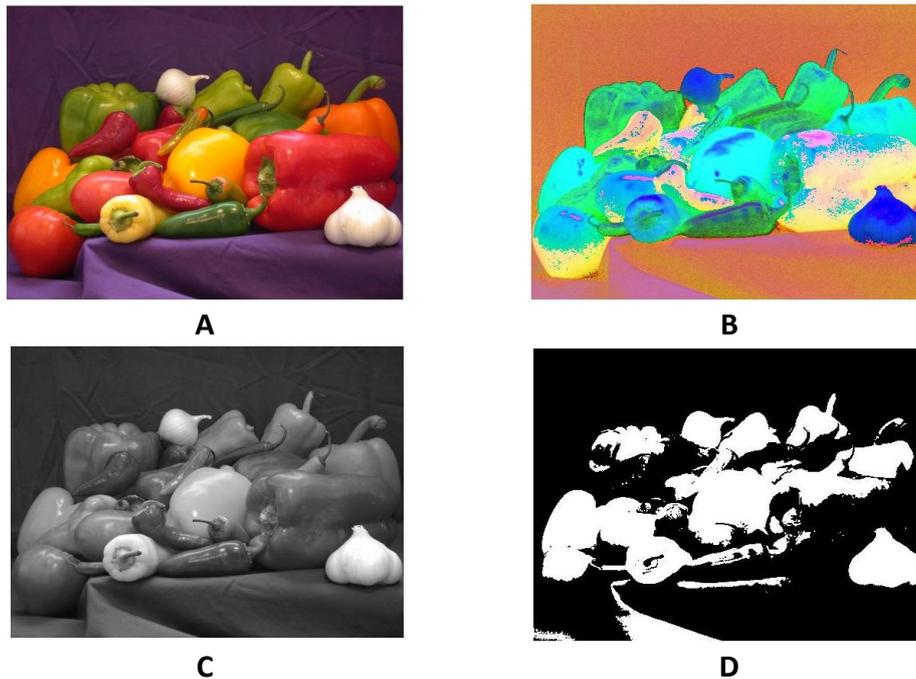


Figura 1. Imagen en RGB (A), HSV (B), escala de grises (C) y binaria (D).

2. HISTOGRAMA

El histograma de una imagen consiste en una gráfica donde se representa el número de píxeles n que tienen un nivel de intensidad determinado (entre 0 y 255).

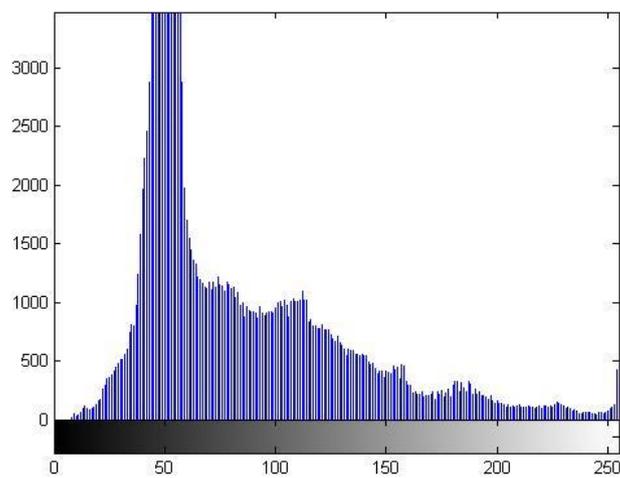


Figura 2. Histograma de la imagen que se muestra en la figura 1C.

ECUALIZACIÓN

La ecualización pretende distribuir equitativamente el número de píxeles de la imagen entre los valores de intensidad de la imagen [50]. Por tanto, consiste en modificar el histograma de una imagen, distribuyendo la frecuencia de valores a lo largo de todo el

rango dinámico posible para ajustar los valores de intensidad de manera uniforme. De esta forma, por consiguiente, se modifica el contraste de la imagen.



Figura 3. Ecuación de la figura 1C.

PERFIL

El perfil de una imagen está formado por el conjunto de valores de intensidad de los píxeles que forman una línea trazada sobre una zona de interés de la imagen.

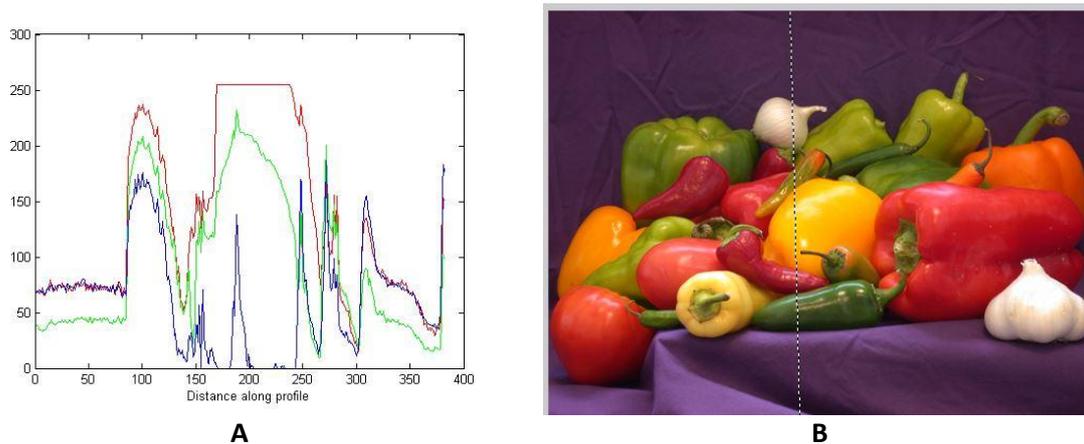


Figura 4. Perfil RGB de la imagen mostrada en la figura 1A (A). Línea del perfil sobre la imagen original (B).

3. UMBRALIZACIÓN

Es un proceso por el que se obtiene una imagen binaria a partir de otra en color o en escala de grises. Consiste en seleccionar un valor de intensidad del histograma (*umbral*) de forma que los píxeles que superen dicha intensidad cambian su valor por 1 (blanco) y los que, por otro lado, tengan un valor inferior al establecido cambian su valor por 0 (negro).

EL MÉTODO DE OTSU

Se considera uno de los mejores métodos de umbralización, puesto que da buenos resultados a pesar de la presencia en las imágenes de ruidos, iluminación inadecuada o histogramas demasiado planos. El método de Otsu establece el umbral óptimo para una imagen maximizando la varianza entre las clases del histograma mediante una búsqueda exhaustiva. La importancia del método de Otsu radica en que es automático, es decir, no necesita supervisión humana ni información previa de la imagen antes de su procesamiento [51].

Una imagen es una función bidimensional de la intensidad del nivel de gris, y contiene N píxeles cuyos niveles de gris se encuentran entre 1 y L . El número de píxeles con nivel de gris i se denota como f_i , y la probabilidad de ocurrencia del nivel de gris i en la imagen viene dada por:

$$p_i = \frac{f_i}{N} \quad (1)$$

En el caso de la umbralización en dos niveles de una imagen los píxeles son divididos en dos clases: C_1 , con niveles de gris $[1, \dots, t]$; y C_2 , con niveles de gris $[t+1, \dots, L]$. Entonces, la distribución de probabilidad de los niveles de gris para las dos clases es:

$$\begin{aligned} C_1 &: \frac{p_1}{\omega_1(t)}, \dots, \frac{p_t}{\omega_1(t)} \\ C_2 &: \frac{p_{t+1}}{\omega_2(t)}, \frac{p_{t+2}}{\omega_2(t)}, \dots, \frac{p_L}{\omega_2(t)} \end{aligned} \quad (2)$$

donde $\omega_1(t) = \sum_{i=1}^t p_i$ y $\omega_2(t) = \sum_{i=t+1}^L p_i$. La media para la clase C_1 y la clase C_2 es:

$$\begin{aligned} \mu_1 &= \sum_{i=1}^t \frac{i \cdot p_i}{\omega_1(t)} \\ \mu_2 &= \sum_{i=t+1}^L \frac{i \cdot p_i}{\omega_2(t)} \end{aligned} \quad (3)$$

Sea μ_T la intensidad media de toda la imagen. Es fácil demostrar que:

$$\begin{aligned} \omega_1 \cdot \mu_1 + \omega_2 \cdot \mu_2 &= \mu_T \\ \omega_1 + \omega_2 &= 1 \end{aligned} \quad (4)$$

Usando análisis discriminante, Otsu definió la varianza entre clases de una imagen umbralizada como:

$$\sigma_B^2 = \omega_1(\mu_1 - \mu_T)^2 + \omega_2(\mu_2 - \mu_T)^2 \quad (5)$$

Para una umbralización de dos niveles, Otsu verificó que el umbral óptimo t^* se elige de manera que σ_B^2 sea máxima; esto es:

$$t^* = \underset{t}{\text{Max}}\{\sigma_B^2(t)\} \quad 1 \leq t \leq L \quad (6)$$

En la figura 5 se puede observar un ejemplo de imagen umbralizada con el método de Otsu.



Figura 5. Umbralización con el método de Otsu de la imagen que se muestra en figura 1C.

4. OPERADORES MORFOLÓGICOS

Son una serie de operadores que modifican la forma o estructura de los puntos que forman la imagen. Generalmente, las operaciones morfológicas tienden a “simplificar” la imagen y a conservar las características principales de las mismas [40]. Estas herramientas, además de ser útiles para la extracción de características, permiten la eliminación de ruido que se produce en todo proceso de segmentación [50].

Los operadores morfológicos se basan en la aplicación local de un elemento estructurante sobre cada uno de los píxeles de la imagen y su vecindario más cercano [51]. Los más utilizados son la dilatación y la erosión.

DILATACIÓN

La dilatación es una operación matemática que recibe dos parámetros: la imagen original y la matriz de puntos de la imagen que forman el elemento estructurante. Podemos definir esta operación mediante la ecuación 1.

$$G(j,k) = \max[F(j,k), F(j,k+1), F(j,k-1), \dots] \quad (7)$$

Como resultado de la operación de dilatación, $G(j,k)$, se asigna al antiguo $F(j,k)$ el valor numérico de gris mayor existente en dicho grupo. Los elementos estructurantes pueden tener diversas formas y estar compuestos por distintos números de píxeles. En la figura 6 se muestran algunos ejemplos de matrices estructurantes.

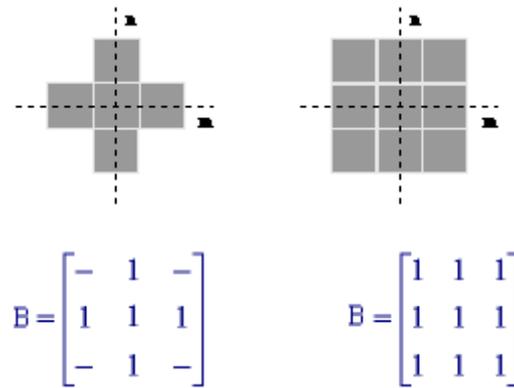


Figura 6: Ejemplos de matrices estructurantes.

En la práctica, con este operador conseguimos que las zonas oscuras de pequeño tamaño desaparezcan [51].

EROSIÓN

La operación de erosión es contraria a la dilatación. Viene definida por:

$$G(j,k) = \text{mín}[F(j,k), F(j,k+1), F(j,k-1)...] \quad (8)$$

Su funcionamiento es el contrario a la dilatación. Este operador toma el valor mínimo de los píxeles que forman el elemento estructurante. El resultado, por tanto, es una imagen más oscura, en donde los detalles claros han desaparecido y se han unido zonas oscuras antes separadas por una pequeña zona más clara (tal y como se observa en la figura 7B).

A partir de estas dos operaciones se pueden realizar otras como las de apertura (*opening* en literatura anglosajona) y cierre (*closing* en literatura anglosajona).

APERTURA

Es una combinación de operaciones morfológicas para eliminar los objetos pequeños de la imagen (o el ruido) a la vez que se preserva la forma y el tamaño de los objetos de la misma [50]. Es el resultado de erosionar para eliminar esos detalles pequeños oscuros, y más tarde dilatar para recuperar, ya sin esos detalles, los niveles de intensidad iniciales.

CIERRE

Es una combinación de operaciones morfológicas con la que, por ejemplo, se consiguen eliminar las discontinuidades en los bordes de la imagen. Es el resultado de aplicar la dilatación para eliminar los detalles de poca importancia de un nivel más claro y después la erosión para recuperar los valores de intensidad de la imagen.

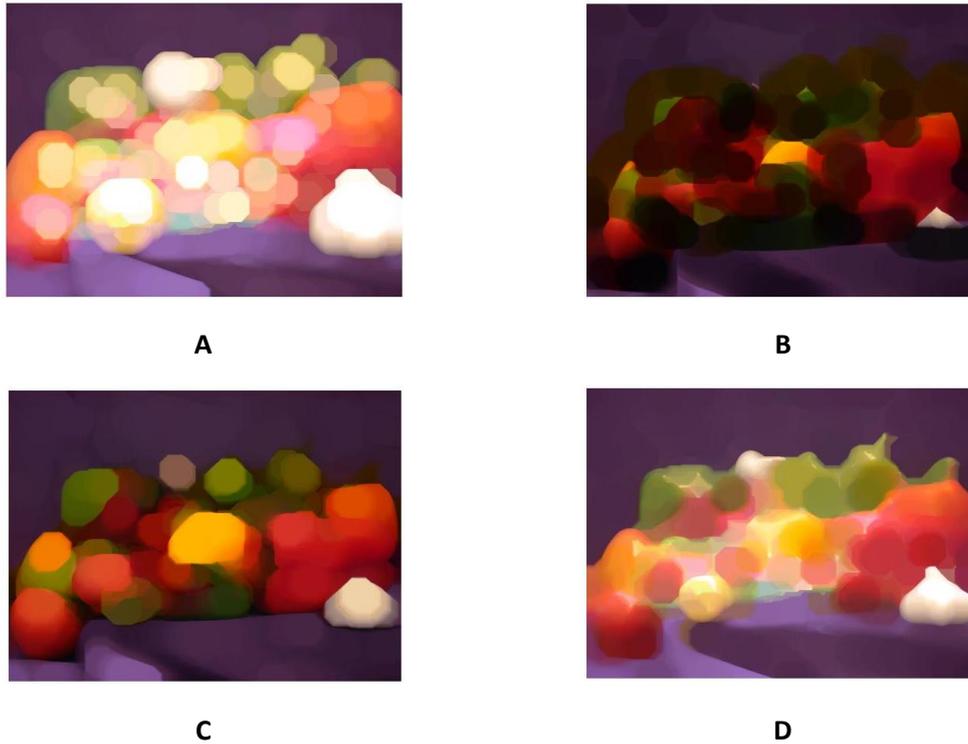


Figura 7. Aplicación de dilatación (A), erosión (b), apertura (C) y cierre (D) sobre la imagen de la figura 1A.

TOP-HAT

La transformada top-hat se entiende como la diferencia entre la imagen original y su apertura. Se define como $TH=X-(X \circ B)$. De esta forma se consigue un filtro paso alto de la imagen [50].

5. DETECCIÓN DE BORDES

Los bordes son una fuente de información muy útil para realizar segmentación, ya que delimitan los objetos, definen los límites entre ellos y el fondo, y de los objetos entre sí.

Las técnicas usadas en la detección de bordes tienen por objetivo la localización de los puntos en los que se produce una variación de la intensidad -donde se pasa del nivel de gris del fondo al objeto- empleándose para ello métodos basados en los operadores derivada. Básicamente se tienen dos posibilidades: aplicar la primera (gradiente) o la segunda derivada (laplaciana). En el primer caso se buscarán grandes picos y en el segundo, pasos de respuesta positiva a negativa o viceversa (paso por cero o zero-crossing).

En este TFG se ha utilizado el método de Canny. El algoritmo de Canny consta de tres pasos: obtención del gradiente, supresión no máxima (adelgazamiento de los bordes) e histéresis de umbral (eliminación de contornos falsos). A continuación, se explica brevemente en que consiste cada uno de ellos [51]:

1-. Para la obtención del gradiente, se realiza un filtrado gaussiano a la imagen original con el objetivo de suavizar la imagen y eliminar el posible ruido existente. Se calcula la magnitud y módulo (orientación) del gradiente para cada píxel, obteniendo dos imágenes (magnitud y módulo).

2-. Se consideran cuatro direcciones: 0° , 45° , 90° y 135° con respecto al eje horizontal. Para cada píxel se busca aquella dirección que mejor se aproxime a la dirección del ángulo de gradiente. Se observa si el valor de la magnitud de gradiente es más pequeño que al menos uno de sus dos vecinos en la dirección del ángulo obtenida anteriormente. De ser así se asigna a 0 dicho píxel, en caso contrario se asigna el valor que tenga la magnitud del gradiente.

3-. Se sigue la orientación de los puntos de borde de la imagen y se escogen dos umbrales, el primero más pequeño que el segundo. Para cada punto de la imagen se localiza el siguiente punto de borde no explorado que sea mayor al segundo umbral. A partir de dicho punto se sigue explorando por las cadenas de máximos locales conectadas, siempre que sean mayores al primer umbral. Los contornos encontrados se almacenan en una lista y son extraídos de la imagen. De esta forma, se eliminan las uniones en forma de Y de los segmentos que confluyan en un mismo punto.

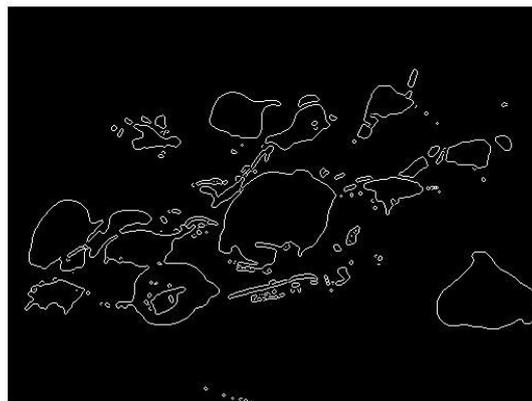


Figura 8. Detector de bordes de Canny sobre la imagen de la figura 1D.

6. FILTRADO DE LA IMAGEN

En este TFG se han utilizado filtros paso-bajo gaussianos. El filtrado paso bajo se emplea para el suavizado de imágenes y para la eliminación de ruido. En el caso que nos ocupa, el interés es el suavizado de la imagen.

Un filtro gaussiano simula una distribución gaussiana bivalente. El valor máximo aparece en el píxel central y disminuye hacia los extremos tanto más rápido cuanto menor sea el parámetro de desviación típica s . El resultado será un conjunto de valores entre 0 y 1. Para transformar la matriz a una matriz de número enteros se divide toda la matriz por el menor de los valores obtenidos. La ecuación para calcularla es:

$$g(x, y) = e^{-\frac{x^2+y^2}{2*s^2}} \quad (9)$$

$$G(x, y) = \frac{g(x, y)}{\min_{x, y}(g(x, y))} \quad (10)$$

El efecto de este filtro se muestra en la figura 9.



Figura 8. Filtro gaussiano aplicado sobre la imagen de la figura 1A.

7. ETIQUETADO

Proceso por el cual a cada objeto se le asigna una etiqueta que permite distinguir entre sí los objetos espacialmente separados. Para ello, y empezando por el píxel superior izquierdo se empieza a recorrer la imagen en dirección a la derecha. Cuando se encuentra el primer píxel que esté a nivel alto se le asocia la etiqueta. Cuando un píxel no sea vecino de uno etiquetado pero esté a nivel alto se le asocia la siguiente etiqueta, 2 y así sucesivamente. [50]

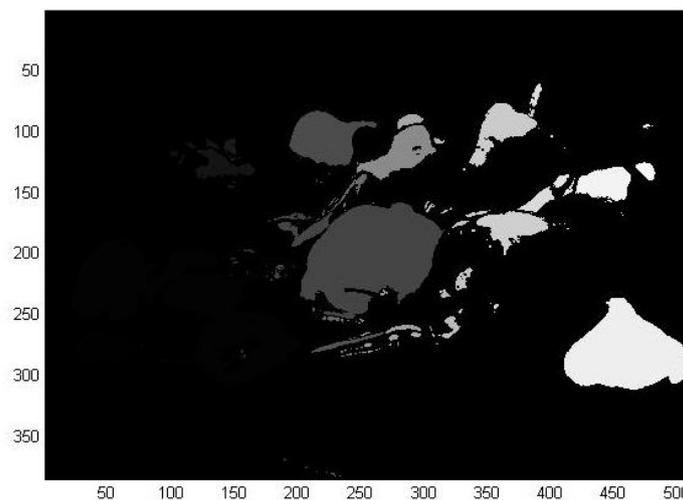


Figura 10. Etiquetado de la imagen que se muestra en la figura 1D.

8. CLASIFICADORES

K-MEANS

K-means es un algoritmo de clasificación no supervisada (*clustering*) que agrupa objetos en k grupos basándose en sus características. En el caso que nos ocupa, se agrupan los píxeles o las regiones de la imagen.

El agrupamiento se realiza minimizando la suma de distancias entre cada objeto y el centroide de su grupo o cluster mediante los siguientes pasos:

1. De entre la serie a clasificar, O_1, O_2, \dots, O_n se escogen, de forma arbitraria, tantos elementos como número de clases y se considera que constituyen los centroides (o valores prototipo de cada clase).
2. El resto de los elementos se asignan a cada clase siguiendo el criterio de mínima distancia a los centroides antes elegidos.
3. Se recalculan los centroides de cada clase. Para ello se toma la media de los valores dentro de cada clase.
4. Se vuelven a asignar, ahora todos los elementos, a cada clase con el criterio de mínima distancia.
5. Se vuelven a calcular los centroides. Si no varían se considera que el algoritmo ha terminado, si no, se vuelve a repetir el paso anterior.

Una serie de factores influyen el comportamiento del algoritmo: el número prefijado de clases, los centroides iniciales, la distribución geométrica de los valores. Por ello no es extraño que se tengan que hacer varias suposiciones hasta encontrar una que resuelva el problema. [50]

FUZZY C-MEANS

Fuzzy C-Means es la adaptación borrosa del anterior algoritmo presentado (K-means). La principal diferencia es que en el esquema borroso, los objetos a clasificar (píxeles o regiones de píxeles en nuestro caso) pueden pertenecer a más de una clase a la vez con diferentes grados de pertenencia.

SUPPORT VECTOR MACHINE (SVM)

Las máquinas de soporte vectorial, máquinas de vectores de soporte o máquinas de vector soporte (*Support Vector Machine* - SVM) son una técnica de clasificación supervisada.

Dado un conjunto de ejemplos de entrenamiento (de muestras) podemos etiquetar las clases y entrenar una SVM para construir un modelo que prediga la clase de una nueva muestra. Intuitivamente, una SVM es un modelo que representa a los puntos de muestra en el espacio, separando las clases a dos espacios lo más amplios posibles mediante un hiperplano de separación definido como el vector entre los dos puntos, de las dos clases, más cercanos al que se llama vector soporte. Cuando las nuevas muestras se ponen en correspondencia con dicho modelo, en función de los espacios a los que pertenezcan, pueden ser clasificadas a una o la otra clase.

9. GENERACIÓN DE SUPERPÍXELES

SIMPLE LINEAR ITERATIVE CLUSTERING - SLIC:

El *Simple Linear Iterative Clustering* (SLIC) es un método de segmentación basado en el uso del gradiente, donde se parte de unos centros de superpíxeles y se va aumentando el tamaño de dichos segmentos en base a similitud en color y proximidad espacial. Fue presentado por Achanta et al. en [52], y es una adaptación del método de clustering *K-means* pero donde el espacio de búsqueda para cada superpíxel se restringe a un determinado vecindario alrededor de su centro.

Formalmente el algoritmo se puede definir como el uso de la técnica *K-means* sobre un espacio compuesto por las coordenadas del píxel (x,y) y el color, llevando a cabo los siguientes pasos:

1. Los centros de los superpíxeles se inicializan en una “cuadrícula” regular, separados por una distancia de S píxeles.

$$S = \sqrt{\frac{N}{k}} \quad (11)$$

donde N es el número de píxeles de la imagen, y k el parámetro principal del método que controla el número de regiones deseadas.

2. Posteriormente los centros son movidos a la localización con menor gradiente en un vecindario de 3×3 . Esto se realiza para evitar situar el centro en un borde, y para disminuir el impacto que pudiera tener algún píxel con ruido.
3. A continuación, cada píxel X_i es asignado al centro de región más cercano, teniendo en cuenta únicamente los centros cuya área de búsqueda incluyen al píxel X_i analizado. Al no considerar todos los posibles centros, se aumenta la velocidad de ejecución del algoritmo frente al enfoque clásico de *K-means*. Esta medida de distancia se define de la siguiente manera:

$$D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2} m^2 \quad (12)$$

siendo d_c y d_s las funciones de normalización de color y de proximidad espacial, que se definen de la siguiente manera:

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \quad (13)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (14)$$

y m el segundo parámetro del método, el cual permite controlar la importancia de la similitud tanto de color como espacial. Si m tiene un valor alto, la proximidad espacial es más importante y por lo tanto se obtendrán píxeles más

regulares. Por el contrario, si m es un valor bajo, los superpíxeles reflejarán mejor los bordes de la imagen, pero tendrán una forma más irregular.

4. Cuando se ha terminado de asociar todos los píxeles al centro más cercano, se actualiza el valor del centro para ser la media de todos los píxeles que pertenecen al mismo clúster.
5. Entonces se calcula una variable de error que representa la diferencia de localización entre el centro anterior y el nuevo, y se repite el proceso hasta que el error converge.
6. Finalmente se ejecuta un post procesamiento para asegurar continuidad entre regiones, donde aquellos píxeles que han quedado aislados se asignan al superpíxel más cercano.

10. TRANSFORMADA WATERSHED

Esta técnica está inspirada en la geografía, de manera que consideramos una imagen en escala de grises como un relieve topográfico, donde los valores mínimos (los más cercanos al negro) son los valles de dicho relieve, y los valores máximos (blancos) son las crestas; y suponemos que en los puntos más bajos del relieve se introduce agua, que iría subiendo llenando cada valle. En los puntos en los que coincidan aguas de diferentes fuentes se crean muros (*watershed*). Así se obtendrían las regiones de la imagen.

El resultado final que se busca en la aplicación de la watershed (y en cualquier método de segmentación) es generar una imagen dividida en regiones de interés, donde cada una de ellas tenga su correspondiente identificador / etiqueta. Para facilitar esta tarea, se suele aplicar watershed sobre el gradiente de la imagen original ya que de por sí proporciona una serie de barreras que ayudan en el proceso de watershed a encontrar una buena segmentación.

La definición formal de la transformada es la siguiente:

Sean M_1, M_2, \dots, M_R los conjuntos de coordenadas de los mínimos de una imagen $g(x, y)$, y $C(M_i)$ las coordenadas de los puntos en la cuenca de atracción asociada al mínimo M_i (este conjunto de puntos formaría lo que se denomina un *componente*). Entonces, $T[n]$ se define como el conjunto de coordenadas (s, t) para los que $g(s, t) < n$:

$$T[n] = \{(s, t) \mid g(s, t) < n\} \quad (15)$$

De forma geométrica, $T[n]$ sería el conjunto de coordenadas de los puntos en $g(x, y)$ que quedan bajo el plano $g(x, y) = n$.

El proceso de watershed se desarrolla en los siguientes pasos [55]:

1. Encontrar los píxeles con el valor mínimo y máximo de $g(x, y)$, que se denotarán como *min* y *max*. El relieve se iría inundando en incrementos de enteros desde $n = \text{min} + 1$ hasta $n = \text{max} + 1$. En cada paso n del proceso

de inundación, se calcula el número de puntos que han quedado bajo el nivel de inundación.

Suponiendo que las coordenadas en $T[n]$ bajo el plano $g(x, y) = n$ se marcan en negro, y el resto en blanco, en cualquier incremento n del proceso de inundación, se obtendría una imagen binaria donde los puntos negros corresponden a aquellos bajo el plano $g(x, y) = n$. Esta explicación resulta útil para entender el resto del proceso.

2. Calcular $C_n(M_i)$, el conjunto de coordenadas de los puntos en la cuenca de atracción asociada al mínimo M_i según la inundación dada en el paso n , con la siguiente operación:

$$C_n(M_i) = C(M_i) \cap T[n] \quad (16)$$

El resultado de este cálculo es una imagen binaria, según se ha explicado anteriormente. Es decir, si $(x, y) \in C(M_i)$ y $(x, y) \in T[n]$, $C_n(M_i) = 1$ en la localización (x, y) ; de lo contrario $C_n(M_i) = 0$.

3. $C[n]$ representa la unión de la parte inundada de las cuencas de atracción en el paso n :

$$C[n] = \bigcup_{i=1}^R C_n(M_i) \quad (17)$$

Para calcular $C[n]$ desde $C[n - 1]$, se define Q como un conjunto de componentes conectados en $T[n]$. Para cada uno de esos componentes $q \in Q[n]$ hay 3 posibles opciones:

- a. $q \cap C[n - 1]$ es vacío, lo cual significa que es un nuevo mínimo, por lo que se añade a $C[n - 1]$ para formar $C[n]$
 - b. $q \cap C[n - 1]$ contiene un componente conectado de $C[n - 1]$, lo que representaría que q cae dentro de alguna cuenca de atracción de algún mínimo. Por tanto, q se añade a $C[n - 1]$ para formar $C[n]$
 - c. $q \cap C[n - 1]$ contiene más de un componente conectado de $C[n - 1]$, significaría que representa un muro, o parte de él, separando dos cuencas de atracción, por lo que se debe crear ese muro / borde.
4. Construir $C[n]$ de acuerdo a las condiciones anteriores. Incrementar $n = n + 1$
 5. Repetir los pasos 3 y 4 hasta alcanzar el máximo $max + 1$.

Sin embargo, la aplicación directa de la transformada watershed sobre el gradiente suele dar lugar a la sobresegmentación. Para salvar este problema, lo más común es el empleo de marcadores (*markers*), que pueden ser combinado con otras técnicas, como filtrados previos. Este enfoque se basa en establecer unos markers en determinadas localizaciones y limitar los mínimos de la técnica watershed únicamente en ellos, controlando así el número de regiones generadas y la localización de las mismas.

Normalmente se definen dos tipos de markers [55]: internos, los cuales corresponderían a objetos de interés; y externos, que representan el fondo.

11. TÉCNICAS DE CONTORNOS ACTIVOS

Las técnicas denominadas *contornos activos* fueron introducidas por [53]. Este tipo de técnicas trata de abordar el problema de localización de bordes, líneas y contornos subjetivos, así como el seguimiento de dichos contornos durante el movimiento. Es un método variacional que busca contornos en la imagen, cuya filosofía se puede considerar novedosa con respecto a los métodos clásicos de detección de bordes.

En su definición, un *contorno activo* representa el contorno de un objeto mediante una curva parametrizada que se puede deformar a partir de una forma inicial hasta un contorno final. El problema de encontrar el contorno final es equivalente a un problema de minimización de energía. De manera que el contorno buscará minimizar siempre dicho funcional de energía, comportándose de forma dinámica. Se le conoce coloquialmente como *snake* por la manera en la que se desliza el contorno a medida que busca minimizar su funcional energético (ver figura 11). Dicho funcional de energía puede definirse por diferentes propiedades según el modelo de *contorno activo* escogido, aunque originalmente se basa en propiedades características de la imagen.

Como se comentó anteriormente, la *snake* se representa como una curva paramétrica. Lo más común sería representarla según una expresión tal que $r(s) = (x(s), y(s))$, con $s \in (0,1)$ siendo s el parámetro espacial de la *snake*. Y aunque existen diversas alternativas para representar su funcional de energía, dependiendo del número de fuerzas que se decidan incluir, generalmente se expresa como muestra la ecuación 18.

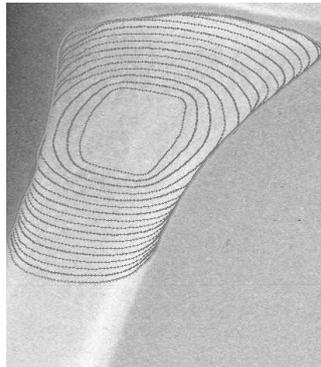


Figura11. Evolución de una *snake* hasta encontrar el contorno del hueso de una radiografía. Imagen extraída de [54].

$$E_{snake}^*(r) = \int_0^1 E_{int}(r(s))ds + \int_0^1 E_{img}(r(s))ds + \int_0^1 E_{res}(r(s))ds \quad (18)$$

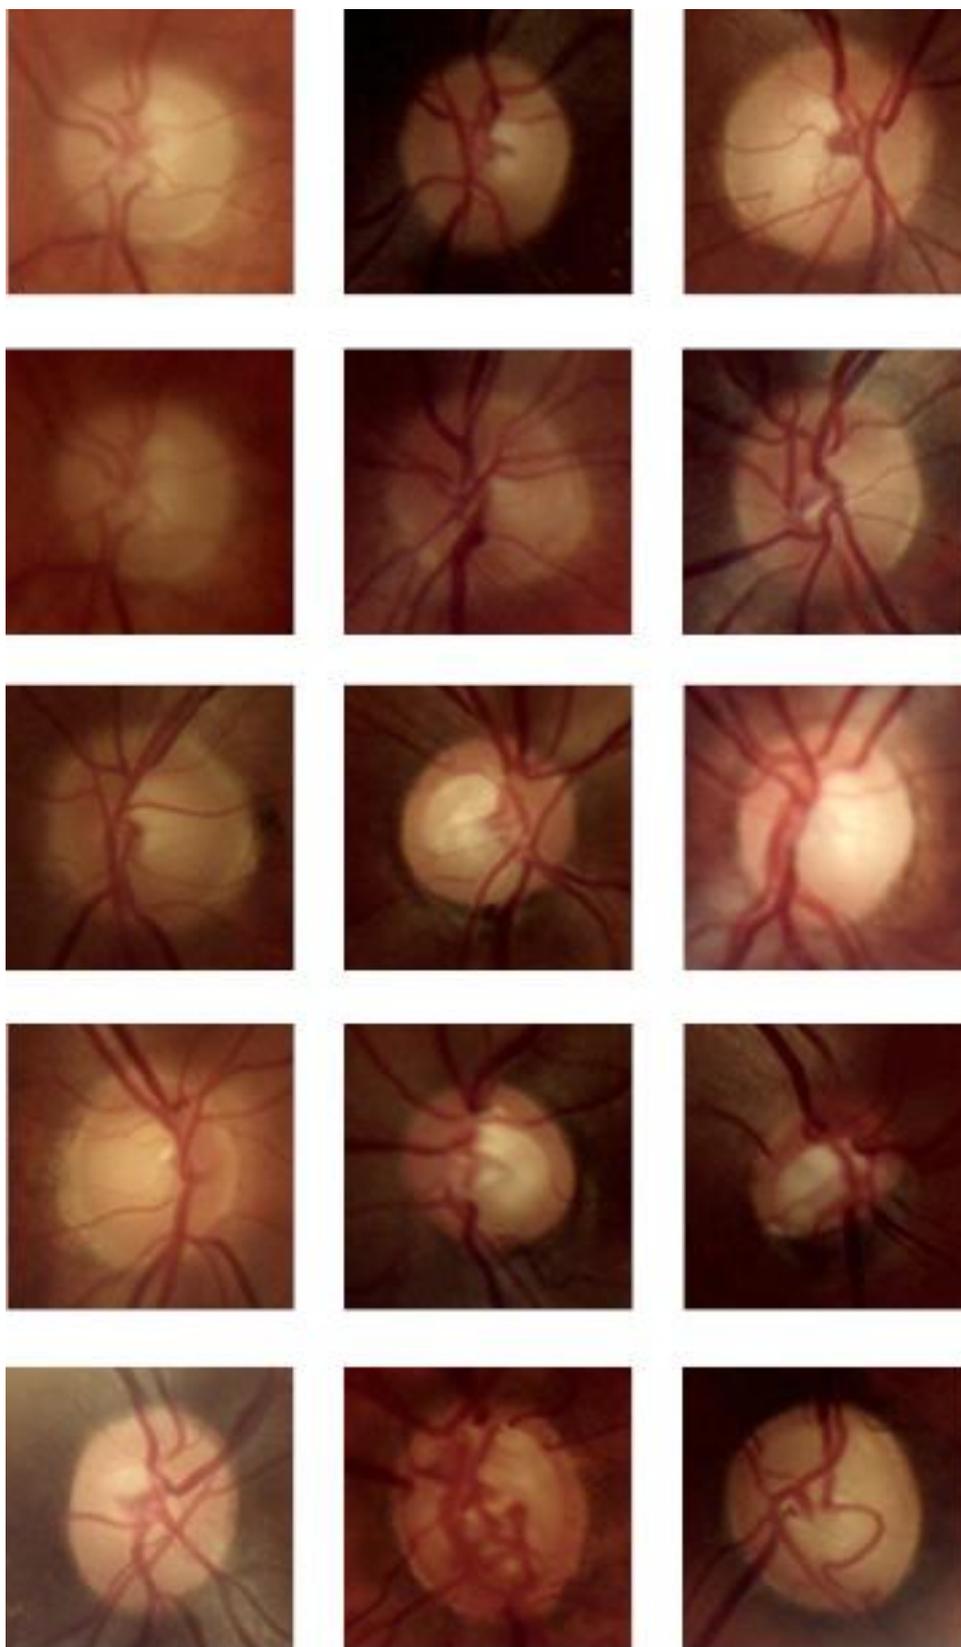
donde E_{int} representa el conjunto de energías internas de la *snake*, E_{img} las fuerzas de la imagen y E_{res} las fuerzas restrictivas externas. La tendencia de una *snake* a minimizar su índice de energía provoca el equilibrio de fuerzas que la afectan, de manera que la *snake* evoluciona procurando que $E_{int} + E_{img} + E_{res} = 0$ [51].

