

UNIVERSIDADE DE SANTIAGO DE COMPOSTELA
DEPARTAMENTO DE ELECTRÓNICA E COMPUTACIÓN



TESIS DOCTORAL

**DETECCIÓN AUTOMÁTICA DEL ÁRBOL
VASCULAR RETINAL EN IMÁGENES DE
FONDO DE OJO**

Presentada por:
Lucía Espona Pernas

Dirigida por:
**María José Carreira Nouche
Manuel F. González Penedo**

Santiago de Compostela, Diciembre de 2008

Dra. María José Carreira Nouche,
Profesora Titular del Área de Ciencias de la
Computación e Inteligencia Artificial de la
Universidad de Santiago de Compostela

Dr. Manuel F. González Penedo,
Profesor Titular del Área de Ciencias de la
Computación e Inteligencia Artificial de la
Universidad de A Coruña

HACEN CONSTAR:

Que la memoria titulada **Detección Automática del Árbol Vascolar Retinal en Imágenes de Fondo de Ojo** ha sido realizada por Dña. **Lucía Espona Pernas** bajo nuestra dirección en el Departamento de Electrónica y Computación de la Universidad de Santiago de Compostela, y constituye la Tesis que presenta para optar al grado de Doctora en Ciencias Físicas.

Santiago de Compostela, Diciembre de 2008

Fdo: **María José Carreira Nouche**
Codirectora de la tesis de licenciatura

Fdo: **Manuel F. González Penedo**
Codirector de la tesis de licenciatura

Fdo: **Javier Díaz Bruguera**
Director del Departamento de
Electrónica y Computación

Fdo: **Lucía Espona Pernas**
Autora de la tesis de licenciatura

A mis padres.

Agradecimientos

Esta tesis doctoral, si bien ha requerido de mucho esfuerzo y dedicación por parte de su autora, no hubiese podido ser llevada a cabo sin las personas e instituciones que han participado en este trabajo. Durante estos años han sido muchas las personas cuyo apoyo y confianza han constituido un soporte muy importante en momentos difíciles, y a quienes quiero expresar mi gratitud por la ayuda desinteresada que me han prestado.

En primer lugar quiero agradecer sinceramente a mis directores por el tiempo que me han dedicado y por su paciencia en las correcciones. Además han contribuido a orientar y ampliar mi formación como investigadora y me han aportado consejos y observaciones que he procurado seguir en la medida de lo posible.

También deseo expresar mi agradecimiento a los centros donde he desarrollado parte de mi doctorado, el Departamento de Electrónica y Computación (USC) y el Departamento de Computación (UDC), por los servicios y medios dispuestos durante los años que he realizado en ellos mi labor de investigación.

No puedo olvidar a mis compañeros del GVA y VARPA que me han ayudado y escuchado durante las incontables horas de trabajo que hemos compartido. Quiero dar las gracias en especial a Marcos y David por su amabilidad y colaboración que me han permitido resolver multitud de dificultades y problemas técnicos surgidos durante la consecución de esta tesis.

A nivel personal ha sido indispensable el haber podido contar con el respaldo incondicional de mis padres, mi hermana y Diego que me han apoyado desde el principio y han creído en mí en todo momento.

La financiación de este trabajo ha sido posible gracias a los proyectos del Ministerio de Ciencia y Tecnología (Sistema Distribuido para Medida del Calibre Retiniano (SID-MECAR), TIC2003-04649-C02-01) y la Xunta de Galicia (Técnicas de visión artificial para medida del calibre retiniano, PGIDIT04PXIC-20602PN).

Diciembre de 2008

Prólogo

Un buen diagnóstico basado en imágenes médicas necesita tanto de una buena adquisición de la imagen como de una correcta interpretación de la misma. Respecto al primer punto, los avances tecnológicos han tenido un gran impacto en la mejora de los procesos de adquisición y almacenamiento de imágenes médicas. En cuanto a la interpretación de las mismas, la participación de las ciencias de la computación está en continua evolución, buscando nuevas técnicas que ayuden al personal médico a interpretar las imágenes de forma fiable y eficiente. Existe un número creciente de aplicaciones para la interpretación de múltiples tipos de imágenes médicas, como radiografías, angiografías, ecografías, tomografías, endoscopias o resonancias. Así, se han desarrollado múltiples sistemas que se emplean en el diagnóstico y estudio de patologías muy diversas, realizando de forma automática la localización de tumores en diferentes tejidos, extracción de malformaciones, segmentación de órganos, detección de distintos tipos de lesiones, etc.

Gracias a estas aplicaciones para el procesado automático de imágenes médicas, los expertos pueden disponer rápidamente de información de partida repetible y de mayor precisión para el proceso de diagnóstico. Se evitan de este modo los problemas que habitualmente presenta el análisis manual, tales como la gran cantidad de tiempo y esfuerzo necesarios, así como la presencia de valoraciones subjetivas y errores. El facultativo deberá aun así estudiar los resultados obtenidos, pero su tarea se ve facilitada en gran medida con la ayuda de estos sistemas de procesado y análisis de imágenes médicas. En un futuro, este tipo de sistemas incluso podrían hacer posible la evaluación periódica a gran escala a todo paciente que se encuentre en el grupo de riesgo de una determinada patología, antes de que muestre sus síntomas. De este modo, se incrementaría la efectividad del tratamiento y se evitarían daños irreversibles, consecuencia de la masificación de consultas al especialista.

Esta tesis se ubica en el ámbito del análisis de las imágenes de fondo de ojo, también denominadas retinografías digitales, y más concretamente en la segmentación automática de la vasculatura retinal. Las estructuras vasculares presentes

en las imágenes de fondo de ojo son estudiadas para la detección y seguimiento de diversas patologías, como son la retinopatía diabética, la hipertensión arterial, la arteriosclerosis, enfermedades cerebrovasculares, problemas cardiovasculares y otras patologías vasculares sistémicas. Fuera del ámbito médico, el árbol vascular es utilizado además en sistemas de autenticación biométrica, por ser único para cada individuo, como la huella dactilar.

Existe pues una necesidad clara de una herramienta para realizar automáticamente un análisis preciso, repetible y eficiente del árbol vascular de la retina. No es una tarea sencilla, ya que las retinografías presentan frecuentemente ruido, contraste insuficiente e iluminación inadecuada. Otra desventaja es la alta variabilidad anatómica entre pacientes y la estructura de la vasculatura retinal. A pesar de todo ello, se han desarrollado hasta el momento métodos muy prometedores, capaces de obtener una segmentación adecuadamente precisa, pero que presentan una eficiencia reducida para su aplicación real.

El modelo desarrollado en esta tesis propone una nueva metodología para detectar automáticamente el árbol vascular en imágenes de fondo de ojo. Este nuevo sistema está inspirado en el modelo de contorno deformable clásico, pero incorpora conocimiento específico del dominio, como son las propiedades topológicas de los vasos sanguíneos. Los contornos activos o snakes permiten integrar información extraída de la imagen por diversas técnicas. Así, este modelo se beneficia de las diferentes aplicaciones desarrolladas en nuestro grupo de investigación, y que iremos introduciendo en los siguientes capítulos, constituyendo un sistema de segmentación fiable y robusto.

Para evaluar nuestro sistema, se ha realizado una validación contra la base de datos de retinografías DRIVE[SAN⁺04] creada especialmente para facilitar los estudios comparativos de la segmentación de vasos sanguíneos en imágenes retinales. Esta base de datos de imágenes es de libre acceso y nos permite evaluar la calidad de nuestros resultados, comparándolos tanto con los obtenidos por humanos expertos como por otros métodos. La detección de estructuras arterio-venosas realizada por nuestro sistema alcanza una notable precisión y una eficiencia muy superior a otros métodos existentes, como se mostrará en los resultados finales.

Como muestra de la utilidad del método aquí presentado, se ha desarrollado una aplicación para el cálculo del índice arterio-venoso. Dicho índice es esencial para el diagnóstico y monitorización de la evolución de un gran número de patologías, entre las que destacan la retinopatía diabética, la arteriosclerosis y la hipertensión, además de permitir la evaluación objetiva de fármacos y tratamientos para dichas enfermedades. Tras contrastar los valores obtenidos con los de otros métodos automáticos validados por oftalmólogos, podemos afirmar la alta fiabilidad de nuestro método.

Índice general

Prólogo	9
1. Introducción	1
1.1. La Imagen de Retina	3
1.2. Segmentación del Árbol Vascular Retiniano	9
2. Modelo Clásico de Snakes	15
2.1. Clasificación de Modelos de Snakes	17
2.2. Modelo de Snake Clásico	19
2.2.1. Discretización del Snake	25
2.2.2. Evolución del Contorno	27
2.2.3. Minimización de la Energía	28
3. Contorno Deformable para Segmentación	31
3.1. Preprocesado de la imagen	32
3.1.1. Conversión a Escala de Grises	33
3.1.2. Selección del Nivel de Precisión	34
3.2. Energía del Snake	36
3.2.1. Términos de Energía	36
3.2.2. Mejora de las Imágenes de Energía	44
3.2.3. Estructura del Snake	53

3.3.	Inicialización	57
3.4.	Evolución del Contorno	59
3.4.1.	Desplazamiento de los Nodos	62
3.4.2.	Inserción de Nuevos Nodos	65
3.4.3.	Operaciones de Control	66
4.	Resultados	73
4.1.	Base de Datos de Retinografías DRIVE	74
4.2.	Preprocesado	76
4.2.1.	Mejora aportada por Nivel de Subpíxel	79
4.2.2.	Comparación entre Métodos de Interpolación	80
4.3.	Parámetros del modelo	84
4.3.1.	Parámetros de Detección y Mejora de Crestas	84
4.3.2.	Parámetros de Detección y Mejora de Bordes	86
4.3.3.	Parámetros de Detección Automática del Disco Óptico	93
4.3.4.	Parámetros del Snake	94
4.4.	Comparación con otros Métodos	96
5.	Aplicación: Cálculo del Índice AV	107
5.1.	Sistema para el Cálculo del Índice AV	108
5.1.1.	Estimación Puntual del Calibre Vascular	110
5.1.2.	Ejemplo Completo Paso a Paso	112
5.2.	Validación de Resultados	121
5.2.1.	SIRIUS	121
5.2.2.	Comparación de Resultados	123
	Conclusiones	127
A.	Procesos Auxiliares al Modelo	137

A.1. Interpolación Bicúbica	137
A.2. Extracción de Crestas	142
A.2.1. Definición de Crestas	142
A.2.2. Descripción del Método de Extracción	143
A.2.3. Ajuste de Parámetros	145
A.3. Extracción de Bordes	146
A.4. Segmentación Morfológica Auxiliar	149
A.5. Detección Automática del Disco Óptico	153

Bibliografía	159
---------------------	------------

Índice de figuras

1.1. (a) Corte transversal del ojo en el que se puede apreciar su anatomía. (b) Imagen de fondo de ojo.	4
1.2. (a) Ejemplo de captura de una imagen de fondo de ojo digital (Imagen cortesía del Dept. of Medical Illustration, University of Aberdeen). (b) Cámara digital Canon para la fotografía de retina.	5
1.3. Fotografías de retina que contienen signos de retinopatía. (a) Hemorragias (círculos negros) y microaneurismas (círculos blancos). (b) Exudados (círculos negros)	7
1.4. Ejemplo de imagen de fondo de ojo.	8
1.5. Porción ampliada de una imagen de fondo de ojo cuyo árbol vascular presenta reflejo central.	9
2.1. Esquema de un snake discreto compuesto por un conjunto de vértices v_i conectados por los segmentos s_i y sobre los que actúan las fuerzas ϵ_i	26
2.2. Ventanas $n \times n$ de movimiento de un nodo del snake. El punto central representa las posición actual y los puntos blancos las nuevas posiciones a las que puede desplazarse. Izquierda: $n = 3$; derecha: $n = 5$	27
3.1. Diagrama que representa el proceso global de ejecución del modelo. . . .	32
3.2. Diagrama que representa las operaciones de preprocesado de la imagen original (conversión a escala de grises y ampliación al doble de su tamaño) situadas en el marco del proceso completo de ejecución del modelo. . . .	33
3.3. Ejemplo de conversión a escala de grises.	34
3.4. Diagrama que representa dentro del proceso global de segmentación, las operaciones de obtención de información de la imagen (crestas, bordes y segmentación morfológica auxiliar) que se emplearán como energías externas en el proceso de evolución del snake.	37

3.5. Resultados de la extracción de bordes, representados en blanco y superpuestos a la imagen original.	38
3.6. Energía de distancia a bordes ϵ_{borde}	39
3.7. Resultados de la extracción de crestas, representadas en blanco y superpuestas a la imagen original.	40
3.8. Energía de distancia a crestas ϵ_{cresta}	41
3.9. Solución de los desbordamientos causados por las discontinuidades del borde mediante las crestas: (a) Situación de discontinuidad en el borde (línea blanca gruesa) que produce en la zona señalada con una flecha, un desbordamiento del snake. (b) Solución del problema por bloqueo del contorno (nodos tachados) al alcanzarse el límite de distancia a cresta (línea blanca punteada).	41
3.10. Presión de Inflado: (a) Movimientos posibles del nodo dependiendo de la dirección asignada. (b) Situación de ejemplo que muestra la utilidad de las posiciones alternativas de avance: el nodo que tiene asignada la dirección de la flecha puede moverse también a las posiciones A y C situadas en el borde (cuadrados oscuros). Sin estas alternativas, sólo podría moverse a la posición B y por tanto saldría fuera del vaso a través de su borde. . . .	42
3.11. Energía de marcador ϵ_{marca} : Detalle del mapa actualizándose por triangulación debido al desplazamiento de un nodo. El nodo situado en la parte punteada del snake se mueve, tal y como indica la flecha. La nueva área en el interior del contorno deformable (representada en blanco) se marca como ya visitada por un nodo.	43
3.12. Mejora de la continuidad de las crestas por unión de extremos. Las flechas destacan puntos en donde el efecto de la mejora es más evidente.	46
3.13. Ejemplo de extracción de puntos característicos.	47

3.14. Mejora de bordes. La línea punteada blanca representa las crestas, las líneas negras gruesas son los bordes originales, las líneas gris oscuro más finas se corresponden con los bordes de la segmentación morfológica añadidos y el área gris claro bordeada por una línea blanca es la segmentación realizada por el snake. Comparando la zona inferior izquierda de ambas imágenes, se aprecia cómo en la imagen (a) el snake se desborda en la bifurcación sin llegar a segmentar el vaso secundario mientras que en la imagen mejorada (b) sí se segmenta ya que los bordes se han mejorado al añadir los obtenidos por la segmentación morfológica. En la zona superior derecha de la imagen (a) los bordes bloquean al snake impidiéndole entrar el vaso que se cruza con el principal. Esta situación se resuelve en la imagen mejorada (b), ya que se abren los bordes mediante la información de crestas, permitiendo al snake segmentar dicho vaso.	49
3.15. Bordes extraídos de la segmentación morfológica auxiliar, representados en blanco y superpuestos a la imagen original.	50
3.16. Imagen de crestas trazadas en blanco sobre la imagen original. En el detalle de la derecha pueden apreciarse mejor las crestas detectadas erróneamente en la zona externa de la imagen. En el detalle superior se muestran las crestas espurias que aparecen en las zonas cercanas al borde del FOV.	52
3.17. Bordes detectados erróneamente en la zona externa de la imagen trazados en blanco sobre la imagen original.	53
3.18. Frente de avance típico y los tres estados posibles de un nodo. Los nodos borde están marcados con una B, los nodos normales están representados con una N y los nodos cresta se etiquetan con una C. Los píxeles gris oscuro representan el área del vaso y la línea blanca punteada corresponde a la cresta.	54
3.19. Diagrama que representa las operaciones de inicialización situadas en el marco del proceso completo de ejecución del modelo.	57
3.20. Inicialización del Snake. Los puntos marcados con una estrella se corresponden con las intersecciones del círculo inicial dibujado en blanco y negro y las crestas trazadas en blanco. Los nodos semilla, representados como puntos blancos, serán aquellos que se sitúan cerca de las intersecciones (estrellas) y estarán activos inicialmente. El resto de los nodos del contorno inicial, dibujados como puntos negros, están inactivos.	58

3.21. Inicialización del snake. A la izquierda se muestra el trazado del contorno circular inicial alrededor del disco óptico. En la figura central se muestra el cálculo de las intersecciones con las crestas que se corresponden con los puntos semilla del snake marcados con círculos negros. En la figura de la derecha se muestra el inicio de la evolución del snake, dibujado en blanco, a partir de los puntos semilla.	59
3.22. Diagrama que representa las operaciones de evolución del contorno situadas en el marco del proceso completo de ejecución del modelo.	60
3.23. Diagrama mostrando el proceso iterativo de evolución del snake. Tras construirse el contorno inicial (SNAKE INICIAL), movemos los nodos del snake (DESPLAZAMIENTO) e insertamos nuevos nodos si fuese necesario (INSERCIÓN DE NUEVOS NODOS). Después, se actualizan las energías y estados de cada nodo (ACTUALIZACIÓN). A continuación se realizan operaciones de control (OPERACIONES DE CONTROL) para verificar que el desarrollo del contorno es adecuado y se efectúan las acciones necesarias. En cada iteración comprobamos si se han desplazado nodos existentes y si se han insertado nuevos nodos. Si ninguna de estas acciones ha tenido lugar en la última iteración, se considera que el snake ha alcanzado la estabilidad y el proceso finaliza. En caso contrario, se repite el proceso cíclicamente.	61
3.24. Desplazamiento de los nodos según su estado. Cada elemento de la cuadrícula representa una posible posición para un nodo, o lo que es lo mismo, un píxel de la imagen. Los nodos del snake se corresponden con los círculos con fondo negro (inactivos) o blanco (activos). Estos últimos presentan una flecha que indica la posición a la que se desplazarán y que presentará una energía menor. El interior del vaso está representado en color blanco mientras que la zona externa es de color gris. Entre ambas se sitúan los bordes de la imagen, trazados en color negro, hacia los cuales se desplazan los nodos en estado <i>borde</i> y los <i>normales</i> , identificados con una 'B' y una 'N' respectivamente. Los nodos <i>cresta</i> , marcados con una 'C', se mueven siguiendo el curso de la cresta, representada en gris oscuro en la parte central del vaso.	63
3.25. Influencia de la presión de inflado ϵ_{dir} en el desplazamiento de los nodos del snake. En la figura de la izquierda se muestran las 8 posibles direcciones que puede determinar la presión de inflado. El diagrama del centro muestra el proceso de avance de un nodo inicialmente en la posición <i>P</i> , con dirección 3 asignada y tres posibles nuevas posiciones <i>A</i> , <i>B</i> y <i>C</i> . Cada una de las tres figuras de la derecha representan la situación que se produciría según a cuál de esas tres nuevas posiciones se desplace el nodo.	64

- 3.26. Proceso de crecimiento del snake. La imagen de la izquierda muestra el desplazamiento de los nodos a nuevas posiciones. Se actualizan sus direcciones asignadas y las distancias entre nodos son revisadas, superándose el umbral *growTh* entre los nodos *j* y *k* y entre *k* y *l*, como se ve en la imagen central. Se insertan los nuevos nodos *n* y *o* en el punto medio de los segmentos \overline{jk} y \overline{kl} respectivamente, como se ve en la figura de la derecha. 66
- 3.27. Operaciones de control de frentes. Las etiquetas de los nodos indican su estado: *C* corresponde a un nodo en estado cresta, *N* indica un nodo en estado normal y *B* un nodo en estado borde. En la figura de la izquierda se muestra un frente de avance con cinco nodos. En la figura central vemos la evolución de ese frente de avance que crece y se aproxima a una zona de bifurcación. La imagen derecha representa la creación de un nuevo frente de avance con su correspondiente nodo cresta que procede a segmentar el vaso sanguíneo superior. 67
- 3.28. Esquema de las operaciones de control realizadas sobre los frentes de avance del snake con figuras representando cada operación y su finalidad (texto en cursiva). La primera de ellas (a) consiste en controlar que en cada frente de avance exista un único nodo cresta. La figura correspondiente muestra un frente de avance en el que hay un único nodo cresta (marcado con una 'C') que sigue el recorrido de la cresta (línea discontinua gris oscuro). Otra de las operaciones es el control del número de nodos de cada frente (b), necesario cuando se producen discontinuidades en el borde (línea gruesa gris oscuro). En las dos figuras del centro vemos dos situaciones opuestas: en la superior (b.1) se muestra un frente bloqueado por tener un número excesivo de nodos (círculos negros), mientras que en la inferior (b.2) se bloquea el avance de un frente que presenta un tamaño demasiado reducido (círculos negros). Por último, se controla la distancia a la cresta del nodo del frente más cercano a la misma (c). En la figura inferior se muestra un frente de avance cuyos nodos son bloqueados (círculos negros) por encontrarse a una distancia excesiva a la cresta (línea gris discontinua). 68
- 3.29. Influencia del parámetro de anchura de vaso máxima. En (a) se muestra el caso de un máximo de anchura de vaso muy elevado que produce grandes desbordamientos. En (b) vemos la situación opuesta: un límite máximo muy reducido que no permite al snake segmentar adecuadamente las zonas de intersección, por su mayor anchura. 69
- 3.30. Influencia del parámetro anchura de vaso mínima. En (a) se representa la situación producida por establecer una anchura de vaso mínima muy reducida: el snake sale del vaso por las pequeñas discontinuidades del borde. En (b) sucede lo contrario, el límite de anchura mínima es muy grande y los capilares más finos no son segmentados. 70

4.1.	Aplicación web para el examen de resultados de segmentación sobre retinografías de la base de datos DRIVE.	75
4.2.	Comparación de resultados mediante segmentación manual por el experto de referencia (arriba) y por un observador humano independiente (abajo). El contorno final se representa en blanco sobre la imagen original.	77
4.3.	Tipos de error en la clasificación binaria de píxeles de una imagen como pertenecientes bien a un vaso o bien al fondo. Los verdaderos positivos (TP) son píxeles correctamente clasificados como parte de un vaso y los verdaderos negativos (TN) son los clasificados como parte del fondo acertadamente. Los falsos positivos (FP) son los píxeles clasificados como formando parte de un vaso incorrectamente y los falsos negativos (FN), los clasificados erróneamente como pertenecientes al fondo. El número total de píxeles clasificados será $P + N$, o equivalentemente $P' + N'$	78
4.4.	Comparación del proceso de segmentación trabajando a nivel de píxel y subpíxel. El contorno final se representa en blanco sobre la imagen original. Arriba: Segmentación a nivel píxel. Abajo: Segmentación a nivel subpíxel. Comparando las parejas de figuras se ve cómo es necesario trabajar a nivel de subpíxel para no perder los vasos finos e incluso alguno de calibre mayor.	81
4.4.	(Cont.)	82
4.5.	Mejora aportada sobre la imagen de bordes mediante la segmentación morfológica. En la figura vemos cómo los bordes extraídos de la segmentación morfológica (en negro) mejoran los bordes obtenidos directamente de la retinografía (en blanco). Esta mejora es más notable en los cruces e intersecciones señalados con flechas, donde los bordes auxiliares evitan las discontinuidades existentes.	88
4.6.	Comparación de resultados empleando la segmentación auxiliar (abajo) y sin ella (arriba). El contorno final se representa en blanco sobre la imagen original.	90
4.6.	(Cont.)	91
4.7.	Proceso de segmentación total de la retinografía incluido el disco óptico, para obtener una comparación exacta de nuestros resultados con los de otros métodos. Se generan dos snakes a partir del mismo contorno inicial (línea discontinua), uno (en blanco) evoluciona hacia el exterior del disco óptico y otro (en negro) hacia el interior.	98

4.8. Comparación de la segmentación realizada por el experto de referencia con la obtenida por un observador independiente (imagen superior) y por nuestro modelo (imagen inferior). La parte coincidente con el experto de referencia se muestra en blanco. Se han marcado en rojo las zonas segmentadas por el método comparado y no por el experto de referencia (falsos positivos). Las verdes se corresponden con vasos detectados por el experto de referencia y no por el método comparado (verdaderos negativos).	101
4.9. Segmentación manual del experto de referencia (en blanco) superpuesta a la imagen original, sobre la que se han marcado en azul los vasos más finos(1 ó 2 píxeles de anchura).	102
4.10. Comparación de la segmentación realizada por el experto de referencia con la obtenida por un observador independiente (imagen superior) y por nuestro modelo (imagen inferior). La parte coincidente con el experto de referencia se muestra en blanco. Se han marcado en rojo las zonas segmentadas por el método comparado y no por el experto de referencia (falsos positivos). Las verdes se corresponden con vasos detectados por el experto de referencia y no por el método comparado (verdaderos negativos).	103
4.11. Segmentación manual del experto de referencia (en blanco) superpuesta a la imagen original, sobre la que se han marcado en azul los vasos más finos(1 ó 2 píxeles de anchura).	104
4.12. Comparación de la segmentación realizada por el experto de referencia con la obtenida por un observador independiente (imagen superior) y por nuestro modelo (imagen inferior). La parte coincidente con el experto de referencia se muestra en blanco. Se han marcado en rojo las zonas segmentadas por el método comparado y no por el experto de referencia (falsos positivos). Las verdes se corresponden con vasos detectados por el experto de referencia y no por el método comparado (verdaderos negativos). 105	105
4.13. Segmentación manual del experto de referencia (en blanco) superpuesta a la imagen original, sobre la que se han marcado en azul los vasos más finos(1 ó 2 píxeles de anchura).	106
5.1. Vista de la interfaz gráfica de la aplicación desarrollada para el cálculo del índice arterio-venoso.	109

5.2.	Descripción del proceso de estimación del calibre vascular. La estructura vascular segmentada se representa en blanco, el fondo de ojo en gris y la cresta es la línea punteada de color gris oscuro. (a) Punto P de intersección del círculo trazado por el usuario y la cresta. En este punto se traza la perpendicular a la cresta \bar{s} . (b) Puntos de cruce con el borde del vaso A y B sobre la recta \bar{s} . A continuación se halla el punto medio C del segmento \overline{AB} . (c) Representación del último paso, consistente en trazar círculos centrados en C aumentando su radio progresivamente. El calibre del vaso será el doble de r , siendo r el radio del mayor círculo que contiene sólo píxeles pertenecientes a la vena, permitiéndose un pequeño margen de error.	111
5.3.	Ejemplos de situaciones en las que la estimación de la anchura de vaso es complicada y nuestro método resuelve con notable éxito. En (a) vemos una bifurcación. En (b) se representa el caso de un pequeño desbordamiento del snake en el proceso de segmentación. En (c) vemos el caso de una perpendicular al vaso mal estimada debido a que la cresta no discurre perfectamente longitudinal a la estructura vascular en ese punto.	112
5.4.	Detección del disco óptico. El centro se representa por un cuadrado rojo y el radio por un círculo verde. En las zonas marcadas de la interfaz vemos las coordenadas numéricas del centro y radio detectados automáticamente al pulsar sobre el botón <i>HOUGH</i>	113
5.5.	Obtención de los puntos semilla representados en verde. Las intersecciones del contorno inicial y las crestas que constituyen los nodos semilla del snake inicial se obtienen al pulsar el botón <i>CROSS</i> . En <i>Th</i> se introduce el umbral de nivel de gris para eliminar puntos pertenecientes a crestas espurias. Los campos destinados a la parametrización del snake permiten ajustar la configuración de los parámetros siguientes: límite de distancia a crestas y bordes (<i>DistLim</i>), umbral de crecimiento (<i>GrowTh</i>), anchura de vaso mínima y máxima (<i>minVW</i> y <i>maxVW</i>) y número de iteraciones (<i>Iters</i>).	114
5.6.	Evolución del snake. Desde el contorno inicial (a), el snake va evolucionando (b y c), hasta estabilizarse completamente (d). Los puntos amarillos corresponden a los nodos activos de los frentes de avance y la línea roja a las zonas del contorno que ya se han estabilizado.	116
5.6.	(Cont.)	117
5.7.	Cálculo del índice AV: definición del radio de análisis.	118
5.8.	Cálculo del índice AV: obtención de los puntos de intersección.	119
5.9.	Selección y clasificación de los vasos de interés, estimación de su anchura y cálculo final del índice AV.	120

5.10. Sistema SIRIUS (System for the Integration of Retinal Images Understanding Services) desarrollado en nuestro grupo de investigación.	122
5.11. Ejemplo de cálculo del índice AV: (a) Empleando la técnica integrada en SIRIUS y (b) por la aplicación desarrollada que se basa en nuestro modelo. En ambas imágenes los puntos de arterias seleccionados se muestran en rojo y los de arterias en azul.	124
6.1. Retinografía en la que el encuadre dificulta el funcionamiento del modelo. En el detalle superior se aprecia cómo un vaso sanguíneo continuaría fuera del FOV aproximadamente por la línea blanca de guiones hasta volver a entrar en él. El snake no podría alcanzar el segundo tramo de ese vaso por romperse la continuidad.	129
6.2. Problemas en la detección de bordes. (a) Detalle ampliado de una retinografía original en la que se aprecia el reflejo intravenoso presente de forma especialmente acusada en uno de los vasos. (b) Imagen de bordes sin mejorar, trazada en blanco sobre la imagen original en la que se muestra cómo se ha detectado erróneamente un borde en el interior del vaso debido al reflejo central.	130
6.3. Problemas en la detección de crestas. (a) Detalle ampliado de una retinografía en la que se aprecia una zona oscura y alargada en la proximidad del disco óptico. (b) Imagen de crestas trazada en blanco sobre la imagen original en la que se muestra cómo se ha detectado erróneamente una cresta sobre la zona mencionada.	131
6.4. Retinografías que presentan dificultad a la hora de detectar automáticamente el disco óptico. La imagen (a) presenta una gran cantidad de vasos en la zona del disco óptico marcada con un círculo blanco punteado. La imagen (b) presenta una deformidad anatómica en el disco óptico que afecta gravemente a su forma habitual.	132
6.5. Principales dificultades encontradas a la hora de estimar el calibre vascular: bifurcaciones (arriba), venas contiguas (centro) y reflejo intravenoso (abajo). Los círculos negros se corresponden a los calibres erróneamente calculados y los círculos blancos a los correctos.	135
A.1. Resultados de la ampliación de un detalle de la imagen original al cuádruple de su tamaño mediante diferentes algoritmos de interpolación.	138

A.2. Representación del proceso de interpolación de una imagen. A partir de cuatro puntos o píxeles de la imagen original mostrada a la izquierda, construimos una imagen ampliada de la cual vemos un fragmento a la derecha. Para obtener esta nueva imagen ampliada es necesario calcular el valor de los nuevos píxeles, como $p(x,y)$ a partir de los valores originales de (0,0), (0,1), (1,0) y 1,1)	140
A.3. Resultado de la ampliación de la imagen original al doble de su tamaño mediante interpolación bicúbica.	141
A.4. Resultados de la extracción de crestas, representados en blanco y superpuestos a la imagen original. Los valores de los parámetros empleados son: Escala de Segmentación (SD) = 4.5, Escala de Integración (SI) = 8, Confianza (CNFD) = 0.08, Umbral de Cresta (THRK) = 0.019, Crestas y Valles (WHC) = 1, Longitud Mínima de Cresta (BMIN) = 170.	143
A.5. Resultados de la extracción de bordes, representados en blanco y superpuestos a la imagen original. Los valores de los parámetros empleados son: Tamaño de Gaussiana (sigma) = 4, Umbral de Histéresis Alto (tHigh) = 0.6, Umbral de Histéresis Bajo(tLow) = 0.4.	147
A.6. Esquema de la segmentación morfológica auxiliar.	150
A.7. Resultados de la segmentación morfológica auxiliar, representada en blanco y superpuesta a la imagen original. Los valores de los parámetros empleados son: Tamaño de Ventana de Filtrado ($W_f \times W_f$) = 4×4 , Porcentaje de Vasos por Imagen (P_{vasos}) = 6 %, Porcentaje de Fondo por Imagen (P_{fondo}) = 87 %, Umbral Mínimo de Filtrado por Tamaño (T_f) = 100.	151
A.8. Localización de la región de interés del disco óptico mediante clusterización. La imagen de la izquierda se corresponde con la retinografía original y la de la derecha con la región de interés que contiene al disco óptico.	153
A.9. Fases principales del algoritmo de localización y extracción del disco óptico.	154
A.10. Eliminación de los bordes correspondientes a vasos sanguíneos en la región de interés: (a) Imagen de bordes original. (b) Imagen de bordes con las crestas añadidas representadas por líneas finas. (c) Imagen de bordes final tras la eliminación de los vasos.	155
A.11. Resultado de la extracción del disco óptico marcado sobre una retinografía original. Los parámetros utilizados son: Límite de Distancia entre Centroides (ϵ) = 350, Tamaño de la Región de Interés ($m \times n$) = 350×350 , Ventana de Vecindad ($w_a \times w_b$) = 6×6 , Radio Mínimo (r_{min}) = 75, Radio Máximo (r_{max}) = 125, Ventana de Centro Válido ($c_a \times c_b$) = 80×80 , Decaimiento de Gaussiana (β) = 10.	157

Índice de tablas

3.1. Pesos de los términos de energía de la ecuación 3.2 en función del estado del nodo. El peso de la energía de marcador σ es el más alto, ya que restringe el movimiento del nodo a zonas no visitadas independientemente de su estado. Los nodos normales y los nodos borde tienen pesos muy similares, dando una importancia alta a la energía de borde ϵ_{borde} . Los nodos en estado cresta están influenciados principalmente por la presión de inflado ϵ_{dir} y la distancia a crestas ϵ_{cresta}	56
4.1. Comparación de la segmentación trabajando a nivel de píxel y de subpíxel. Los resultados se expresan en términos de precisión, sensibilidad, y especificidad.	79
4.2. Comparación del tiempo de ejecución medio en segundos para el sistema de detección de vasos propuesto, trabajando a nivel de píxel y subpíxel. T_{res} corresponde con la ampliación de la imagen original al doble de su tamaño. La extracción lleva un tiempo T_{cr} para las crestas y T_{borde} para los bordes. T_{crEn} y T_{bordEn} corresponden al cálculo de las imágenes de energía para las crestas y los bordes, respectivamente. La evolución del snake en sí está representada por T_{snk} . T_{total} es el tiempo de procesamiento total necesario para llevar a cabo el proceso de segmentación de la imagen al completo.	79
4.3. Modelo sin Segmentación Auxiliar. Comparación de la segmentación empleando diferentes métodos de interpolación. Los resultados se expresan en términos de precisión, sensibilidad, especificidad y tiempo de interpolación en segundos.	83
4.4. Modelo con Segmentación Auxiliar. Comparación de la segmentación empleando diferentes métodos de interpolación. Los resultados se expresan en términos de precisión, sensibilidad, especificidad y tiempo de interpolación en segundos.	83

- 4.5. Valores de los parámetros principales del extractor de crestas que le permiten alcanzar una elevada sensibilidad de detección. *SD* y *SI* presentan valores bajos para filtrar el ruido sin perder definición en la imagen. *CNFD* tiene un valor adecuado incluso para imágenes de baja calidad. *THRK* está configurado para aumentar la sensibilidad del sistema. El valor de *WHC* indica que se extraen las crestas y los valles, permitiendo generalidad en el tipo de imágenes. *BMIN* está expresado en píxeles e implica una sensibilidad bastante alta. 85
- 4.6. Valores de los parámetros principales empleados para mejorar las imágenes de crestas. *maxDist* determina la distancia máxima en píxeles entre dos extremos de un segmento de cresta para que se estudien las relaciones entre ambos. El ángulo máximo para considerar unión (*maxDiffAngle*) es de 135° , mientras que para cruce o bifurcación (*maxForkJointAngle*) su valor es de aproximadamente 110° . *linkLim* indica el límite de distancia máxima en píxeles para unir dos puntos extremos de un cruce, bifurcación o unión. *radiusExternCr* establece el radio en píxeles con respecto al borde del FOV dentro del que se eliminan las crestas existentes. 85
- 4.7. Valores de los parámetros principales del extractor de bordes de Canny para lograr una alta sensibilidad. *sigma* indica un reducido tamaño del filtro gaussiano para no suavizar demasiado la imagen. *tHigh* y *tLow* corresponden respectivamente a los umbrales alto y bajo de intensidad que definen la función de histéresis, manteniéndose una alta sensibilidad. 87
- 4.8. Valores de los parámetros principales empleados para mejorar las imágenes de bordes. *limEnhanceEdges* está expresado en píxeles e indica el radio de eliminación de bordes en torno a las crestas. *cleanWin* define el tamaño de la ventana en píxeles para eliminar los bordes debidos al ruido. *radiusExternEd* indica el radio en píxeles con respecto el borde del FOV dentro del que se eliminan bordes por considerarlos espurios. 87
- 4.9. Comparación de la segmentación empleando la segmentación morfológica auxiliar y sin ella. Los resultados se expresan en términos de precisión, sensibilidad, especificidad y tiempo en segundos. 92

4.10. Valores de los parámetros principales para la obtención de la segmentación morfológica auxiliar. Se ha seleccionado una configuración intermedia para adecuarse a la calidad de las imágenes que no presentan excesivo ruido, alcanzándose un compromiso entre sensibilidad y eficiencia. El tamaño del filtro de mediana ha sido ajustado para que se elimine la mayor parte del ruido sin perder de precisión. Los porcentajes de vasos y fondo por imagen han sido estimados para no ser excesivamente restrictivos pero sin que se clasifiquen como vasos demasiadas estructuras debidas al ruido o lesiones. El número mínimo de píxeles para el filtrado por tamaño se ha seleccionado intentando reducir el número de posibles confusiones con lesiones o hemorragias pero sin perder vasos finos o capilares.	92
4.11. Valores de los parámetros principales para la detección automática del disco óptico.	93
4.12. Valores de los pesos de los términos de energía de la ecuación 4.4 en función del estado del nodo. El peso de la energía de marcador σ es el más alto, ya que restringe el movimiento del nodo a zonas no visitadas independientemente de su estado. Los nodos normales y los nodos borde tienen pesos muy similares, dando una importancia alta a la energía de borde ϵ_{borde} . Los nodos en estado cresta están influenciados principalmente por la presión de inflado ϵ_{dir} y la distancia a crestas ϵ_{cresta}	95
4.13. Valores de los parámetros principales que determinan el comportamiento del modelo de contornos activos. <i>maxWidth</i> y <i>minWidth</i> están expresados en píxeles y son fundamentales en las operaciones de control de frentes, así como el umbral de distancia a crestas, representado por <i>distLim</i> . <i>growTh</i> determina el umbral de distancia en píxeles entre nodos para la inserción de un nuevo nodo e indica el nivel de definición del snake, que en este caso es elevado.	96
4.14. Resultados de diferentes métodos de segmentación existentes, el método propuesto (Snake) y un observador independiente (2º Observador), comparándolos con la misma segmentación realizada por un experto (<i>gold standard</i>).	97
4.15. Resultados obtenidos en la segmentación de cada una de las imágenes de test de la base de datos DRIVE. Los resultados se expresan en términos de precisión, sensibilidad y especificidad.	102
5.1. Resultados de cálculo del índice AV por nuestro modelo y empleando la técnica de referencia. Los calibres medios se expresan en píxeles.	125

Capítulo 1

Introducción

La adquisición y la interpretación de una imagen médica son dos aspectos igualmente importantes de cara a efectuar un buen diagnóstico. Los procesos de adquisición de imágenes médicas han experimentado una notable mejora gracias a los avances tecnológicos [N06]. Muchas de las nuevas técnicas de imagen médica no serían posibles sin la existencia de hardware y software específicos que reconstruyan, post-procesen y almacenen correctamente las imágenes obtenidas. En cuanto a la interpretación de imágenes médicas, su automatización ha sido mucho menor y continúa siendo una tarea que habitualmente realiza un especialista.