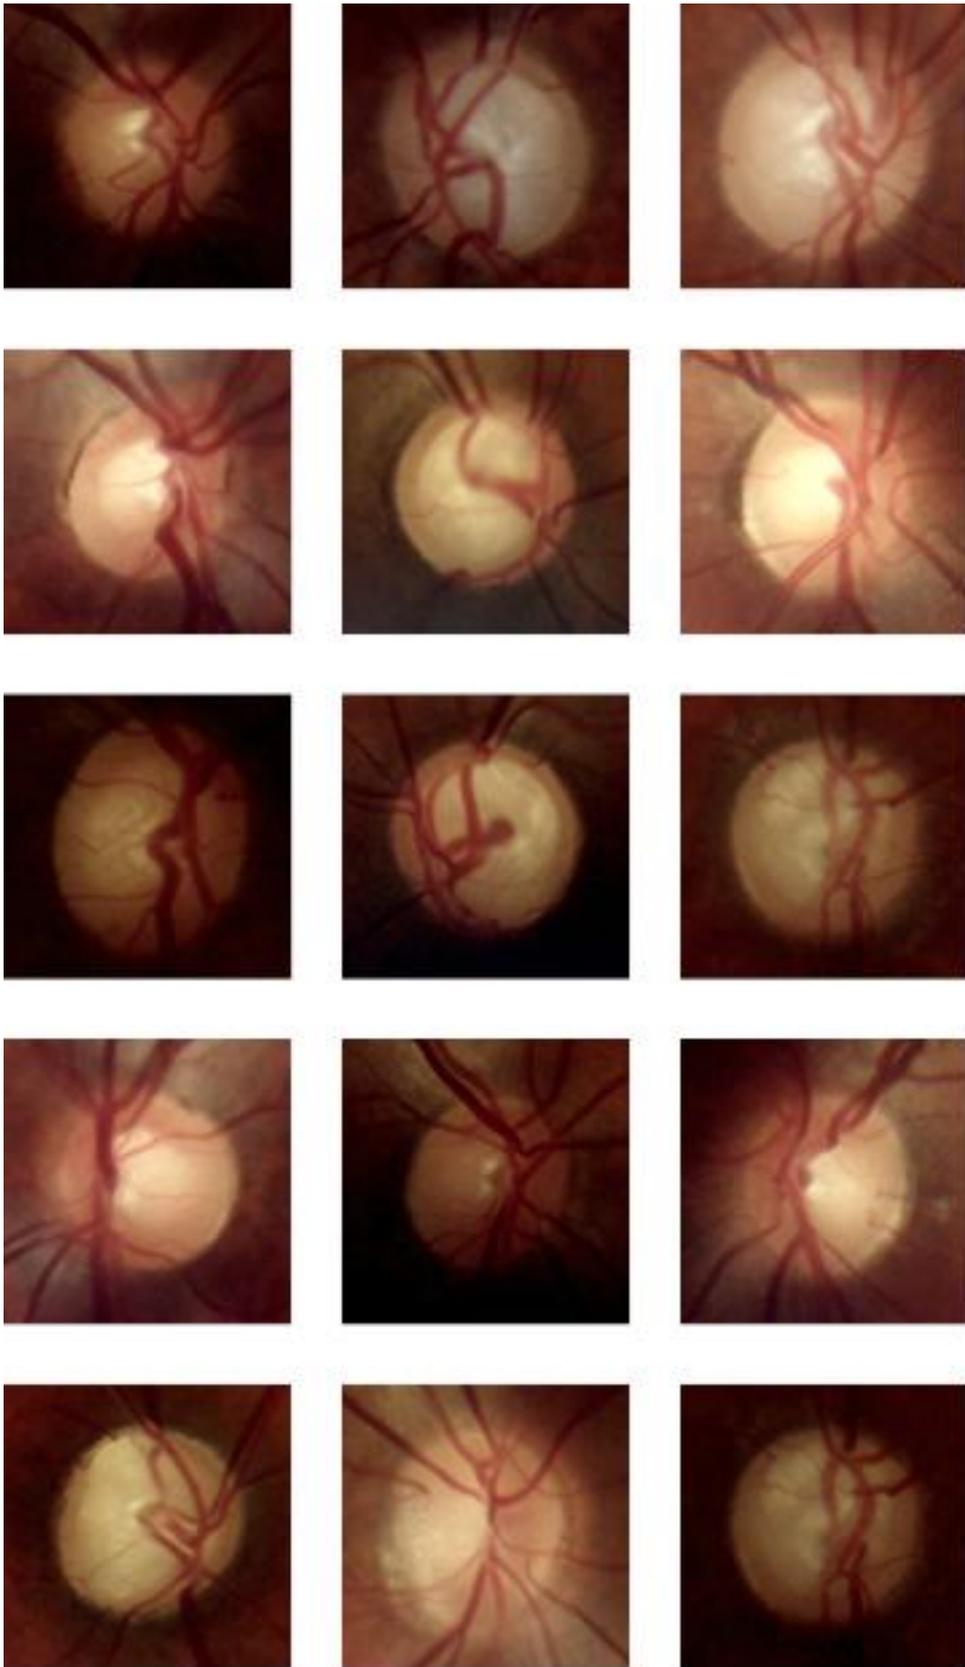
El principal problema de la aplicación automática de estas técnicas es el alto número de parámetros que hay que ajustar a priori y la alta dependencia de los resultados finales del contorno inicial escogido para la evolución de la *snake*.

ANEXO II IMÁGENES UTILIZADAS EN ESTE TRABAJO FIN DE GRADO (HORUS Y COMPASS)

1. IMÁGENES DE PRUEBA SELECCIONADAS

RETINOGRAFÍAS HORUS





RETINOGRAFÍAS COMPASS



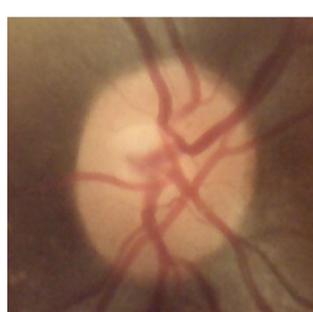
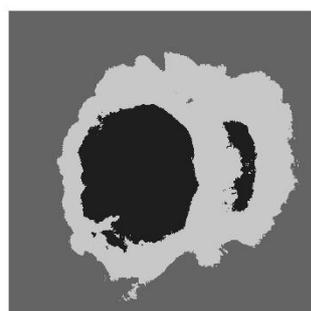
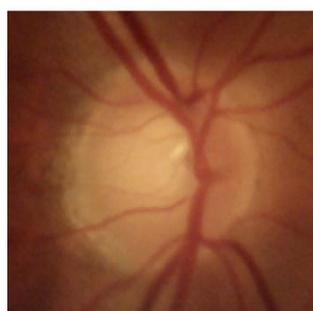
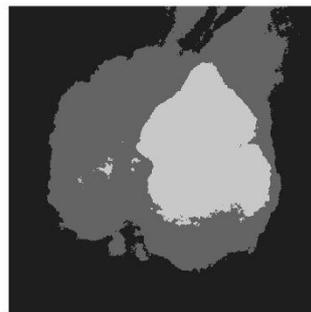
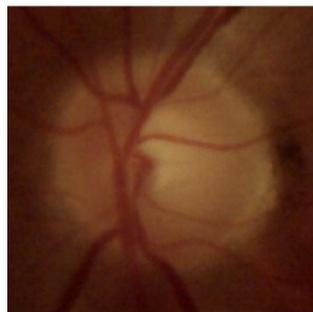
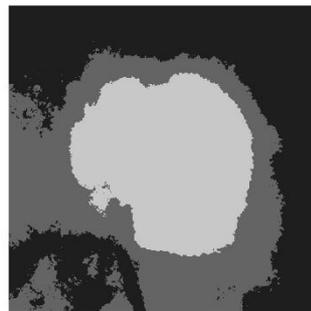
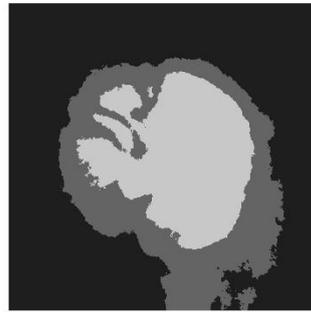
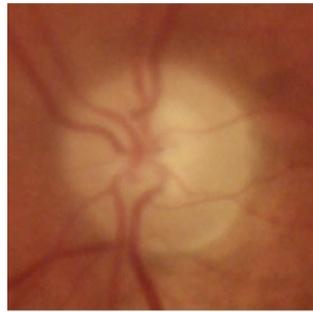
ANEXO III RESULTADOS EXPERIMENTALES DE LOS MÉTODOS REPLICADOS EN ESTE TFG SOBRE LAS IMÁGENES HORUS Y COMPASS

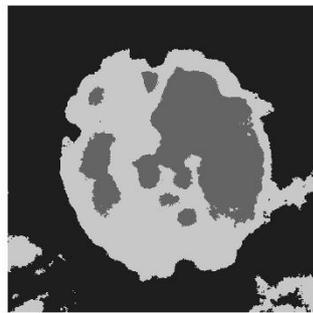
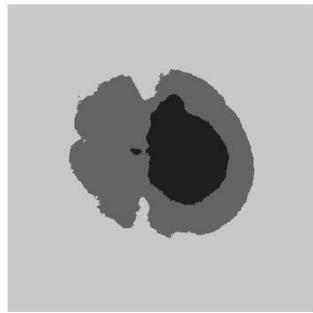
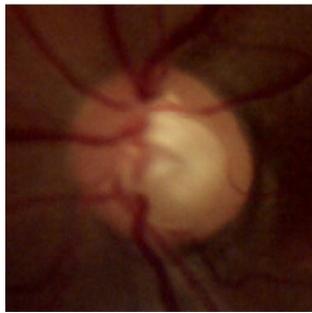
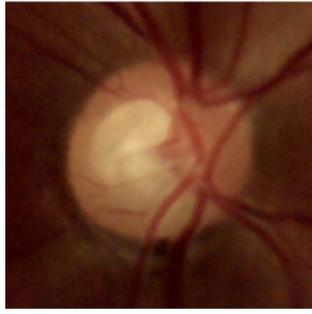
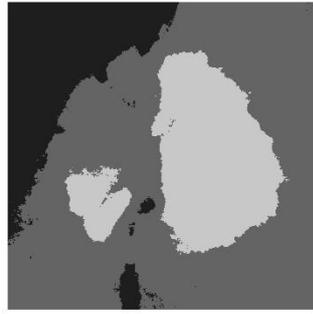
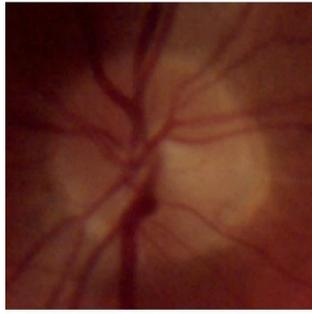
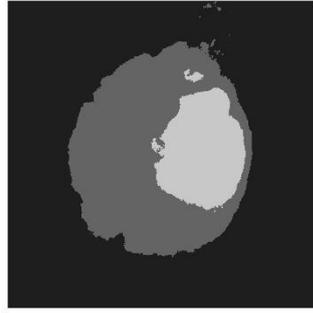
1. RESULTADOS DE [10]

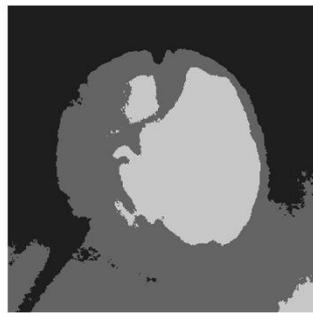
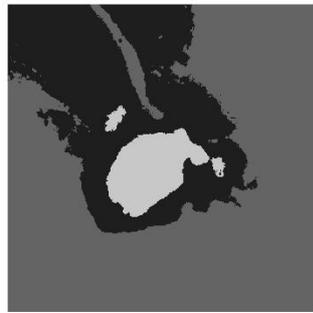
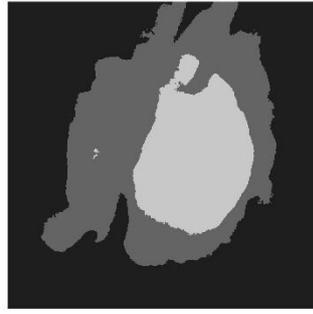
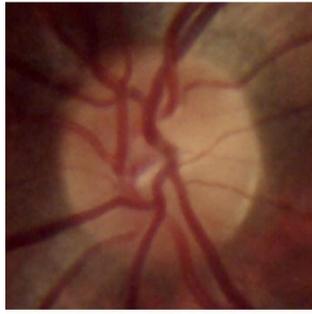
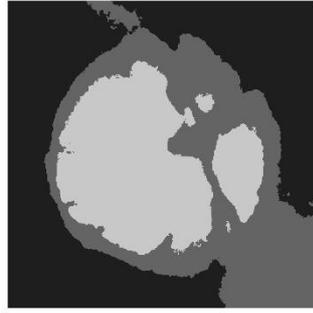
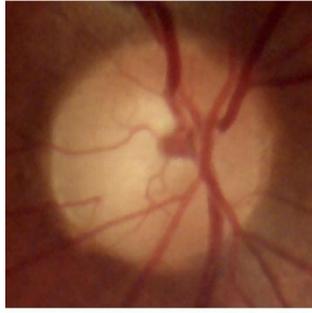
1.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS

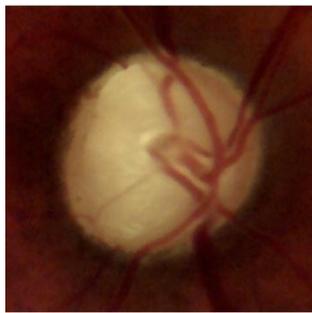
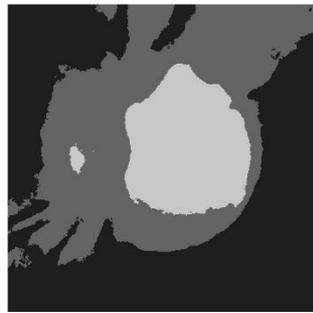
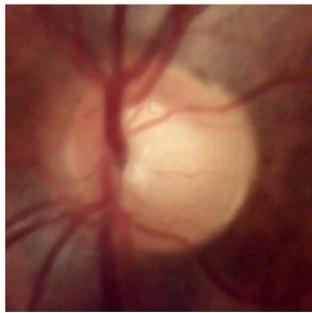
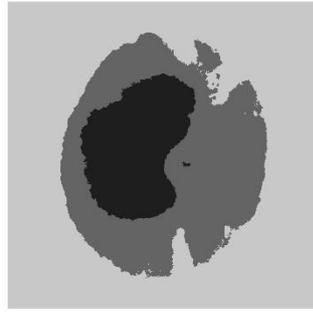
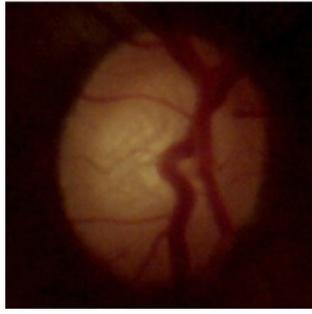
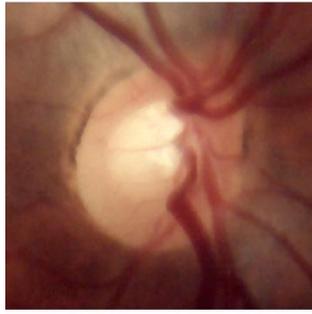
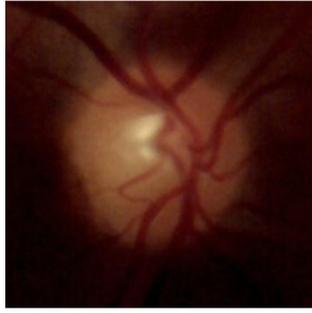
Imagen original

Imagen segmentada





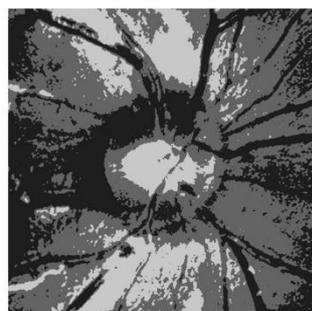
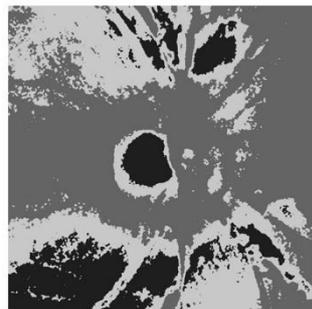
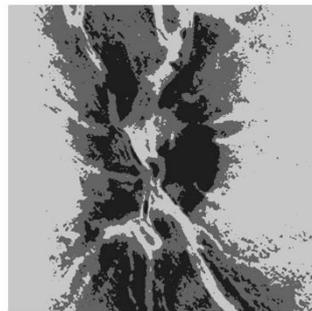
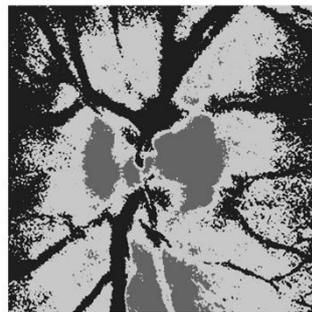
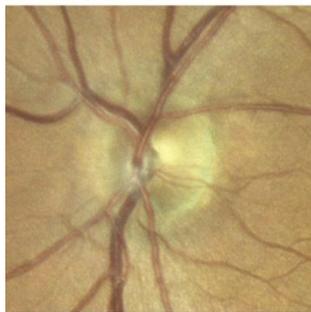
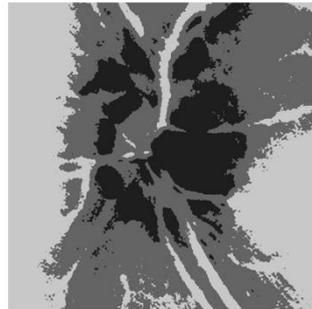
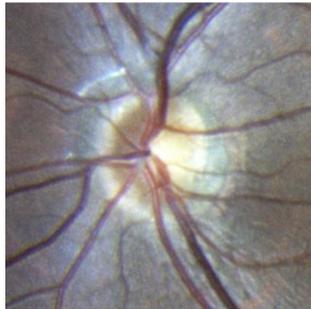


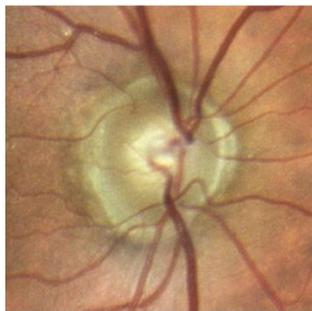
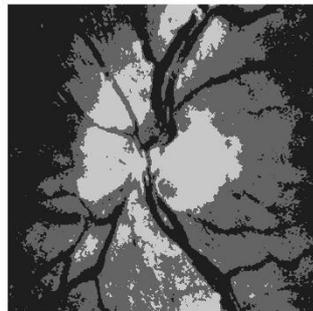
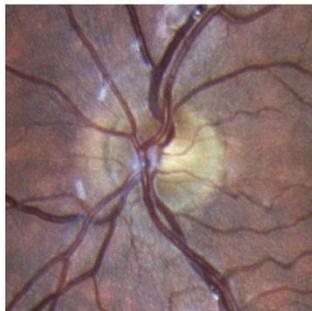
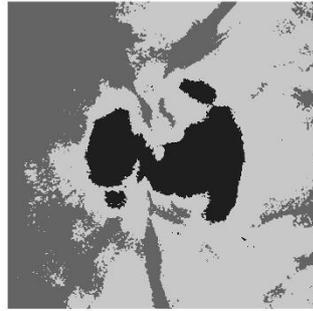
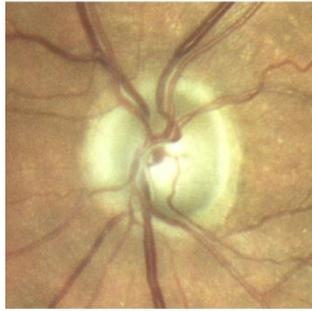
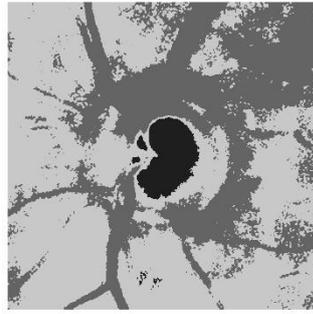
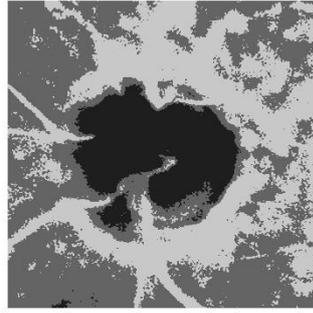
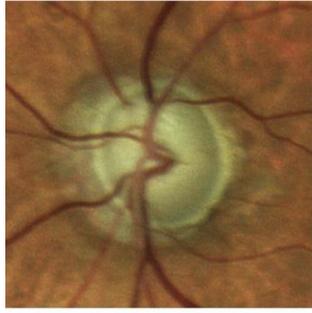


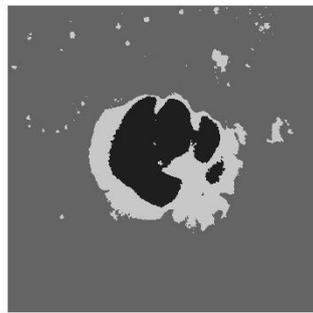
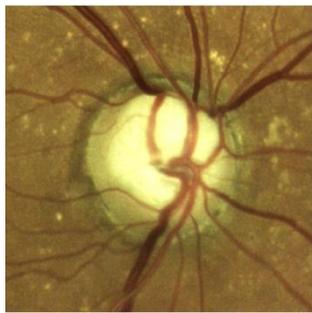
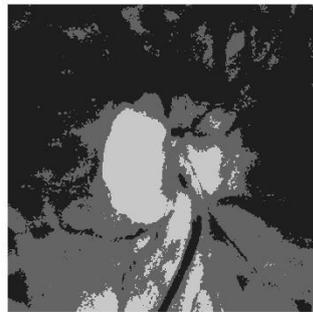
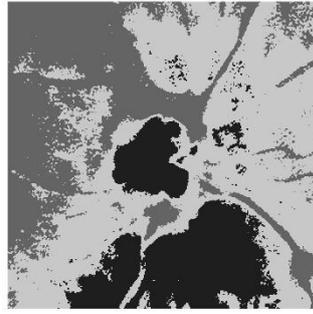
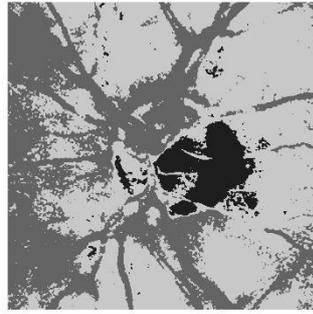
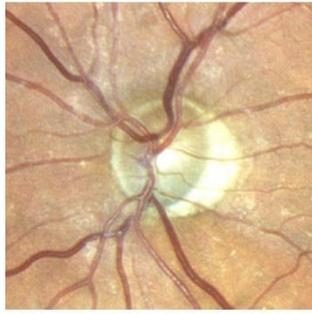
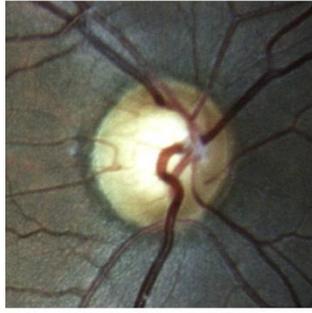
1.2. SOBRE LA BASE DE RETINOGRAFÍAS COMPAS

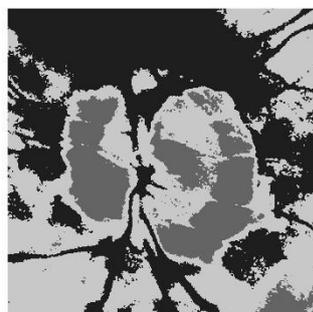
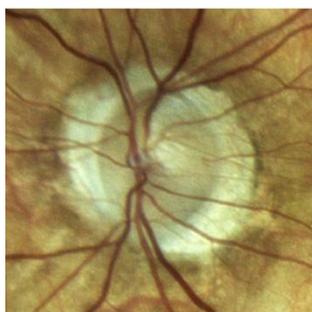
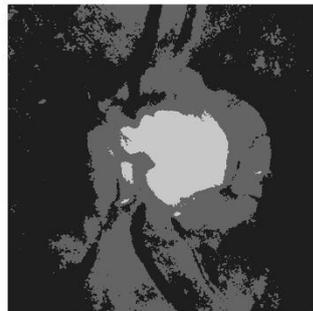
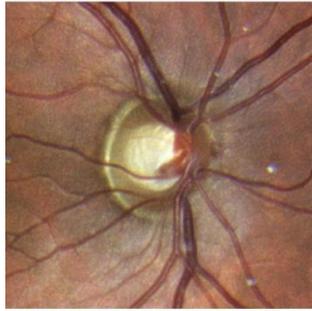
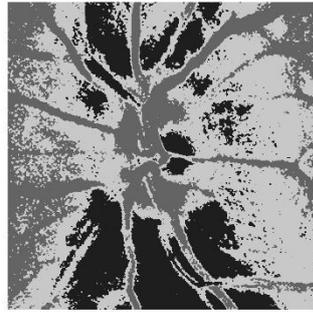
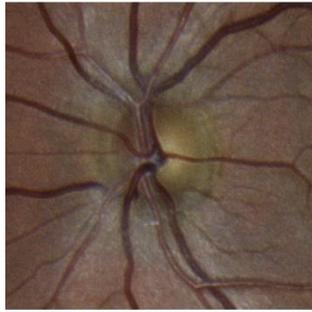
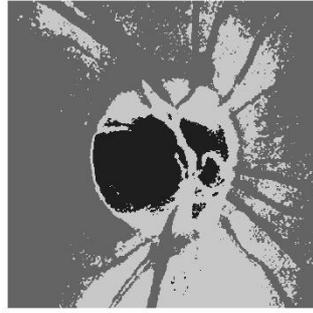
Imagen original

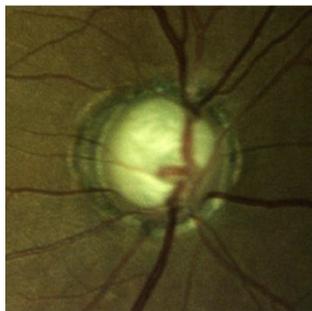
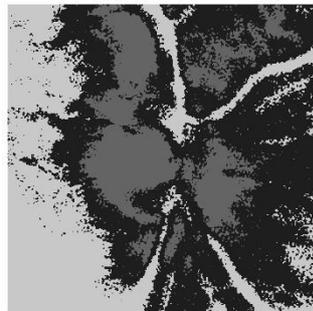
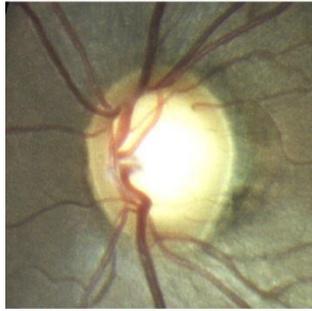
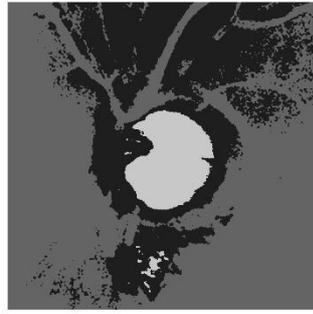
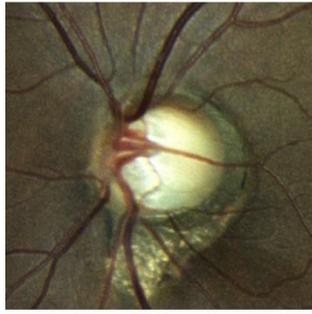
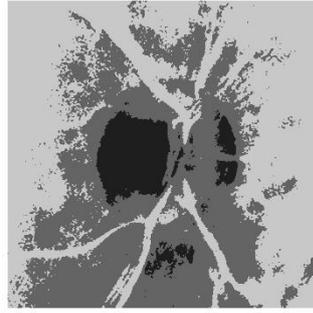
Imagen segmentada

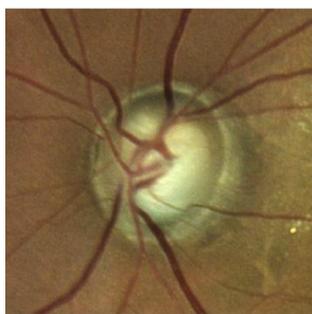
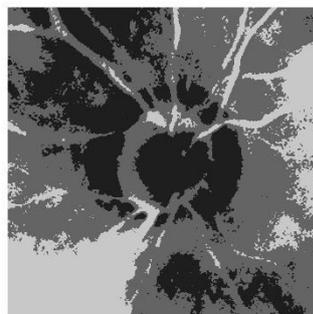
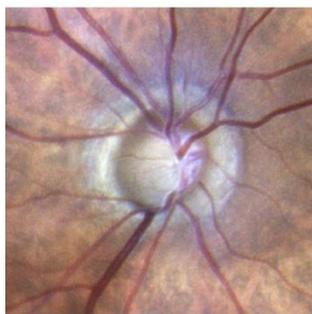
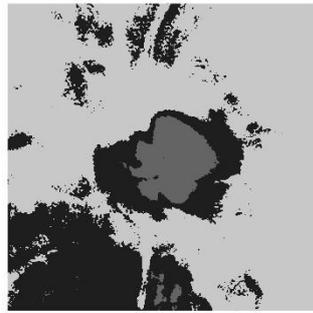
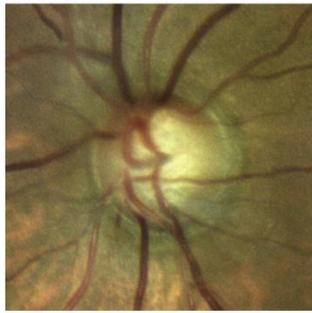
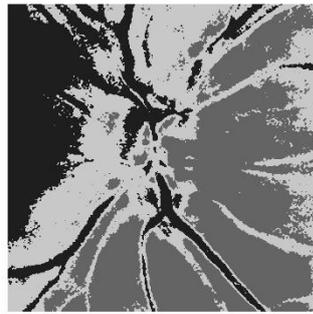
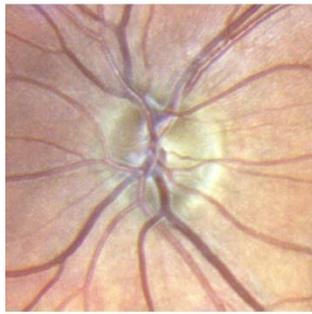






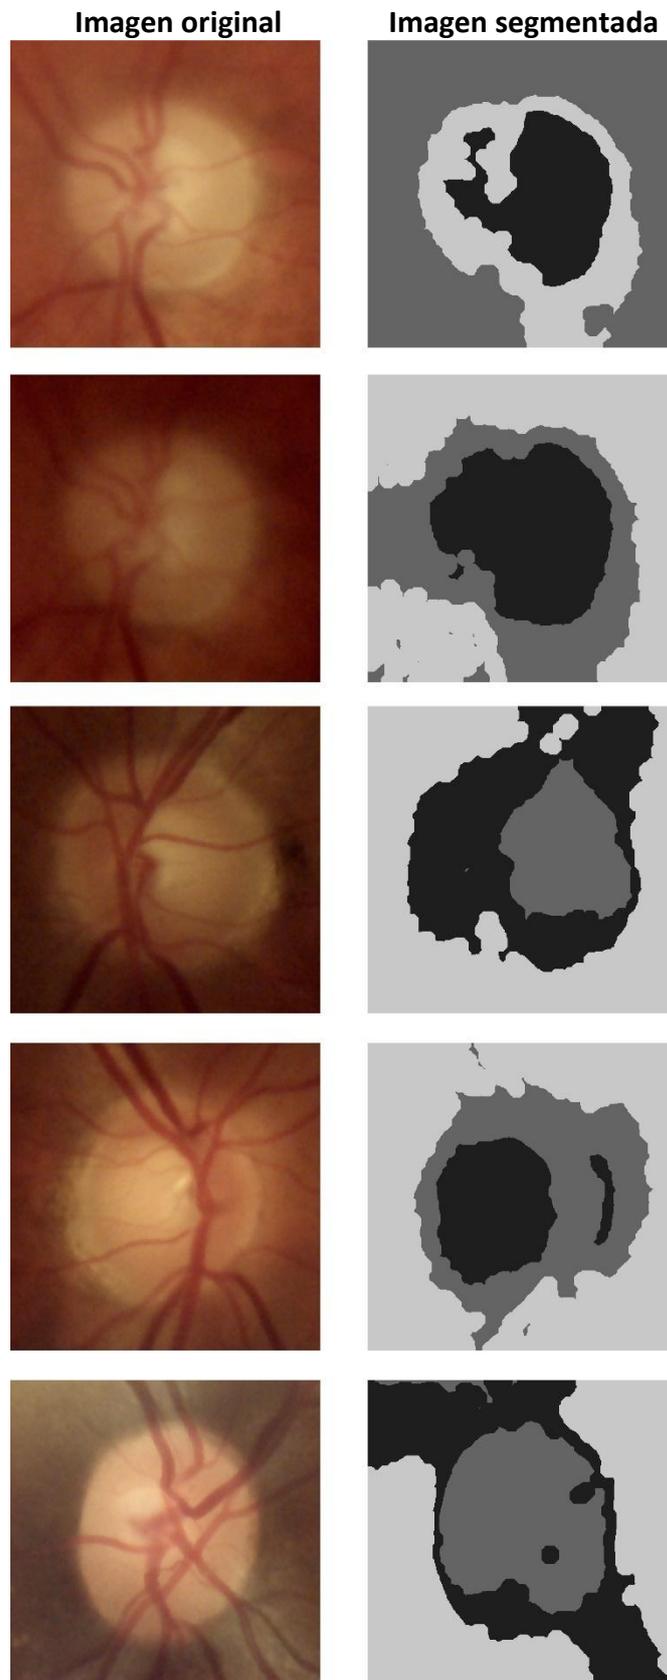


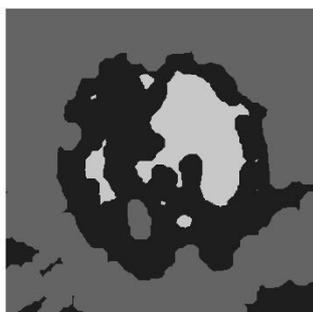
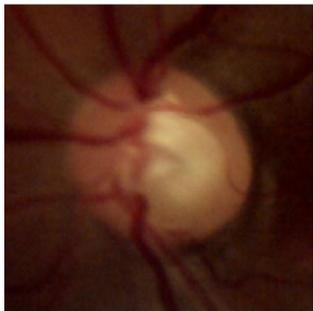
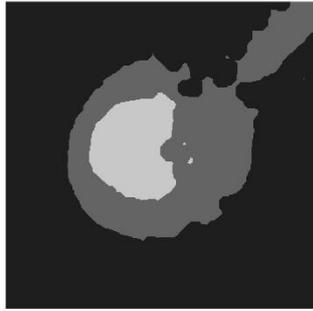
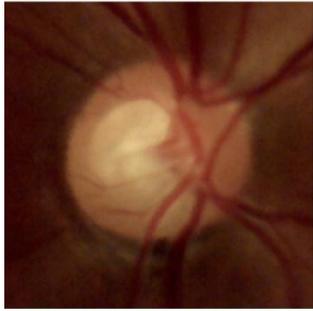
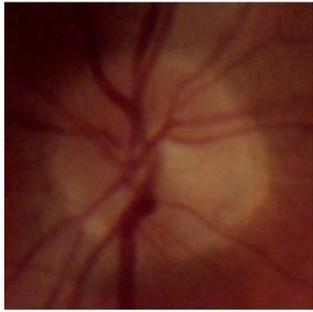


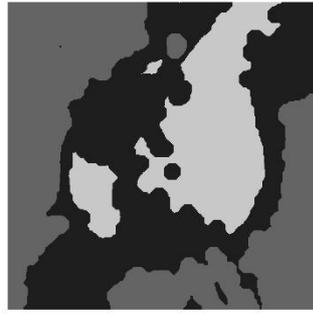
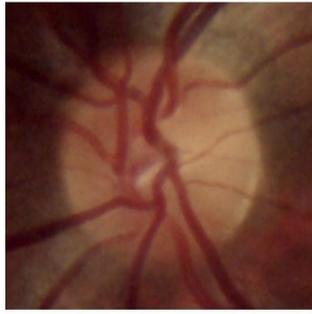
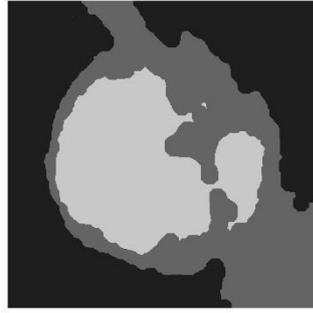
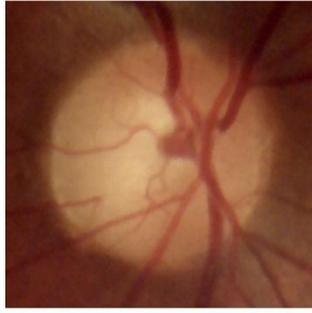


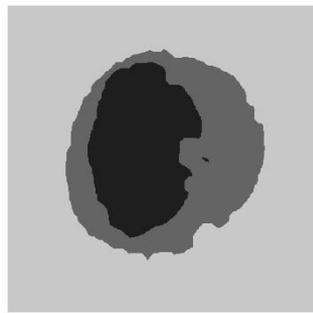
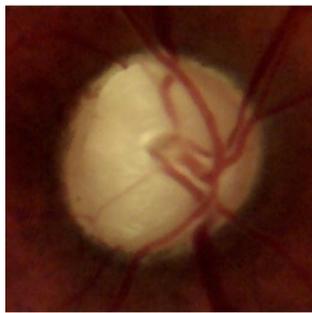
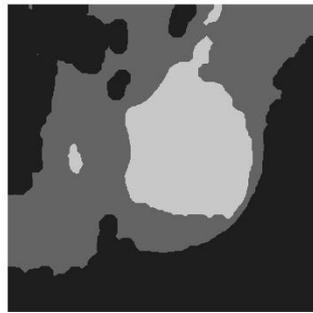
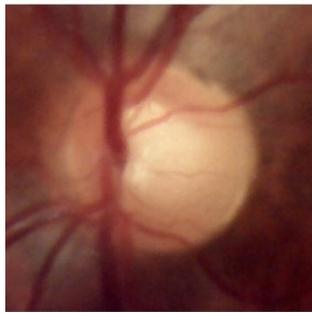
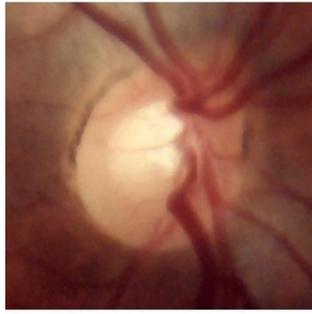
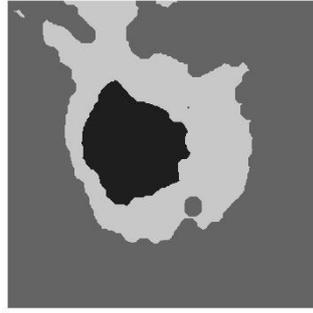
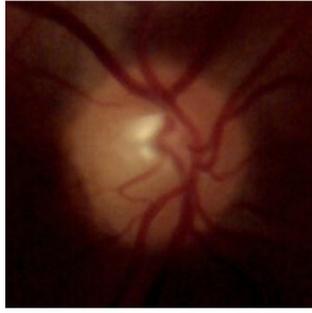
2. RESULTADOS DE [13]

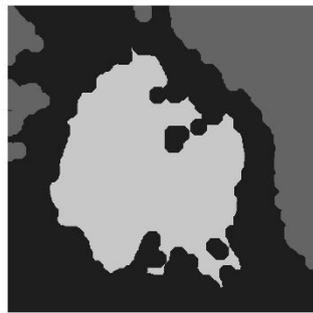
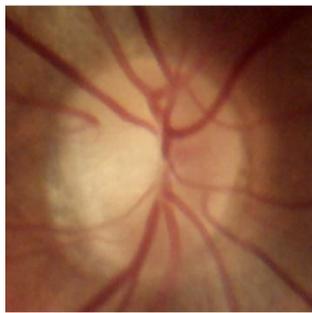
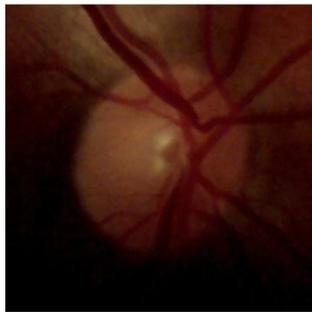
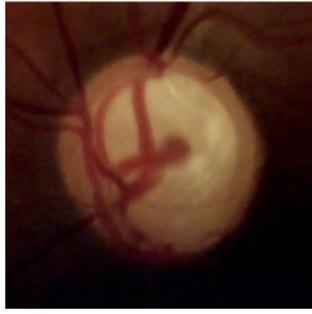
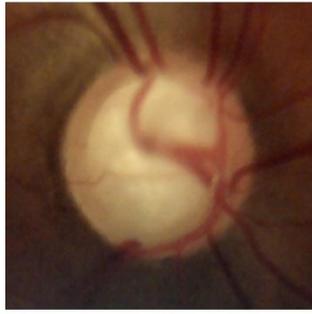
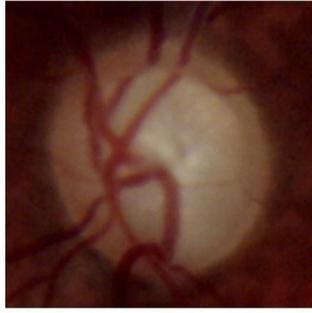
2.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS

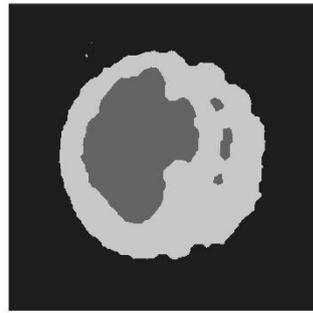
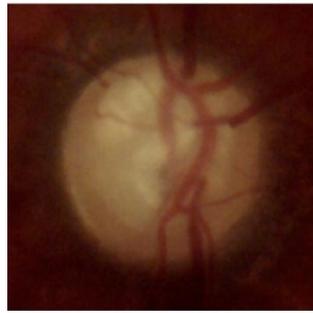
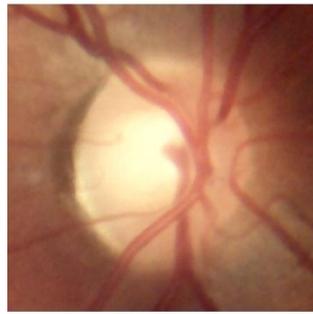
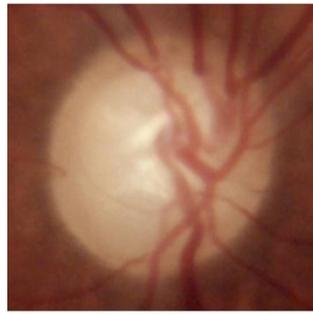












2.2. SOBRE LA BASE DE RETINOGRAFÍAS COMPAS

Imagen original

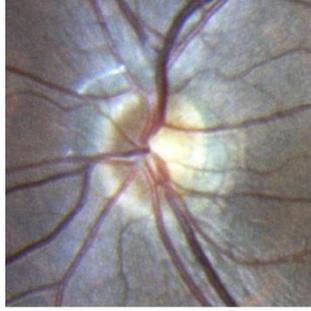
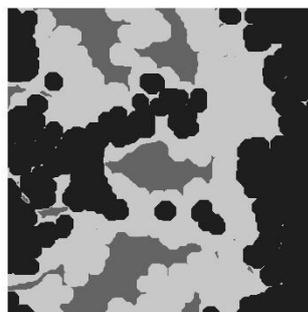
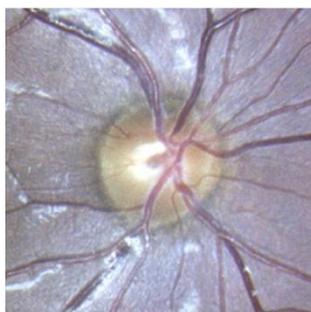
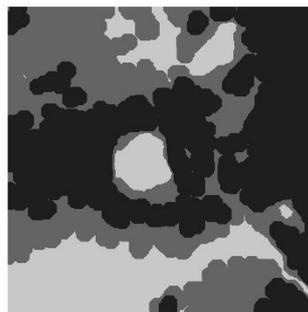
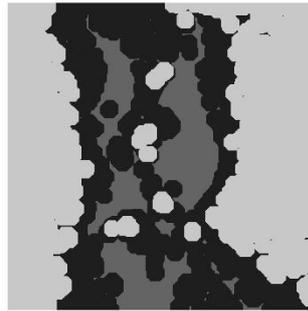
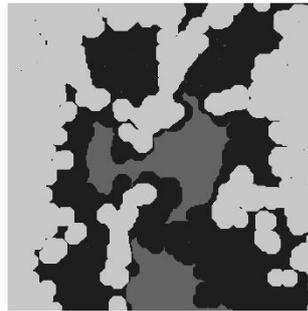
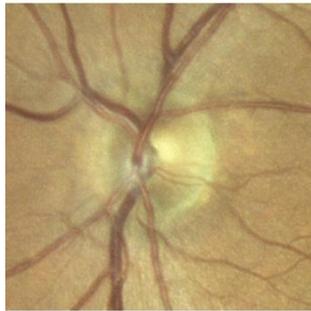
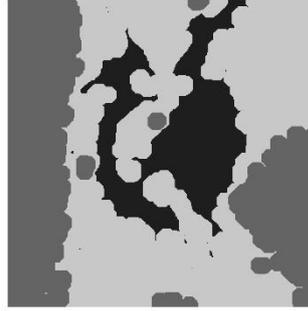
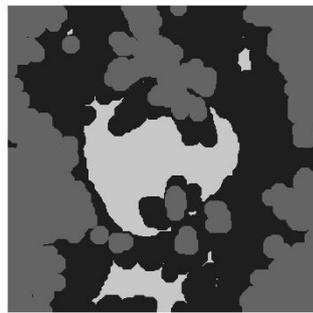
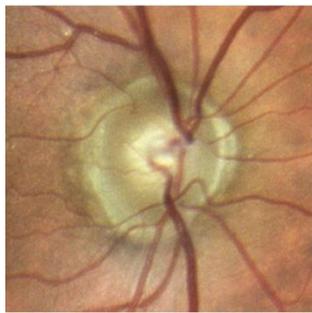
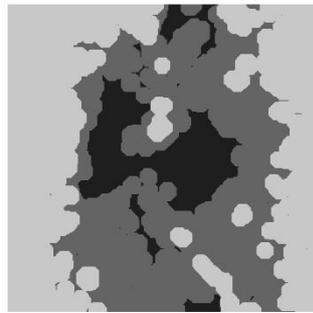
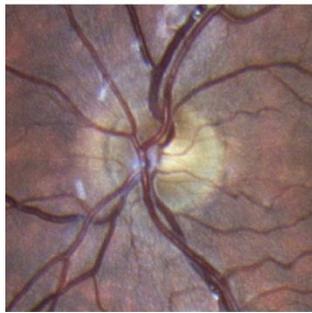
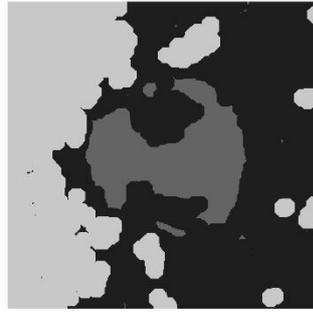
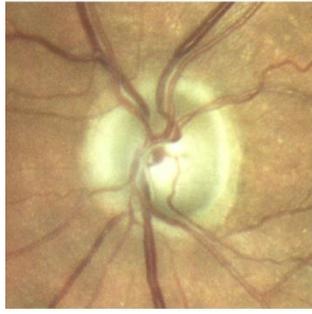
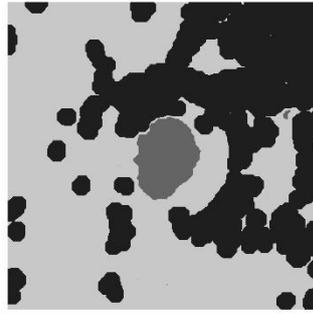
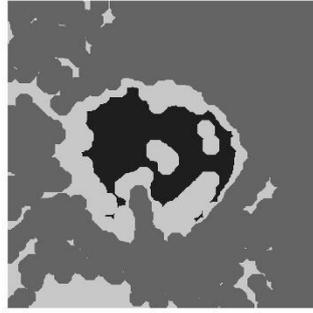
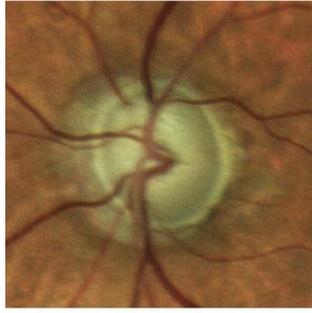
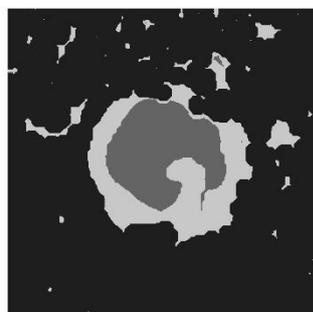
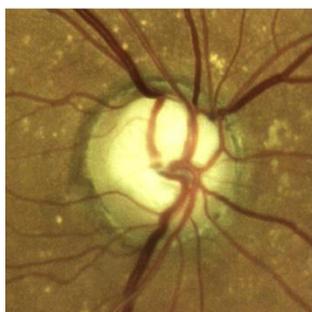
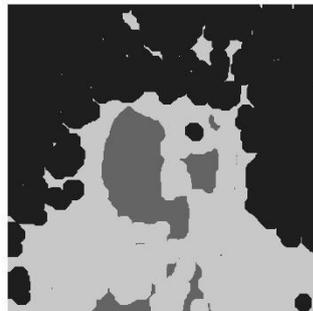
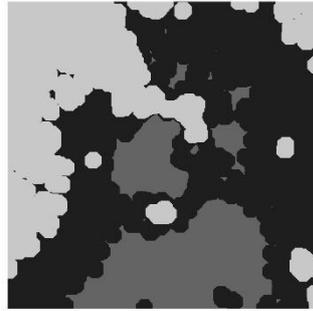
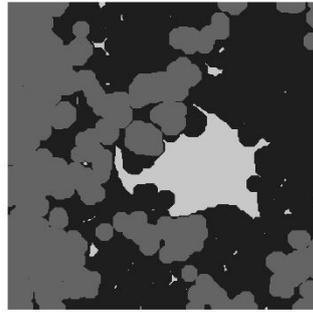
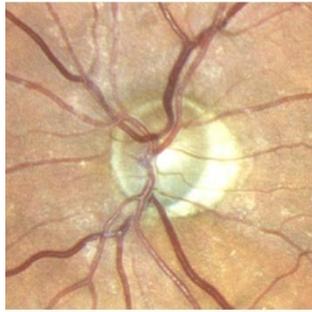
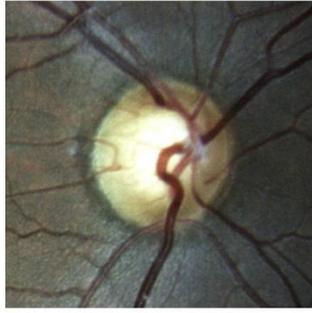
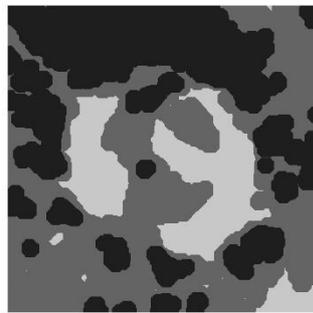
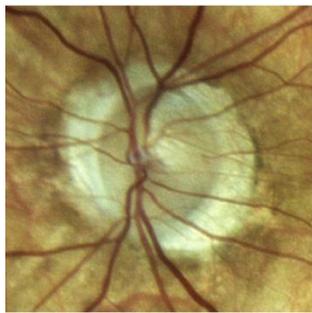
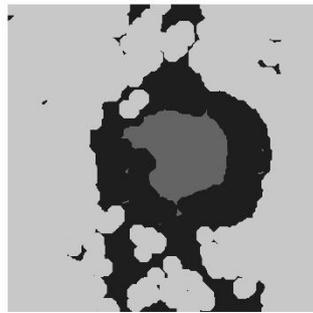
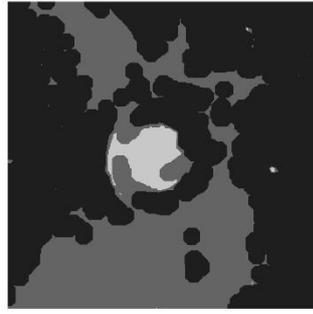
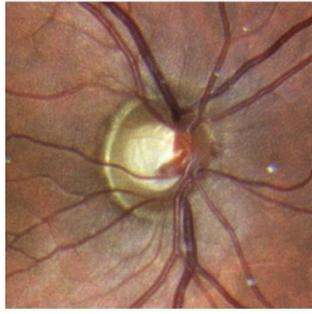
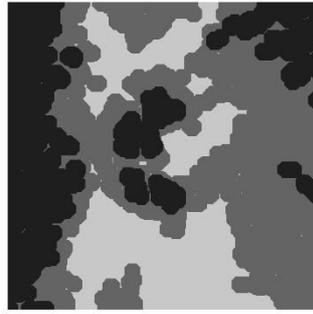
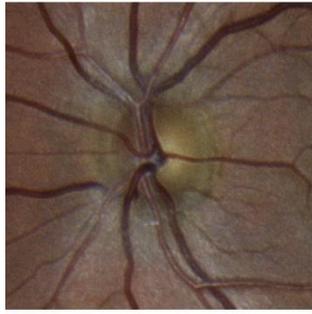
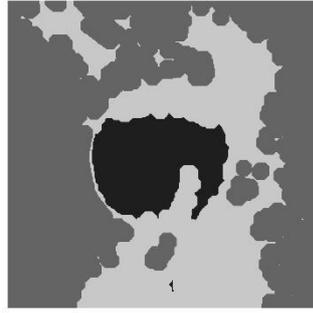


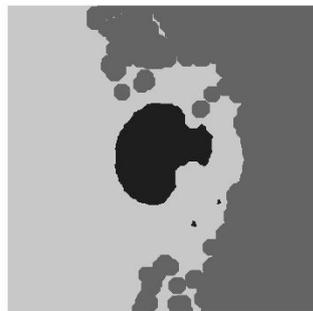
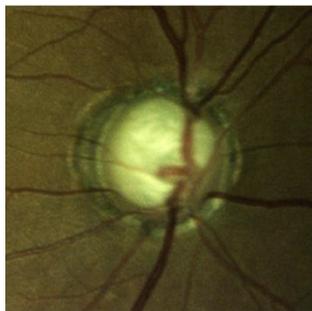
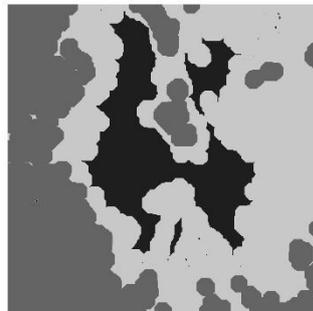
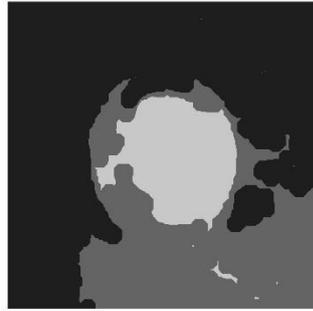
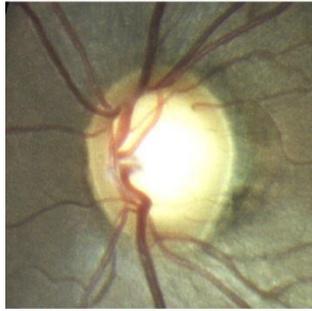
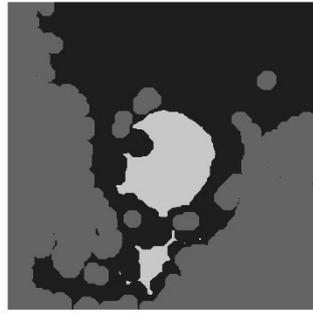
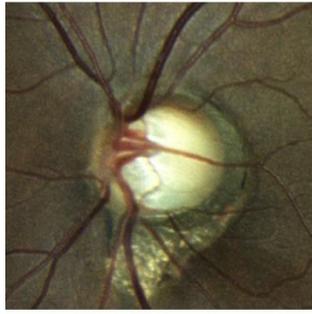
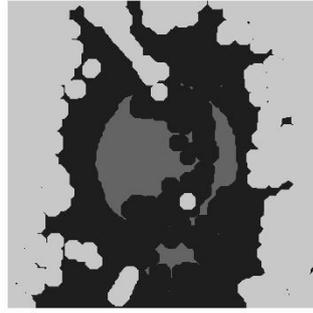
Imagen segmentada

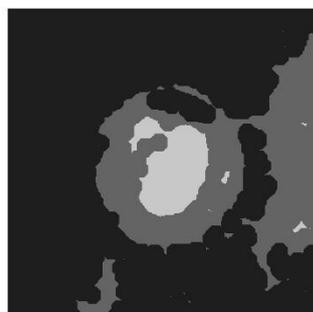
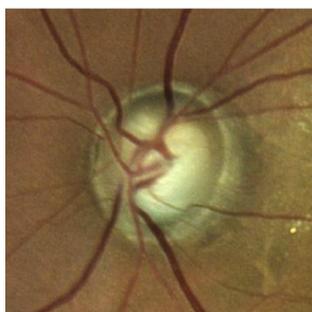
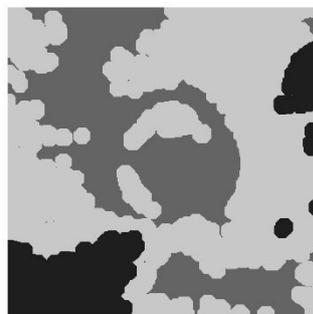
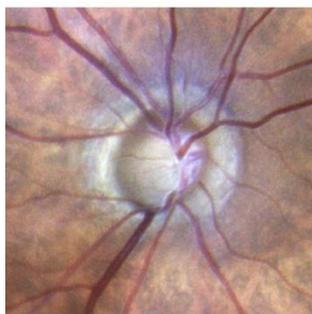
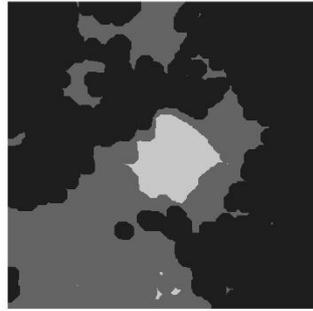
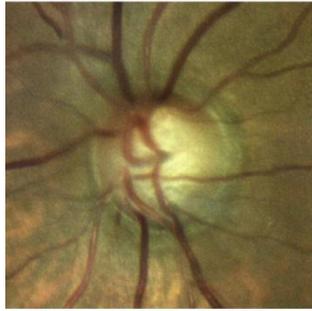
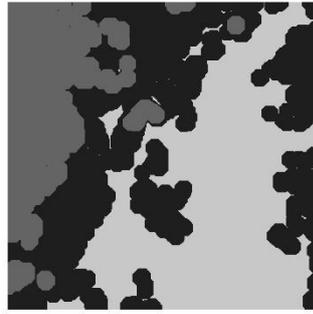
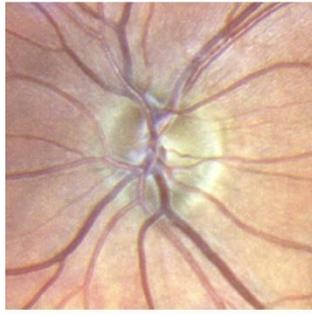
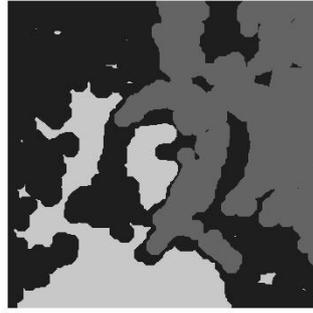






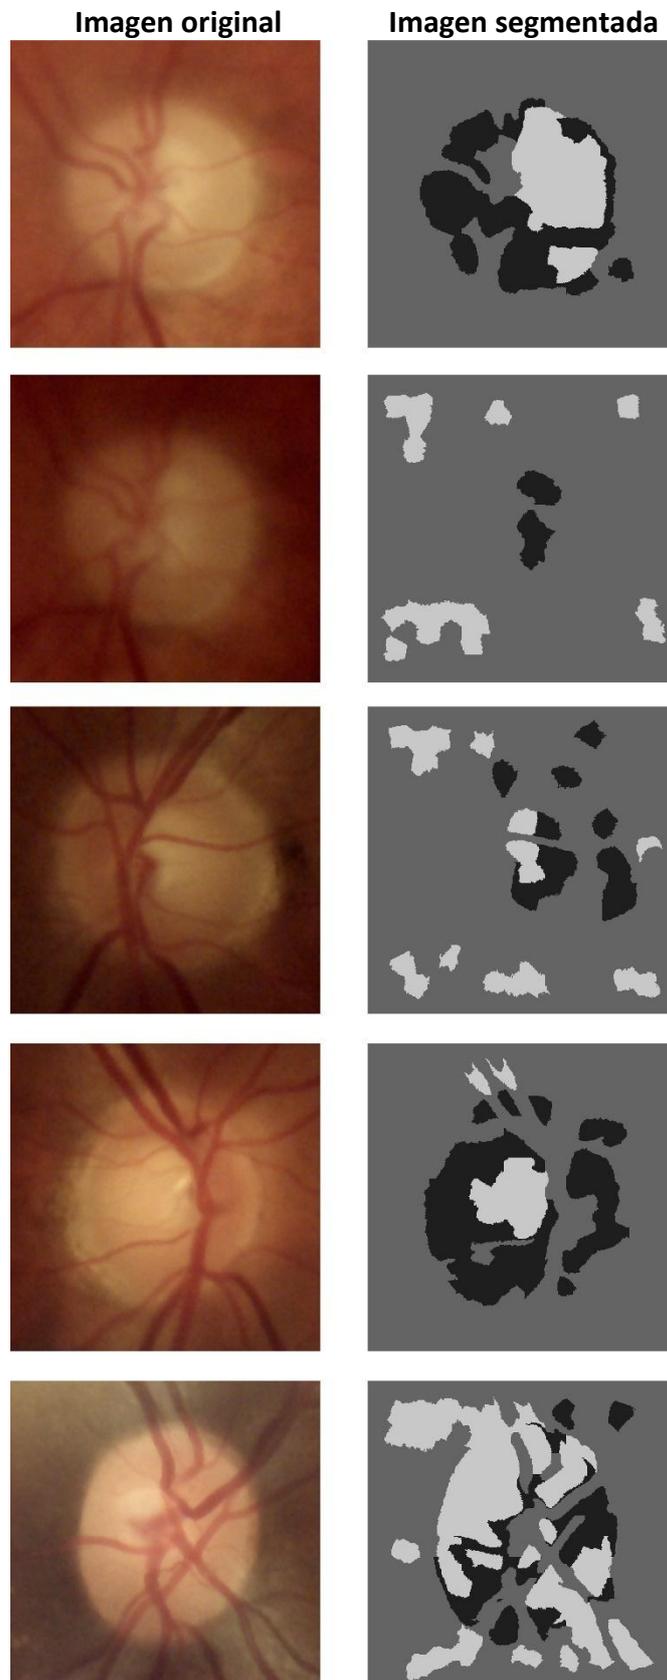


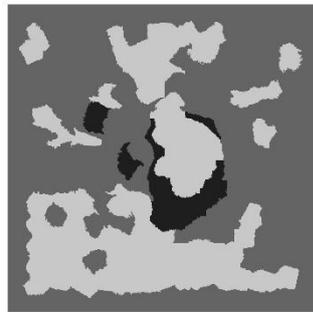
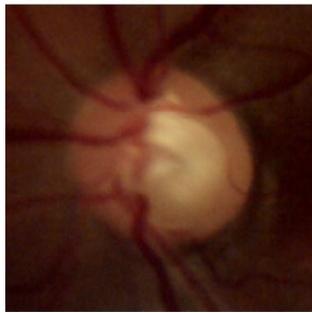
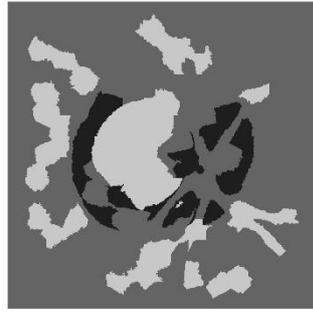
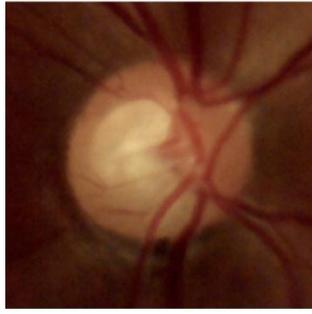
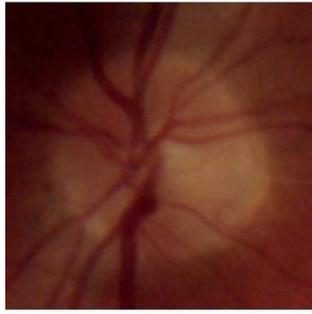
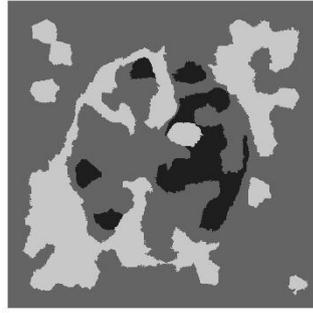


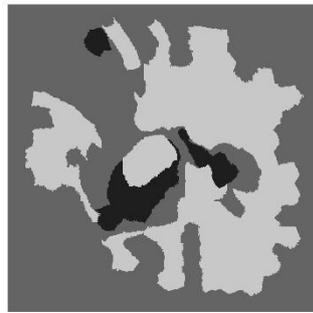
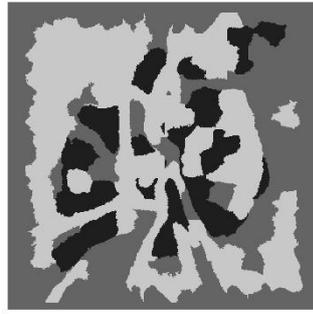
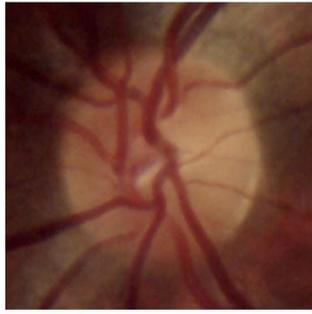
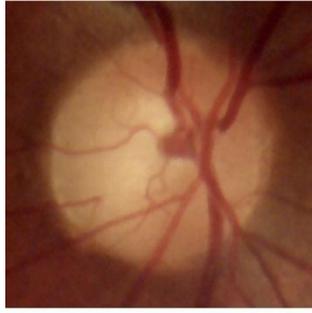