Desde hace algunos años esto ha empezado a cambiar considerablemente y cada vez hay más aplicaciones que ayudan al personal médico a interpretar las imágenes. Este es el caso de la tecnología CAD (Computer Aided Diagnosis), que básicamente indica al operario humano qué zonas de la imagen parecen anormales y requieren una mayor atención. El uso de herramientas para el procesado automático de imágenes médicas permite a los expertos disponer de mayor información de partida para hacer más rápido el proceso de análisis. Además, se evitan de este modo los errores y valoraciones subjetivas que introduce el procesamiento manual de las imágenes médicas. Mediante estos sistemas de procesamiento se simplifica y agiliza el diagnóstico, aunque el experto humano deberá revisar los resultados obtenidos por dichos sistemas.

Los sistemas de procesado automático de las imágenes de fondo de ojo están evolucionando continuamente debido a su importancia en el estudio de diversas patologías así como por su utilidad en biometría. Como explicaremos más adelante, la retinografía digital es además una técnica no invasiva y de bajo coste, lo que la hace adecuada para su implantación en centros de salud.

El análisis de la vasculatura de la retina es esencial en el diagnóstico y segui-

miento de la diabetes [KKM⁺06][NWS⁺08], hipertensión arterial [SWWc04], arteriosclerosis [HBKc99], enfermedades cerebrovasculares [PAM⁺05][dJIW⁺07], y cardiovasculares [SLW⁺08][WKK⁺06]. En el caso de la hipertensión, los vasos sanguíneos presentes en el ojo son los primeros en manifestar síntomas tales como variaciones en el calibre, microaneurismas y hemorragias. Por otro lado, algunas anomalías en el árbol arterio-venoso retiniano pueden reflejar significativamente el daño provocado por estas patologías, lo cual influiría decisivamente en el diagnóstico de complicaciones cerebro y cardiovasculares [IdJVc04].

El árbol vascular retinal es único para cada persona por lo que puede ser utilizado para identificación de personas, como sucede con las huellas dactilares [UPPJ04]. En la actualidad están siendo desarrollados diversos sistemas de autenticación biométrica [MPP⁺06][OMP⁺06][OPEG07].

Las alteraciones provocadas en el calibre retiniano por la edad son un tema médico controvertido. Diversos autores han observado que en las personas sanas, la vejez es una causa fundamental de las variaciones en el calibre vascular arteriolar [KKMc07][WKK⁺03]. Sin embargo, no existe un acuerdo sobre el tipo de modificaciones en las arteriolas retinianas que producen dicha alteración: estrechamiento, ancheamiento, aumento de la tortuosidad e incluso hay autores que afirman que tales modificaciones no se producen [EDWc89]. Un sistema de medición objetivo y fiable del calibre retiniano, en el que se integraría este trabajo, ayudaría a la resolución de este tipo de controversias y a la realización de estudios médicos en este ámbito.

La medida de los calibres de las estructuras vasculares de la retina permite además calcular el índice arterio-venoso. El índice arterio-venoso es un parámetro crucial en el estudio de la retinopatía diabética, ya que permite evaluar las alteraciones producidas por esta enfermedad sobre las estructuras vasculares retinianas. Este tipo de retinopatía debida a la diabetes se encuentra entre las principales causas de ceguera. Las pérdidas de visión son irreversibles generalmente por lo que un diagnóstico temprano es fundamental. En un futuro se podría tener un sistema automático que haga posible la evaluación a gran escala, es decir, realizar pruebas a todo paciente que se encuentre en el grupo de riesgo de una determinada patología, antes de que aparezcan sus síntomas. Realizar periódicamente la detección de retinopatías a la población diabética sería una forma de diagnosticar esta enfermedad en su fase inicial y, de esta manera, incrementar la efectividad del tratamiento.

La valoración de los cambios vasculares de una imagen de retina realizada manualmente es un proceso bastante subjetivo a la vez que muy costoso. La segmentación del árbol arterio-venoso completo por un experto constituye una tarea tediosa que requiere aproximadamente dos horas. Para automatizar este proceso,

es necesario desarrollar una técnica fiable y eficiente como la presentada en esta memoria.

En el capítulo 1 describiremos más a fondo el dominio de aplicación del problema, prestando especial atención a las características de las imágenes de fondo de ojo y las dificultades que plantean de cara a la segmentación de sus estructuras vasculares. A continuación pasaremos a exponer las técnicas generales de segmentación de imágenes y las aproximaciones propuestas actualmente al problema. También presentaremos un esquema del sistema de segmentación del árbol vascular que hemos desarrollado.

1.1. La Imagen de Retina

Para una correcta comprensión de la utilidad y funcionamiento del sistema aquí presentado, consideramos necesario realizar una breve introducción al dominio médico subyacente. En primer lugar describiremos la anatomía del ojo y explicaremos el proceso de obtención de las imágenes de fondo de ojo sobre las que nuestro sistema realiza la detección.

El ojo humano es similar a una cámara: la luz que pasa a través del iris se concentra en la retina a través de la lente, situada en la parte anterior del ojo. En la retina la información visual es codificada y transmitida a través del nervio óptico al cerebro, donde se interpreta como imágenes visuales. En la figura 1.1 (a) podemos observar una sección transversal del ojo humano en la que se señalan sus partes fundamentales.

El presente trabajo se centrará en el estudio de la retina y especialmente su vasculatura, ya que es ésta la parte del ojo que muestra los síntomas de diferentes enfermedades. La retina en sí es una membrana de células neuronales fotosensibles que cubren la superficie interna de la parte posterior del ojo (i.e. *fundus* o fondo de ojo). La figura 1.1(b) muestra una fotografía de fondo de ojo que corresponde a una parte de la retina centrada en la mácula.

Las neuronas fotosensibles no están distribuidas igualmente por toda la retina. La mácula, situada en el área central de la retina, contiene la mayor densidad de nervios sensibles a la luz y en consecuencia produce la mejor resolución visual. En el centro de la mácula se sitúa la fovea, una pequeña depresión que contiene la mayor concentración de células fotosensibles y que se encarga de la visión aguda y detallada. Si la zona macular se ve afectada por alguna patología existe un gran riesgo de pérdida de visión.

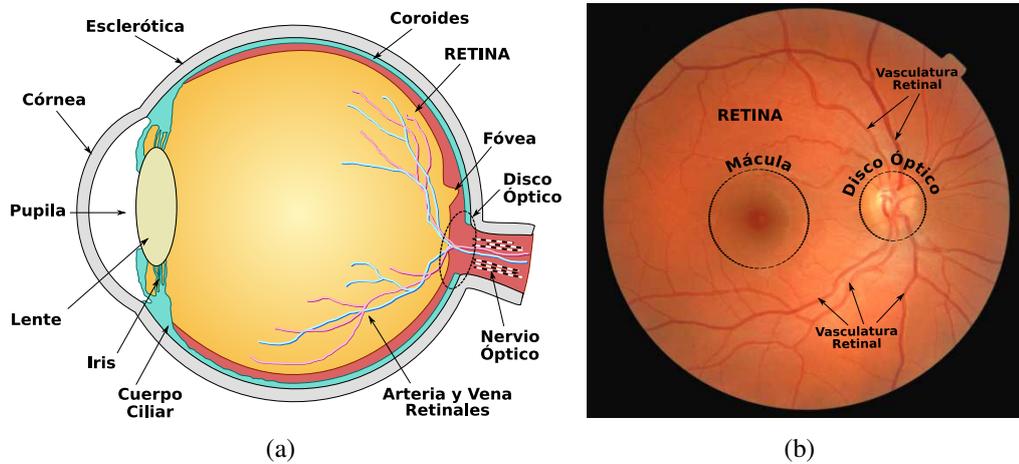


Figura 1.1: (a) Corte transversal del ojo en el que se puede apreciar su anatomía. (b) Imagen de fondo de ojo.

Otras estructuras importantes mostradas en la figura 1.1(b) son el disco óptico y la vasculatura retiniana. El disco óptico o *papila* no contiene células fotorreceptoras por lo que se denomina *punto ciego*. Es aquí donde los axones de las células ganglionares dejan el ojo en el nervio óptico que conecta con el córtex visual. El córtex visual es la parte del cerebro que procesa toda la información visual y la hace comprensible. El diámetro del disco óptico es de unos 1.5 mm, con el eje vertical algo mayor que el horizontal [CAM⁺97]. Es de una coloración rosada, existiendo una gran variabilidad según la persona. En las imágenes de fondo de ojo con las que trabajaremos, puede identificarse como la estructura circular y brillante de la que parte el árbol arterio-venoso.

La vasculatura retiniana está compuesta principalmente por la vena y la arteria central de la retina [KHS75]. Estos vasos proceden de las ramas de la arteria oftálmica y entran en el globo ocular cerca del nervio donde se ramifican siguiendo el recorrido de los nervios. Al igual que el nervio óptico y sus ramificaciones, la retina también cuenta con una importante cantidad de vasos que llevan sangre y oxígeno. Esta red de vasos sanguíneos, aparentemente compleja, sigue unos patrones estructurales sencillos. Habitualmente la arteria y vena centrales de la retina se dividen en dos troncos, uno superior y otro inferior, en cuanto pasa a través del nervio óptico al interior del ojo. A su vez estos troncos se suelen dividir en dos ramas principales, temporal y nasal. De este modo, cada cuadrante de la retina está irrigado por un vaso significativo. En consecuencia, la distribución de la red vascular retiniana es inherentemente radial, partiendo del nervio óptico y extendiéndose por todo el fondo de ojo (ver figura 1.1(b)).

Las venas siguen el trayecto de las arterias, excepto variaciones anatómicas,

siendo el tronco venoso más grueso, oscuro y sinuoso que el arterial. Las ramas del árbol retiniano se entrecruzan frecuentemente entre ellas. La arteria discurre siempre sobre un mismo plano anatómico, sin embargo la vena se curva generalmente por debajo de la arteria, siendo lo contrario poco habitual.



(a)



(b)

Figura 1.2: (a) Ejemplo de captura de una imagen de fondo de ojo digital (Imagen cortesía del Dept. of Medical Illustration, University of Aberdeen). (b) Cámara digital Canon para la fotografía de retina.

Además de la observación directa por un oftalmólogo empleando un oftalmoscopio, la retina puede ser examinada indirectamente mediante fotografía digital, denominada *retinografía digital* o *imagen de fondo de ojo*, como se muestra en la figura 1.2(a). Con ello se desacoplan las partes de adquisición e interpretación de la imagen. Existen diferentes técnicas para fotografiar la retina aprovechando las propiedades reflectantes del fondo de ojo y empleando diferentes tipos de luz y dispositivos de captura. Constituyen una manera no invasiva e inocua de examinar las estructuras vasculares retinianas. Por otra parte, permite el examen, almacenamiento y transferencia inmediatos y en soporte informático, lo que lo convierte en un proceso más barato que la fotografía analógica que requiere un revelado previo en papel y además que impide el desarrollo de sistemas automáticos de procesado y análisis. Otra técnica empleada para el estudio de la vasculatura retiniana es la *angiografía fluoresceínica*, que sí es invasiva ya que requiere inyectar al paciente un contraste para poder tomar las fotos del fondo ocular.

Los dispositivos empleados para obtener las imágenes de fondo de ojo son cámaras digitales basadas en CCD con una óptica especial como la mostrada en la figura 1.2(b). Las cámaras CCD (*Dispositivo de Carga Acoplada*), son dispositivos electrónicos muy sensibles que registran exposiciones largas. Para facilitar la

captura permitiendo entrar una mayor cantidad de luz, se puede dilatar la pupila mediante la aplicación de gotas por vía oftálmica o disminuyendo la iluminación ambiental. Este proceso se denomina *midriasis*, aunque con las cámaras modernas generalmente no es necesario, como es el caso de las empleadas en este trabajo, procedentes de la base de imágenes pública DRIVE, descrita en [NSvG⁺04].

Como se menciona al inicio de este capítulo, las imágenes de fondo de ojo muestran los síntomas de diversas patologías como son diabetes, hipertensión o arteriosclerosis. Aparte de las variaciones en calibre de los vasos sanguíneos retinales, pueden aparecer otros signos que indican la presencia de afecciones retinales asociadas a dichas patologías. Este tipo de situaciones pueden provocar pérdidas de visión difícilmente recuperables, por lo que una detección temprana es fundamental.

Retinopatías como la provocada por la diabetes conllevan la estimulación del crecimiento de nuevos vasos sanguíneos denominada *neovascularización*. Este crecimiento puede parecer beneficioso, pero no lo es ya que los nuevos vasos sanguíneos crecen de forma anormal, lo que provoca cicatrización y, en ocasiones, desprendimiento de retina. También pueden crecer o incluso sangrar dentro de la cavidad vítrea. Este proceso es muy perjudicial para la visión y puede ocasionar ceguera total o casi total.

Otro daño provocado por la retinopatía en la retina es la ruptura de pequeños capilares que provoca hemorragias. Estas hemorragias pueden distorsionar partes del campo visual o, si se encuentran cerca de la mácula, pueden nublar la visión (ver figura 1.3(a)). La aparición de microaneurismas constituye otro signo inequívoco de enfermedad como se muestra en la figura 1.3(a)), al igual que los exudados algodonosos (ver figura 1.3(b)), debidos a procesos isquémicos o pérdida de proteínas y lípidos.

Las fotografías digitales en color de la retina denominadas *retinografías* sobre las que trabajará nuestro sistema abarcan gran parte de la retina, incluyendo el árbol vascular, el disco óptico y la mácula. En la figura 1.4 , los vasos sanguíneos presentan una tonalidad más oscura que el fondo retiniano y el disco óptico aparece como una zona brillante y redondeada. La mancha oscura y difusa situada en la zona central de la imagen se corresponde con la mácula.

La segmentación del árbol vascular retiniano es una tarea de gran complejidad, tanto por las características que presentan las imágenes de fondo de ojo, como por las dificultades que plantean las propias estructuras vasculares objeto de la segmentación. Las retinografías contienen frecuentemente ruido introducido en el proceso de adquisición. También suele suceder que el contraste insuficiente o que la iluminación de la imagen no sea adecuada. Otra desventaja de este tipo

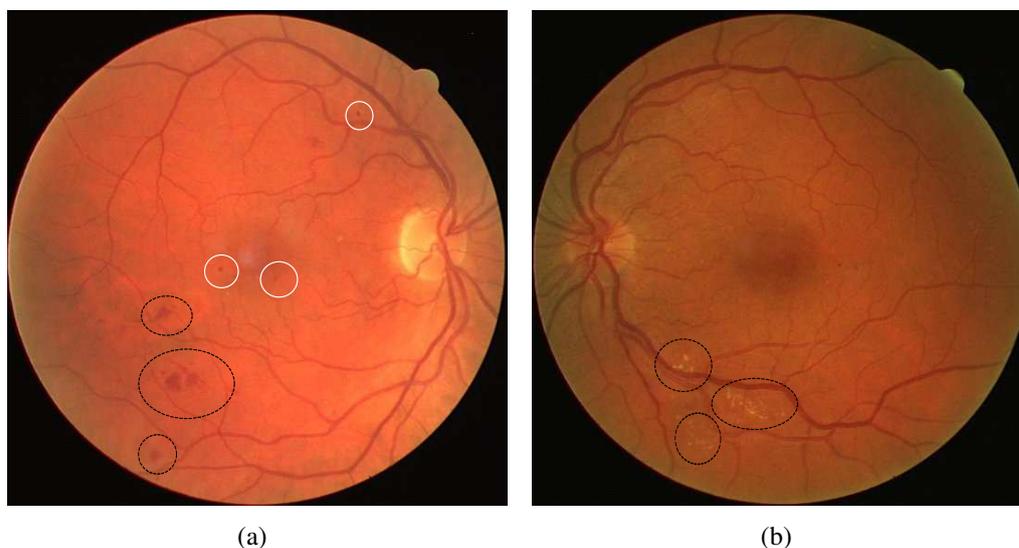


Figura 1.3: Fotografías de retina que contienen signos de retinopatía. (a) Hemorragias (círculos negros) y microaneurismas (círculos blancos). (b) Exudados (círculos negros)

de fotografías médicas es la alta variabilidad anatómica entre pacientes. Aunque la estructura global es semejante, existe una gran diversidad de configuraciones vasculares. Además, ciertas patologías afectan a la superficie de la retina y a los vasos sanguíneos presentes en ella, como hemos expuesto, lo que introduce aún mayores variaciones. En consecuencia, la imagen obtenida de una persona sana y de una afectada por una retinopatía serán muy diferentes, y el sistema deberá ser capaz de efectuar una correcta segmentación en ambos casos.