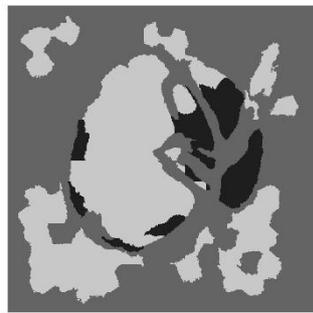
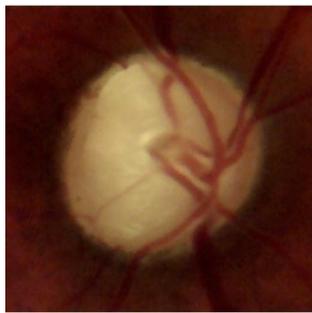
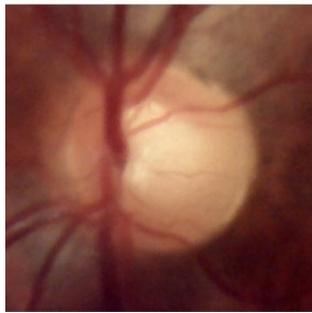
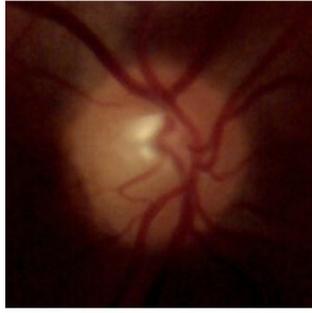
3. RESULTADOS DE [17]

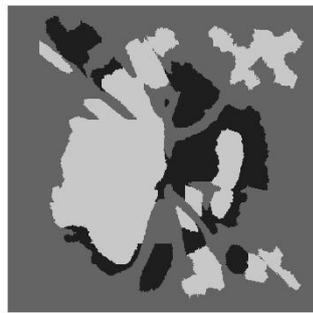
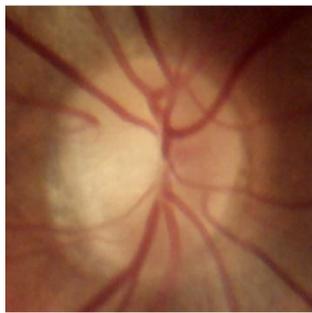
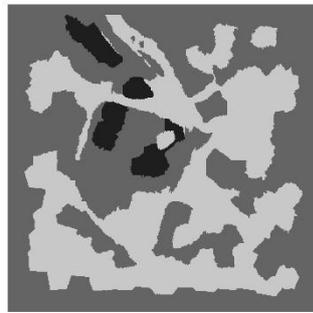
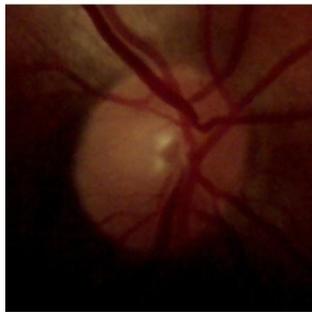
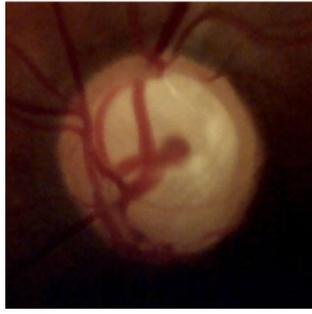
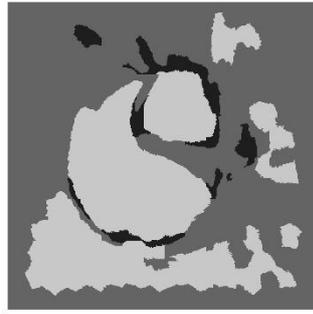
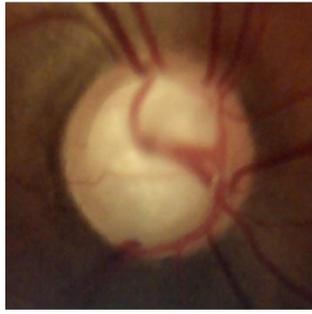
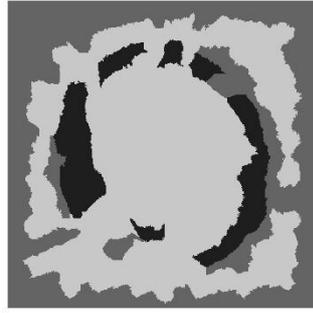
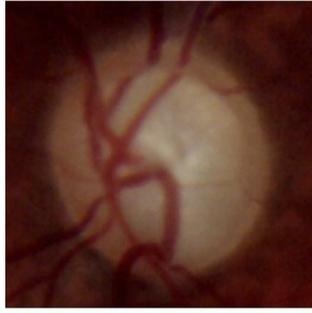
3.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS. CONJUNTO DE ENTRENAMIENTO: UNA IMAGEN

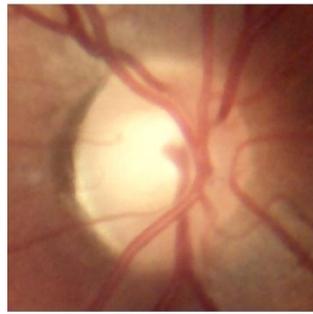
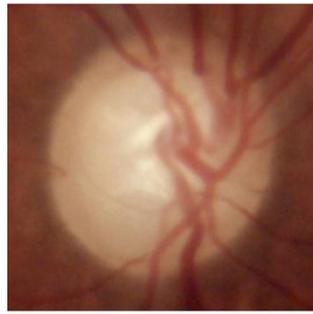












3.2. SOBRE LA BASE DE RETINOGRAFÍAS HORUS. CONJUNTO DE ENTRENAMIENTO: VARIAS IMÁGENES

Imagen original

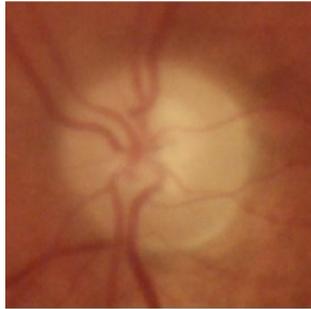
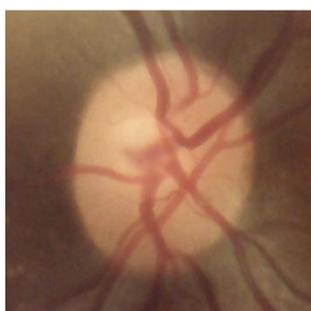
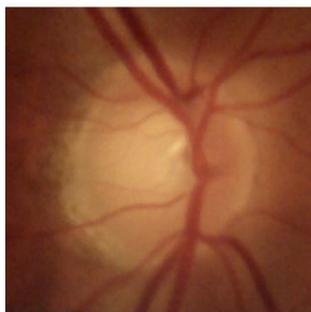
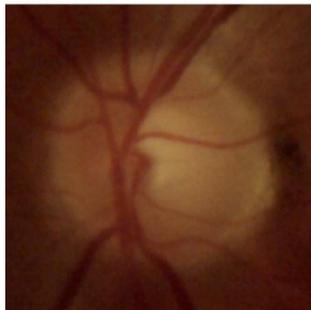
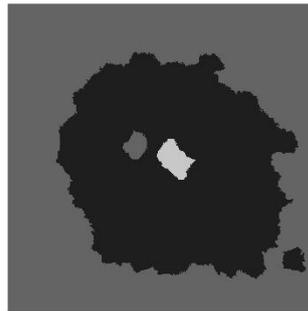
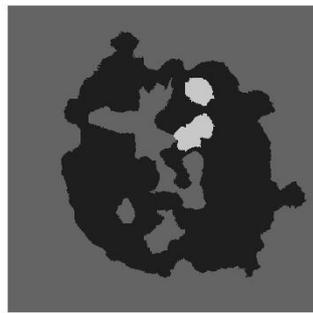
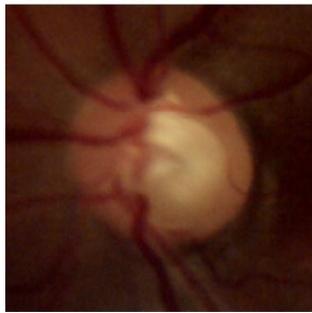
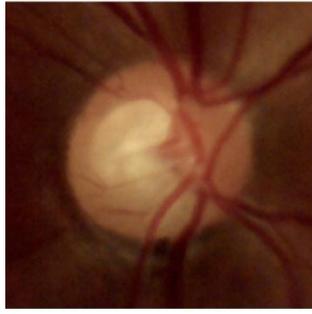
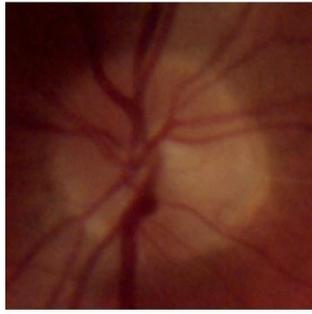
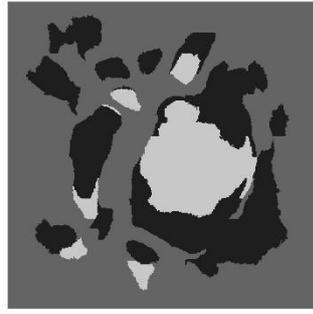
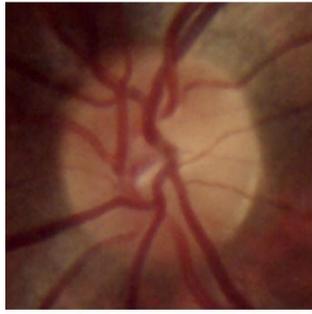
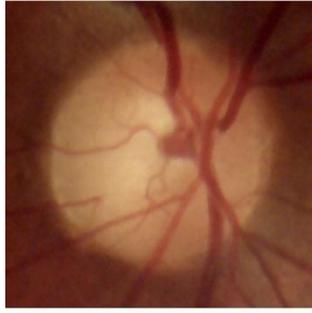
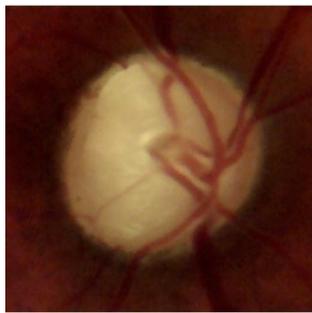
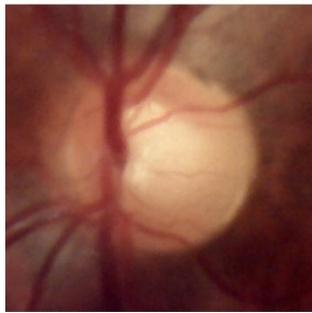
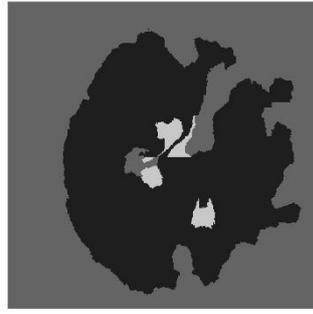
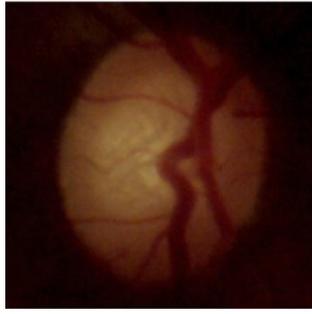
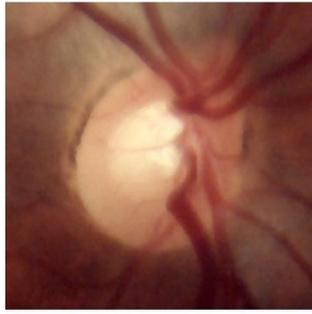
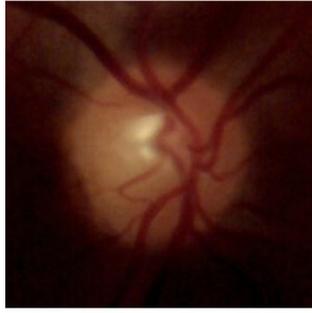


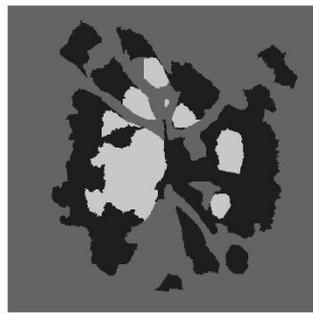
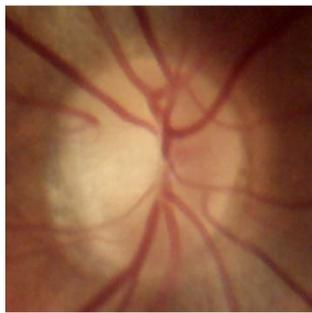
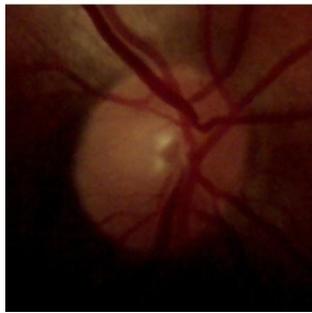
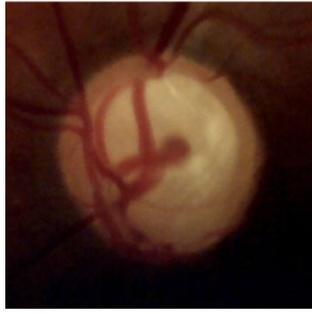
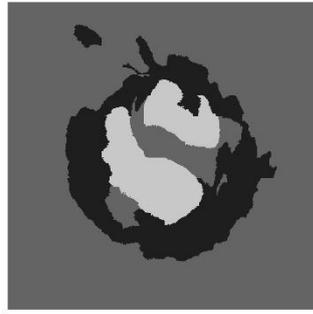
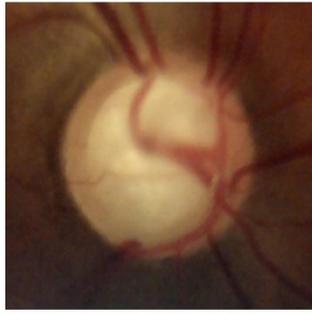
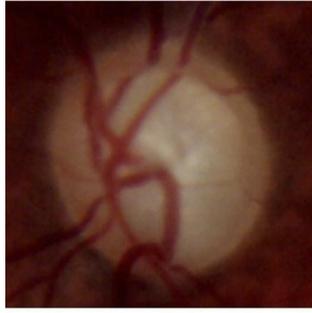
Imagen segmentada

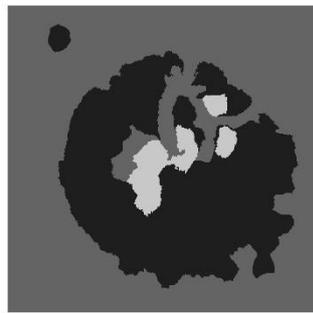
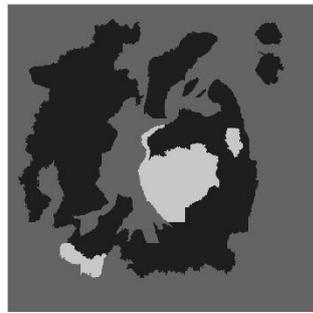
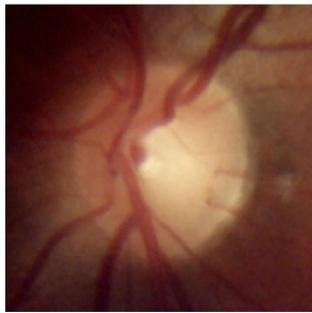
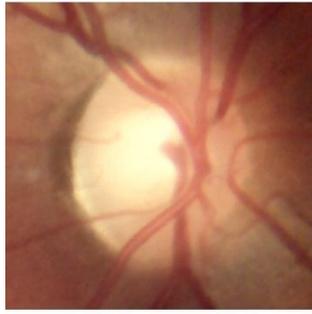
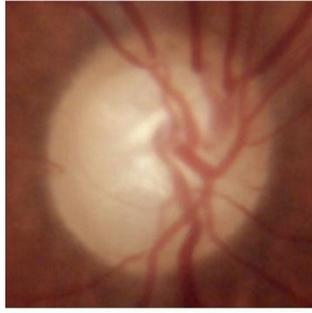












3.3. SOBRE LA BASE DE RETINOGRAFÍAS COMPASS. CONJUNTO DE ENTRENAMIENTO: UNA IMAGEN

Imagen original

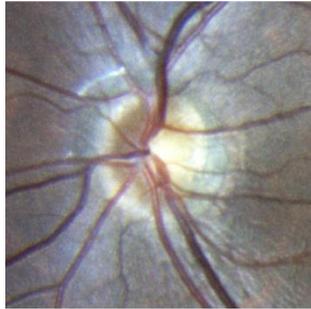
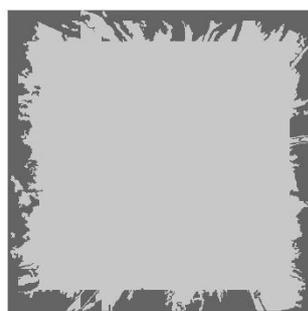
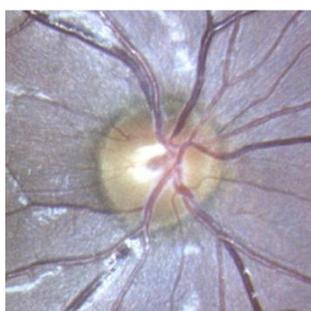
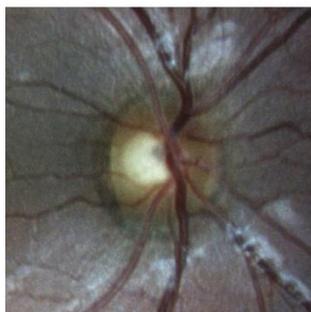
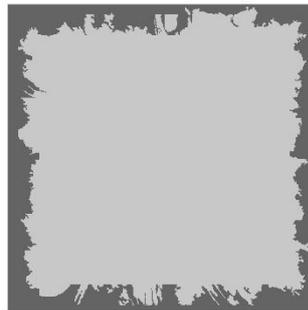
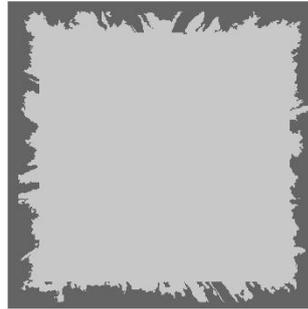
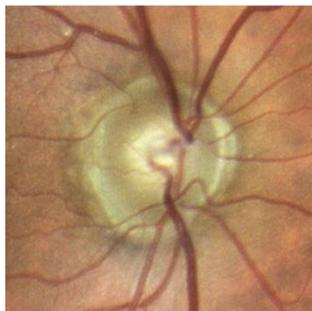
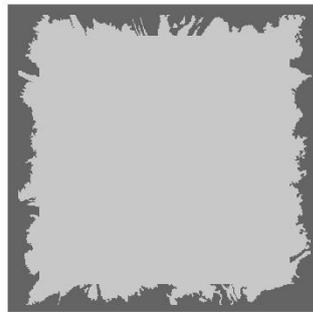
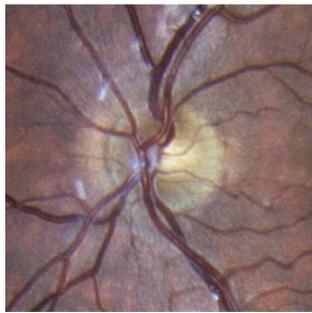
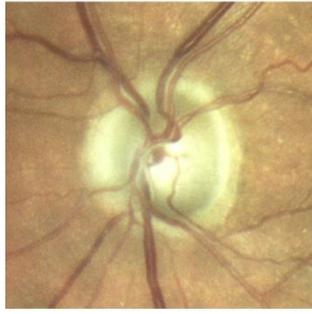
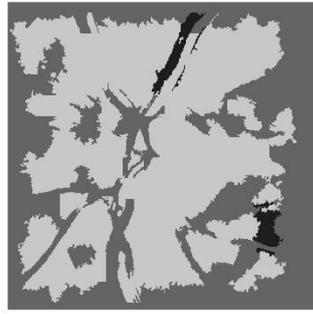
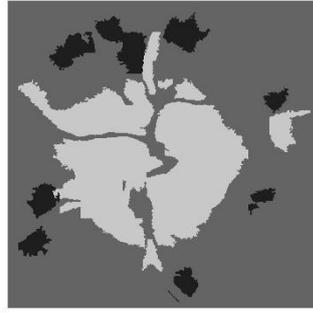
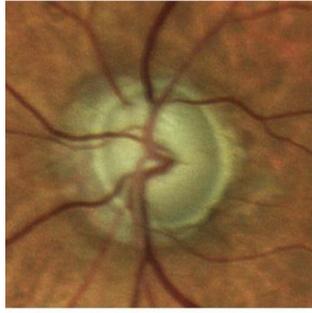
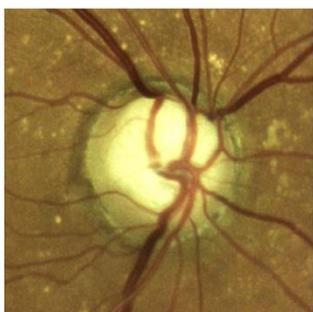
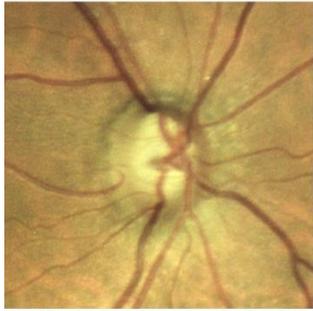
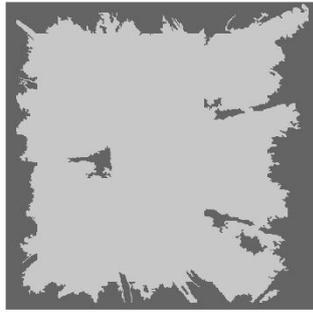
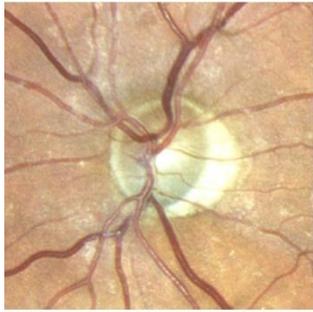
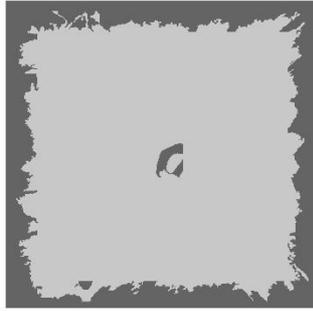
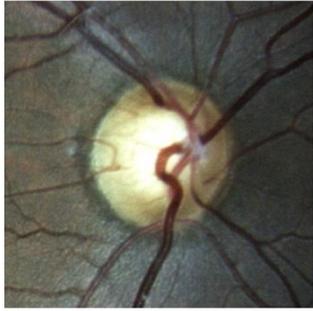
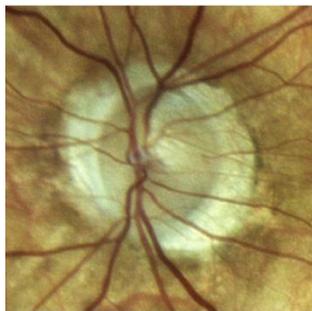
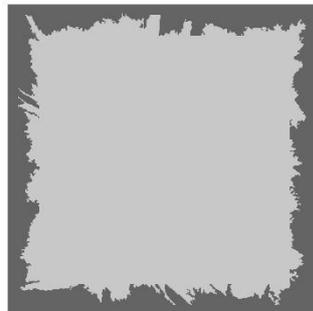
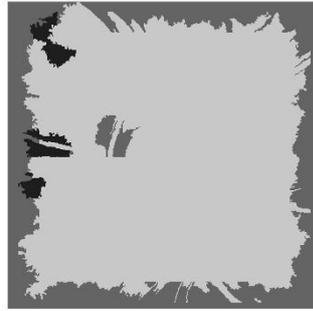
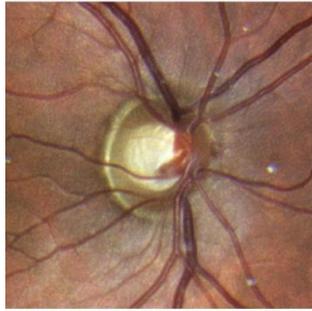
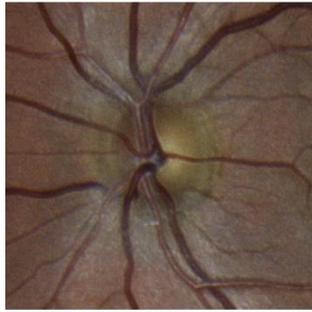


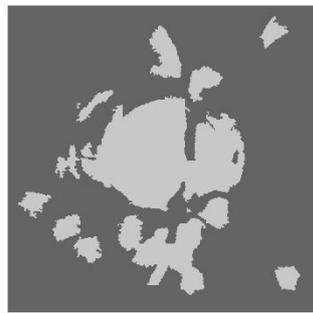
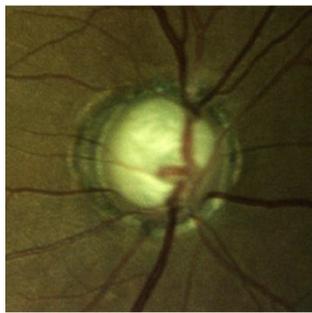
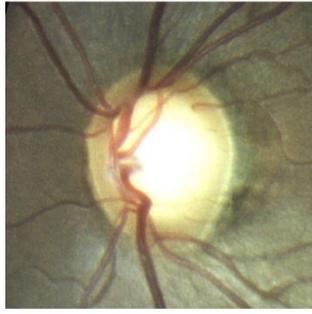
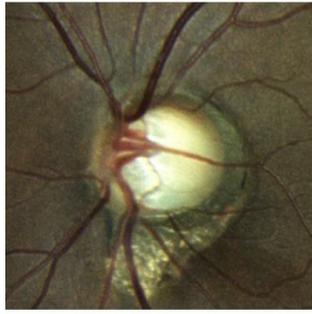
Imagen segmentada

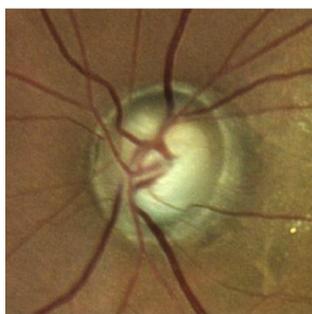
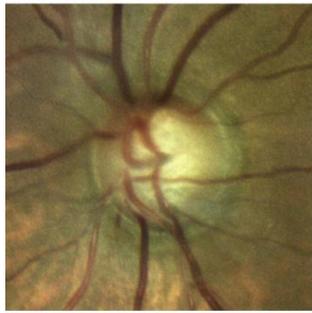
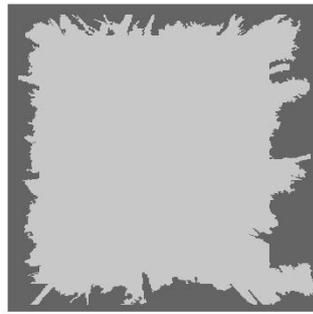
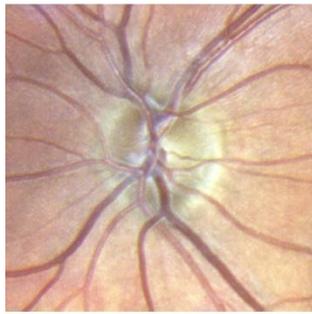
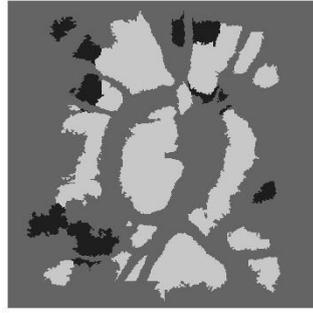












3.4. SOBRE LA BASE DE RETINOGRAFÍAS COMPASS. CONJUNTO DE ENTRENAMIENTO: VARIAS IMÁGENES

Imagen original

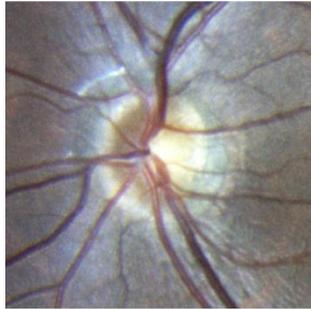
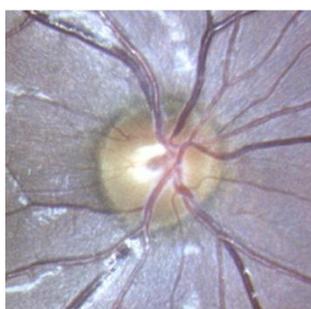
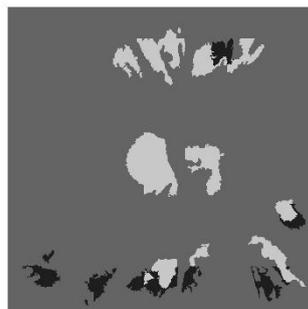
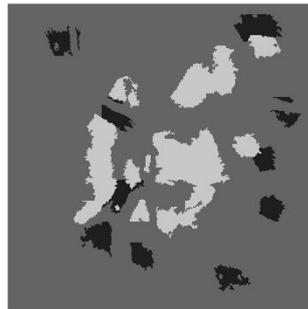
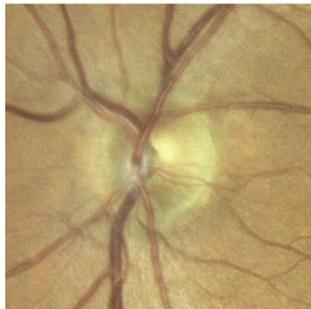
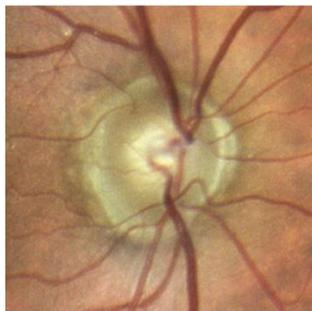
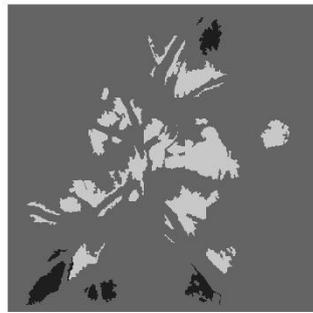
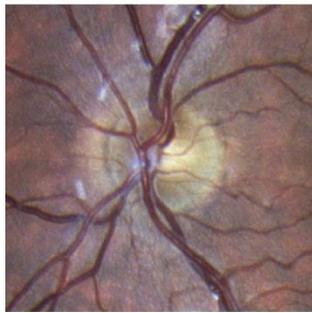
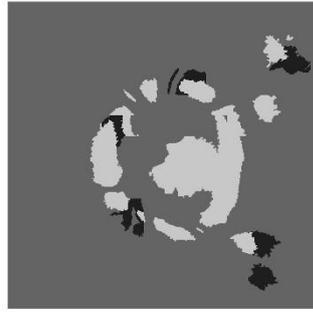
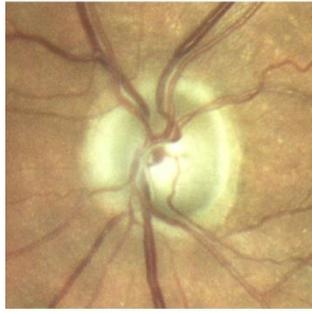
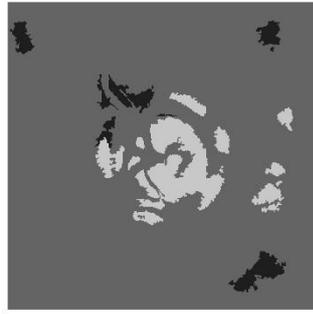
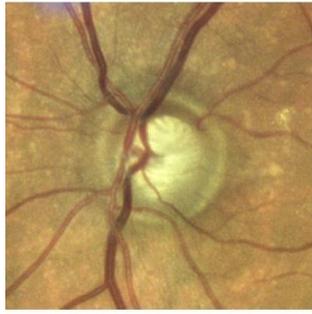
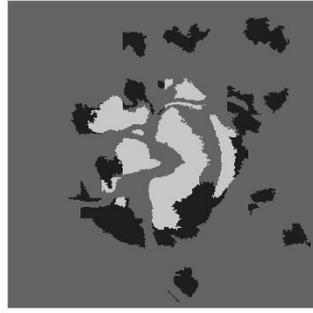
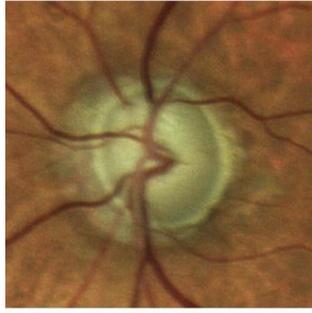
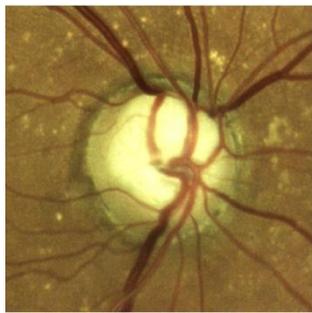
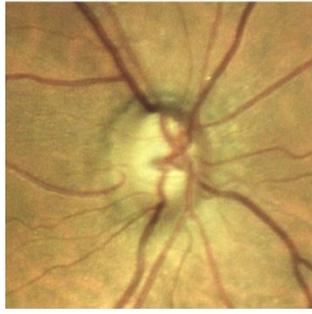
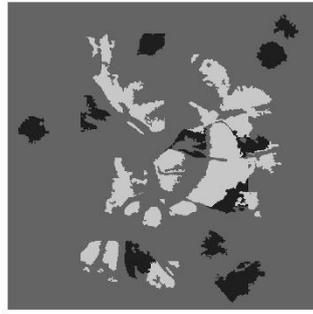
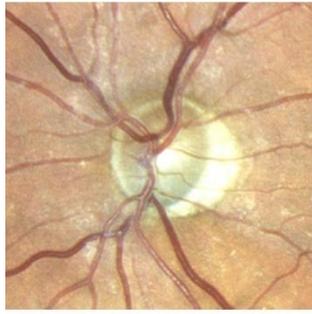
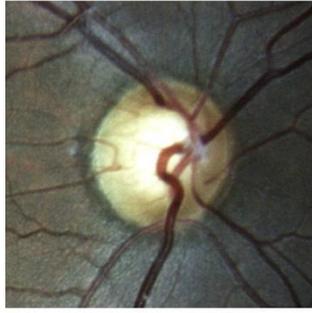
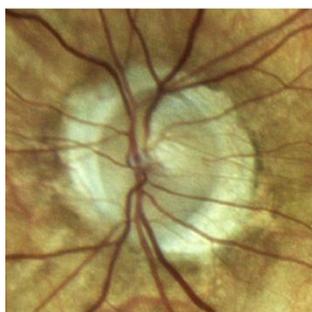
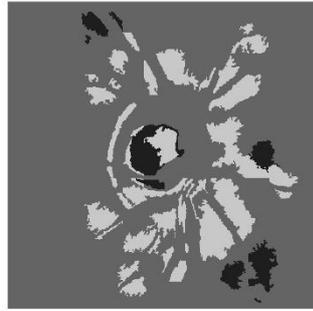
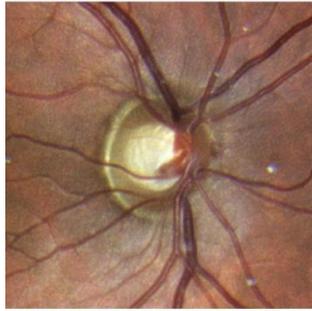
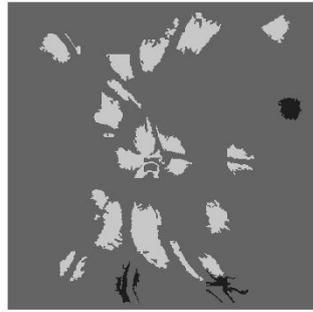