Los vasos sanguíneos son unas estructuras bastante complejas de detectar correctamente debido a que su tonalidad o nivel de gris no es constante a lo largo de un mismo vaso. Dentro del propio árbol arterio-venoso existe una alta variabilidad entre las estructuras que lo conforman, presentándose apreciables diferencias de contraste entre venas y arterias. También se diferencia significativamente la morfología de los vasos principales, más lineales y anchos, y los capilares, estrechos y tortuosos. Uno de los principales problemas que plantea la segmentación del árbol arterio-venoso es el denominado *reflejo central*. La retina y las paredes de los vasos sanguíneos sanos no son visibles oftalmoscópicamente, solamente lo es la columna sanguínea. Esta columna sanguínea produce un reflejo luminoso al ser iluminada desde el oftalmoscopio, apareciendo una estría o reflejo en su centro. Este fenómeno se produce más en las arterias que en las venas, pero presenta una luminosidad mayor en estas últimas. Ciertas patologías, como la arteriosclerosis, incrementan la densidad y grosor de la pared vascular, produciendo variaciones

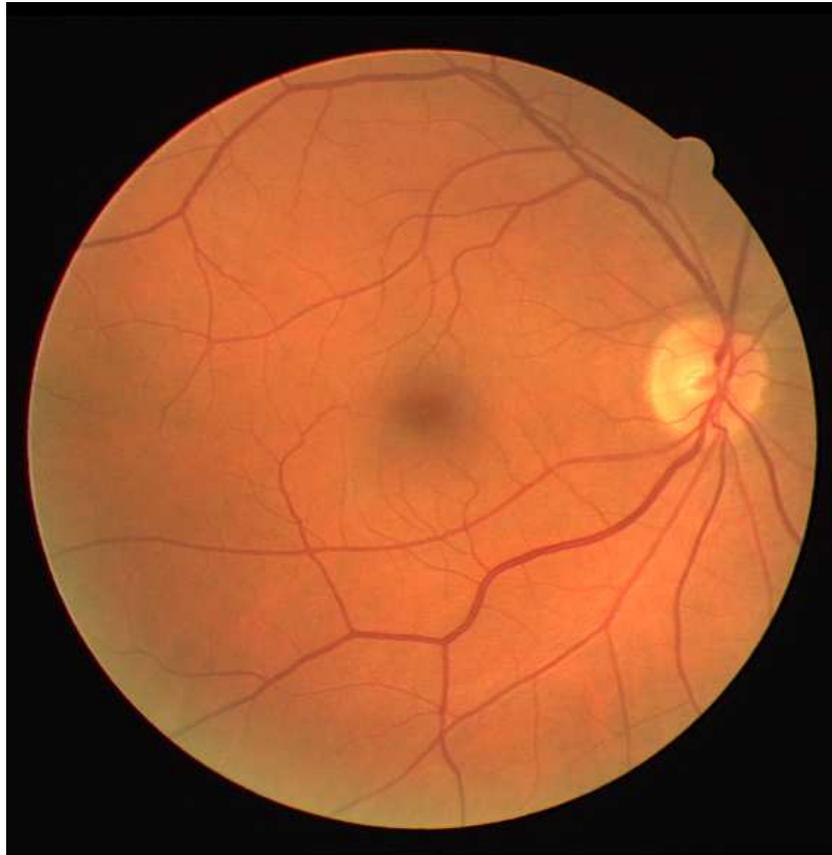


Figura 1.4: Ejemplo de imagen de fondo de ojo.

respecto a su apariencia normal. Esto supone una variación importante del perfil morfológico que se trata de detectar, provocando en ocasiones que la parte central del vaso donde se produce el reflejo no se reconozca como parte del mismo. En la figura 1.5 se muestra un fragmento ampliado de una imagen de fondo de ojo en el que se puede apreciar dicho fenómeno.

La red vascular de la retina presenta una geometría en forma de árbol con cruces y bifurcaciones que pueden confundir a un sistema de detección que se base en el seguimiento de estas estructuras. Otro motivo frecuente de error en el proceso de segmentación es provocado por las lesiones de las retinopatías que pueden ser morfológicamente similares a las estructuras vasculares, siendo difícilmente diferenciables de estas.

A pesar de todo esto el árbol vascular retiniano posee ciertas propiedades que facilitan el proceso de segmentación del mismo. La linealidad, la conectividad y su forma tubular son las características más ampliamente explotadas por las

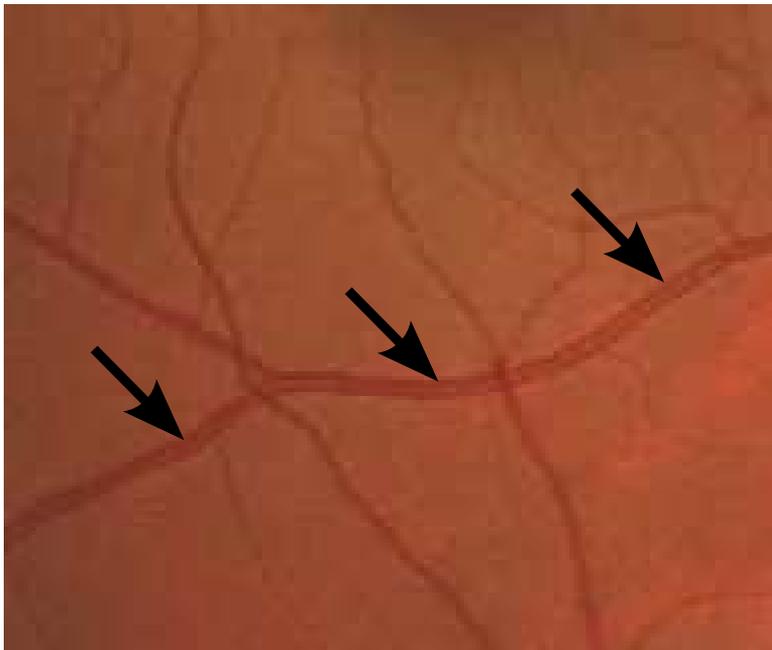


Figura 1.5: Porción ampliada de una imagen de fondo de ojo cuyo árbol vascular presenta reflejo central.

diferentes aproximaciones propuestas a este problema, incluida la desarrollada en este trabajo.

1.2. Segmentación del Árbol Vascular Retiniano

Debido a la importancia adquirida por la segmentación vascular en diversos sistemas de diagnóstico médico, se han realizado numerosos esfuerzos de investigación en esta área. El problema de la detección de vasos sanguíneos ha sido abordado desde aproximaciones y técnicas muy variadas en cuanto a la modalidad de imagen, dominio de aplicación, grado de automatismo, etc. En líneas generales, podemos clasificar los métodos de segmentación del árbol vascular retinal en los siguientes grupos:

- Técnicas de reconocimiento de patrones
- Redes neuronales
- Técnicas de aprendizaje automático
- Aproximaciones basadas en modelos

- Sistemas basados en seguimiento
- Detección de objetos tubulares

Son muy numerosas las aproximaciones basadas en reconocimiento de patrones, tanto supervisadas [SAN⁺04] [SLCJ⁺06] como no supervisadas [CCK⁺89] [JM03], y frecuentemente en combinación con otras técnicas [MC06] [MPHS⁺99].

Las redes neuronales son muy atractivas en la segmentación de imágenes médicas para clasificación con límites no lineales y por su capacidad de aprendizaje. Nekovei y Sun [NS95] emplean una red de retropropagación para la detección de vasos sanguíneos en angiografías por rayos X. El sistema no extrae el árbol vascular en sentido estricto, sino que etiqueta los píxeles como *vasos* y *no-vasos*. La clasificación obtenida es precisa pero las redes neuronales tienen la desventaja de tener que ser re-entrenadas cada vez que se añade una nueva propiedad y además el ajuste fino de su funcionamiento es una tarea compleja.

Los métodos basados en aprendizaje automático funcionan bastante bien en términos de precisión pero su complejidad computacional es mucho mayor que la de otras aproximaciones. Rost y col. [RML98] desarrollaron un sistema basado en conocimiento, denominado SOLUTION (*Solution for a Learning Configuration System for Image Processing*), diseñado para adaptar automáticamente algoritmos de procesamiento de imágenes de bajo nivel a las necesidades de la aplicación. Su intención es superar la dificultad que constituyen los requisitos de cambio extensos del sistema existente para trabajar en diferentes entornos. El sistema acepta descripciones de tareas en términos de lenguaje natural de alto nivel y configura la secuencia apropiada de operadores de procesamiento de imágenes empleando conocimiento experto. En la implementación actual, el proceso de extracción está limitado a contornos. Otros sistemas que se basan en aprendizaje automático son [GMT⁺96] y [VVL⁺04] que lo combina con un sistema basado en modelos.

Las aproximaciones basadas en modelos de contornos son también ampliamente utilizadas en la segmentación de estructuras vasculares. Entre ellas se destacan las basadas en modelos deformables clásicos [MT96] y geométricos [CKS97]. También se han empleado en combinación con otras técnicas [TOB⁺00]. Los contornos activos presentan la flexibilidad necesaria para enfrentarse a situaciones de presencia de ruido, falta de definición y otros problemas que aparecen comúnmente en las retinografías digitales. Además son capaces de integrar la información de la imagen proveniente de diferentes fuentes (bordes, valor de gris, etc.) y al mismo tiempo aprovechan el conocimiento previo acerca de las características de las estructuras a segmentar. Como desventajas de este tipo de técnicas podemos señalar su inicialización, que es a menudo difícil de automatizar, así como el coste computacional del cálculo de ciertas energías.

Además se ha abordado la segmentación de la vasculatura retinal mediante sistemas basados en seguimiento [QJ03] [TP98] y por detección de objetos tubulares [KTKS00].

En estudios comparativos como [KQ04], puede encontrarse información más extensa sobre los métodos de detección de vasos sanguíneos y en [NSvG⁺04] se trata concretamente la detección del árbol vascular de la retina. A pesar de las múltiples técnicas y algoritmos que se han desarrollado, la segmentación vascular continúa siendo un área abierta para la investigación y queda mucho trabajo por realizar en este ámbito.

A continuación expondremos de forma sintética algunas de las aproximaciones representativas a la segmentación vascular en imágenes de fondo de ojo. En la sección de resultados se muestra una comparación de su precisión y coste computacional. Para que dichas medidas sean equiparables a las obtenidas por nuestro sistema, se han seleccionado aquellas que tienen disponibles los resultados obtenidos sobre las imágenes de la base de imágenes pública DRIVE [NvG02]. En la sección de resultados compararemos la segmentación manual experta (*gold standard*) con los resultados obtenidos por estos métodos, un segundo observador humano y el método que hemos desarrollado.

Chauduri y col. [CCK⁺89] observaron que los perfiles de intensidad de gris de las secciones transversales de los vasos retinianos podían ser aproximados por una Gaussiana. Propusieron un filtro emparejado bidimensional para detectar estos vasos. Los segmentos vasculares en diferentes orientaciones se detectan convolucionando la imagen con versiones giradas del patrón del filtro emparejado y reteniendo solo la respuesta máxima. A una resolución angular de 15° se necesitarían un total de 12 convoluciones. Se puede aplicar un umbral a la imagen resultado para obtener una segmentación binaria de la vasculatura. Esta propuesta constituye una interesante aplicación de los filtros emparejados que sin embargo no logra alcanzar el nivel de precisión requerido para su uso médico, como veremos en el capítulo de resultados.

Martínez-Pérez y col. [MPHS⁺99] emplean una combinación de análisis de espacio escalar y crecimiento de regiones para segmentar la vasculatura. Se utilizan dos atributos a diferentes escalas para caracterizar los vasos sanguíneos, la magnitud del gradiente de la intensidad de la imagen $|\nabla I|$ y la fuerza de cresta. Una cresta es una zona contigua de puntos de la imagen que conforma un nivel máximo o mínimo con respecto a sus puntos colindantes y en el caso de las retinografías se corresponde con la línea central de un vaso sanguíneo. La fuerza de cresta se determina calculando el autovalor absoluto más alto $|\lambda_1|$ de la matriz de derivadas de segundo orden de la intensidad de la imagen. Para ajustarse a la diferencia en anchura de los vasos a través de la retina ambas características se

normalizan por la escala s sobre el espacio escalar, manteniendo solo los máximos locales. El máximo local de la magnitud del gradiente γ y el máximo local de la fuerza de cresta κ se definirían entonces como:

$$\gamma = \max_s \left[\frac{|\nabla I(s)|}{s} \right], \quad \kappa = \max_s \left[\frac{|\lambda_1(s)|}{s} \right] \quad (1.1)$$

Los histogramas de ambas características se emplean en la etapa final de crecimiento de regiones, en el cual los píxeles se dividen en dos clases: *vasos* y *no-vasos*. Esto se lleva a cabo mediante la alternancia del crecimiento de regiones de vasos y de fondo, creciendo y disminuyendo los umbrales de característica tras cada iteración. El proceso continúa hasta que no se añaden más píxeles a ninguna de las dos clases. Esta aproximación tampoco logra alcanzar la precisión necesaria para una aplicación real, como veremos en la comparación dentro del capítulo de resultados.

Jiang y col. [JM03] proponen un modelo de trabajo por umbral local adaptativo basado en un esquema de pruebas multi-umbral. Los vasos retinianos no se pueden segmentar mediante un umbral global debido a los gradientes en el fondo de la imagen. En lugar de ello, proponen aplicar a la imagen varios umbrales. En cada aplicación de un umbral se extraen todos los objetos binarios en la imagen umbralizada. Aplicando un proceso de clasificación a los objetos, solo se retendrán aquellos que presenten características de vaso sanguíneo. La sensibilidad del método se puede manipular cambiando los parámetros del proceso de clasificación, i.e. haciéndolo más o menos estricto. Este modo supone una mejora respecto de las anteriores aproximaciones en términos de precisión, pero sin satisfacer las necesidades de un sistema médico, como veremos en la comparación final.

Staal y col. [SAN⁺04] proponen un método supervisado para segmentación de imágenes en color, lo que requiere un conjunto de imágenes segmentadas manualmente como entrenamiento. Los vasos sanguíneos son estructuras alargadas: esta propiedad intrínseca es aprovechada para desarrollar un método basado en primitivas que denominan PBM(Primitive-Based Method). El algoritmo utiliza las primitivas de la imagen formadas desde las crestas (líneas centrales de los vasos) detectadas. Estas primitivas se agrupan en conjuntos que aproximan segmentos de líneas rectas, que según sus características se les asignará una probabilidad de pertenecer a una estructura vascular. Además, con estos elementos se divide la imagen en pequeñas parcelas o *patches*, asignando cada píxel a su primitiva más cercana. Dentro de cada *patch*, el elemento de línea define un sistema de coordenadas local respecto al cual se extraen características para cada píxel. Los vectores de características de cada píxel se clasifican en pertenecientes o no a un vaso sanguíneo mediante un clasificador *kNN* y efectuando un proceso de selección incre-

mental secuencial de características. El paradigma clasificatorio kNN (K-Nearest Neighbour) se fundamenta en que cada nuevo caso se asigna a la clase más frecuente a la que pertenecen sus K vecinos más cercanos. Mediante este método se alcanza una precisión suficiente pero su coste computacional es demasiado alto.

Soares y col. [SLCJ⁺06] proponen un método de segmentación que emplea la transformada de Gabor y clasificación supervisada. En este sistema cada píxel está también representado por un vector de características. Estos vectores están compuestos por la intensidad de píxel y las respuestas de la transformada *Wavelet* de Gabor bidimensional tomadas a múltiples escalas. La *Wavelet* de Gabor es capaz de sintonizarse a determinadas frecuencias, permitiendo filtrar el ruido y mejorar los vasos en una sola etapa. El espacio de características resultante se emplea para clasificar cada píxel como perteneciente a un vaso o no. Se emplea para ello un clasificador de Bayes con funciones de probabilidad de densidad condicionados por clase (verosimilitud) descritas como mezcla de Gaussianas. Estas funciones de probabilidad producen una rápida clasificación, siendo a su vez capaces de modelar superficies de decisión complejas. Al igual que el anterior, precisa de un entrenamiento supervisado para estimar las funciones de probabilidad. Esta aproximación alcanza una precisión muy cercana al observador independiente pero el tiempo necesario para procesar cada imagen es excesivo, sin contar el tiempo de entrenamiento previo.

Mendoça y col. [MC06] proponen un método de segmentación que combina filtros diferenciales para la detección de las crestas y operadores morfológicos para rellenar los segmentos de vasos. Se consideran en esta aproximación diversas propiedades de intensidad y morfológicas de las estructuras vasculares, tales como linealidad, conectividad y anchura. La segmentación de los vasos sanguíneos se realiza en las siguientes fases:

1. Procesado de la imagen para normalizar el fondo y mejorar los vasos finos;
2. Detección de las líneas centrales de los vasos para definir un conjunto de puntos alrededor de las mismas;
3. Crecimiento de la región para rellenar finalmente los vasos;

Las líneas centrales se obtienen seleccionando conjuntos conectados de puntos candidatos tras procesar las salidas de cuatro operadores diferenciales direccionales. Para la segmentación final se emplea un método iterativo de crecimiento de regiones que integra los contenidos de varias imágenes binarias. Estas imágenes binarias resultan de la aplicación de filtros morfológicos dependientes de la anchura de vaso. De este modo en cada paso se utiliza un nivel de la representación

multiescala de la estructura vascular basada en una aproximación morfológica con elementos estructurales de tamaño variable. Esta solución es algo más eficiente que la anterior aunque su coste computacional continua siendo muy elevado y además su precisión es menor.

La técnica de detección del árbol vascular retinal desarrollada en esta memoria se clasifica dentro de las aproximaciones basadas en modelos. Más concretamente, nuestra metodología redefine el modelo de contornos deformables clásico, incorporando características topológicas de los vasos sanguíneos retinales. Aprovechamos pues las propiedades de continuidad y linealidad que presentan dichas estructuras vasculares. Este modelo nos permite además beneficiarnos de varias aplicaciones desarrolladas en nuestro grupo de investigación. Principalmente, se emplean las crestas o líneas centrales de los vasos y la segmentación morfológica que se obtiene de la imagen de fondo de ojo. La disposición radial partiendo del disco óptico que presenta la vasculatura retinal, junto con una aplicación que obtiene la localización del mismo, posibilitan la inicialización automática del contorno. El modelo desarrollado combina por tanto, información de la imagen (crestas, bordes, etc) junto con conocimiento previo de las estructuras vasculares retinales (linealidad, continuidad, anchura media, etc.) para obtener una segmentación robusta a pesar del ruido y la variabilidad en la calidad de las imágenes. En cuanto al coste computacional, se ha simplificado la complejidad de ciertos aspectos del modelo clásico, como son las restricciones de flexibilidad y elasticidad, obteniéndose una alta eficiencia.

Una vez introducido el dominio de aplicación y presentadas las diferentes aproximaciones existentes, pasaremos a describir en el segundo capítulo de esta memoria el modelo clásico de contornos deformables en el que se basa el sistema aquí propuesto. En el tercer capítulo nos centraremos en las características y funcionamiento del sistema desarrollado. En el cuarto capítulo se muestra una evaluación de la calidad de los resultados obtenidos junto con medidas de eficiencia del modelo. Se incluye además una comparativa con los resultados de otras aproximaciones propuestas y los obtenidos por un experto humano. El quinto capítulo de esta memoria se dedica a la aplicación de nuestro modelo en el desarrollo de un sistema para el cálculo del índice arterio-venoso. Por último, expondremos las conclusiones extraídas de la realización de este trabajo así como los objetivos y líneas de investigación futuras.

Capítulo 2

Modelo Clásico de Snakes

Los modelos de contornos deformables o activos han sido ampliamente utilizados en el análisis de imágenes médicas [MT96], resultando una técnica muy robusta y potente. Este tipo de técnicas combinan geometría, física y teoría de la aproximación. Los contornos activos han demostrado ser efectivos en segmentación, emparejamiento y seguimiento de estructuras anatómicas, aprovechando las restricciones derivadas de los datos de la imagen junto con el conocimiento previo sobre la localización, tamaño y forma de dichas estructuras. Son capaces además de adaptarse a la variabilidad de las estructuras biológicas en el tiempo y entre diferentes individuos.

El modelo de contornos deformables presenta una serie de ventajas sobre otras técnicas empleadas en visión artificial:

- Permite integrar diferentes tipos de información de la imagen en su función de energía. Por ejemplo podemos emplear la topología de las estructuras a detectar, conocimiento heurístico sobre la imagen o filtrado del ruido presente en las mismas.
- Puede trabajar sobre objetos que presentan falsos puntos de contorno o que carecen de puntos de contorno reales.
- Es útil tanto en tareas de segmentación estática como en seguimiento de contornos dinámicos.
- Proporciona descripciones de alto nivel de las imágenes sin necesidad de un post-procesado de salida.

Se han empleado con éxito aproximaciones basadas en contornos activos en

multitud de ámbitos: segmentación (basada en contornos, color, texturas o regiones), reconstrucción, seguimiento de objetos (rígidos, no rígidos y articulados, en 2D y en 3D), ajuste elástico, reconocimiento de patrones, registro y reconocimiento de expresión facial, construcción automática de atlas anatómicos, cirugía virtual, modelización elástica de cuerpos sólidos deformables, etc.

En el ámbito concreto de la segmentación vascular retiniana, estos modelos deformables ofrecen ciertas ventajas con respecto a otras técnicas de segmentación existentes. En primer lugar, los snakes son capaces de trabajar adecuadamente en imágenes con presencia de ruido y con el problema que supone el reflejo central (figura 1.5) o las variaciones de intensidad presentes en las estructuras vasculares. No es posible efectuar una segmentación correcta enfrentándonos a estos problemas si empleamos un método que se base únicamente en los niveles de gris.

Los contornos deformables proporcionan una manera simple de integrar información proveniente de diferentes fuentes mediante el concepto de *energía* que describiremos en el siguiente apartado. De este modo podemos aprovechar algunas de las técnicas desarrolladas previamente en nuestro grupo de investigación (extracción de crestas y segmentación morfológica) y de extracción de bordes (ver Apéndice A).

Los snakes son capaces de adaptarse a las diferencias morfológicas tales como diferencias en anchura de vaso o tortuosidad. Además, por su tipo de evolución, que consiste básicamente en su deformación y crecimiento, nos permiten aprovechar la propiedad de continuidad lineal que presenta el árbol vascular retiniano.

Los métodos existentes basados en clasificadores, como por ejemplo [SAN⁺04] o [SLCJ⁺06], presentan el inconveniente de no tener en cuenta las propiedades de la red vascular hasta finalizar el proceso de segmentación. Así, no se aprovecha la información sobre conectividad, linealidad, forma tubular, etc, hasta que la segmentación ha concluido, sirviendo únicamente como criterios de validación de la calidad del resultado obtenido.

A continuación presentaremos una clasificación general de los modelos de contornos deformables y seguidamente nos centraremos en el modelo de snakes clásico en el que se basa el modelo que hemos desarrollado para la segmentación del árbol vascular retiniano.

2.1. Clasificación de Modelos de Snakes

Los modelos de contornos deformables o snakes pueden clasificarse en dos grandes grupos según su representación:

- Snakes *geométricos* o implícitos
- Snakes *paramétricos* o explícitos

Los modelos de snakes geométricos representan un enfoque alternativo al modelo clásico que se define implícitamente por la estructura geométrica de la imagen. En lugar de hacer evolucionar un contorno inicial, se deforma una curva natural de la imagen, como puede ser un borde. De este modo, en vez de que el contorno fluya sobre la imagen, se modifica la imagen en sí. Aunque el control de la evolución puede ser complicado, los snakes geométricos presentan ciertas ventajas. Por ejemplo, existen menos restricciones topológicas, pudiendo modificar automáticamente su topología o incluso combinarse y dividirse en diferentes contornos. Por otra parte, son independientes de la parametrización de contorno y tienen una mayor simplicidad computacional [XAYP00]. Además posibilitan la existencia de varios contornos simultáneamente así como la aplicación de manera sencilla a imágenes tridimensionales [RAH97] [LL02]. Son especialmente adecuados para la segmentación de objetos con formas muy complejas y topologías desconocidas.

Entre los modelos de snakes geométricos destacamos los *snakes geodésicos* basados en el cálculo de distancias mínimas locales denominados GAC (Geodesic Active Contour), que han sido aplicados tanto a segmentación en escala de grises [CKS97] como en imágenes en color [SZG06].

Los snakes paramétricos [SD89] se basan en el modelo clásico de snakes propuesto por Kass y col. [KWT88] que describiremos en el siguiente apartado. Básicamente consiste en una curva elástica que se deforma dinámicamente adaptándose a la forma de un objeto en respuesta a fuerzas internas (elásticas) y fuerzas externas (fuerzas de la imagen y restricciones). Esta aproximación es más intuitiva que los modelos implícitos. Su formulación matemática facilita la integración de información de la imagen, propiedades del contorno inicial estimado y restricciones basadas en conocimiento, en un único proceso de extracción. Los modelos paramétricos tienen ciertas limitaciones ya que en general sólo pueden manejar objetos topológicamente simples y son muy sensibles a las condiciones iniciales. Además la topología de las estructuras de interés debe ser conocida de antemano.

Como ejemplos de modelos paramétricos están los *B-snakes*, cuyo contorno se representa mediante una curva parametrizada (B-Spline) [BHU00] [WT06] y

los snakes estadísticos [TOB⁺00] [Hor99], que incorporan técnicas estadísticas en las funciones de energía del snake.

Los *T-snakes* (Topological Adaptive Snakes) [TM00] representan un extensión de los modelos paramétricos y han sido utilizados en segmentación de imagen médica [CR04]. Se intenta con esta técnica conseguir las ventajas de los modelos geométrico y paramétrico, superando las limitaciones de estos últimos. La idea básica es incrustar un modelo de snakes paramétrico discretizado en el dominio de la imagen adaptado, por ejemplo mediante una descomposición afín ACID (Affine Cell Image Decomposition), e incorporar un sistema de reparametrización dinámica. El modelo resultante tiene la potencia de la formulación implícita, con una gran flexibilidad topológica y menor dependencia de la inicialización. Al mismo tiempo se permite el empleo de restricciones en forma de funciones de energía y permite la interacción del usuario.

Para reducir la limitación de los snakes paramétricos que supone la alta dependencia de la inicialización, surgen los denominados *snakes duales*[GN97]. Esta aproximación consiste en un contorno que se expande desde el interior del objeto a segmentar y otro que se contrae desde el exterior del mismo. Los dos contornos están interrelacionados para proporcionar una fuerza que conduzca a los contornos fuera de los mínimos locales, lo cual hace la solución menos sensible a la posición inicial [GGO00].

En un punto intermedio entre los modelos geométricos y los paramétricos se sitúan los *Pixel Level Snakes* (PLS). Los PLS representan un modelo topográfico activo e iterativo en el que los contornos se representan explícitamente y evolucionan hacia curvas de mínima distancia. Debido a su alto nivel de discretización y su evolución píxel a píxel pueden manejar transformaciones topológicas mediante operaciones integradas y accesibles. Se han empleado en la segmentación de imágenes de fondo de ojo siendo posible su implementación hardware [AMDVP07].

Como base del modelo desarrollado en esta tesis se ha seleccionado el modelo de snakes paramétricos por ser el más adecuado a las características del dominio concreto de aplicación. El modelo paramétrico permite integrar fácilmente información de la imagen proveniente de diversas fuentes, con lo que podemos beneficiarnos de las aplicaciones existentes que nos proporcionan las líneas centrales de los vasos sanguíneos y una segmentación morfológica auxiliar, y emplearlas simultáneamente con la imagen de bordes extraídos de la imagen para definir las energías externas del snake. Además podemos aprovechar el conocimiento existente sobre las características topológicas de las estructuras a segmentar. El modelo incorpora las propiedades de continuidad, linealidad y disposición arbórea de las venas y arterias de la retina. Al ser más intuitivo y explícito, también permite

un mayor control de su comportamiento y el establecimiento de restricciones de deformación adaptadas al dominio. Por otra parte, este modelo explícito simplifica la visualización de los resultados y proporciona una mejor interacción con el usuario que será fundamental para un sistema de ayuda al diagnóstico. Las limitaciones principales de los modelos paramétricos no afectan en este caso, ya que el problema de la inicialización se soluciona gracias a la disposición radial del árbol vascular y a que la topología general de las estructuras vasculares es conocida.

Nuestro modelo puede definirse como un snake paramétrico discretizado que evoluciona sobre el espacio también discreto de los píxeles de la retinografía digital. Esta imagen se preprocesa, de modo que es convertida a escala de grises y ampliada para obtener una mayor precisión. Después se localiza automáticamente el disco óptico, de cuyo centro parten todos los vasos sanguíneos retinales. Se inicializa a continuación el snake como una circunferencia alrededor del disco óptico detectado que interseca con las estructuras vasculares en diversos puntos. Desde cada uno de esos puntos de intersección, el snake comienza a deformarse, desplazando sus nodos y creciendo iterativamente. El snake fluye así por el árbol vascular empujado por la presión de inflado y guiado por las crestas o líneas centrales de los vasos, que se han extraído previamente. Se mantienen en todo momento restricciones basadas en la anchura de los vasos sobre la evolución del snake, que continúa avanzando hasta estabilizarse completamente al alcanzar progresivamente los bordes de todas las estructuras vasculares detectadas.

Así pues, el sistema desarrollado en el presente trabajo se basa en el modelo de contornos deformables clásico. Este modelo ha sido el que más atención ha atraído desde su presentación por Kass y col. [KWT88], y representa un caso especial de la teoría general de modelos deformables multidimensionales [Ter87]. Ha sido necesario efectuar diversas modificaciones al modelo clásico para superar algunas de las limitaciones que presentan los modelos paramétricos, aumentar su eficiencia y adaptarlo al caso concreto de la extracción del árbol arterio-venoso en imágenes de fondo de ojo. Antes de centrarnos en el modelo desarrollado en esta tesis, describiremos el modelo clásico.

2.2. Modelo de Snake Clásico

Nuestro modelo está basado en el modelo clásico de contorno deformable, denominado *modelo de snakes*. Este modelo paramétrico fue propuesto por Kass y col. [KWT88] para segmentar los contornos de objetos en imágenes bidimensionales.

Un snake es una curva elástica que, situada sobre una imagen, evoluciona a partir de su posición y forma original hasta posicionarse sobre puntos característicos de la propia imagen, ajustándose a la forma de la estructura deseada.

La idea básica del modelo de snakes consiste en identificar, medir o delimitar una estructura de interés en la imagen sobre la que se está trabajando. Para la aplicación de este modelo se deben establecer básicamente un punto o contorno inicial, unas fuerzas que actúen adecuadamente sobre el modelo y un método para minimizar la energía del mismo.

La función de energía asociada a ese contorno servirá tanto para modelar su comportamiento como para atraer el contorno activo hacia rasgos de la imagen. El mínimo de la función de energía del snake nos dará el contorno buscado en la imagen.

Como se puede observar a partir de su definición, el planteamiento de los snakes es muy sencillo e intuitivo desde un punto de vista conceptual. El paralelismo con conceptos físicos (fuerzas, elasticidad, campo de potencial) está presente en todo el esquema y es de gran ayuda para comprender el modelo de forma global.

Formalmente, se define al contorno activo como una curva paramétrica en el plano de la imagen $(x, y) \in \mathfrak{R}^2$. La ecuación paramétrica de un snake en función de la longitud de arco $s \in [0, 1]$ con x e y función de las coordenadas se define como:

$$v(s) = (x(s), y(s)) \quad (2.1)$$

La forma del contorno que queremos detectar se encontrará contenida en la imagen $I(x, y)$ y vendrá dada por el siguiente funcional. Este puede entenderse como la representación de la energía que posee el contorno, correspondiendo la forma final del contorno al mínimo de esta energía.

$$\epsilon_{snake}(V(s)) = \epsilon_{int}(V(s)) + \epsilon_{ext}(V(s)) \quad (2.2)$$

El primer término ϵ_{int} es la *energía interna* del snake, que representa a las fuerzas internas responsables de su elasticidad y flexibilidad. Las fuerzas internas modelan la resistencia de la curva al estiramiento y controlan la deformación. El segundo término ϵ_{ext} es la *energía externa* del snake, y corresponde a las fuerzas que introducen el acoplamiento del snake a las características de la imagen como pueden ser bordes o líneas. Las fuerzas externas se diseñan de tal manera que atraigan al snake hacia la forma a localizar. Típicamente, se consideran como aspectos relevantes de la imagen los puntos de contorno, que son función tanto de su posición como de la magnitud de su gradiente.

Una vez situada en la imagen, el snake realiza una adaptación iterativa del contorno bajo la influencia de las fuerzas externas e internas para minimizar su energía global hasta estabilizarse en su mínimo. Equivalentemente podemos definir esta función de energía global en el dominio continuo como:

$$\int_0^1 \epsilon_{snake}(v(s)) = \int_0^1 \epsilon_{int}(v(s))ds + \int_0^1 \epsilon_{ext}(v(s))ds \quad (2.3)$$

donde ϵ_{int} representa la energía interna y ϵ_{ext} la energía externa.

La deformación del snake aparece como resultado de la acción combinada de estas fuerzas externas e internas. En la imagen, a la localización de cada píxel le corresponde un valor de energía determinado, compuesto por la influencia de los dos tipos de energías. A continuación describiremos en detalle ambos tipos de energías y su papel en la evolución del snake, comenzando por la energía interna.

La energía interna se describe como:

$$\epsilon_{int}(V(s)) = \int_0^1 \alpha(s) \left| \frac{\partial V(s)}{\partial s} \right| + \beta(s) \left| \frac{\partial^2 V(s)}{\partial s^2} \right| \quad (2.4)$$

Esta energía caracteriza un contorno flexible, que se puede estirar como una goma elástica. Dos funciones paramétricas determinan las características del contorno:

- $\alpha(s)$ pondera la primera derivada de la curva. Este término permite controlar la tensión del contorno, es decir, el contorno se comporta como una membrana de una determinada elasticidad.
- $\beta(s)$ influye la segunda derivada de la curva. Este término permite al contorno activo comportarse como una lámina de una determinada rigidez, esto es, controla la flexibilidad.

A pesar de que los parámetros α y β se presentan como funciones de la longitud del arco de curva s , en la práctica se reducen normalmente a funciones constantes. Así se disminuye la complejidad del modelo sin que esto implique una reducción en la capacidad de detección del snake, como muestran los resultados obtenidos por diferentes autores como [RB96],[CIHK96] o [KLA97].

Según los valores de α y β se pueden presentar los siguientes casos:

- $\alpha = \beta = 0$: En este caso la fuerza interna es nula. No existe pues nada que ligue los puntos del snake entre sí de manera que el modelo deformable no actúa como tal. Se comporta simplemente como un conjunto de puntos que interactúan individualmente con la imagen sobre la que se sitúan y son

atraídos por el campo de energía que esta define. No existen en este caso restricciones que impidan que el snake acabe completamente fragmentado. Se permite por tanto la aparición de discontinuidades de primer orden.

- $\alpha > 0, \beta = 0$: El valor positivo de α provoca que aparezca el factor de estiramiento en la curva. De esta manera, cada punto del contorno tenderá a estar lo más próximo posible a sus vecinos, ya que esta es la configuración que proporciona un valor más bajo de energía. Así, tendremos un contorno continuo interactuando con la imagen y no solamente una colección de puntos aislados como en el caso anterior. Por otro lado, el valor nulo de β implica la no existencia en el modelo de imposiciones relativas a la curvatura que presenta el snake a lo largo de su contorno. Desde el punto de vista matemático nos encontramos con una discontinuidad de segundo orden, y desde el punto de vista gráfico permitimos la aparición de esquinas en el contorno del snake.
- $\alpha > 0, \beta > 0$: El valor positivo de α restringe la aparición de discontinuidades de primer orden y el valor positivo de β anula la discontinuidad de segundo orden. De esta manera, el snake generará curvas continuas y suaves.

Dotando a α y β de valores negativos se obtendrían efectos contrarios. Cuanto más alto fuese el valor absoluto de α mas tendencia tendrían los puntos del snake a enredarse unos con otros. Por otro lado, cuanto mayor fuese el valor absoluto de β , más probabilidad existiría de que las soluciones generadas definieran curvas puntiagudas, con grandes irregularidades en lugar de transiciones suaves.

La elección de los coeficientes de la energía interna se realiza en función de los intereses de cada caso, ajustándolos al dominio de aplicación. Es importante destacar así mismo que debe existir cierta compensación entre estos coeficientes, de modo que ninguno de ellos eleve el valor de su término de energía asociado hasta el punto de hacer insignificante la aportación del otro o incluso de la propia energía externa de la imagen.

Un valor demasiado alto de α podría provocar que el snake se colapsara en un punto, debido a que el factor dominante es aquel que tiende a mantener los puntos del contorno lo más cercanos posible entre sí. En el caso de un contorno circular, por ejemplo, este tendería a disminuir progresivamente su radio hasta terminar en un único punto.

Si por el contrario, le damos a β un valor suficientemente elevado, pero bajo en comparación con α , estructuras más finas y detalles de la imagen serían ignorados por el snake. En caso contrario, un valor más elevado de β llevaría al snake a

obtener soluciones excesivamente suaves, perdiendo valles y crestas pronunciadas en el contorno del objeto, y obteniendo contornos demasiado burdos como para ser considerados soluciones útiles al problema.