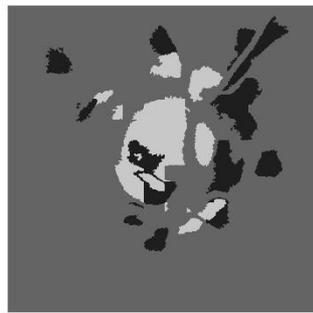
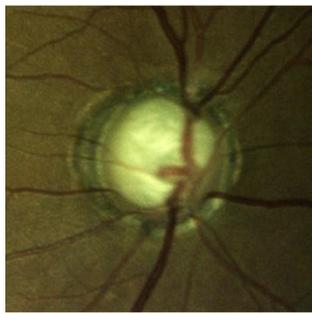
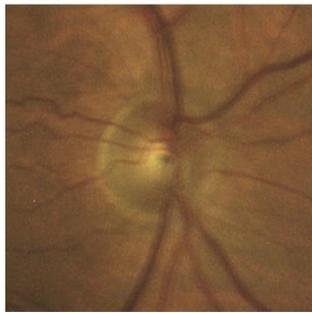
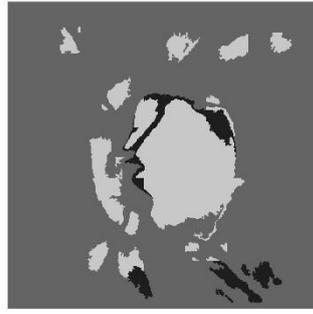
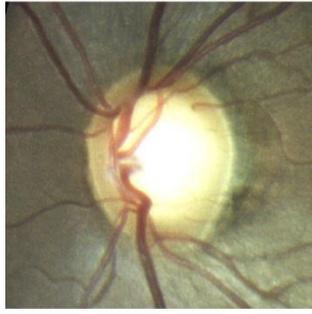
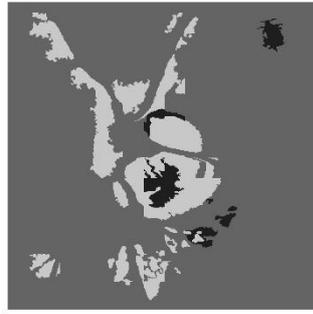
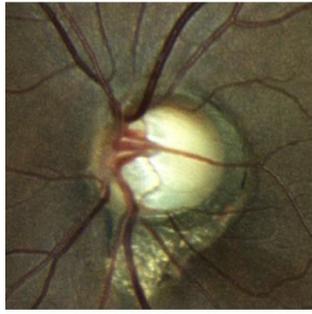
Imagen segmentada

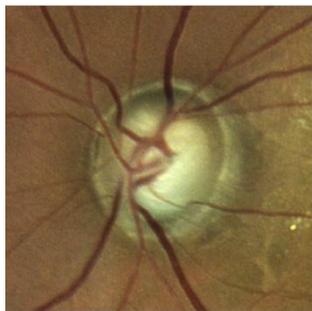
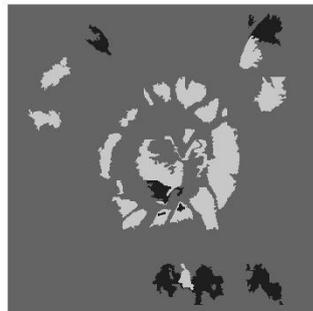
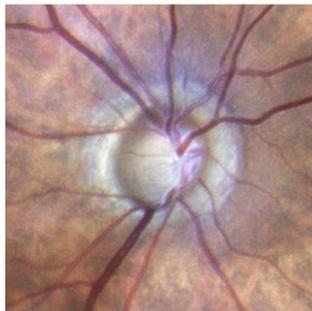
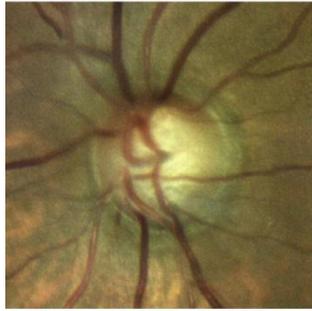
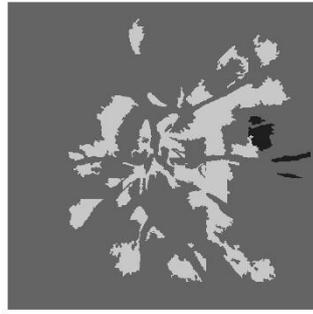
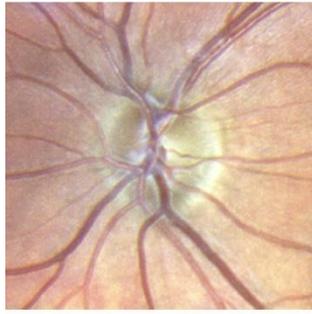






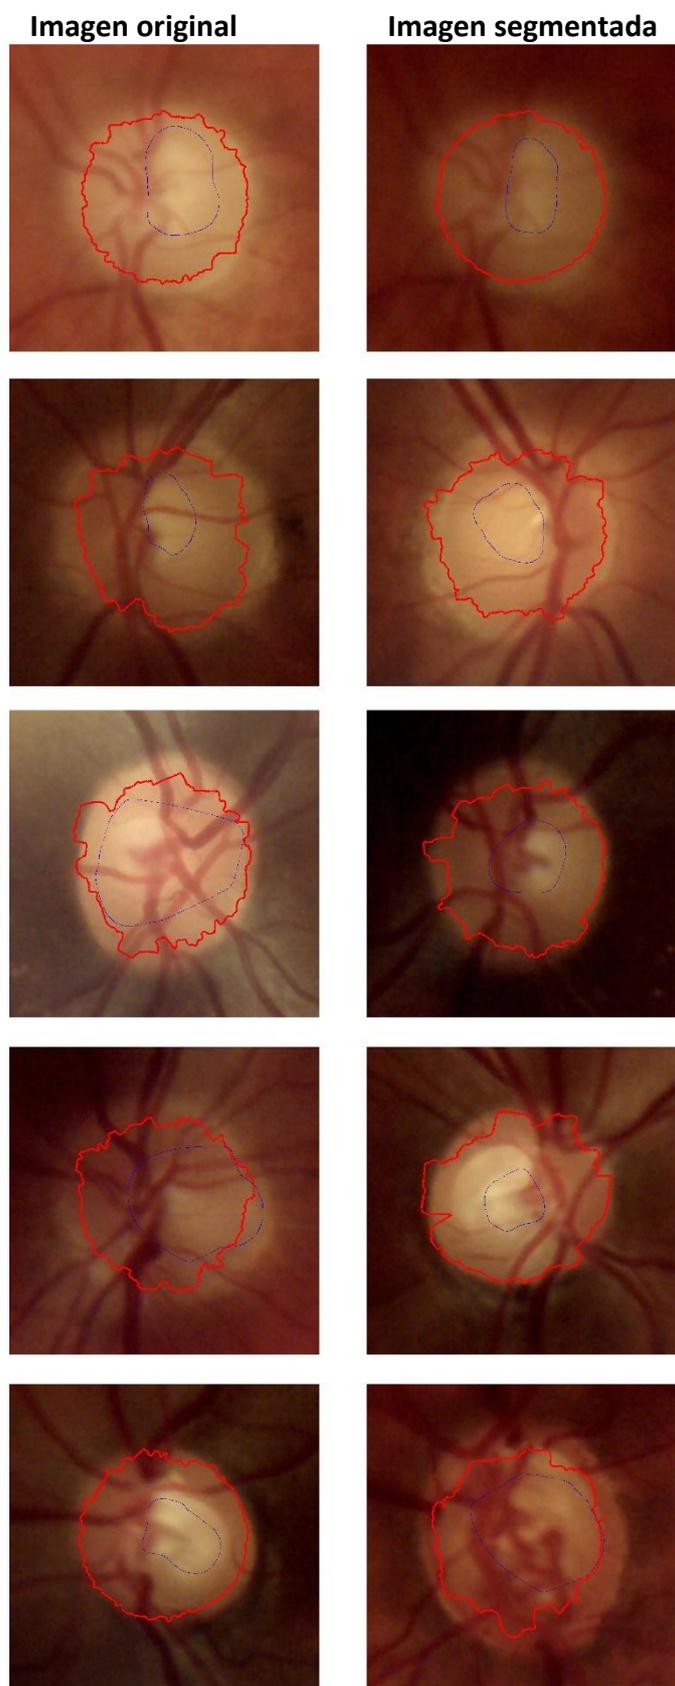


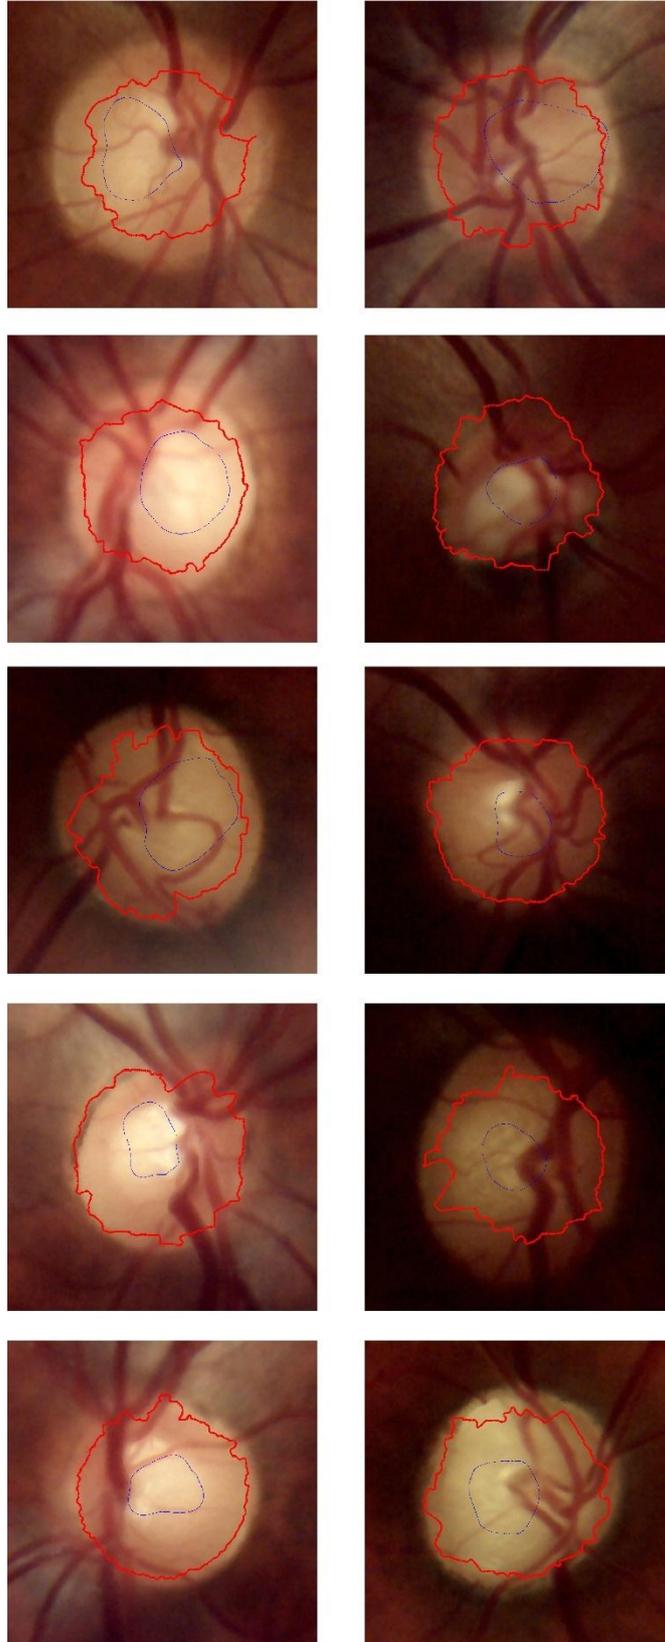


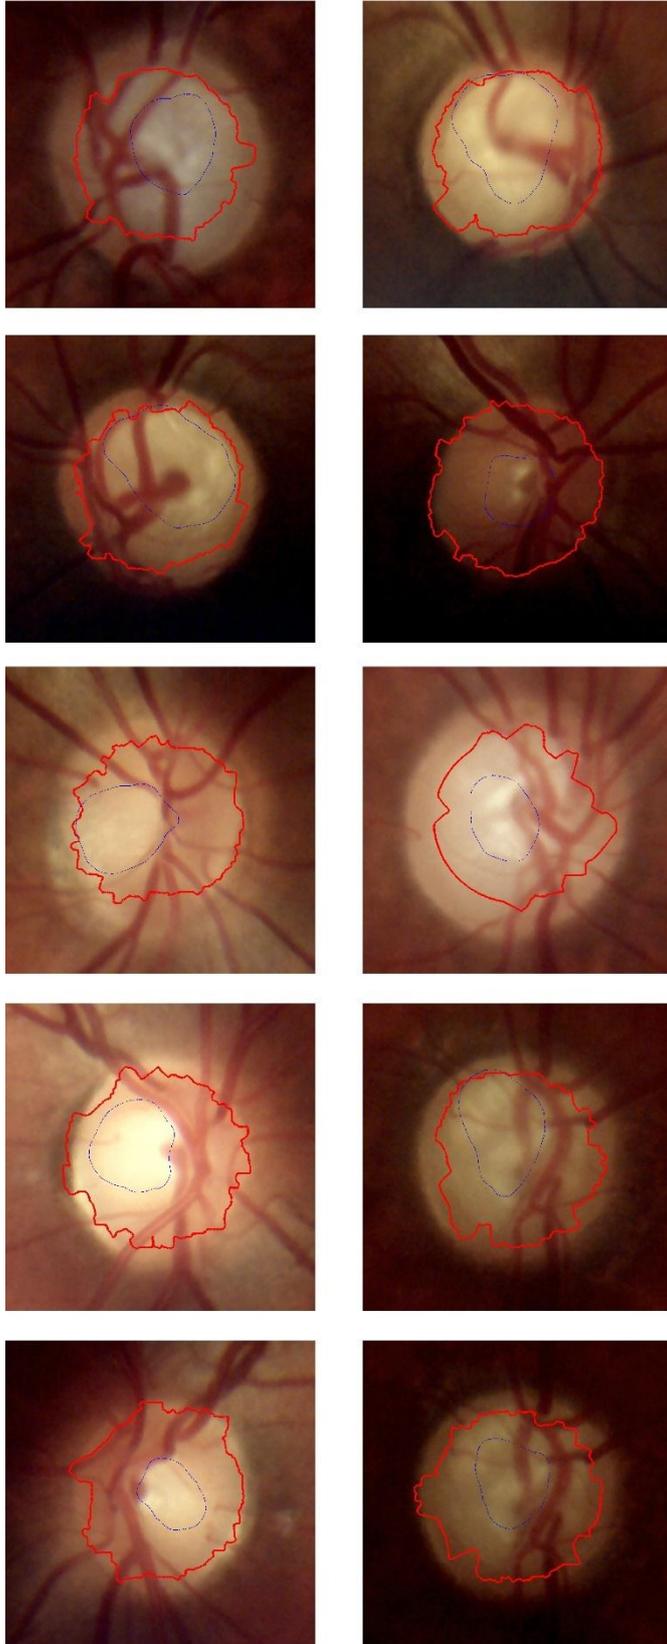


4. RESULTADOS DE [28]

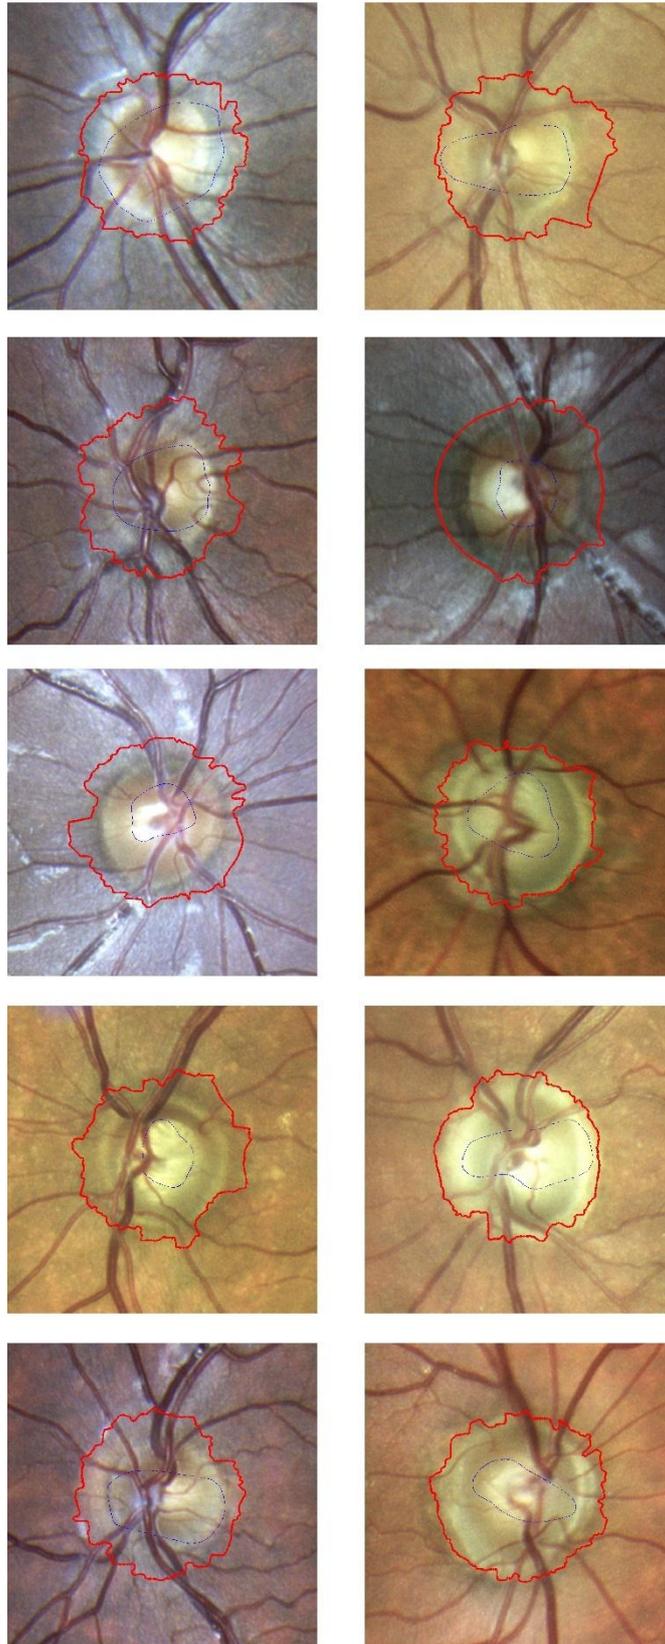
4.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS

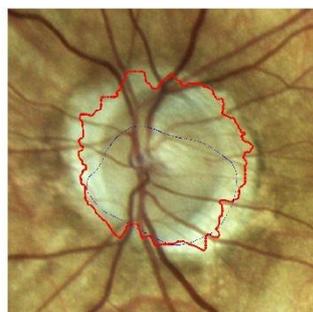
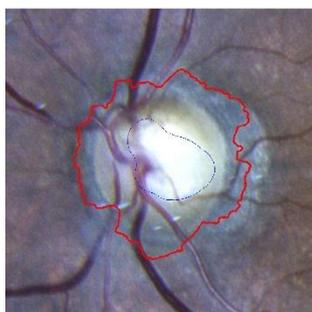
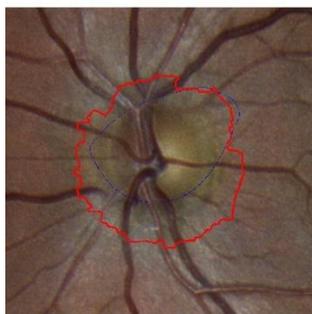
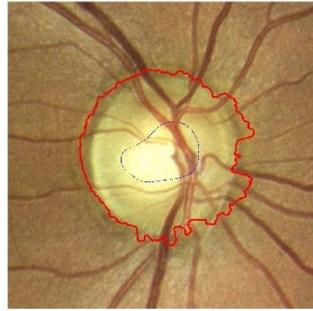
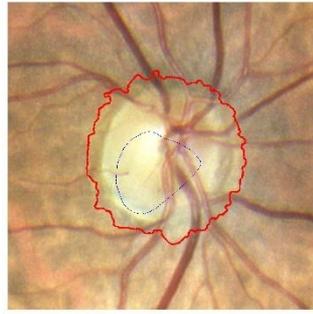
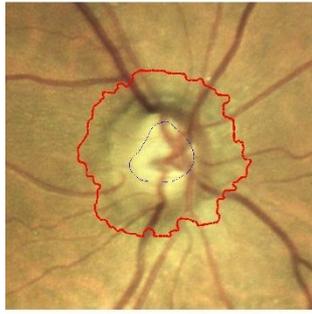
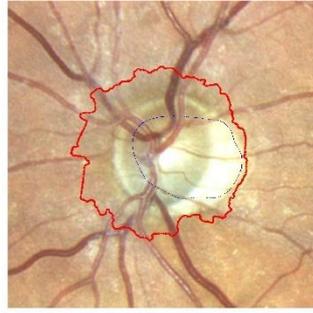
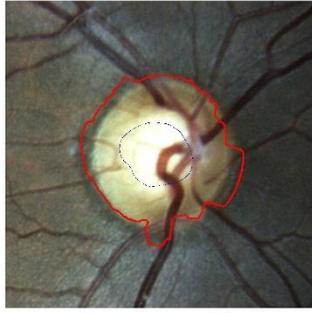


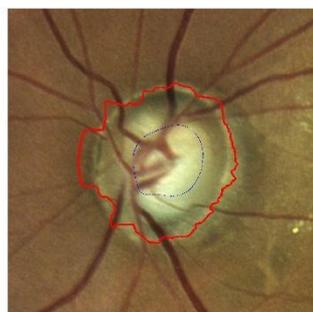
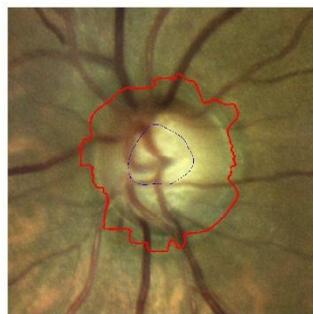
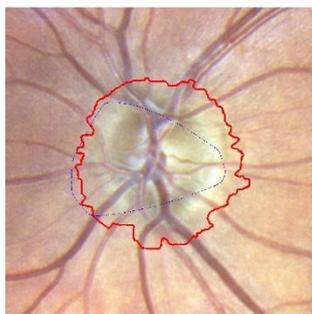
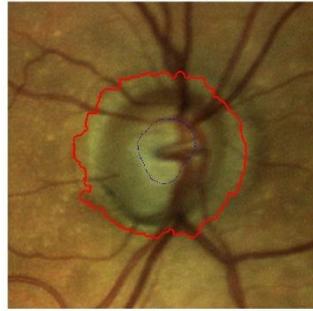
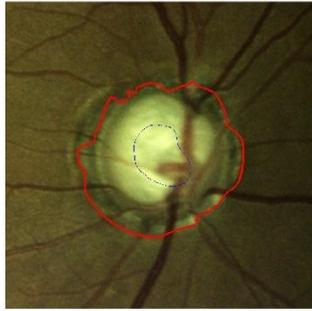
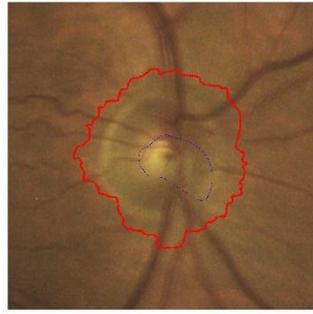
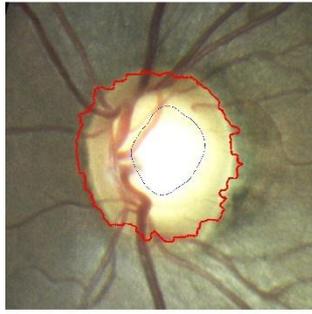
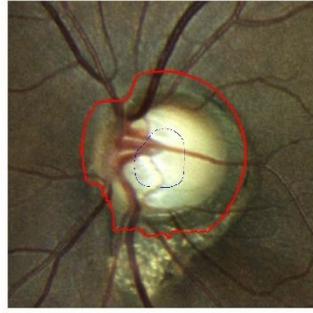




4.2. SOBRE LA BASE DE RETINOGRAFÍAS COMPASS

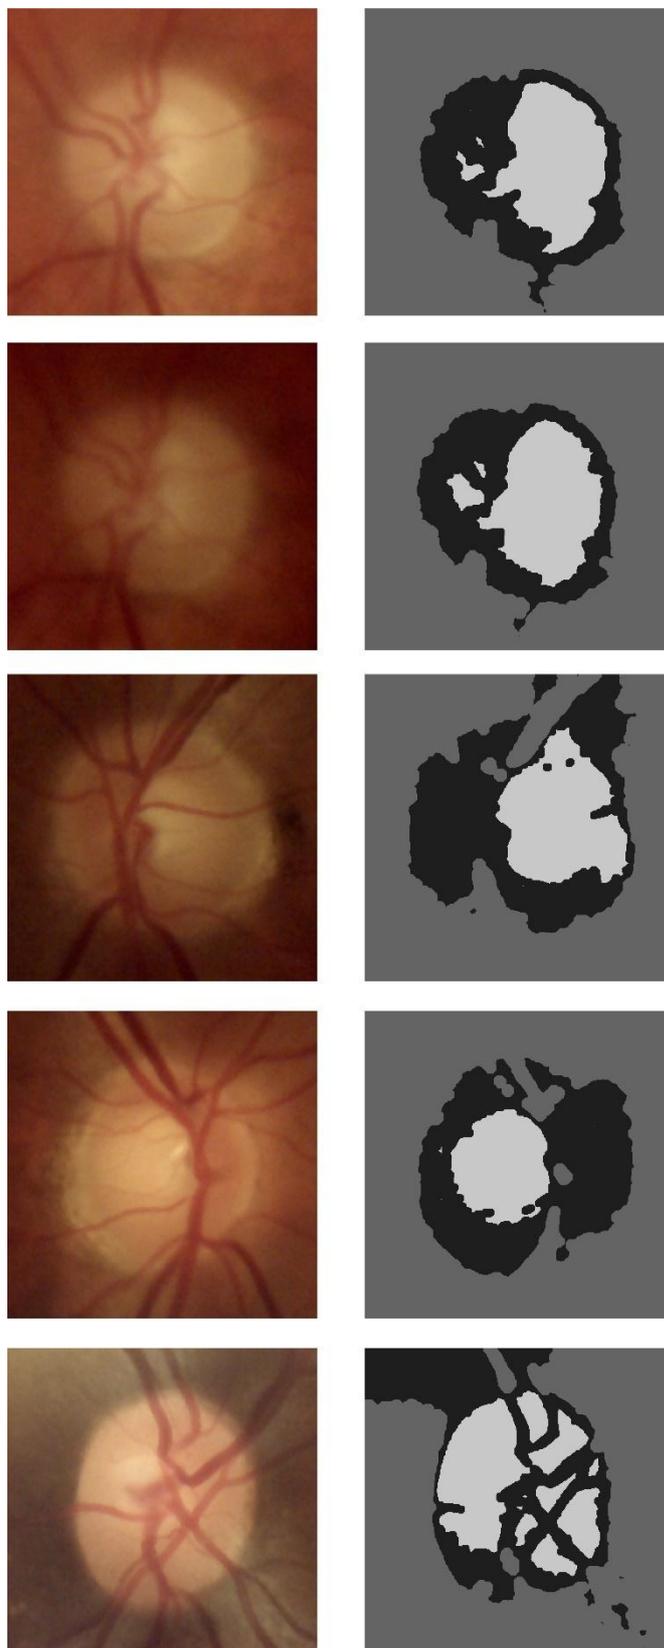


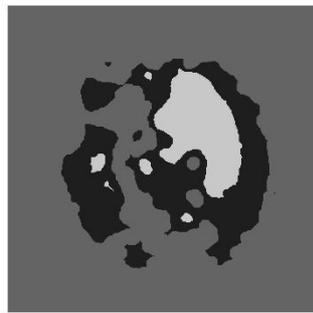
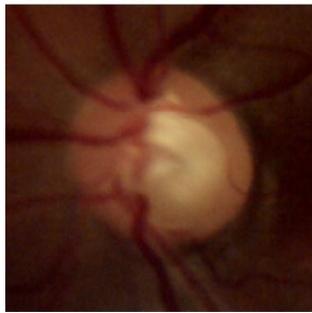
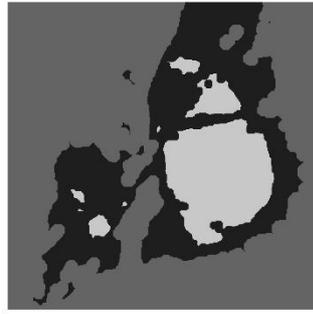
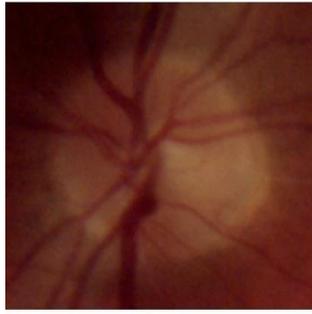


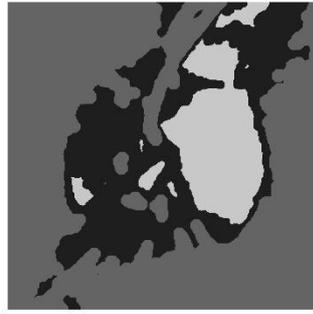
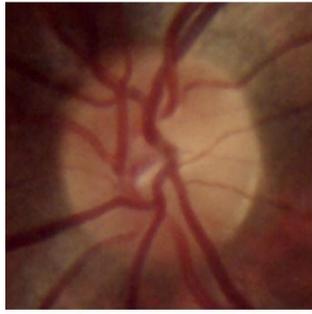
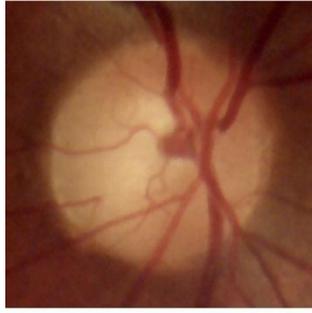


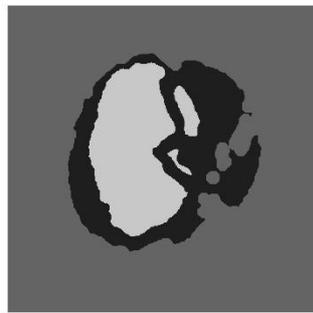
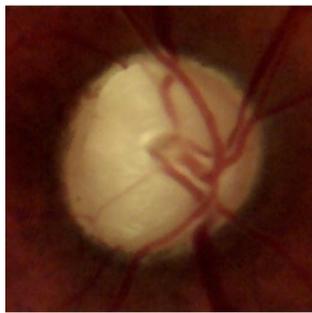
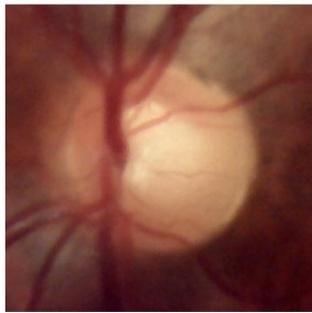
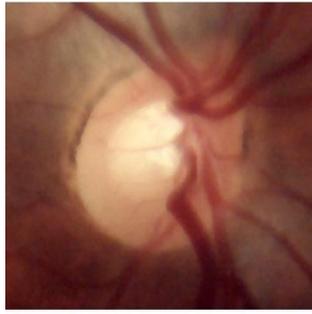
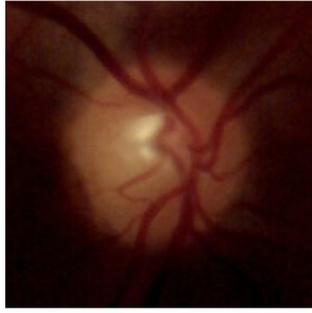
5. RESULTADOS DE [30]

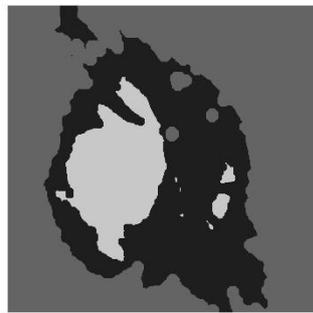
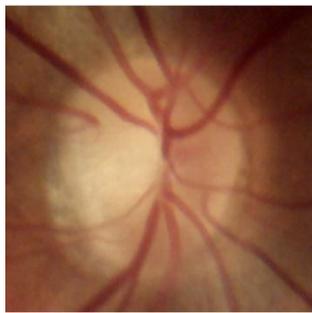
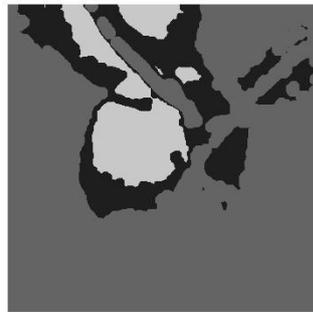
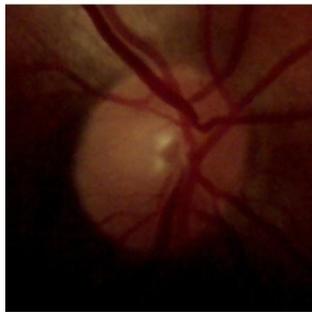
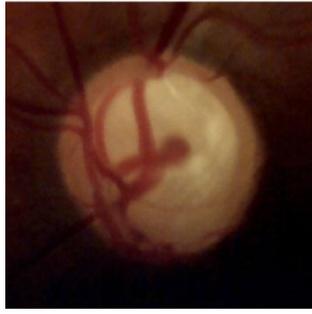
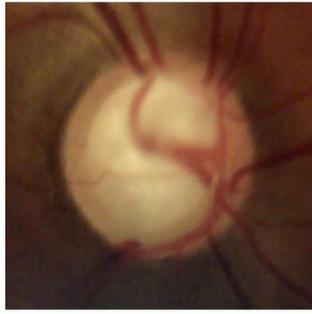
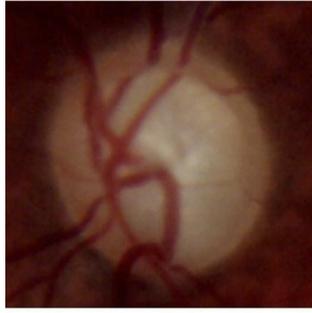
5.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS

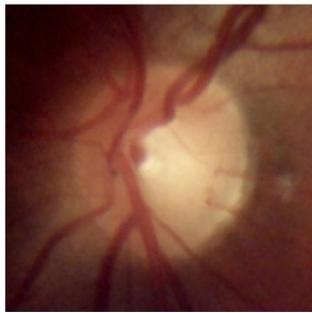
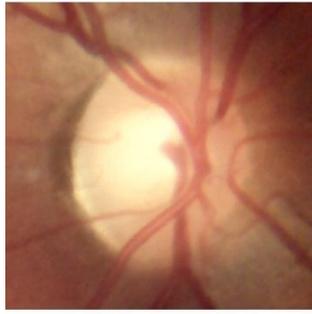
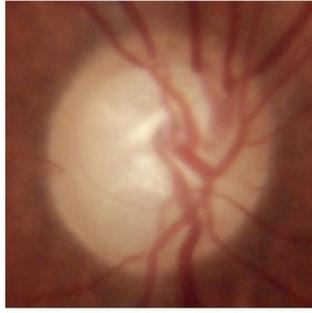












5.2. SOBRE LA BASE DE RETINOGRAFÍAS COMPASS

Imagen original

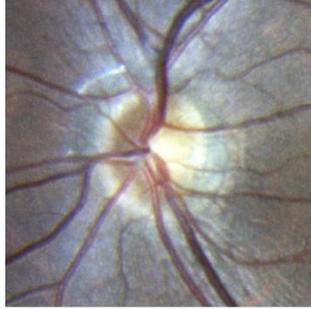
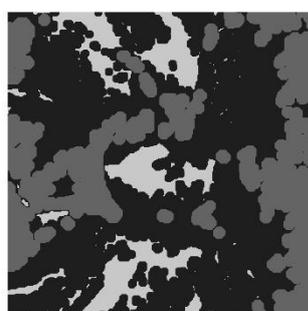
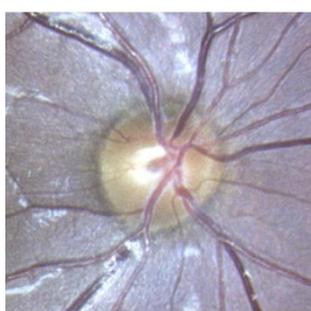
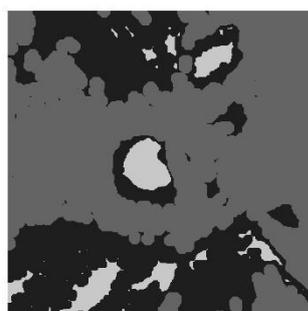
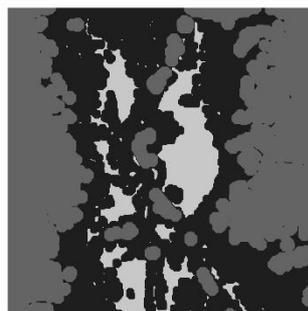
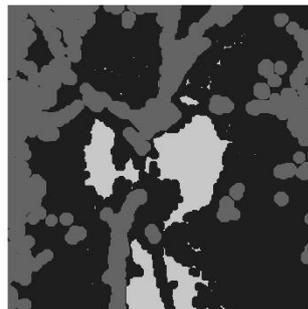
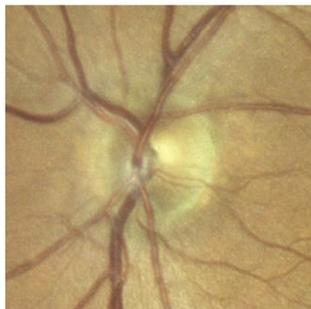
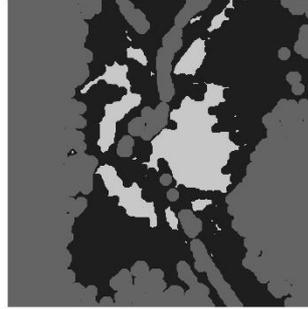
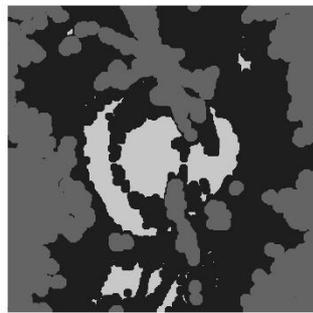
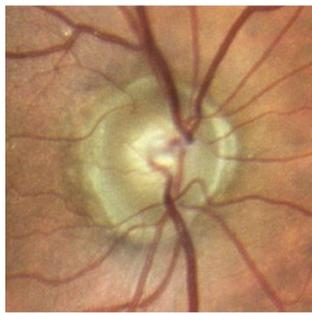
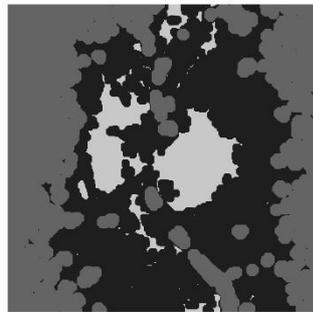
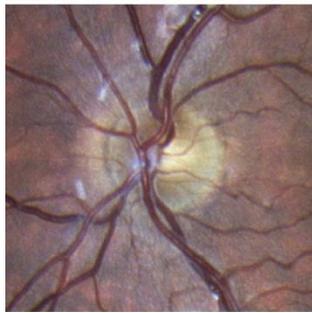
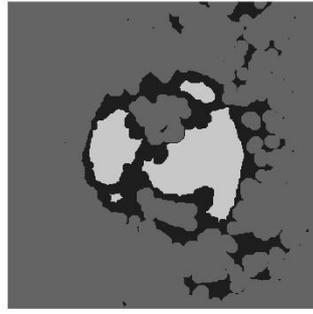
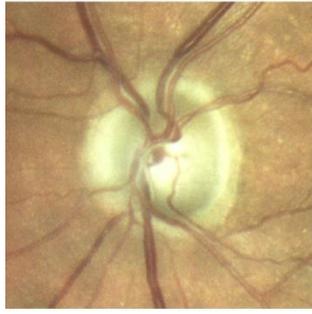
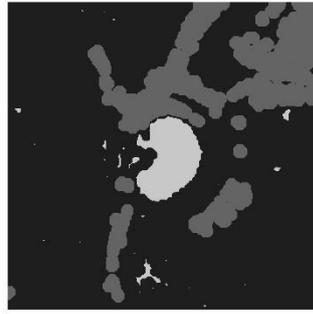
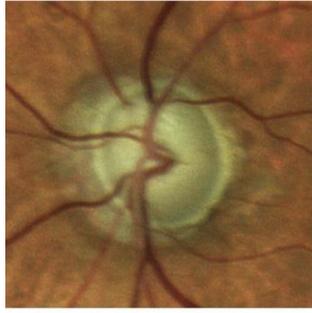
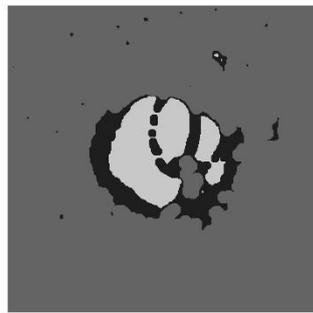
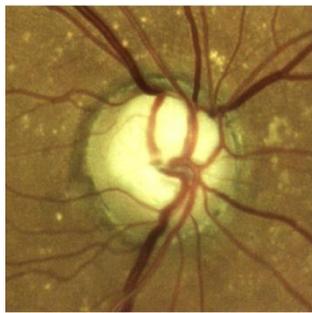
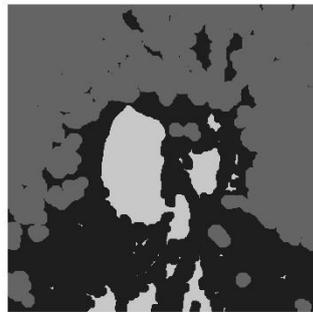
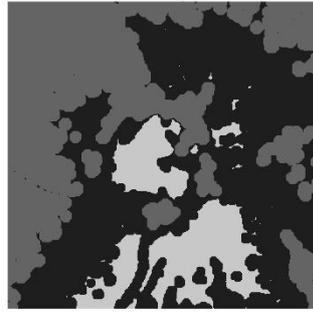
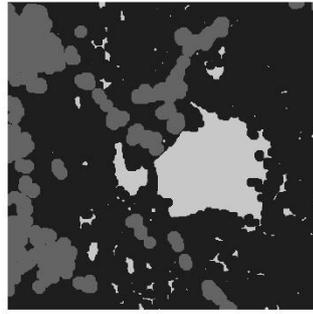
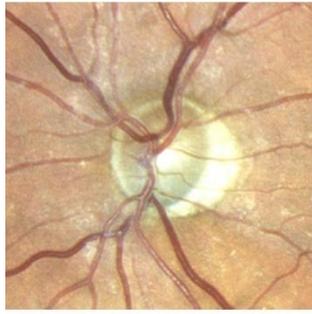
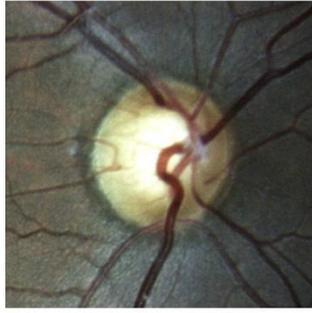
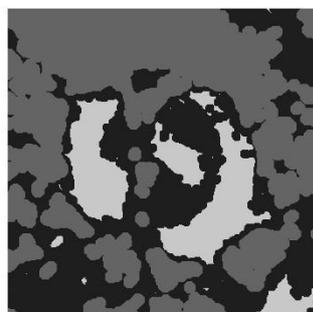
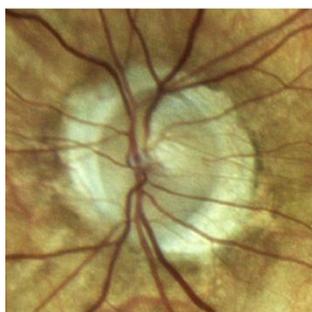
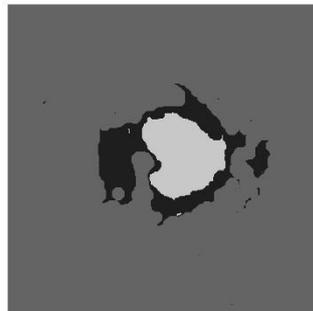
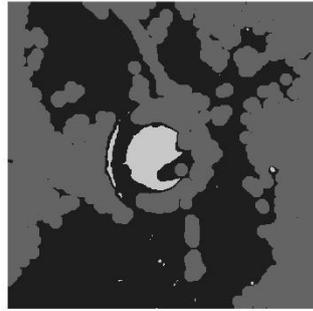
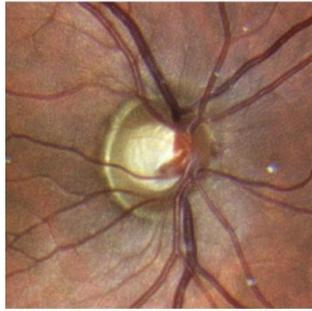
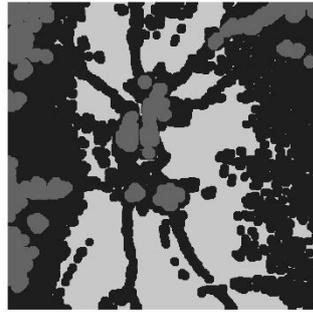
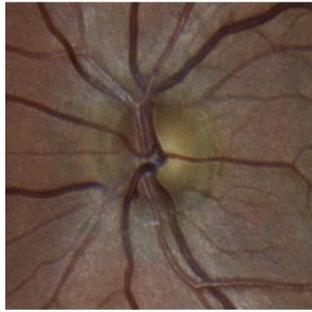
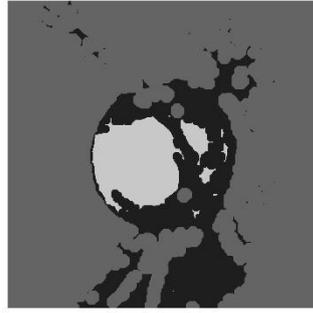
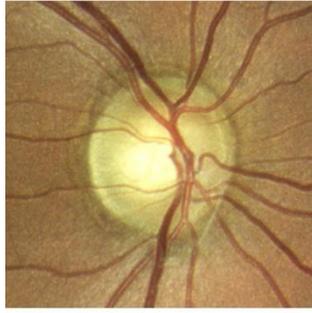


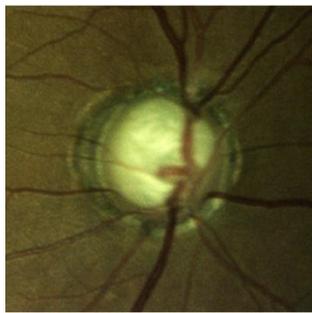
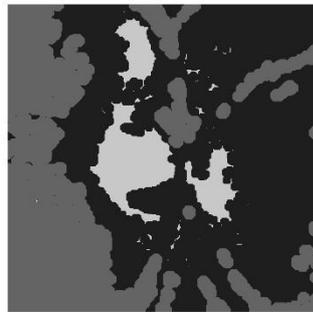
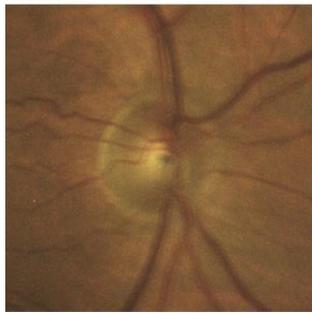
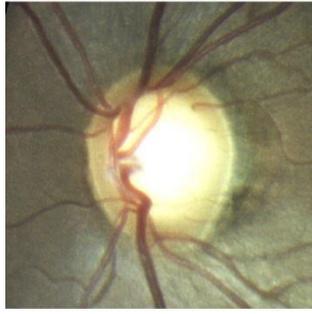
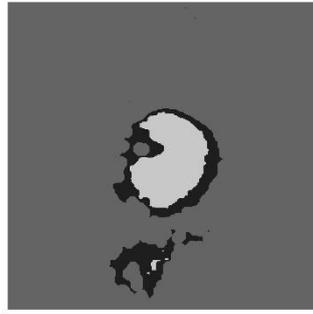
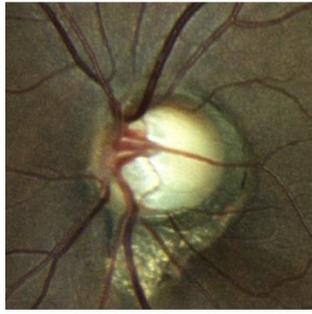
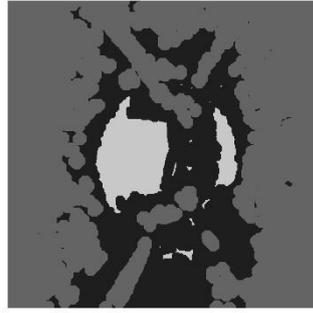
Imagen segmentada

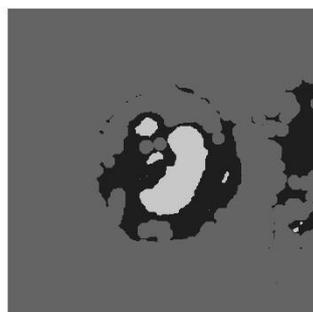
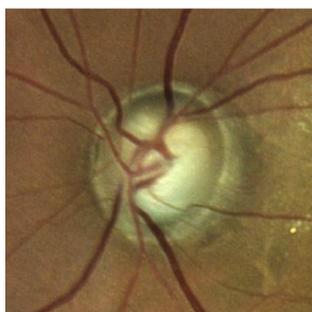
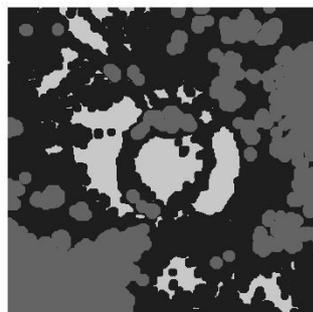
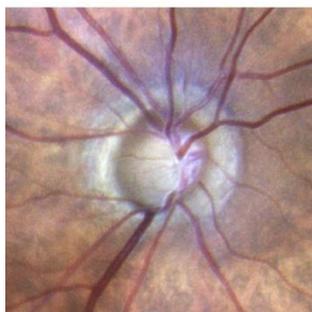
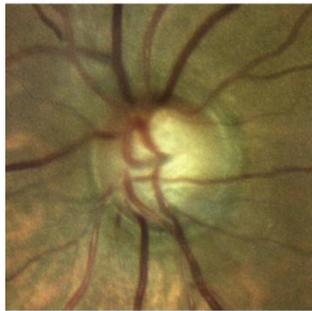
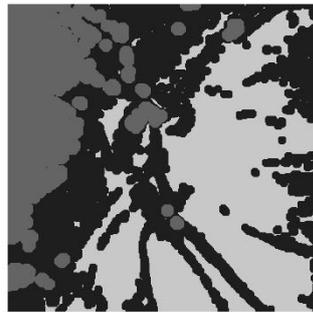
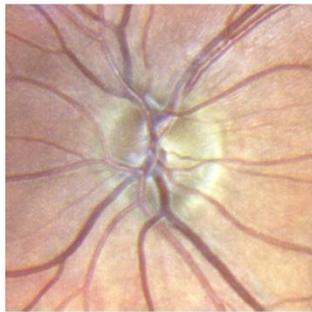
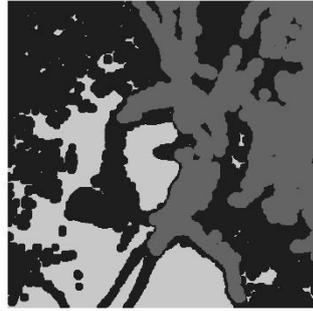






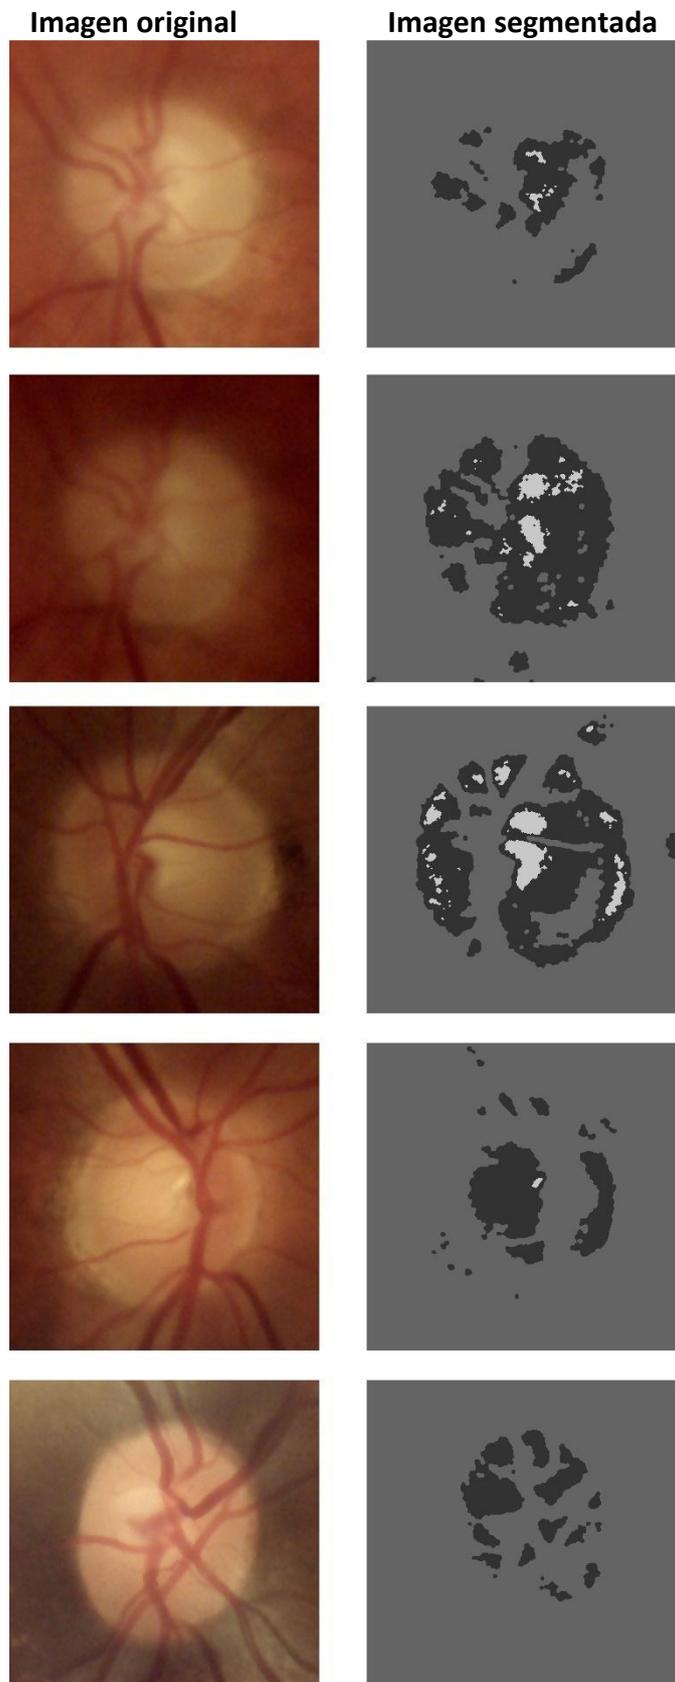


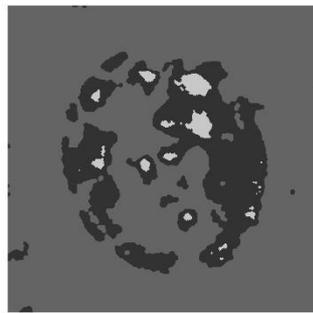
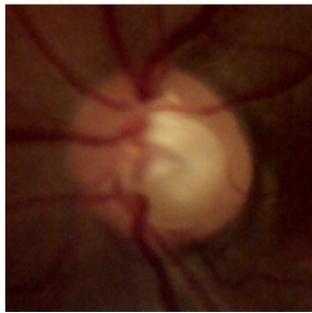
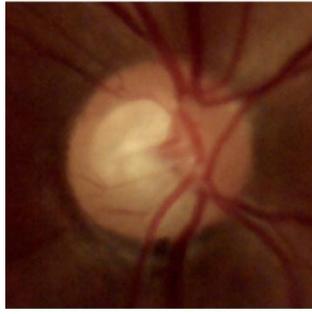
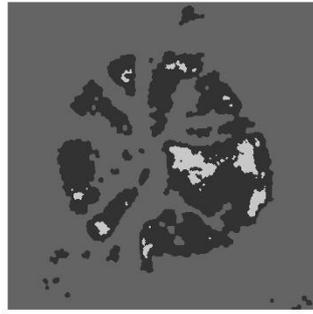
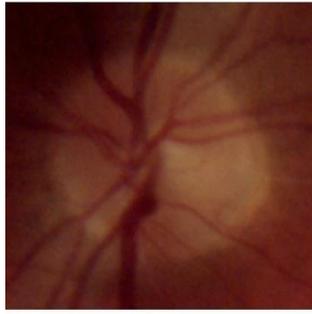
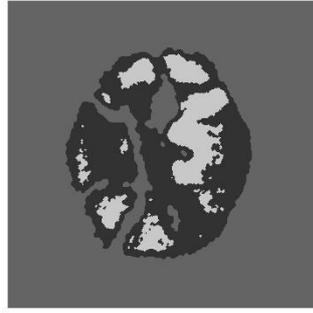


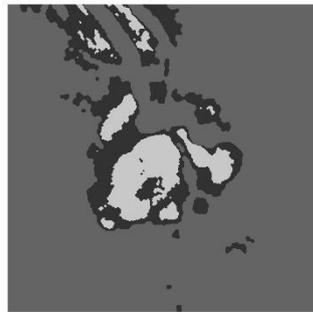
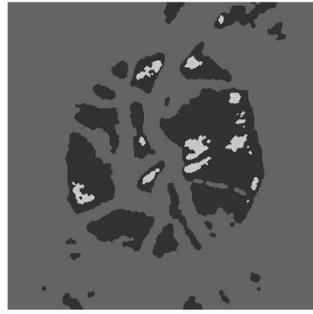
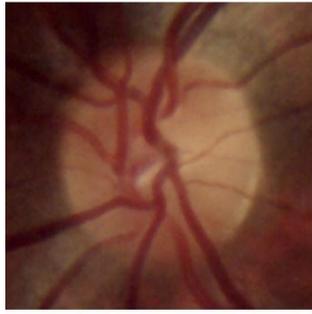
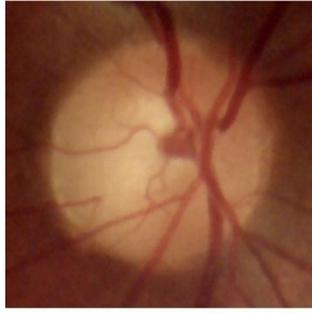


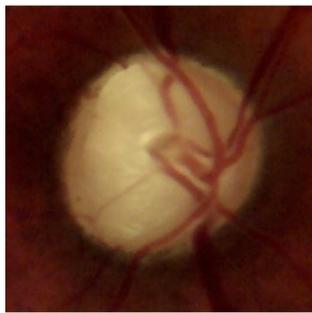
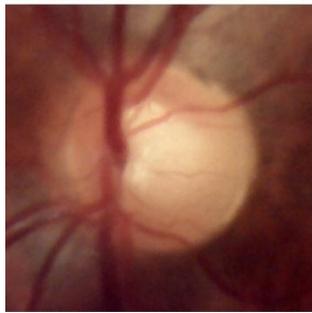
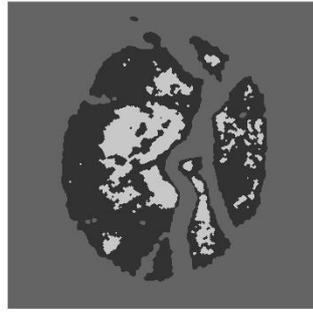
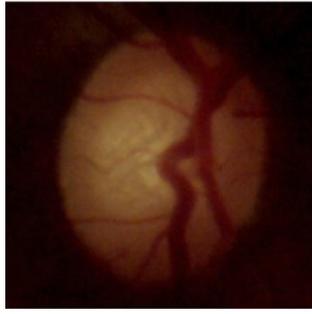
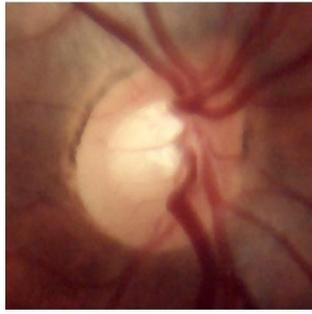
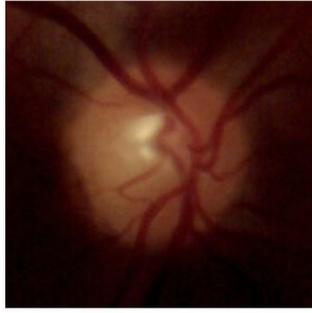
6. RESULTADOS DE [31]

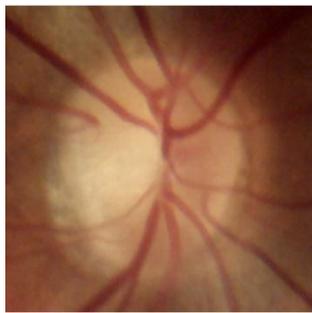
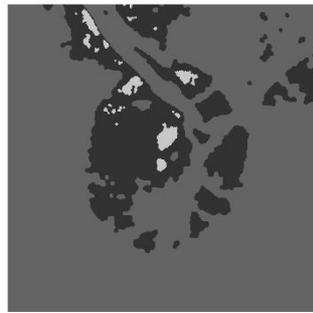
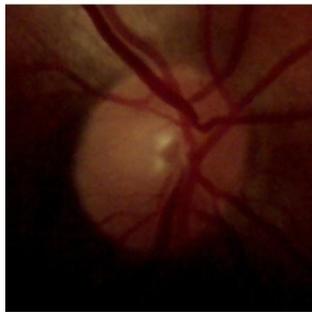
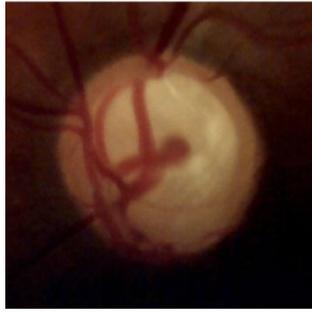
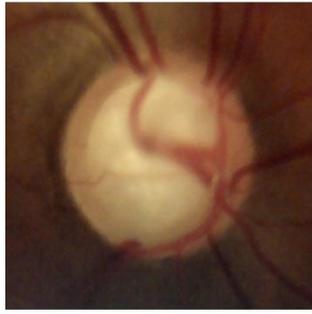
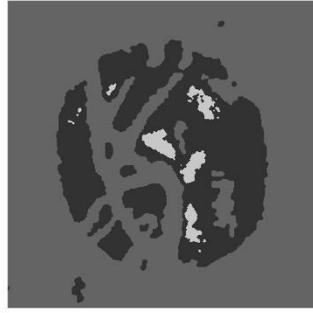
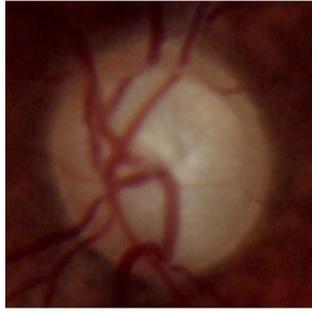
6.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS

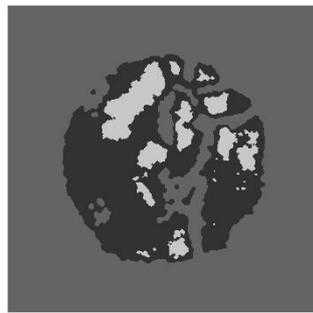
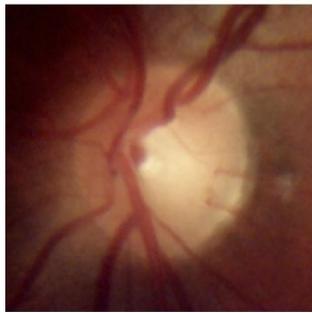
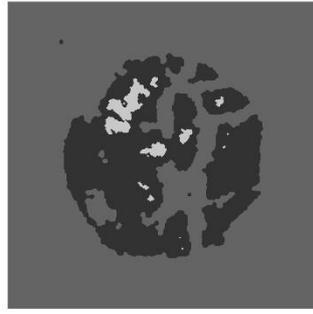
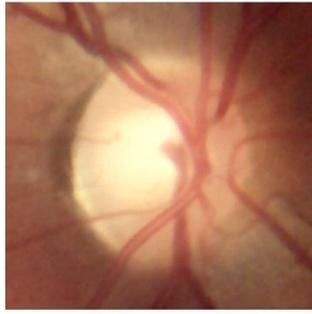
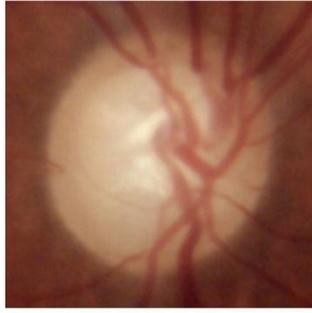












6.2. SOBRE LA BASE DE RETINOGRAFÍAS COMPASS

Imagen original

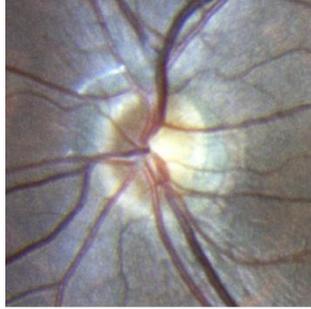
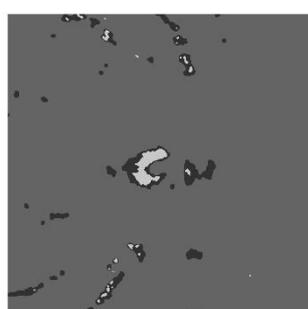
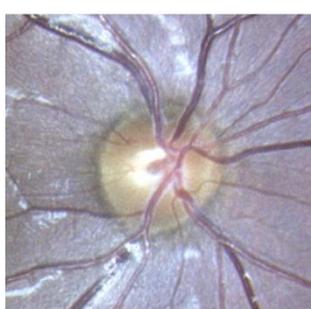
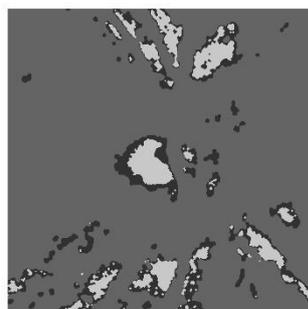
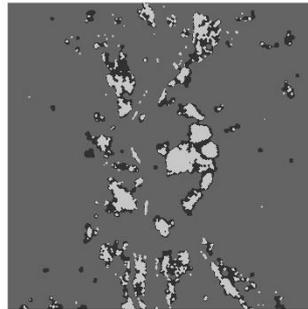
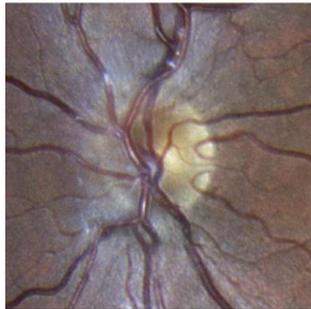
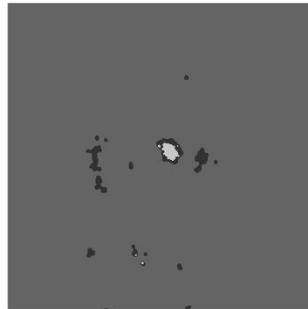
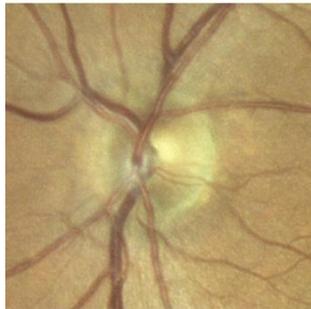
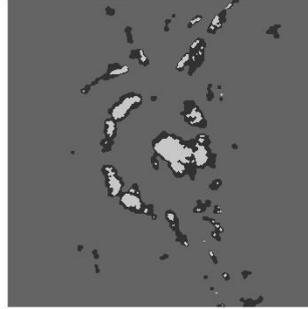
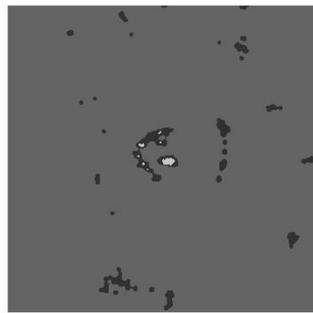
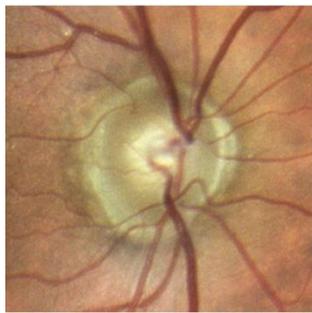
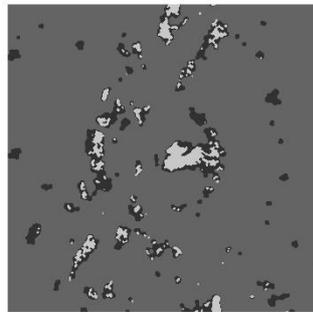
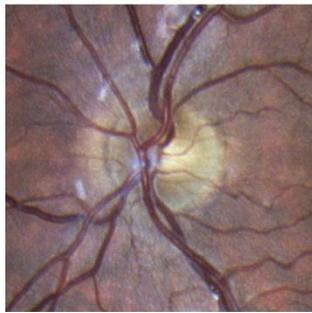
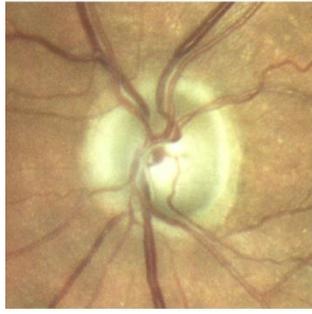
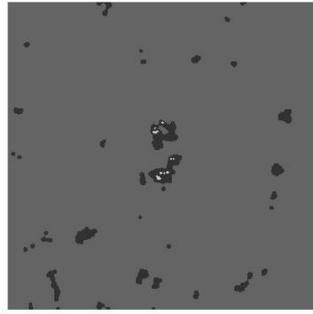
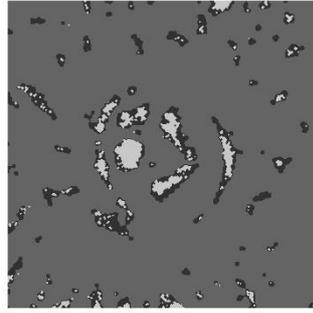
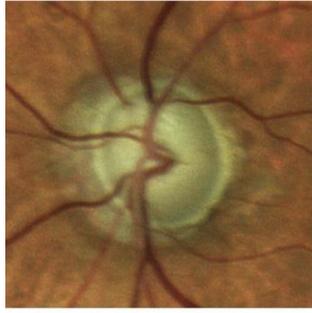
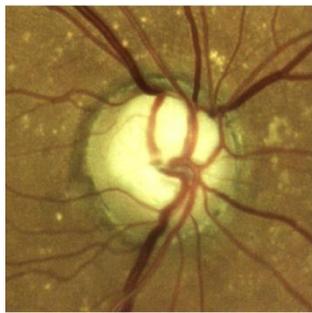
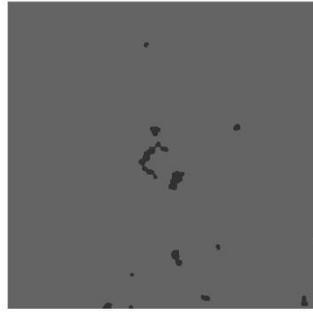
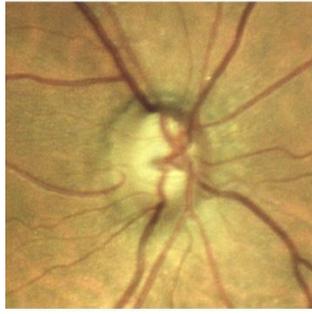
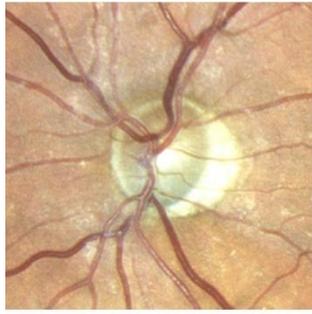
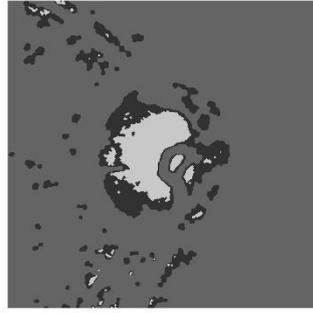
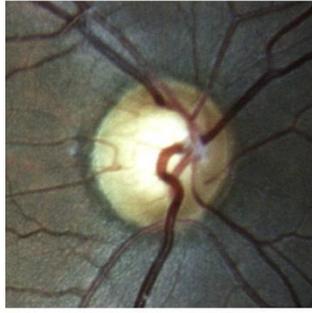
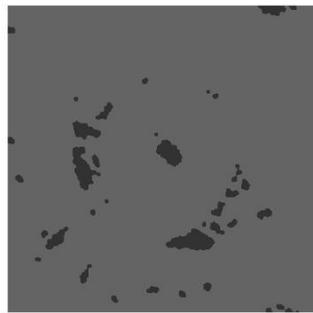
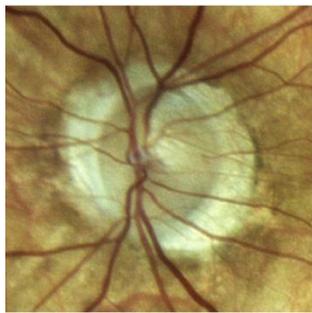
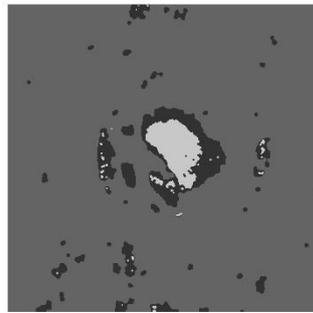
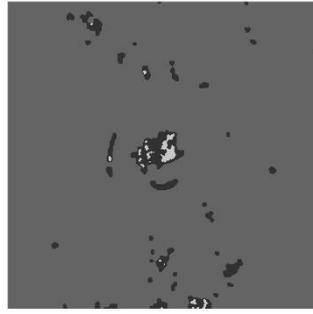
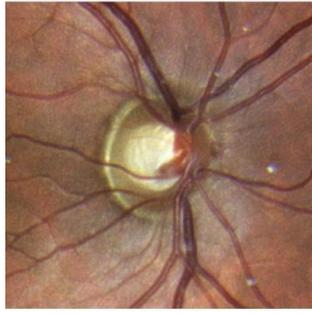
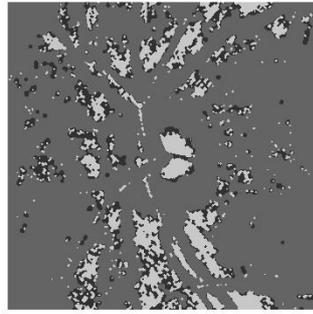
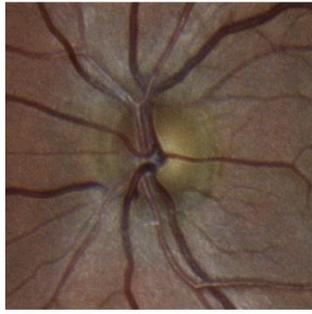
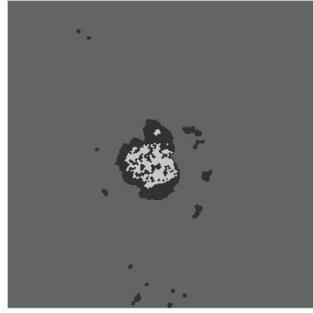
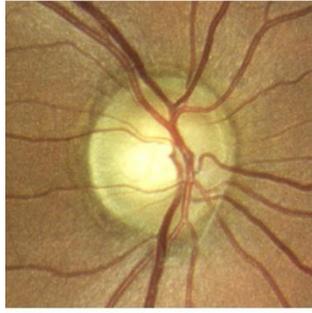


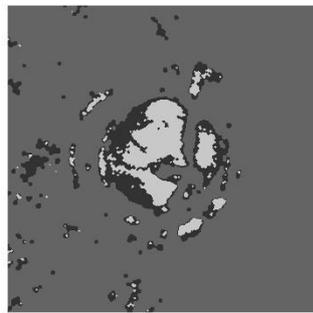
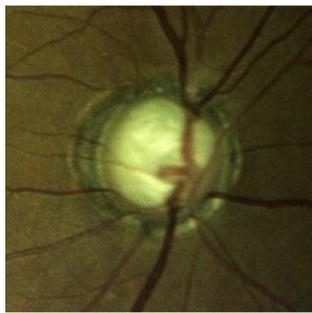
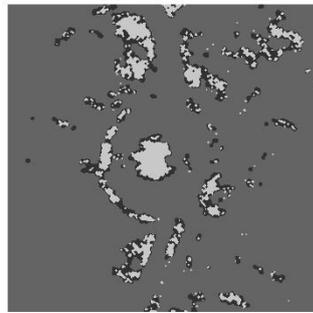
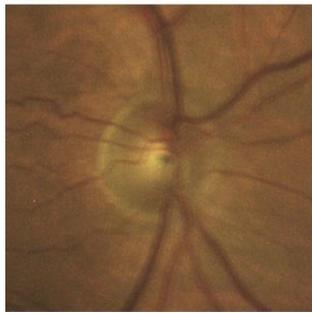
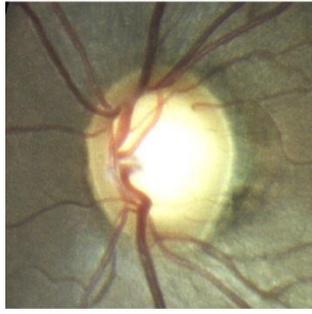
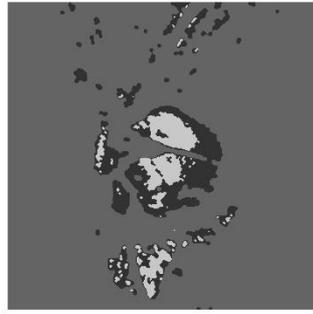
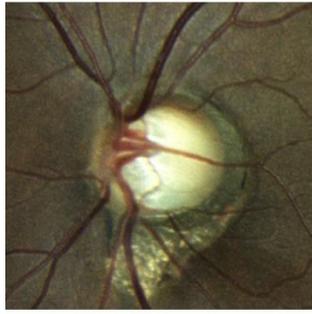
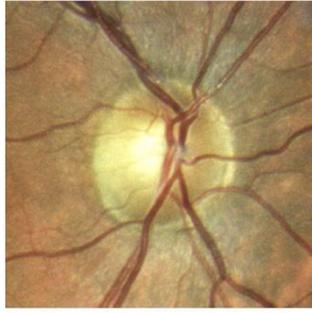
Imagen segmentada

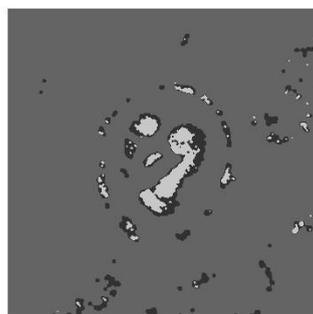
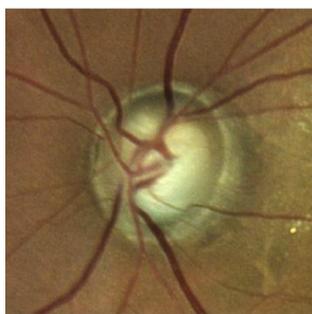
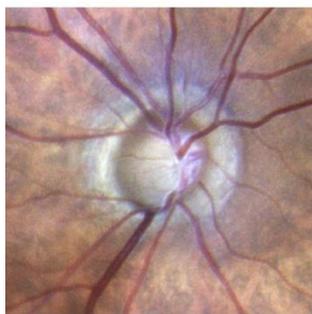
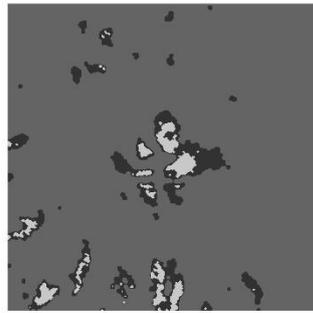
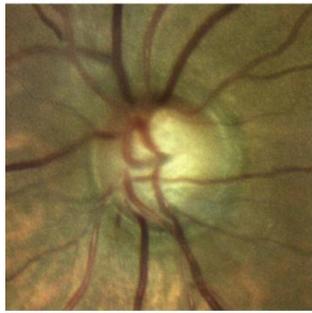
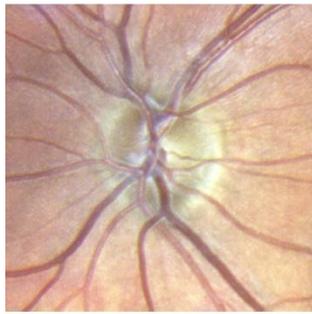
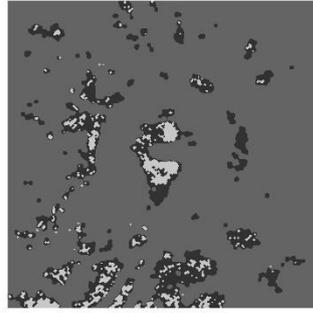






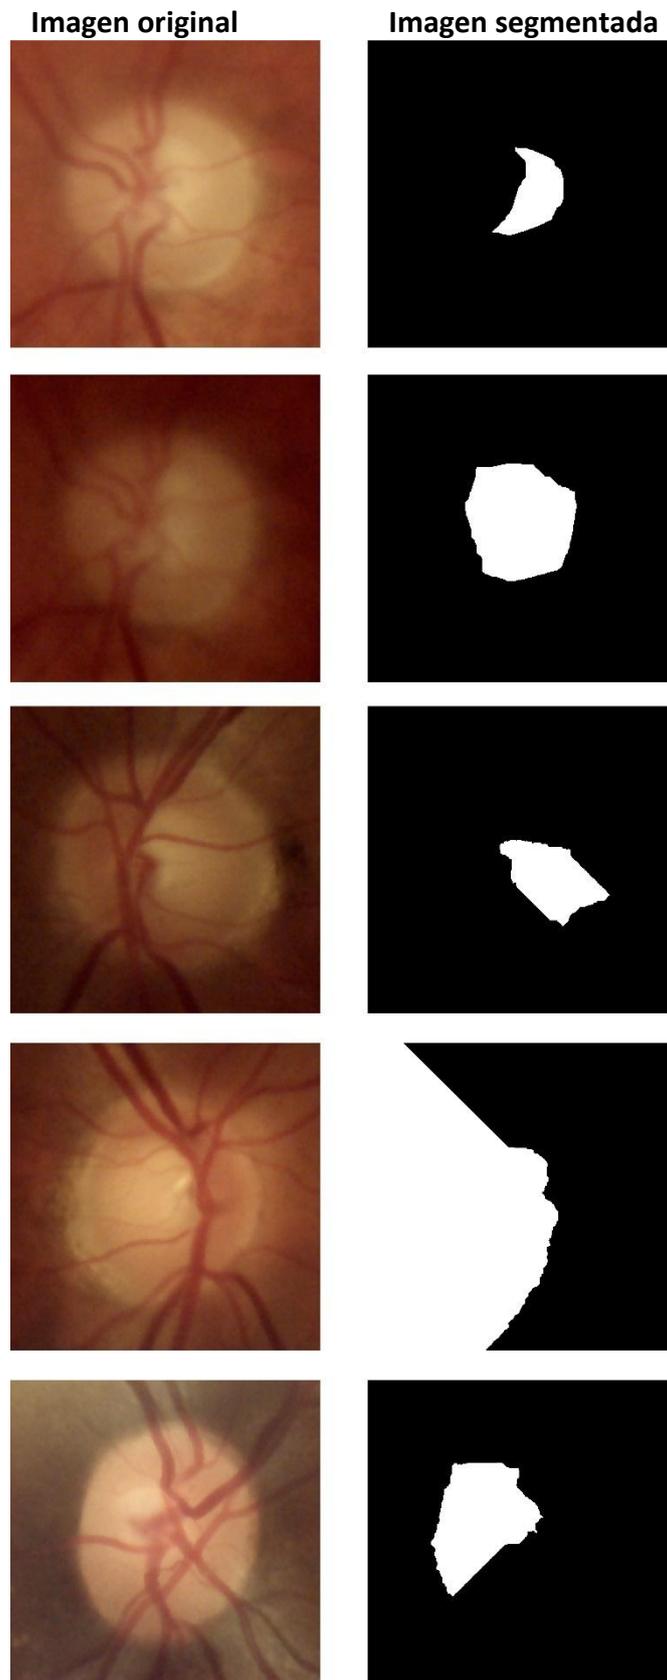


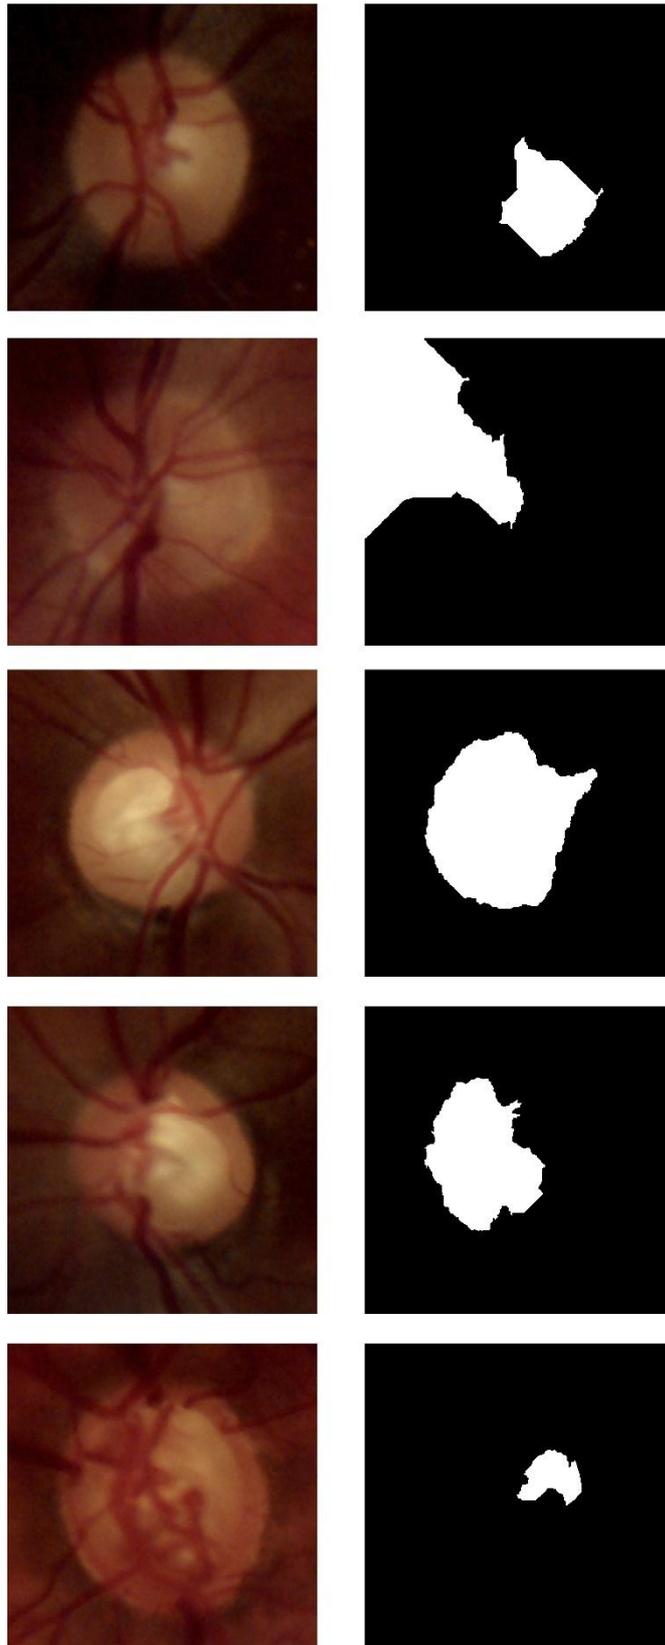


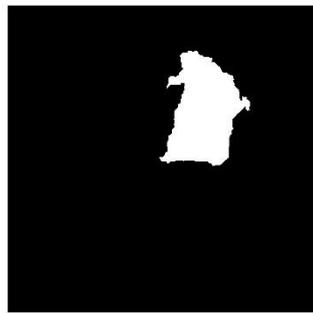
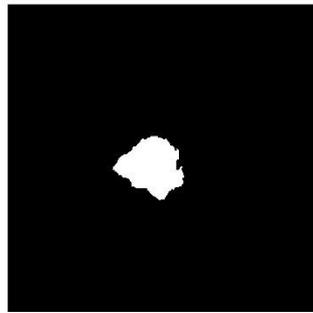
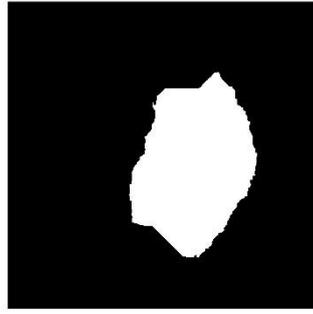
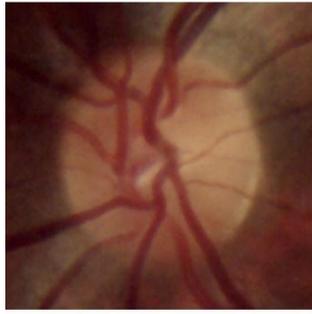
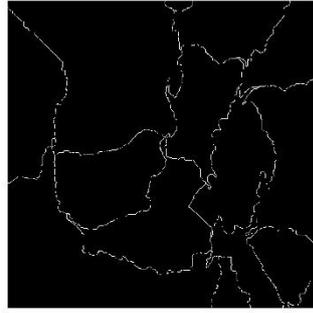
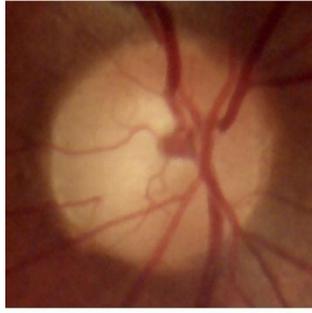


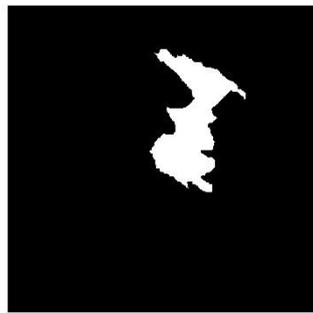
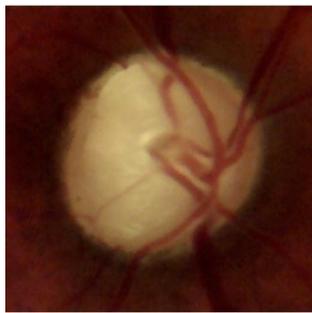
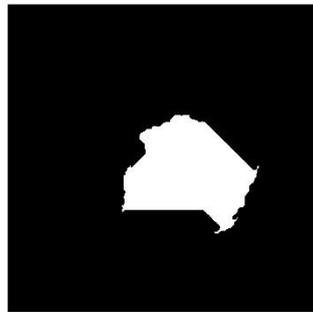
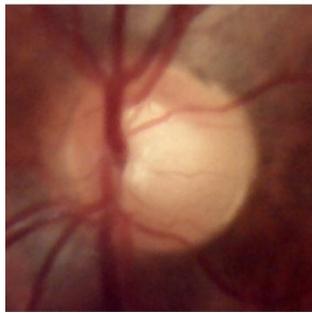
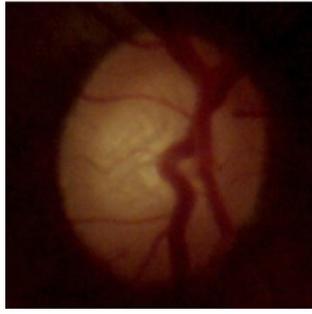
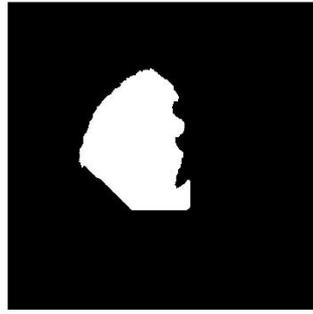
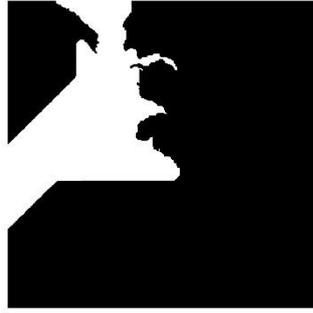
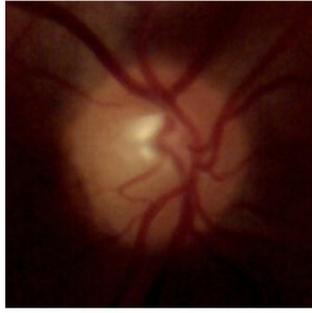
7. RESULTADOS DE [36]

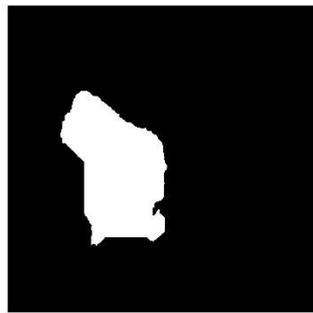
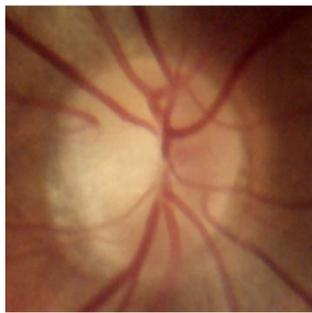
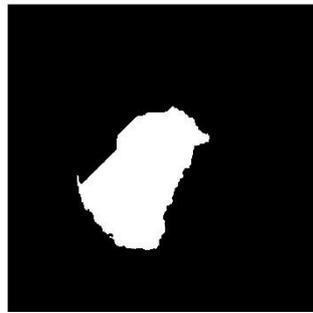
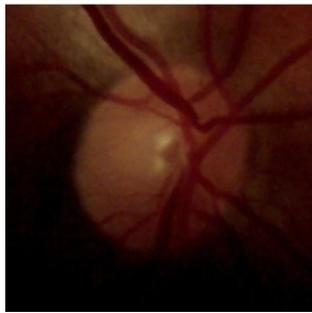
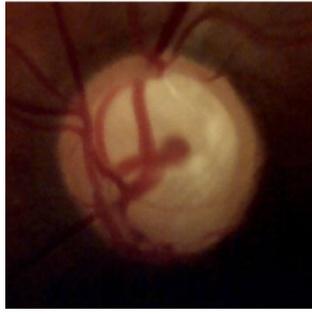
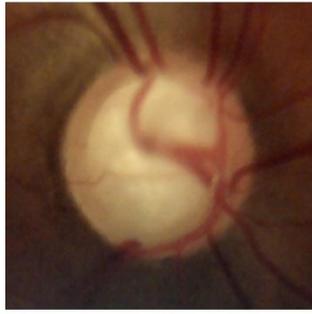
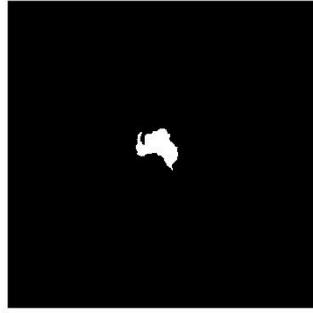
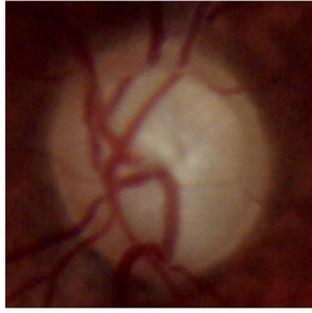
7.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS

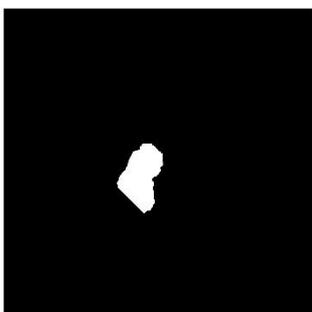
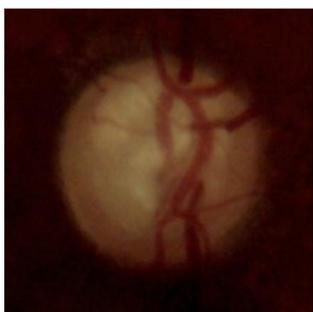
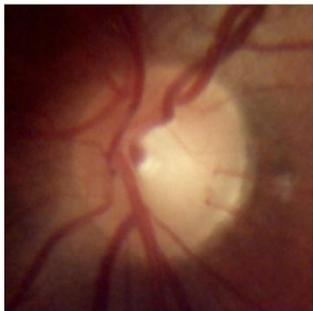
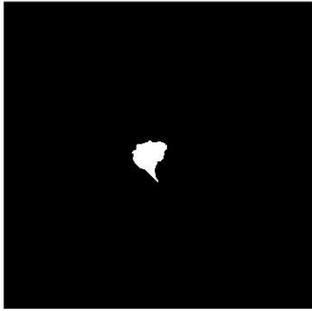
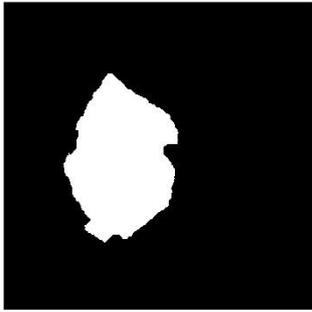
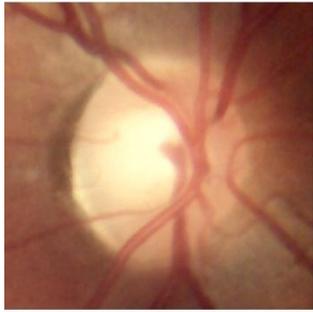
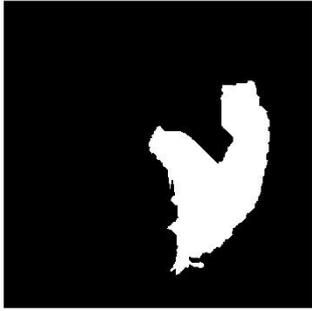
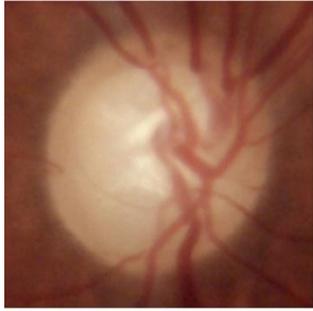




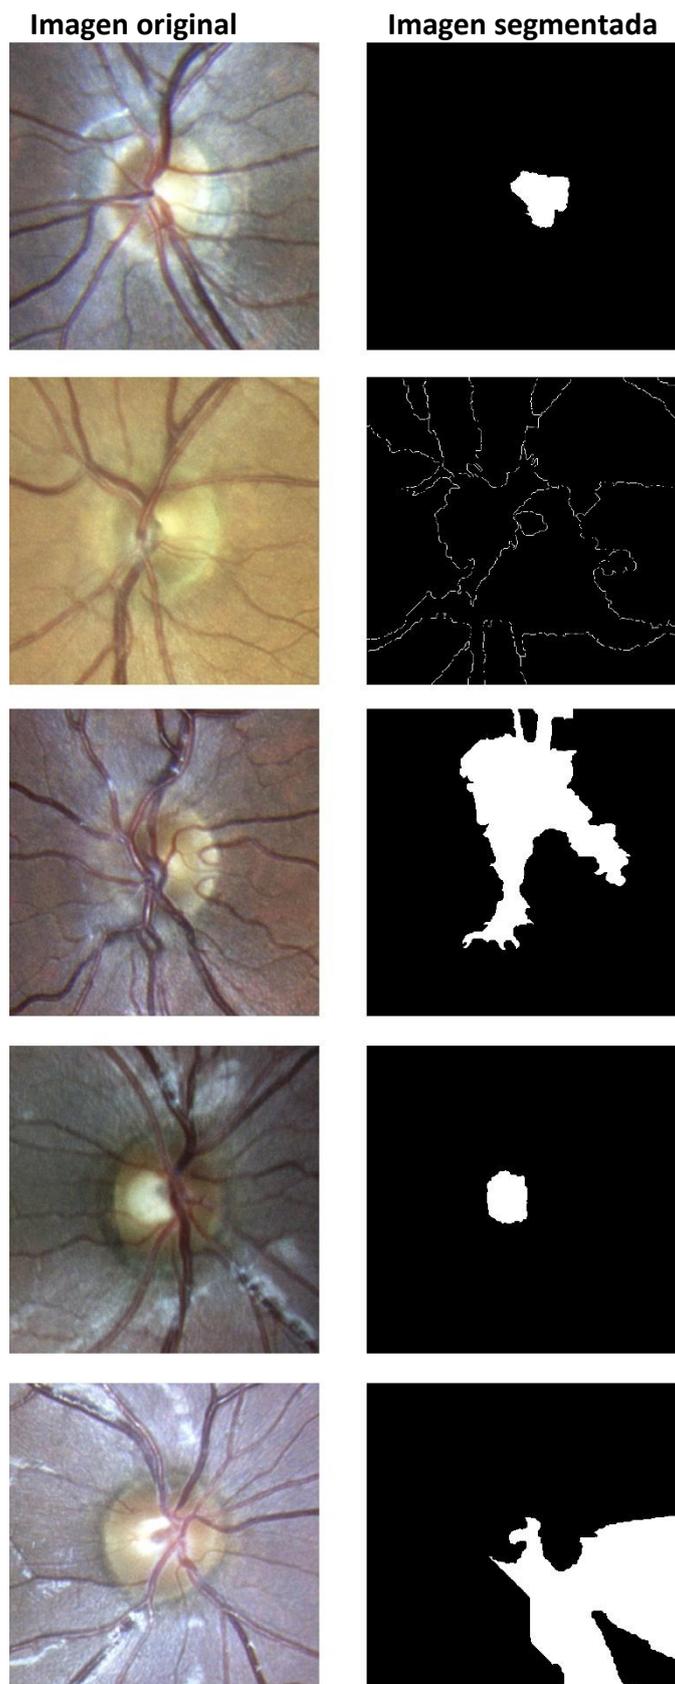


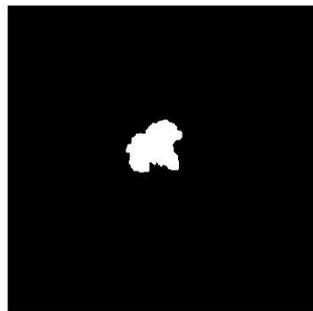
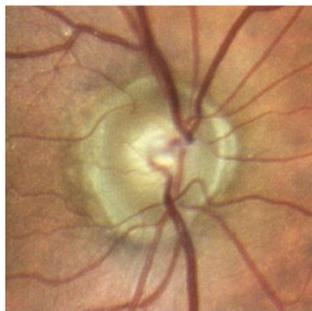
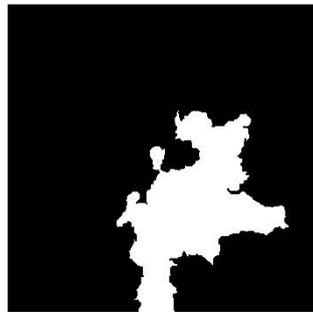
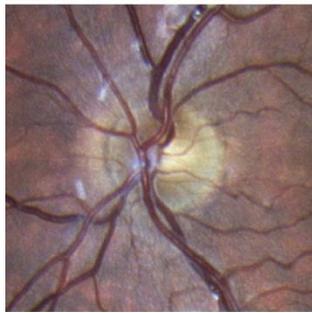
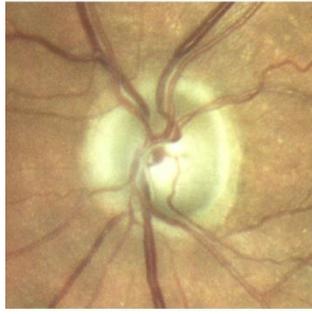
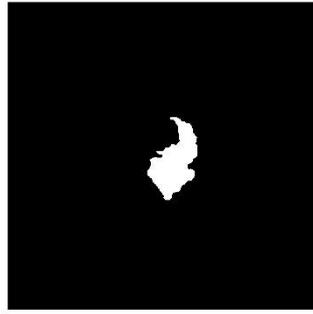
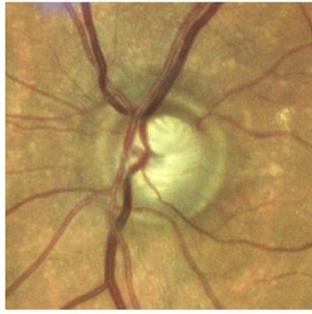
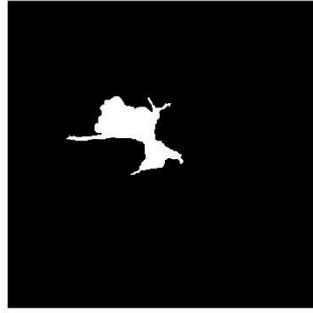
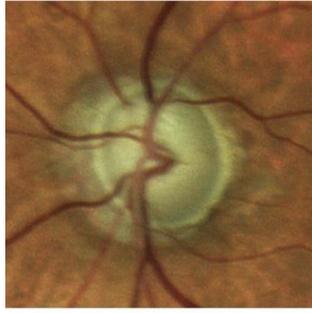