Por tanto, es importante alcanzar un compromiso entre ambos parámetros que proporcione utilidad y generalidad al procedimiento de análisis de contornos, evitando la manipulación continua de sus valores. La determinación de estos parámetros se lleva a cabo habitualmente de forma empírica, modificando sus valores de manera sustancial cuando cambiamos de un dominio a otro, o incluso dentro del mismo dominio si variamos el tipo de objetos a detectar.

Una vez presentada la energía interna, pasaremos a describir el otro término fundamental en la evolución del snake: la energía externa. La energía externa marca las principales diferencias entre los distintos modelos de snakes propuestos por en la literatura.

Expondremos aquí la propuesta de modelo deformable [KWT88], modelo de partida y referencia de una gran mayoría de los trabajos desarrollados con este tipo de aproximaciones. En la ecuación 2.5 se muestra la expresión de la energía externa ϵ_{ext} , que se describe en el modelo original:

$$\epsilon_{ext}(V(s)) = \int_0^1 \epsilon_{imagen}(V(s)) + \epsilon_{rest}(V(s)) \quad (2.5)$$

El término ϵ_{rest} representa una serie de fuerzas de restricción que pueden hacer que el snake sea atraído o repelido por zonas concretas de la imagen. Un ejemplo de estas fuerzas podrían ser los denominados *muelleres* que atraen a los puntos del snake hacia un punto de interés de la imagen. Otra posible fuerza de restricción es la fuerza de repulsión que puede representar, por ejemplo, una zona que llevaría al snake a un mínimo local.

El término ϵ_{imagen} correspondiente a la energía de la imagen se descompone a su vez en los siguientes términos:

$$\epsilon_{imagen} = \omega_{linea}\epsilon_{linea} + \omega_{borde}\epsilon_{borde} + \omega_{term}\epsilon_{term} \quad (2.6)$$

Cada término lleva un peso ω_j asociado, que pondera su influencia en el cómputo total de la energía externa.

El término ϵ_{linea} es el funcional más simple que se puede utilizar, calculado como la intensidad de la imagen. Dependiendo del signo del parámetro de ponderación ω_{linea} puede hacer que el snake sea atraído por líneas claras u oscuras. Aunque aporta información importante, este término por sí solo puede llevar al snake hacia puntos de ruido que colapsarían el modelo en un contorno falso.

El término ϵ_{borde} representa la energía asociada a los bordes de los objetos que atraerán el snake. Puede calcularse empleando la teoría de detección propuesta en [MH80]. El término ϵ_{term} nos permite detectar las terminaciones de los segmentos y esquinas empleando la curvatura de las líneas de nivel en la imagen ligeramente suavizada. Combinando ϵ_{borde} y ϵ_{term} se consigue que el contorno activo sea atraído por los bordes o terminaciones de los mismos.

A partir del modelo original descrito, han surgido multitud de trabajos en los cuales se modifican en mayor o menor medida diversos aspectos. Estas modificaciones pueden dividirse en tres categorías según se centren en la función de energía, en la metodología del algoritmo o modifiquen totalmente el modelo. Para elegir el modelo con el que abordar el problema al que nos enfrentamos se suelen contemplar tres factores:

1. Dominio de aplicación en el que se va a trabajar.
2. Características de las estructuras que se pretenden detectar.
3. Tipo de imágenes de las que se va a disponer.

Así pues, en ciertos dominios de aplicación hay energías externas definidas en el modelo tradicional que no son de utilidad, mientras que pueden emplearse como fuerzas externas otro tipo de características de la imagen. Por ejemplo, el sistema basado en snakes desarrollado por Morris [Mor02] para la extracción de senderos en imágenes aéreas no utiliza la energía de bordes. Esto se debe a que precisa detectar caminos estrechos en los que esta información no es de interés. Sin embargo, sí emplea la intensidad de la imagen definida en el modelo tradicional. Añade una nueva fuerza externa derivada de los datos proporcionados por un GPS, que permite obtener la estructura aproximada del sendero a extraer y por tanto la orientación de búsqueda del máximo local.

También han surgido diversas definiciones de fuerzas externas que pretenden superar las limitaciones del modelo clásico, como por ejemplo los problemas de la detección de bordes cóncavos y su dependencia de la inicialización. Esto se debe a que las energías externas existentes no logran atraer los puntos del snake hacia el interior de las concavidades presentes en el borde. Una solución a este problema es el denominado *Gradient Vector Flow* (GVF) [XP97], que posteriormente fue generalizado en [XP98]. Esta nueva fuerza externa resuelve las dificultades del modelo clásico a la hora de segmentar formas con bordes cóncavos, amplía el rango de captura permitido y es insensible a las variaciones en la inicialización. Zhao y col.[ZQ00] combinan esta tecnología de GVF con medidas estadísticas de afinidad de píxel. Así consideran otras características extraídas de la imagen

para segmentar objetos mediante modelos de snakes: intensidad, gradiente, color y textura. De este modo, obtienen un sistema muy robusto incluso en imágenes con ruido y que es capaz de superar los problemas de discontinuidades y concavidades en el borde. La desventaja de este método es su alto coste computacional, ya que es necesario resolver una ecuación de difusión de optimización.

Otra solución a las limitaciones mediante la definición de una fuerza externa es la propuesta por Park y col.[PC02]. Presentan como nueva fuerza externa el *Virtual Electric Field* (VEF), que se basa en el campo eléctrico creado por las cargas eléctricas virtuales en el contorno del objeto, siendo considerados cargas eléctricas virtuales las intensidades o los bordes de una imagen. El modelo de contornos activos desarrollado presenta un rango de captura ilimitado, es independiente de la inicialización y es capaz de converger a las concavidades de los objetos. Por otra parte, esta fuerza puede calcularse de forma rápida realizando una convolución sobre la imagen.

En nuestro caso, debido a la disposición radial y forma tubular de las estructuras vasculares objeto de segmentación, no existen problemas de dependencia de la inicialización ni de la presencia de concavidades. Emplearemos la energía de bordes definida en el modelo tradicional, pero incluiremos otras nuevas, adaptadas al dominio de aplicación concreto, como veremos en el capítulo 3 en el que se describirá el modelo desarrollado en esta memoria.

En los siguientes apartados realizaremos una descripción más detallada de aspectos fundamentales del modelo de snakes como son la discretización del contorno, el proceso de evolución del mismo y las técnicas de minimización de la energía.

2.2.1. Discretización del Snake

La formulación genérica de los snakes se basa en curvas continuas parametrizadas por la longitud del arco de curva s . Sin embargo, a la hora de abordar el problema desde el punto de vista computacional se debe realizar una discretización de los diferentes elementos con los que se trabaja.

Esta necesidad surge como consecuencia de que las imágenes digitales sobre las que aplicaremos el modelo están compuestas por elementos discretos, denominados *píxeles*. Estos píxeles crean un campo de potencial discreto ya que a la ubicación de cada uno de ellos se le asocia un valor de energía externa determinado. Normalmente le corresponderá un valor de gradiente o una medida de distancia al punto de borde más cercano.

El propio snake también ha de ser discretizado, transformando su contorno en una aproximación poligonal del mismo. Denominaremos a dicha aproximación V y estará compuesta por N vértices [RSM95] que denotaremos por v_i , $i = 0 \dots N - 1$. Cada vértice del snake tendrá por coordenadas $v_i = (x_i, y_i)$. En la figura 2.1 se muestra un esquema de un snake discreto y las fuerzas que actúan sobre los vértices que lo componen.

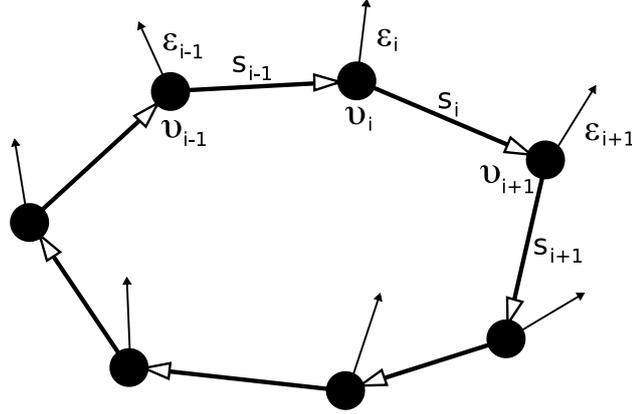


Figura 2.1: Esquema de un snake discreto compuesto por un conjunto de vértices v_i conectados por los segmentos s_i y sobre los que actúan las fuerzas ϵ_i .

La primera y segunda derivada de la ecuación 2.4 se pueden expresar usando una aproximación por diferencias finitas, como la diferencia entre puntos contiguos. Debido a esto el valor de la energía pasa a ser función de la localización singular de cada punto:

$$\epsilon_{int}(v_i) = \alpha |v_i - v_{i-1}|^2 + \beta |v_{i-1} - 2v_i + v_{i+1}|^2 \quad (2.7)$$

donde v_i representa la posición del i -ésimo vértice del snake.

Así el problema se reduce a encontrar el conjunto V de nodos que minimicen la siguiente expresión:

$$\sum_i (\epsilon_{int}(v_i) + \epsilon_{ext}(v_i)) \quad (2.8)$$

Para simplificar computacionalmente el problema, se incorporan al modelo de forma habitual restricciones que reducen de manera considerable el número de operaciones a realizar. Una de estas restricciones consiste en limitar el movimiento de cada punto del snake a una ventana de desplazamiento, de forma que en cada iteración del proceso se pueda escoger entre m posibles nuevas posiciones. Dicha ventana tendrá un tamaño de $n \times n$, siendo n impar, de modo que el vértice actual se sitúa en el centro de la ventana como se muestra en la figura 2.2 que representa dos ventanas, una de tamaño 3×3 y otra de tamaño 5×5 .

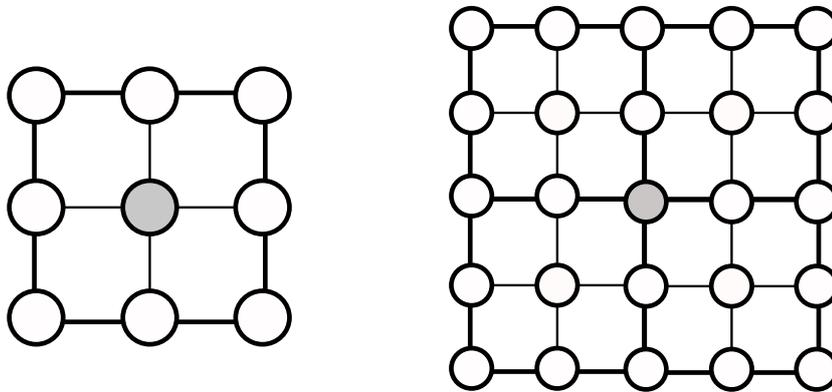


Figura 2.2: Ventanas $n \times n$ de movimiento de un nodo del snake. El punto central representa la posición actual y los puntos blancos las nuevas posiciones a las que puede desplazarse. Izquierda: $n = 3$; derecha: $n = 5$.

Definiendo una matriz de desplazamiento con m posiciones posibles, para un total de N puntos que forman el snake, se realizarían $m \times N$ evaluaciones de funciones. Este valor podría reducirse aún más mediante un algoritmo que optimice el desplazamiento de todos y cada uno de los vértices del snake. En el apartado 2.2.3, dedicado a las técnicas de minimización de energía, veremos algunos de estos algoritmos.

2.2.2. Evolución del Contorno

El comportamiento dinámico del proceso de ajuste de contornos se puede caracterizar por dos etapas, la deformación y el remuestreo, que se repiten alternativamente.

- **Deformación.** Durante el proceso de deformación el modelo inicial se transforma moviendo los vértices en un proceso controlado por la minimización de la función de energía asociada. Este proceso finaliza cuando todos los vértices alcanzan un estado de equilibrio correspondiente con un mínimo de energía del sistema.
- **Remuestreo.** El proceso de remuestreo controla la resolución del modelo deformable. Esta resolución está relacionada con la escala en la que se procesa la imagen y depende del número de vértices y el espacio entre ellos. Este proceso adapta automáticamente la resolución del contorno a la escala de la imagen, mediante la definición de un umbral de distancia d_k . Entre cada dos vértices consecutivos del snake unidos por un segmento de tamaño

mayor que d_k , se inserta un nuevo vértice. Para extraer información global de la imagen emplearemos resoluciones bajas, mientras que si nos interesa información detallada de la forma del objeto, se emplearía una alta resolución. Por otro lado, cuantos más nodos haya en el snake, mayor será el coste computacional del proceso de evolución del contorno. Así este parámetro d_k debe ser cuidadosamente ajustado al dominio de aplicación para mantener un equilibrio entre nivel de detalle y eficiencia del modelo.

2.2.3. Minimización de la Energía

A continuación presentaremos brevemente los cuatro grandes grupos en los que podemos clasificar los métodos de minimización de la energía. El método de minimización que se seleccione para un modelo basado en snakes será el responsable del proceso de deformación del mismo.

- **Análisis Numérico.** Este tipo de algoritmos se basan en las ecuaciones de Euler-Lagrange. Fueron propuestos en el modelo original de snakes [KWT88] empleando un método de diferencias finitas. Para minimizar la energía del snake se recurre al cálculo de variaciones, que aplicado a este problema obtiene una ecuación diferencial. Esta se corresponde con la ecuación 2.9, que debe cumplirse por los extremos del funcional, estableciendo así las condiciones de contorno.

$$\left\{ \begin{array}{l} \alpha x_{ss} + \beta x_{ss} + \frac{\partial \mathcal{E}_{ext}}{\partial x} = 0 \\ \alpha y_{ss} + \beta y_{ss} + \frac{\partial \mathcal{E}_{ext}}{\partial y} = 0 \end{array} \right\} \quad (2.9)$$

La ecuación 2.9 puede resolverse mediante el método de diferencias finitas, consistente en discretizar la curva $V(s)$ y las funciones en intervalos equiespaciados respecto del parámetro s . En [CC93] se puede encontrar más información sobre este método.

- **Métodos estocásticos.** Este tipo de métodos consisten en un proceso iterativo que permite buscar un mínimo global, evitando caer en mínimos locales, mediante cambios aleatorios. Existen varios métodos de minimización estocástica, siendo el más utilizado el denominado *Temple Simulado* (SA, *Simulated Annealing*). El SA se basa en el proceso físico de búsqueda del estado de equilibrio: a una temperatura elevada, los átomos de los metales están distribuidos aleatoriamente y a medida que esta va disminuyendo, los átomos tienden a colocarse en una configuración que minimiza la energía del sistema. Esta disposición de mínima energía se consigue aunque haya

un estado intermedio que implique variaciones positivas en la configuración de la energía. Si el sistema no alcanzase el equilibrio puede quedar atrapado en un mínimo local que produzca irregularidades en la configuración final de los átomos. Más información sobre este método y su aplicación se puede encontrar en [Sto94].

- **Métodos Probabilísticos.** La minimización probabilística realiza exclusivamente cambios deterministas acelerando así el proceso de convergencia. El Método Iterativo condicional (*ICM, Iterative Conditional Method*) propuesto [Bes89], es uno de los más empleados. El *ICM* se puede interpretar como un *SA* que utiliza toda la información disponible en el contexto V para optimizar un cambio. Su idea básica es que a partir de V (conjunto de parámetros del modelo), que posee una probabilidad $P(V)$, se pueda actualizar la posición del nodo v_i maximizando la probabilidad a posteriori de reducir su energía, calculada mediante el teorema de Bayes.
- **Programación Dinámica.** Esta técnica se emplea en resolución de problemas de optimización cuando no todas las variables de la función que queremos optimizar están interrelacionadas simultáneamente [BD62][Ber00]. Si se trata de minimizar algún funcional que dependa de ciertas variables, este tipo de minimización se basa en la idea de calcular todas y cada una de las posibles combinaciones de variables. Se comprueba el valor del funcional para cada una de esas configuraciones y se escogerá la que presente el valor mínimo.

Para seleccionar uno de estos métodos hemos de tener en cuenta su adecuación al modelo de snakes y especialmente a la definición de su energía. La técnica de análisis numérico garantiza que se alcanza un mínimo global pero presenta un coste computacional muy elevado, por lo que su aplicación se reduce a dominios muy limitados, tanto en número de nodos como en cantidad y complejidad de los términos de energía. Los métodos estocásticos y probabilísticos presentan un buen compromiso entre eficiencia y calidad de minimización, aunque existe el riesgo de que el sistema se estanque en un mínimo local. La programación dinámica mejora la capacidad de convergencia a un mínimo global y su concepción es simple e intuitiva, sin embargo su eficiencia disminuye cuando el número de posibles movimientos es elevado ya que implica el cálculo de múltiples combinaciones.

En nuestro caso no emplearemos ninguna de estas técnicas, sino que optaremos por una solución basada en la exploración exhaustiva local (fuerza bruta) en la que moveremos individualmente cada nodo a su posición de menor energía. Las características de nuestro modelo permiten que mediante esta técnica podamos alcanzar una eficiencia mucho mayor que con cualquiera de las otras, ya que sólo

hemos de valorar para cada nodo tres posibilidades de desplazamiento. Al ser una técnica de minimización local no se garantiza la convergencia a mínimos globales, dificultad que solucionaremos mediante la definición de energías específicas y el control de la evolución del contorno. En el siguiente capítulo describiremos en detalle la características de nuestro modelo de snakes, incluyendo estos nuevos términos de energía, la estructura de su contorno, su proceso de evolución y las operaciones de control.

Capítulo 3

Contorno Deformable para Segmentación del Árbol Vasculare Retiniano

En este capítulo describiremos la estructura y funcionamiento del modelo desarrollado, explicando detalladamente cómo se lleva a cabo el proceso de segmentación.

Para la detección del árbol vascular de la retina se utilizará un modelo de contorno deformable. El snake que se empleará está discretizado al igual que el espacio de trabajo donde lleva a cabo la segmentación, es decir, la imagen de fondo de ojo. De este modo trabajaremos con un contorno polinómico cerrado que evoluciona sobre una superficie de píxeles.

Así pues, nuestro sistema de segmentación constituye una adaptación del modelo genérico de contornos deformables paramétricos al dominio concreto de las estructuras vasculares retinianas. Las modificaciones consiguen incorporar conocimiento específico del dominio y aprovechar las propiedades topológicas arteriovenosas para lograr un mejor ajuste del contorno. Se ha redefinido el modelo clásico de snakes discretizando el contorno, añadiendo estados a los nodos y definiendo energías internas y externas específicas. Además, utilizaremos información de las imágenes obtenida mediante aplicaciones ad-hoc o aprovechando utilidades desarrolladas en nuestro grupo de investigación, como son la extracción de crestas, detección de bordes, segmentación morfológica y localización del disco óptico.