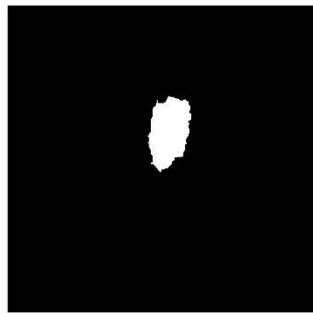
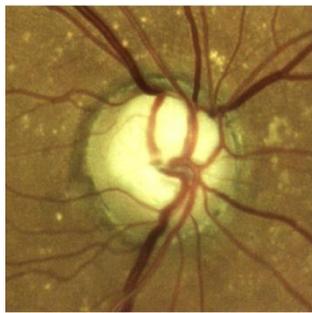
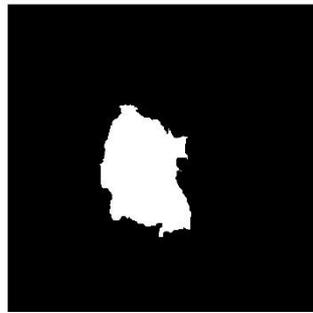
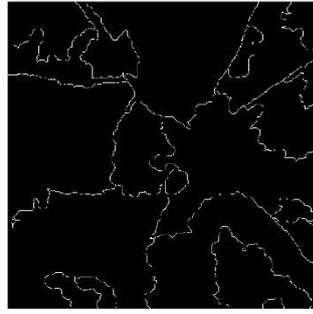
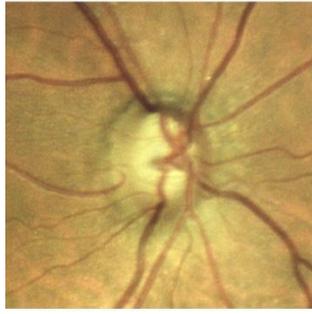
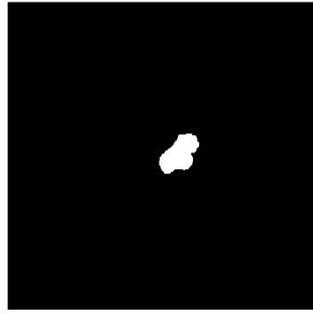
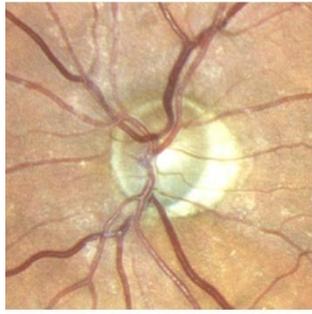
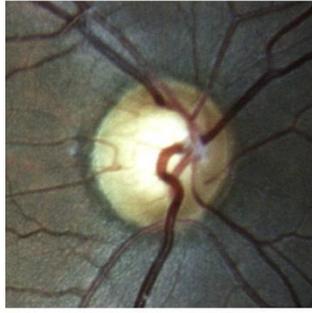


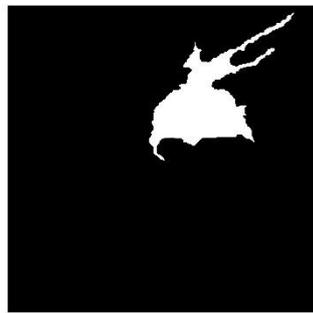
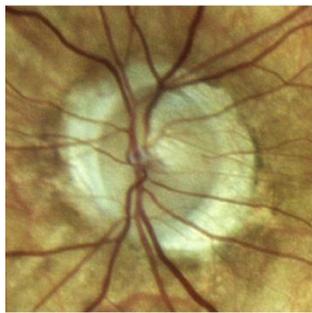
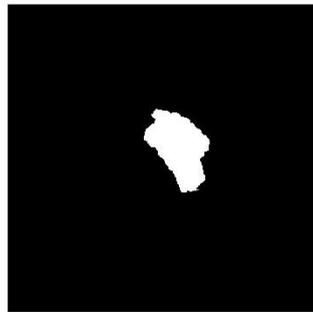
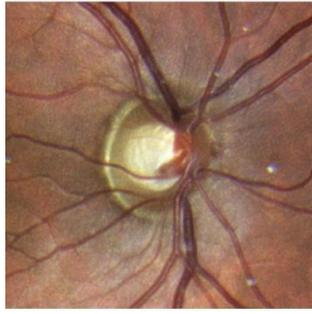
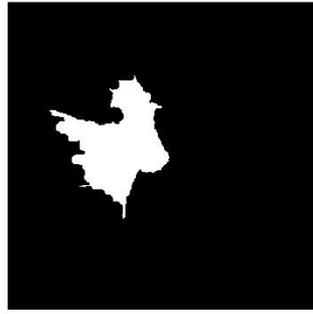
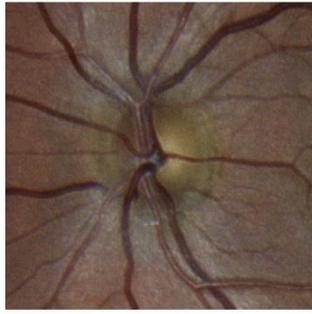


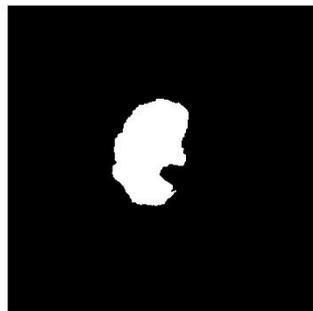
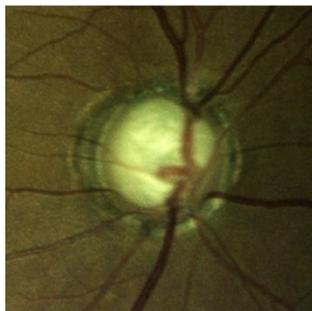
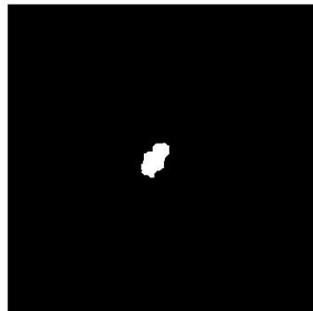
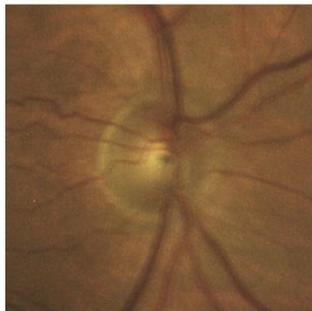
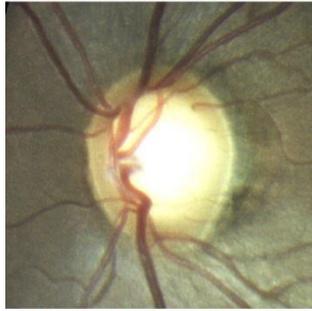
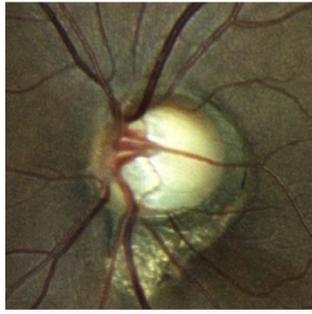
7.2. SOBRE LA BASE DE RETINOGRAFÍAS COMPASS

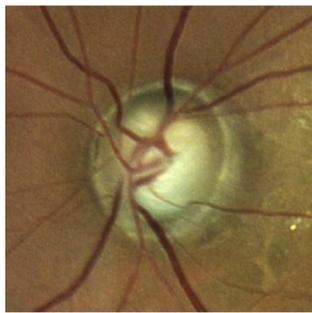
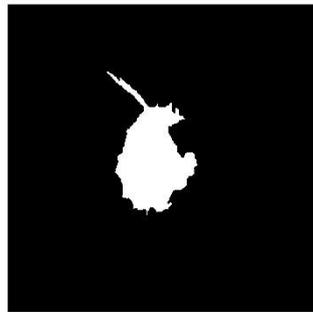
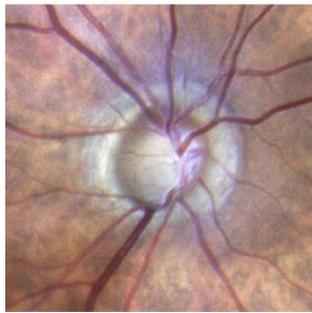
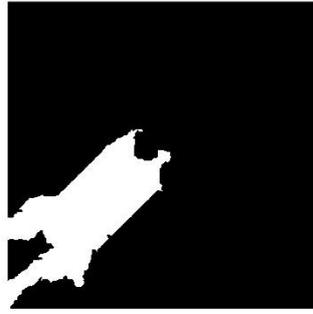
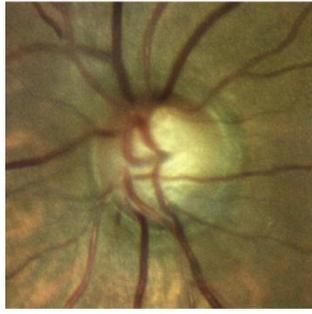
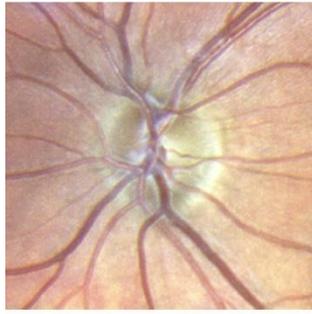








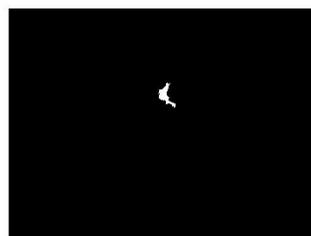
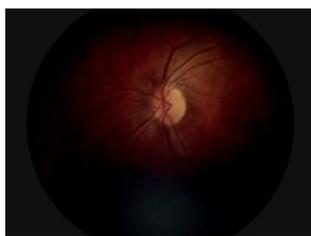
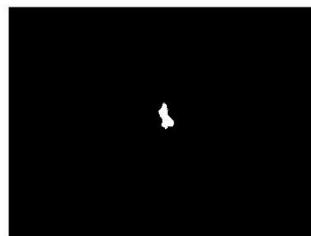
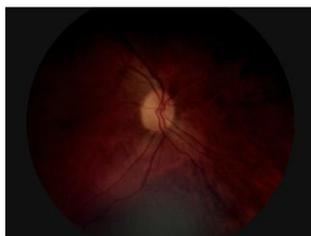
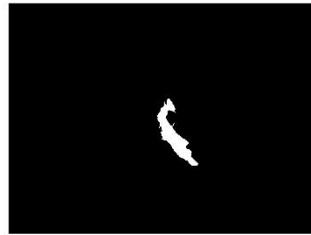
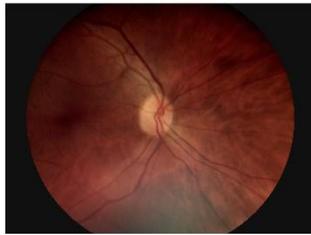
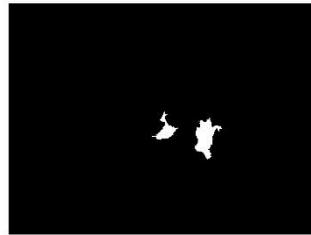
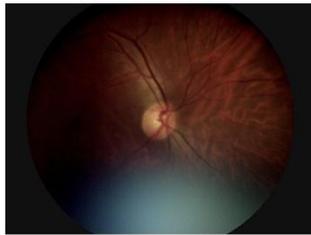
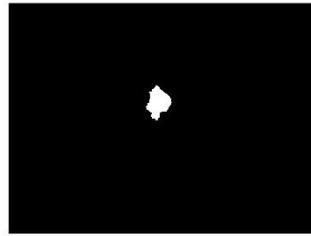
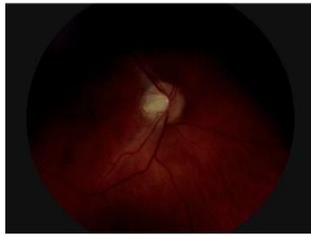




7.3. SOBRE LAS IMÁGENES COMPLETAS:

Imagen original Horus

Imagen segmentada



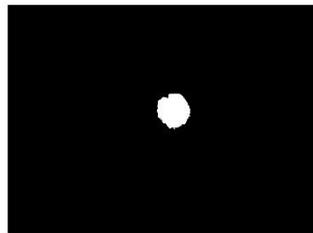
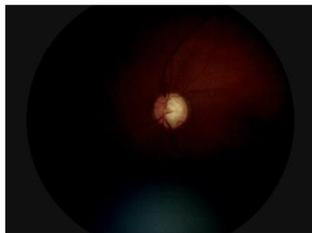
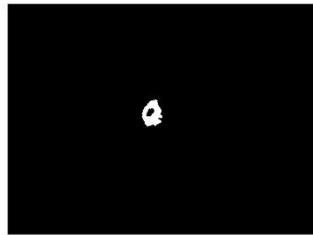
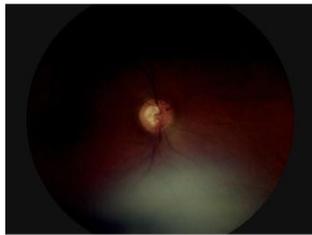
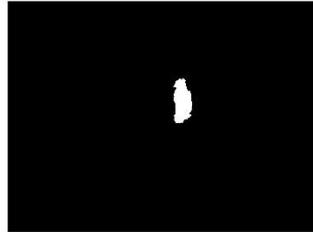
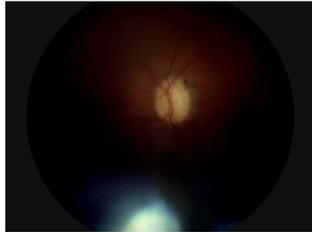
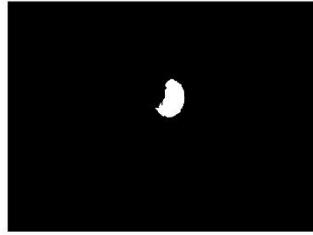
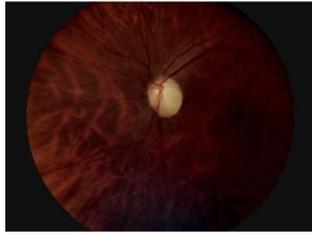
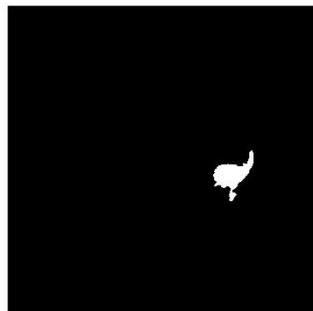


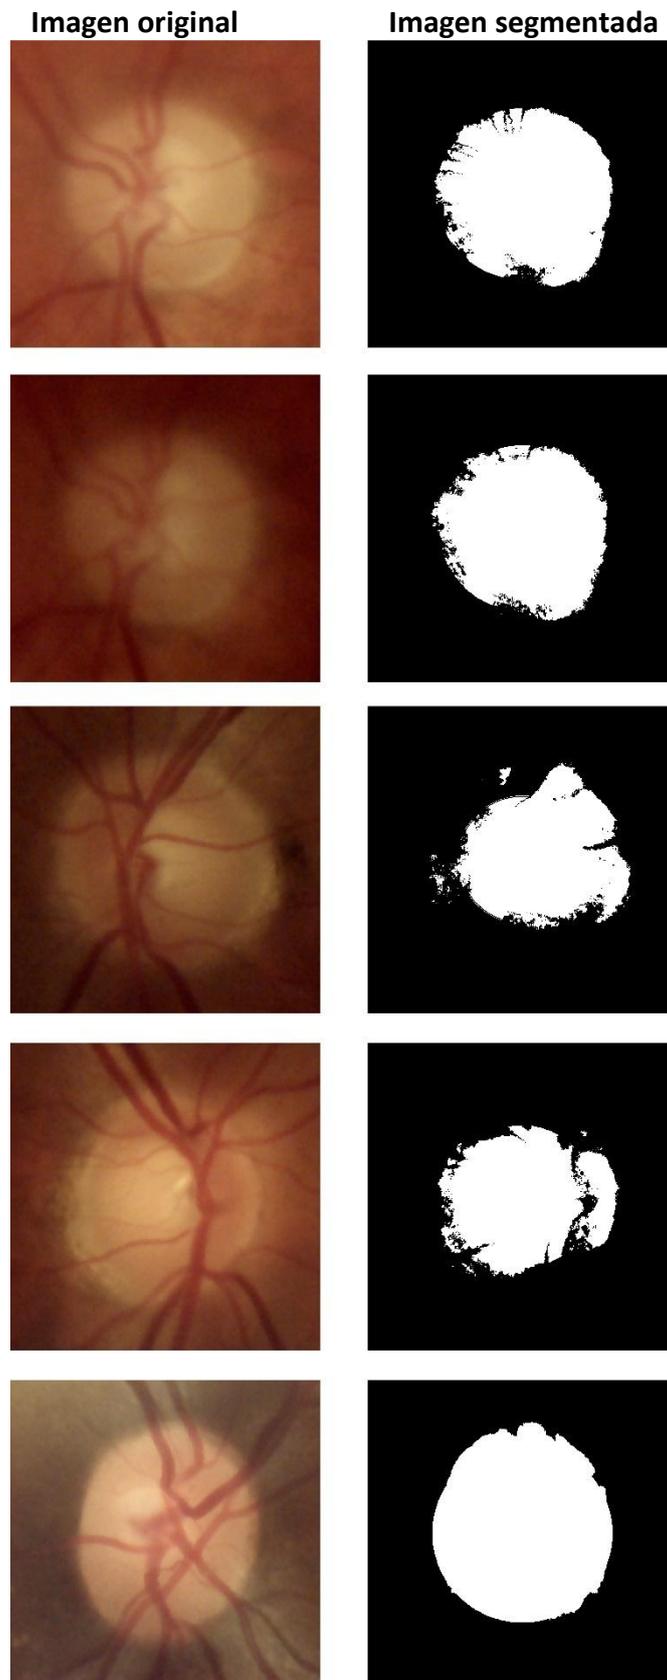
Imagen original Compass

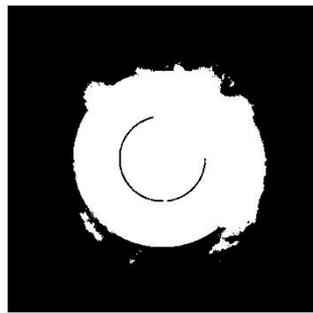
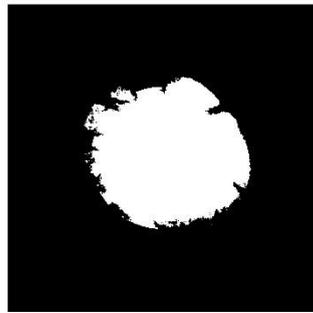
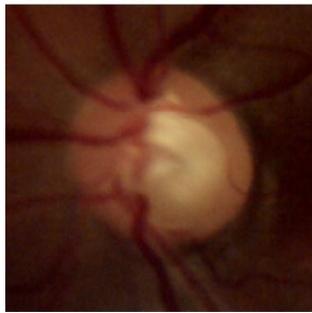
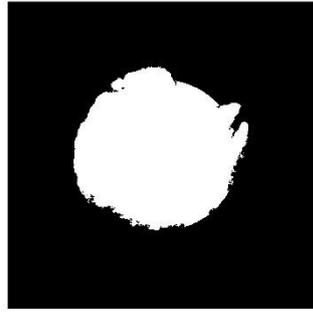
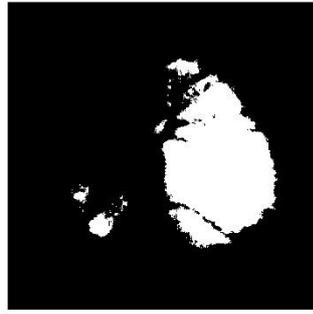
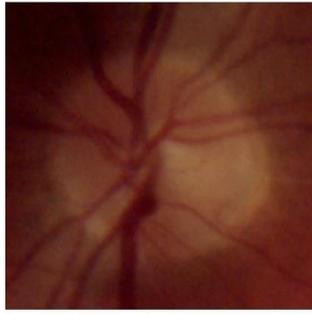
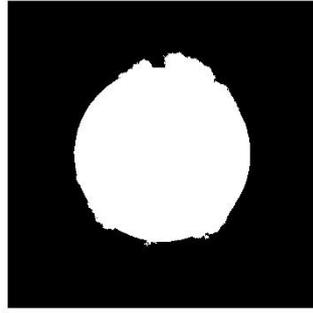
Imagen segmentada

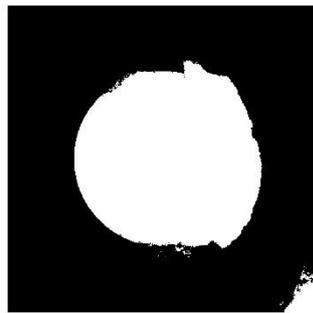
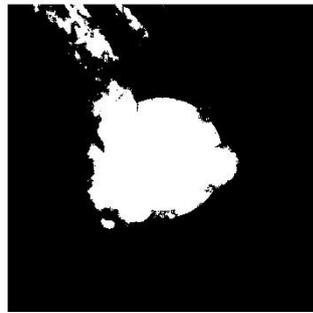
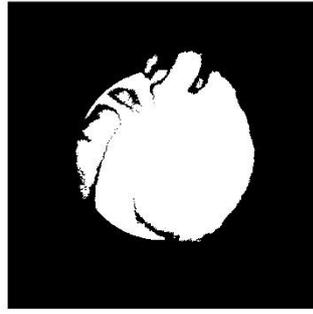
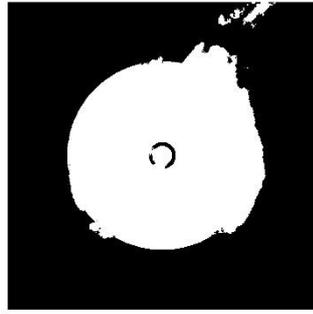
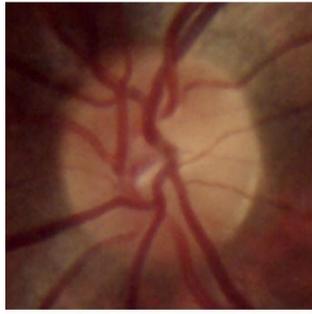
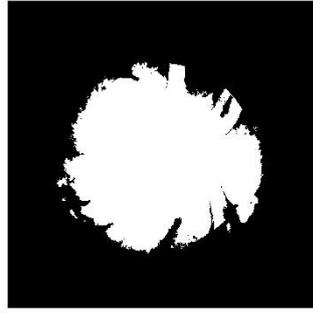
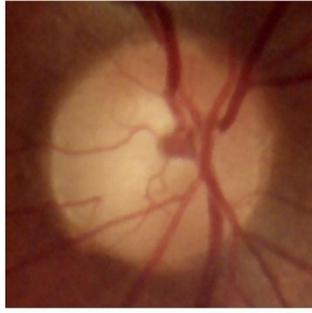


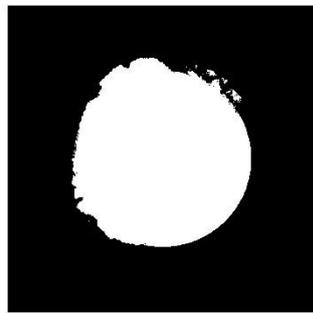
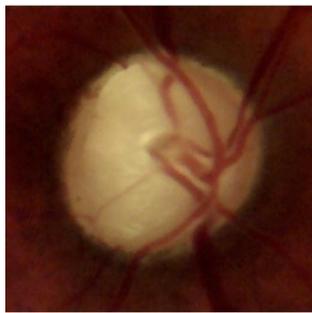
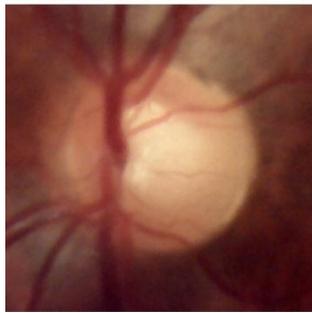
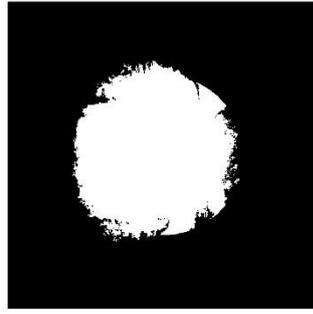
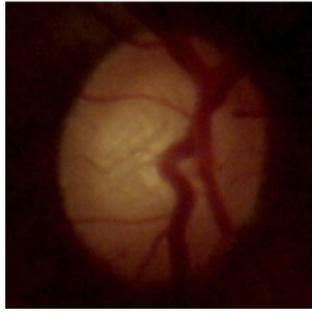
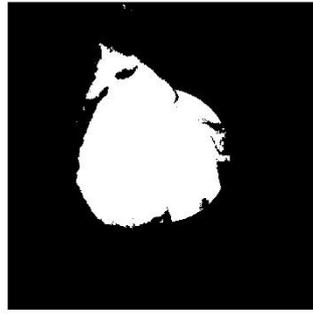
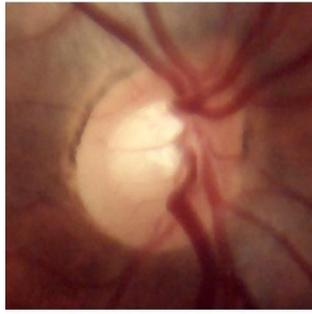
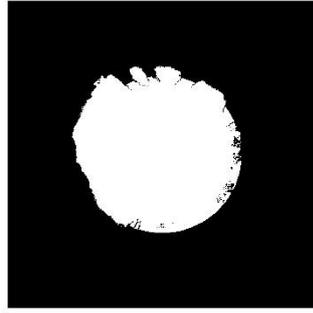
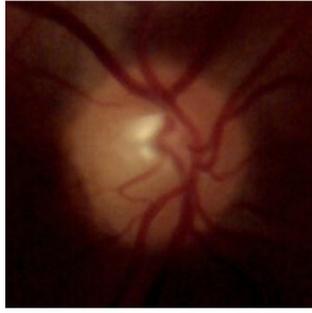
8. RESULTADOS DE [34]

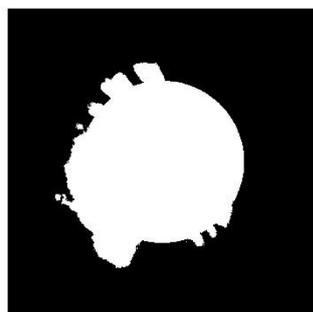
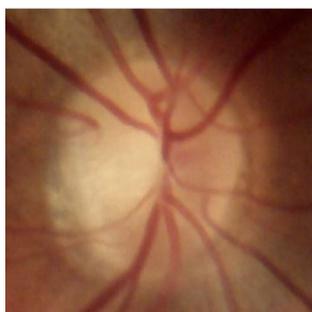
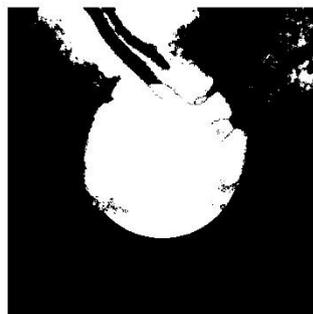
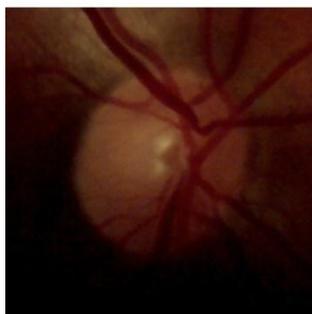
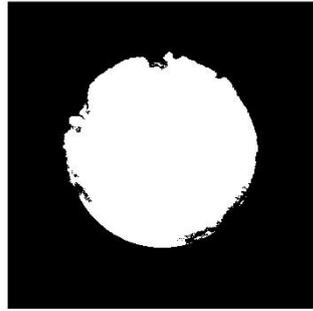
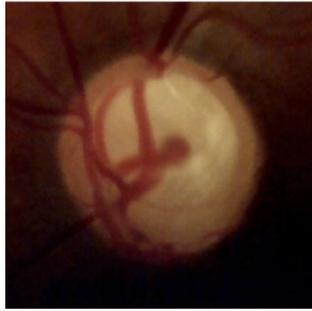
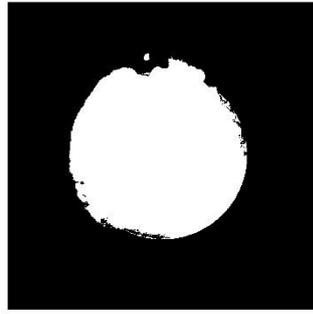
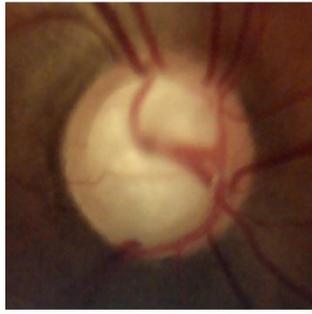
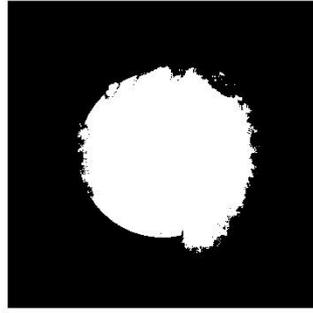
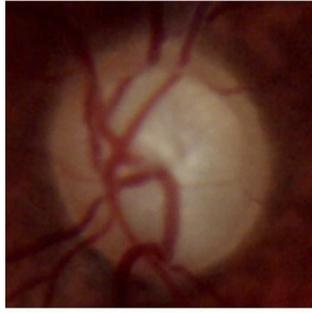
8.1. SOBRE LA BASE DE RETINOGRAFÍAS HORUS

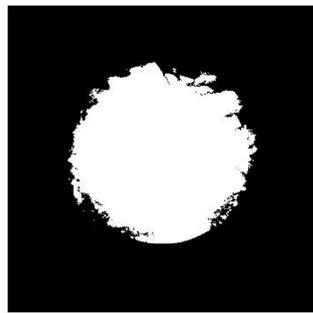
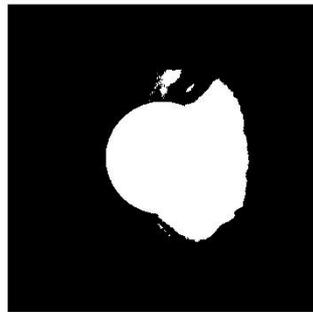
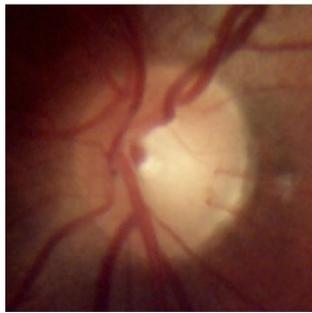
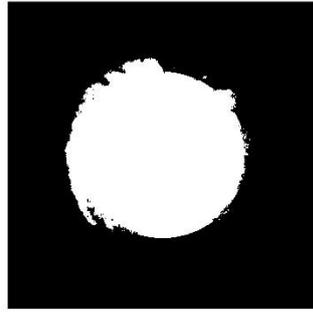
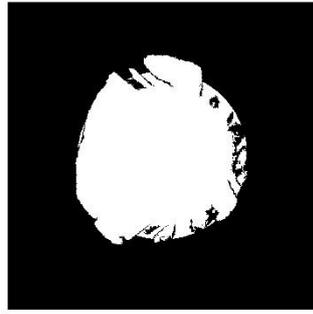
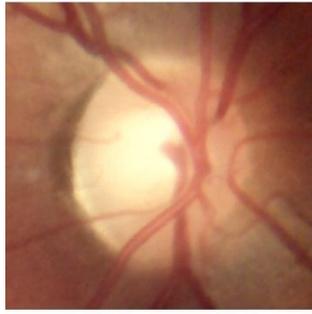
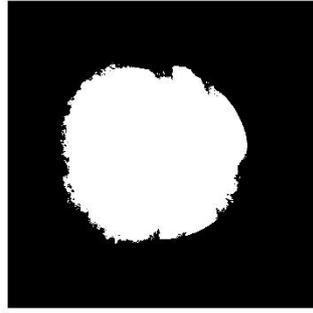
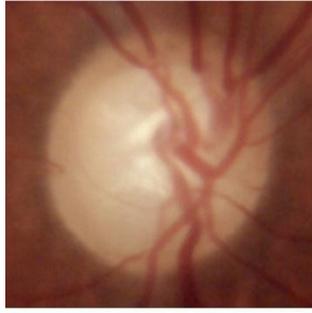












8.2. SOBRE LA BASE DE RETINOGRAFÍAS COMPASS

Imagen original

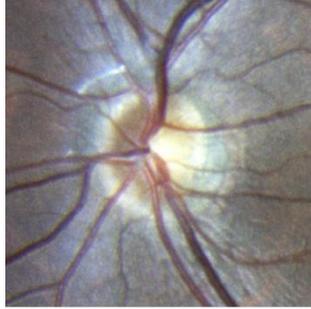


Imagen segmentada