La figura 3.1 muestra gráficamente este proceso global de funcionamiento del sistema desarrollado. En primer lugar se realiza un preprocesado de la imagen original en la que se convierte a escala de grises y se amplía al doble de su tamaño.

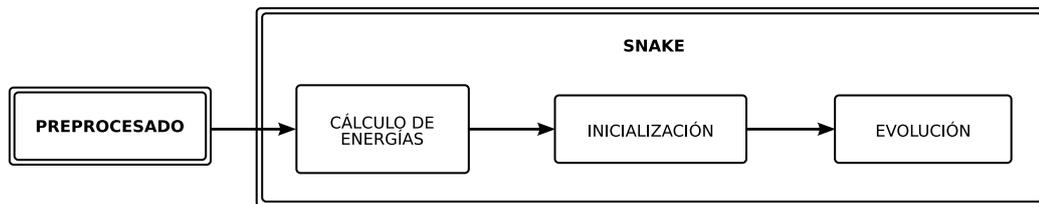


Figura 3.1: Diagrama que representa el proceso global de ejecución del modelo.

De esta imagen obtenemos las crestas, los bordes y la segmentación morfológica auxiliar que emplearemos como energías para guiar la evolución del snake. Después realizamos la localización del disco óptico que junto con la imagen de crestas nos permite crear el contorno inicial. Este snake inicial irá segmentando los vasos, guiado por toda la información extraída de la imagen. Este proceso de evolución continúa hasta que el snake haya segmentado el árbol vascular completo.

En los siguientes apartados de este capítulo explicaremos cada una de las fases del proceso mencionadas. Así, describiremos en primer lugar el preprocesado que se realiza sobre la imagen original y justificaremos la selección del nivel de precisión con el que trabajaremos. A continuación, presentaremos los métodos de obtención de crestas, bordes y segmentación morfológica, así como las operaciones realizadas para la mejora de la calidad de los mismos para su posterior utilización como energías del snake. Seguidamente detallaremos todas las energías que gobernarán el snake y su influencia en la estructura del contorno. Por último, nos centraremos en la inicialización y evolución del contorno deformable.

3.1. Preprocesado de la imagen

Para poder trabajar adecuadamente con la imagen es necesario realizar previamente un preprocesado de la misma. Básicamente hemos de transformar a escala de grises la imagen que está originalmente en color y ampliarla al doble de su tamaño. Ambas operaciones son sencillas pero de gran importancia para alcanzar una adecuada segmentación de la vasculatura retinal. La figura 3.2 muestra la ubicación dentro de la ejecución global de estas operaciones de procesado que se explican más detalladamente en los siguientes apartados.

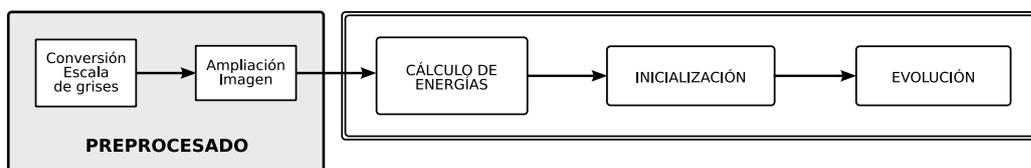


Figura 3.2: Diagrama que representa las operaciones de preprocesado de la imagen original (conversión a escala de grises y ampliación al doble de su tamaño) situadas en el marco del proceso completo de ejecución del modelo.

3.1.1. Conversión a Escala de Grises

Aunque las fotografías originales son en color, la mayoría de aproximaciones al problema encontradas en la literatura trabajan sobre una conversión de la misma a escala de grises. La información de color es descartada generalmente porque la distribución de color de las imágenes de fondo de ojo puede variar notablemente de un paciente a otro debido a la presencia de pigmentos en las coroides y el epitelio de la retina, influyendo en ello factores tales como el origen étnico. Además las venas presentan una alta variabilidad de color dependiendo de su localización a causa de la iluminación no uniforme durante el proceso de captura de las retinografías.

Diversas pruebas realizadas previamente muestran que la información de color es redundante para el objetivo del sistema, por lo que utilizarla introduciría una complejidad innecesaria en el modelo aumentando el coste temporal de ejecución. De los tres canales de color RGB, el azul no contiene prácticamente información útil para el proceso de segmentación, obteniéndose resultados muy semejantes omitiendo dicho canal. Se han desarrollado sistemas que realizan la extracción del árbol vascular trabajando sólo con uno de los otros dos canales de color de la retinografía [LGB00]. En nuestro caso, se realiza la conversión a escala de grises considerando los tres canales de color puesto que puede ser necesario para otras aplicaciones auxiliares al modelo, como la detección del disco óptico.

Esta conversión se realiza mediante una aplicación de procesamiento de imágenes y consiste básicamente en asignar a cada píxel un valor de gris correspondiente a la media ponderada del que tiene en cada uno de los tres canales de color. Dicha función transforma una imagen en color de 24 bits y tres canales en una en escala de grises de 8 bits y un solo canal. La fórmula aplicada para combinar los tres componentes de color es la siguiente:

$$Y = 0,3R + 0,59G + 0,11B \quad (3.1)$$

donde Y representa el valor de gris que se asignará al píxel y R , G y B se corresponden respectivamente con los valores de las componentes roja, verde y azul de

dicho píxel en la imagen en color. La asignación de pesos hace que que la luminosidad de la imagen en escala de grises obtenida sea perceptivamente equivalente a la de la imagen en color original.

La figura 3.3 muestra un ejemplo de esta conversión de la imagen original en color a escala de grises. En la imagen en escala de grises, los vasos sanguíneos presentan una tonalidad más oscura que el fondo retiniano y el disco óptico aparece como una zona brillante y redondeada. La mancha difusa situada en la zona central de la imagen se corresponde con la mácula.



(a) Imagen original en color

(b) Imagen en escala de grises

Figura 3.3: Ejemplo de conversión a escala de grises.

3.1.2. Selección del Nivel de Precisión

La decisión sobre el nivel de precisión con el que vamos a trabajar es muy importante para el cálculo de parámetros que impliquen la estimación del calibre vascular, como por ejemplo el índice arterio-venoso. Dicho nivel debe ser seleccionado de manera que se mantenga un compromiso entre exactitud en la detección y eficiencia del proceso. Como expondremos en este apartado, será necesario realizar el proceso de segmentación a nivel subpíxel para alcanzar una precisión suficiente, aunque ello suponga un incremento del coste computacional [ECPO08].

Uno de los motivos principales de la necesidad del nivel subpíxel es la segmentación de vasos finos. Nuestro modelo de contornos deformables precisa de

una cierta anchura en las estructuras tubulares a segmentar para poder avanzar en su interior. Los vasos más finos, de entre uno y tres píxeles de ancho, se pierden frecuentemente si trabajamos a nivel de píxel. Otra de las razones que nos llevan a trabajar a nivel de subpíxel es la precisión en la medidas del calibre vascular que se realicen sobre el árbol arterio-venoso segmentado. Una diferencia de uno o dos píxeles en la estimación de la anchura de un vaso puede afectar significativamente a los parámetros médicos que se calculen considerando la misma. Trabajando a nivel de subpíxel tenemos una mejor localización de los límites de cada estructura vascular segmentada ya que presentarán el doble de resolución. En la sección de resultados se incluyen figuras y tablas que muestran visual y numéricamente la mejora que supone la segmentación a nivel subpíxel.

Otras aproximaciones a la segmentación vascular precisan asimismo trabajar a nivel de subpíxel para lograr una correcta segmentación. Es el caso del sistema de segmentación basado en un modelo difuso presentado por Phalm y col. [PTBLK05] o el modelo de segmentación basado en crestas de imágenes en color de la retina desarrollado por Staal y col. [SAN⁺04].

Si queremos que nuestro snake alcance una precisión de nivel subpíxel, será necesario ampliar previamente la imagen original al doble de su tamaño. Para ampliar la retinografía minimizando las pérdidas de calidad, es imprescindible emplear un algoritmo de interpolación adecuado. En el apéndice A se describe la técnica aquí empleada, interpolación bicúbica, que amplía la imagen manteniendo en gran medida las propiedades originales. La interpolación bicúbica presenta una complejidad computacional elevada por lo que su efecto en la eficiencia del modelo es notable, aunque se ve compensado por la precisión alcanzada. En la sección de resultados se justifica empíricamente esta elección comparando los resultados obtenidos tras aplicar diferentes métodos de interpolación.

Además del tiempo necesario para llevar a cabo la interpolación, aparecen otros incrementos en el tiempo de procesado necesario. Todas las imágenes de energía extraídas de la imagen original deberán obtenerse ahora desde una ampliación de la misma al doble de su tamaño. De este modo, el cálculo de las crestas, bordes y segmentación morfológica será más costoso computacionalmente.

La complejidad del modelo también se incrementa considerablemente. El número de nodos del snake será mucho mayor puesto que el área a segmentar se ha duplicado. Si tenemos un contorno mucho más extenso y mantenemos el nivel de detalle, es decir, la distancia entre nodos, la cantidad de elementos que conforman nuestro snake aumenta. El proceso de minimización de energía es local a cada nodo, así que cuantos más nodos haya, más operaciones de cálculo de energía hay que realizar en cada iteración. El número de actualizaciones de estado, operaciones de control o inserciones de nuevos nodos por iteración se incrementan de

manera similar.

Aun así, la eficiencia del modelo continúa siendo muy elevada en comparación con otros métodos existentes. Sobre todo en cuanto a la sensibilidad, el valor alcanzado trabajando a nivel de píxel es insuficiente. Esto es debido a que la mayoría de los vasos finos no se segmentan adecuadamente. Aunque esto no es relevante para el cálculo del calibre vascular retiniano, que sólo considera los vasos principales, limita la utilidad de nuestra aplicación para otros usos. Incrementos mayores en las dimensiones son inabordables debido a las repercusiones en el coste computacional. El nivel subpíxel alcanza así pues, una eficiencia considerable y una precisión suficientes para ser empleado como herramienta de ayuda al diagnóstico incluso en aplicaciones de tiempo real.

En el capítulo de resultados se detallan los niveles de precisión, sensibilidad y especificidad alcanzados trabajando a nivel de píxel y de subpíxel. También se incluyen las medidas de tiempo de ejecución para cada una de dichas versiones del proyecto e imágenes mostrando los resultados obtenidos.

3.2. Energía del Snake

En esta sección explicaremos en detalle la definición de energías del modelo desarrollado, así como la obtención de las mismas. Una vez definidas las fuerzas que gobernarán el snake, pasaremos a describir la estructura del contorno.

3.2.1. Términos de Energía

En este apartado describiremos las energías que se definen en nuestro modelo de contornos deformables y que gobernarán su evolución. Como se señaló en la ecuación (2.2), un snake está habitualmente modulado por energías internas y externas. No emplearemos las energías internas tal y como se definen en el modelo clásico debido a que los vasos sanguíneos de la retina pueden presentar formas tortuosas, no teniendo sentido controlar la elasticidad o flexibilidad del contorno modeladas por dichas funciones de energía interna.

En la figura 3.4 se muestran las operaciones principales relacionadas con la obtención de las energías externas. Las energías internas dependen de la configuración del contorno en cada momento por lo que no pueden ser obtenidas previamente sino que se calculan dinámicamente en el proceso de evolución del modelo.

La energía global que afecta a este snake estará definida como la suma de las

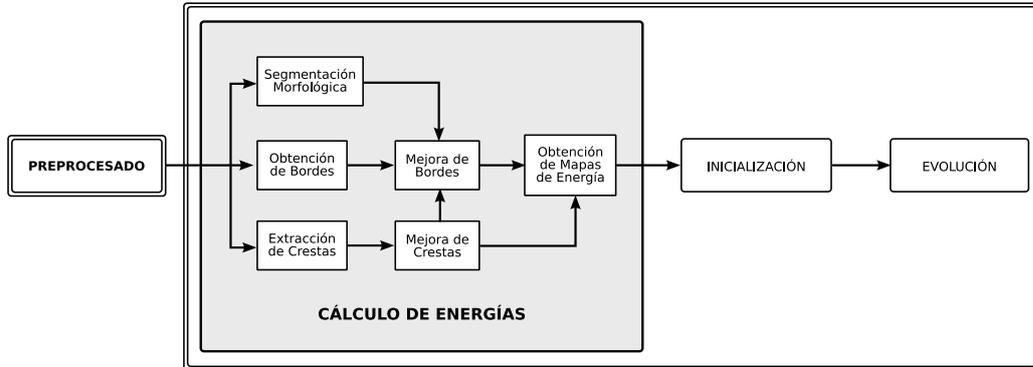


Figura 3.4: Diagrama que representa dentro del proceso global de segmentación, las operaciones de obtención de información de la imagen (crestas, bordes y segmentación morfológica auxiliar) que se emplearán como energías externas en el proceso de evolución del snake.

energías internas ϵ_{int} y externas ϵ_{ext} , que a su vez se componen de un conjunto de energías y factores de peso:

$$\epsilon_{snake} = \epsilon_{ext} + \epsilon_{int} = \gamma\epsilon_{borde} + \delta\epsilon_{cresta} + \nu\epsilon_{dir} + \sigma\epsilon_{marca} + \omega\epsilon_{difer} \quad (3.2)$$

Los tres primeros términos, ϵ_{borde} , ϵ_{cresta} y ϵ_{dir} , se corresponden con energías externas ya que sus valores vienen definidos por características de la imagen. Sin embargo, los términos ϵ_{marca} y ϵ_{difer} son considerados energías internas puesto que dependen de la situación del contorno deformable. A continuación, explicaremos en detalle cada uno de los términos de energía que componen la ecuación 3.2.

El primer término ϵ_{borde} corresponde con la energía de distancia a bordes. La imagen de bordes ha sido obtenida mediante el algoritmo de Canny [Can86], descrito en el apéndice A. En la figura 3.5 se muestra el resultado de la extracción de bordes superpuesto en blanco a la retinografía. Una vez que la imagen de bordes está disponible, el mapa de energía se calcula asignando a cada punto su distancia euclídea al borde más cercano. Por motivos de eficiencia, sólo se calcula la distancia a bordes para los puntos que se encuentran suficientemente cerca de los mismos. La figura 3.6 muestra el mapa de energía obtenido a partir de la imagen de bordes. Esta energía ayuda en el avance de los nodos del snake que se encuentran cerca de los bordes del vaso. Además frena dichos nodos cuando alcanzan un mínimo, esto es, cuando alcanzan un punto del borde.

La energía de distancia a bordes se define de la siguiente forma:

$$\forall v_i, \epsilon_{borde} = dist(v_i, I_{borde}) \quad (3.3)$$

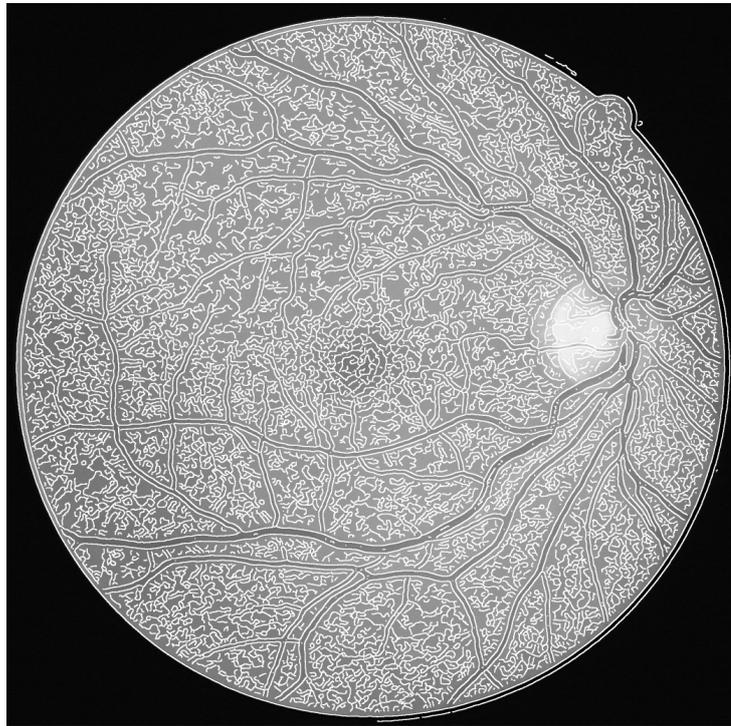


Figura 3.5: Resultados de la extracción de bordes, representados en blanco y superpuestos a la imagen original.

donde v_i es un nodo del snake e I_{borde} es la imagen de bordes. $dist(v_i, I_{borde})$ representa la distancia euclídea entre el nodo considerado v_i y el punto de borde más cercano.

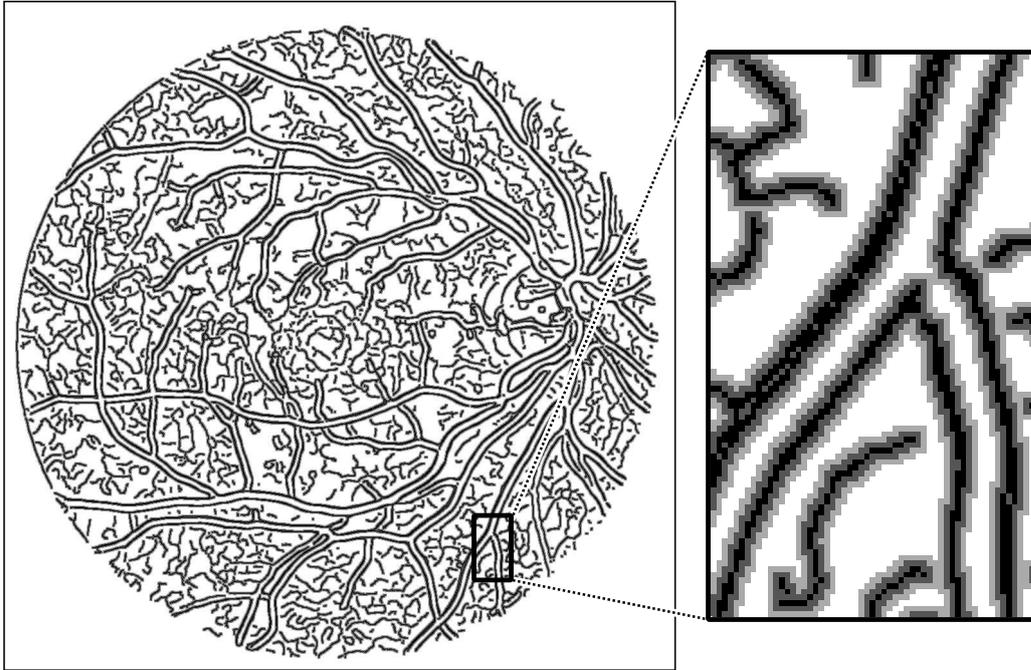


Figura 3.6: Energía de distancia a bordes ϵ_{borde} .

El segundo término ϵ_{cresta} corresponde a la energía de distancia a crestas. Las crestas se corresponden con las líneas centrales de los vasos sanguíneos o, dicho de otro modo, son zonas contiguas de mínima intensidad local. Las crestas se extraen de la imagen mediante el método desarrollado por nuestro grupo de investigación que se describe en detalle en el apéndice A [CPM⁺04]. La figura 3.7 muestra las crestas superpuestas en blanco a la retinografía. La energía de distancia a crestas ϵ_{cresta} se obtiene a partir de la imagen de crestas de manera similar que ϵ_{borde} . En la figura 3.8 se representa el mapa de energía de distancia a crestas obtenido calculando la distancia euclídea de cada punto a la cresta más cercana.

Este término de energía se introduce principalmente con el objeto de guiar el snake a lo largo de la estructura arterio-venosa, haciéndolo fluir por el interior de los vasos. Asimismo, ayuda a evitar los desbordamientos del contorno causados por las discontinuidades de los bordes ya que actúa como energía de frenado. Se produce un bloqueo del avance del contorno cuando, entre otros factores, se alcanza un límite de máxima distancia a crestas, como se muestra en la figura 3.9. Este proceso de bloqueo del snake se explica en detalle en el apartado 3.4 dedicado a la evolución del contorno.

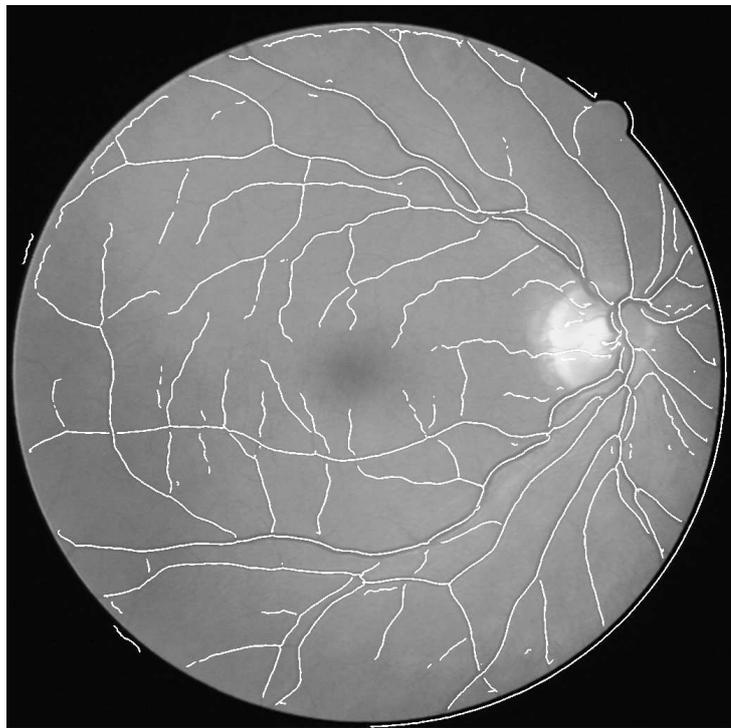


Figura 3.7: Resultados de la extracción de crestas, representadas en blanco y superpuestas a la imagen original.

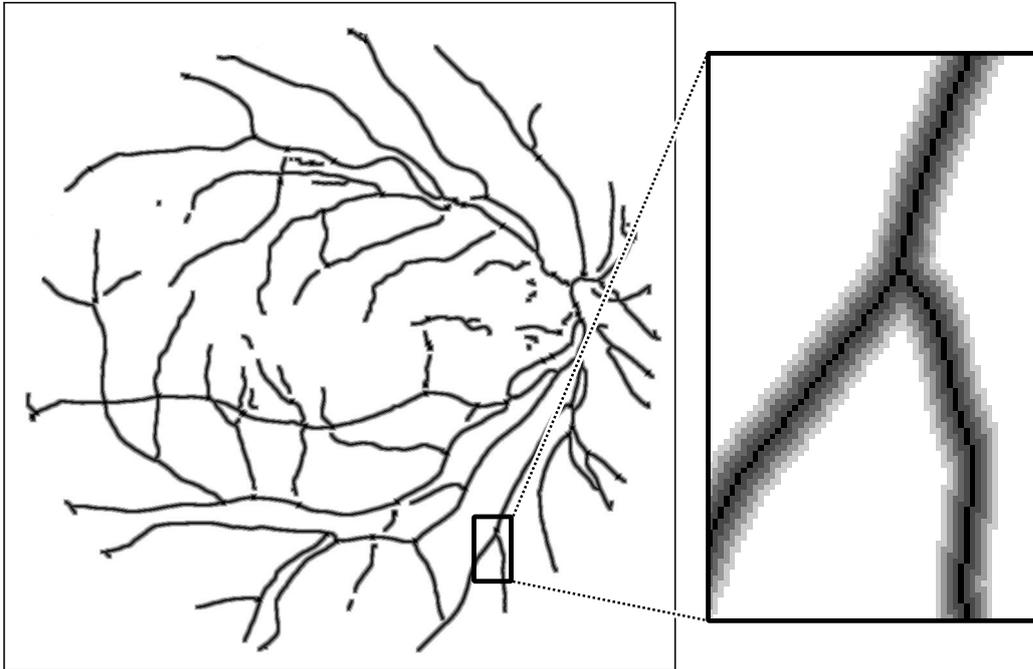


Figura 3.8: Energía de distancia a crestas ϵ_{cresta} .

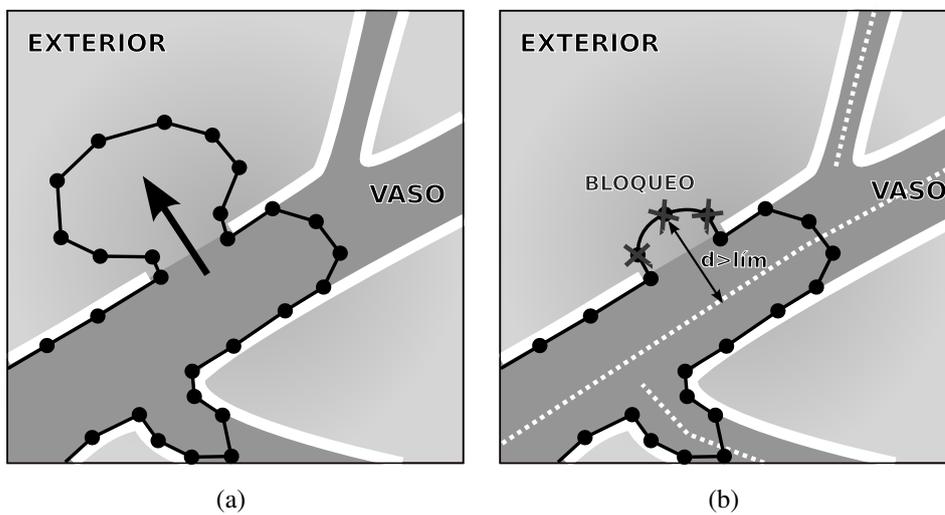


Figura 3.9: Solución de los desbordamientos causados por las discontinuidades del borde mediante las crestas: (a) Situación de discontinuidad en el borde (línea blanca gruesa) que produce en la zona señalada con una flecha, un desbordamiento del snake. (b) Solución del problema por bloqueo del contorno (nodos tachados) al alcanzarse el límite de distancia a cresta (línea blanca punteada).

La energía de distancia a crestas se define según la siguiente ecuación:

$$\forall v_i, \epsilon_{cresta} = dist(v_i, I_{cresta}) \quad (3.4)$$

donde v_i es un nodo del snake e I_{cresta} es la imagen de crestas. $dist(v_i, I_{cresta})$ representa la distancia euclídea entre el nodo considerado v_i y el punto de cresta más cercano.

La presión de inflado ϵ_{dir} es la mayor fuerza de expansión del snake. Cada nodo tiene una dirección de avance asignada que determina las tres posibles posiciones adyacentes (llamadas A, B y C) a las que se puede mover. La presión de inflado incitará a cada nodo del snake a moverse a una nueva posición de entre esas tres. Se seleccionará siempre la posición que presente una menor energía, como se explica a continuación. La figura 3.10(a) muestra las tres posiciones de desplazamiento permitidas para cada dirección asignada al nodo. El desplazamiento de un nodo siempre es de distancia un píxel, así un nodo puede moverse a 3 de las 8 posiciones adyacentes al mismo. Ofreciendo estas tres alternativas se evitan situaciones como la mostrada en la figura 3.10(b). En ella vemos cómo el nodo puede pasar a través de un borde y continuar moviéndose fuera de los límites del vaso. La presión de inflado fuerza al nodo a moverse a la posición de menor energía de entre esas tres, que correspondería a un punto de borde, en el cual se estabilizaría quedando correctamente segmentada esa porción del vaso.

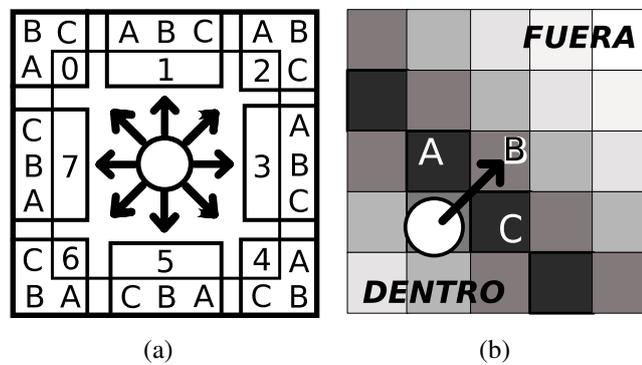


Figura 3.10: Presión de Inflado: (a) Movimientos posibles del nodo dependiendo de la dirección asignada. (b) Situación de ejemplo que muestra la utilidad de las posiciones alternativas de avance: el nodo que tiene asignada la dirección de la flecha puede moverse también a las posiciones A y C situadas en el borde (cuadrados oscuros). Sin estas alternativas, sólo podría moverse a la posición B y por tanto saldría fuera del vaso a través de su borde.

El cuarto término de energía ϵ_{marca} es la energía de marcador. Para limitar la dilatación del snake, consideramos una imagen marcador que puede ser vista como un mapa de energía más. Este mapa se crea iterativamente, rellenándolo por

triangulación a medida que los nodos se desplazan. La figura 3.11 muestra este proceso de actualización del mapa de energía de marcador. Este término es necesario para asegurar que no se producen solapamientos del snake sobre sí mismo o una vuelta atrás, ya que las energías definidas hasta el momento, aunque no propician este tipo de situaciones, no bastan para evitarlos. Esta energía de marcador fuerza al nodo a moverse siempre hacia nuevas posiciones de energía y lo bloquea cuando todas sus alternativas de avance han sido ocupadas con anterioridad, pues es necesario evitar que un nodo vaya a posiciones ya visitadas aunque tengan valores de energía menores para los otros términos. Por lo tanto, su peso deberá ser mayor que el de las demás energías.

La siguiente ecuación define esta energía de marcador:

$$\forall v_i, \epsilon_{marca} = \begin{cases} 1 & \iff I_{marca}(v_i) = 255 \\ 0 & \text{en otro caso} \end{cases} \quad (3.5)$$

donde v_i es un nodo e I_{marca} es la imagen de marcador. El valor de $I_{marca} = 255$, color blanco, indica que esa posición ya se ha analizado.

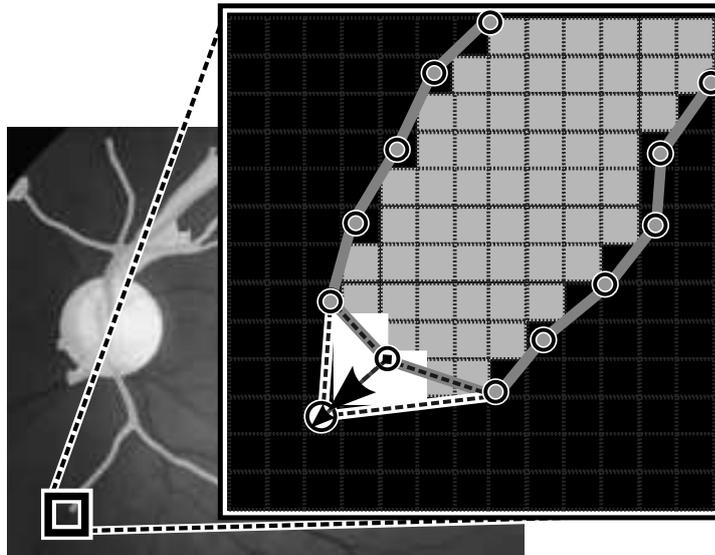


Figura 3.11: Energía de marcador ϵ_{marca} : Detalle del mapa actualizándose por triangulación debido al desplazamiento de un nodo. El nodo situado en la parte punteada del snake se mueve, tal y como indica la flecha. La nueva área en el interior del contorno deformable (representada en blanco) se marca como ya visitada por un nodo.

La energía de diferencia ϵ_{dif} se define para reforzar el control sobre la expansión del snake, incitando a los nodos a ocupar posiciones diferentes a las de sus

vecinos. De este modo se alcanza una mayor precisión ya que se establecen más puntos de límite de vaso. Este término debe tener un peso mucho menor que los demás, puesto que la importancia de que la posición sea nueva es menor que la distancia a bordes o crestas. Esta energía sólo actuará decisivamente en el desplazamiento del nodo en los casos de igualdad en el valor de los otros términos de energía.

La energía de diferencia puede ser definida por la siguiente ecuación:

$$\forall v_i, \epsilon_{dif} = \begin{cases} 1 & \iff dist(v_i, v_{i-1}) + dist(v_i, v_{i+1}) = 0 \\ 0 & \text{en otro caso} \end{cases} \quad (3.6)$$

donde v_i es un nodo y v_{i-1} y v_{i+1} son los nodos situados antes y después en el contorno del snake, es decir, sus vecinos directos. $dist(v_i, v_{i-1})$ representa la distancia euclídea entre el nodo considerado v_i y el nodo inmediatamente anterior en el contorno del snake v_{i-1} . De manera equivalente, $dist(v_i, v_{i+1})$ se corresponde con la distancia euclídea existente entre el nodo considerado v_i y el nodo siguiente en el contorno del snake v_{i+1} .

Como veremos en el apartado 3.2.3, el cálculo de la energía que presenta una posición para un nodo concreto dependerá, además de todos los términos descritos, del estado del nodo que estemos considerando. Cada estado de nodo presentará un conjunto de pesos para los términos de energía de la ecuación 3.2, según la cual se calcula la energía total de cada posición. Los valores de esta energía son determinantes en la evolución del snake por lo que deben ser lo más exactos posible para obtener una segmentación vascular precisa.

Previamente a la obtención de los términos de energía externa ϵ_{borde} y ϵ_{cresta} se efectúan los procesos de mejora sobre las imágenes de crestas y bordes que describiremos en el siguiente apartado y que están representadas en la figura 3.4 .

3.2.2. Mejora de las Imágenes de Energía

Las energías de distancia a crestas y bordes, ϵ_{cresta} y ϵ_{borde} , son fundamentales para guiar el snake y estabilizarlo en los puntos adecuados. Así, la calidad de los bordes y crestas extraídas de la imagen es determinante en la obtención de una segmentación vascular precisa. La presencia de ruido, la mala iluminación y el bajo contraste que presentan a menudo las imágenes de fondo de ojo provocan la aparición de discontinuidades y pequeñas imprecisiones en las crestas y bordes extraídos. Se hace pues necesario un post-procesado de las imágenes de crestas y bordes para corregir este tipo de problemas y adecuarlas así a su posterior uso

como términos de energía externa. En este apartado describiremos estos procesos de mejora, comenzando por los aplicados sobre la imagen de crestas.

La extracción de crestas es un paso crucial e irreversible dentro del proceso global de funcionamiento de nuestro sistema. La información proporcionada por la imagen de crestas es de una importancia tal que si la cresta correspondiente a un vaso no fuese detectada, es muy probable que esa estructura vascular quedase sin segmentar. Si dicha situación tuviese lugar en una de las ramificaciones principales, todas las ramas vasculares y capilares que partan de ella tampoco podrían segmentarse.

Por todo ello, hemos dedicado un gran esfuerzo a la parametrización del extractor de crestas para encontrar una configuración que sea globalmente adecuada a todo el conjunto de retinografías disponibles y conseguir obtener así los mejores resultados posibles. Pese a todo, como ya hemos comentado en la introducción, las imágenes de fondo de ojo son bastante problemáticas por lo que en ocasiones hay zonas en las que las crestas no se extraen correctamente.

El problema más común que presentan las imágenes de crestas es la falta de continuidad en las bifurcaciones y cruces. En la figura 3.12 (a) pueden observarse las rupturas de la línea de cresta que aparecen en zonas de bifurcación de vasos. Como se explicó en el capítulo anterior, nuestro modelo de segmentación emplea las crestas como guías para su avance por la estructura vascular. Estas rupturas de la continuidad de las líneas de cresta dificultan el avance del mismo, por lo que surge la necesidad de buscar una solución a esta cuestión.

A continuación presentaremos brevemente las características principales de una utilidad, denominada *Minutia*, desarrollada en nuestro grupo de investigación [OMP⁺06] que forma parte de un sistema de autenticación biométrica a partir de imágenes de retina, pero que es aquí empleada en la mejora de crestas.

Este método de verificación de identidad se basa en retinografías digitales, puesto que el árbol vascular retinal de cada persona es único. El proceso de emparejamiento se basa en la extracción de los *puntos característicos* y el registro de los mismos para calcular la similitud entre las imágenes de entrada. Dichos puntos característicos corresponden a las terminaciones y bifurcaciones de las crestas extraídas de la retinografía [CPM⁺04]. Para la obtención de los puntos característicos se precisa además la localización del disco óptico [BPB⁺06].

El algoritmo de extracción de los puntos característicos se compone de las siguientes fases:

1. **Detección de segmentos.** Se realiza un seguimiento de cada segmento de cresta, etiquetando sus nodos inicial y final. Además se asigna a cada uno

una circunferencia rodeando el disco óptico, vamos recorriendo recursivamente todas las demás a través de las bifurcaciones y uniones. Realizamos aquí una verificación de las direcciones asignadas y comprobamos que su punto inicial es la parte más cercana al disco óptico y el final es la más alejada del mismo. En caso de que no sea haya computado correctamente, se intercambian las etiquetas de dichos puntos. Se realiza también la reconsideración de los candidatos de bifurcación, ya que al tener la dirección correcta del segmento podemos estimar el ángulo real que forma con el segmento del que suponemos que parte. En el ejemplo de la figura 3.13(b) el ángulo que forman r y s será φ si consideramos que $r = \overline{BA}$, pero si consideramos el segmento en sentido opuesto, $r = \overline{AB}$, el ángulo será $\pi - \varphi$.

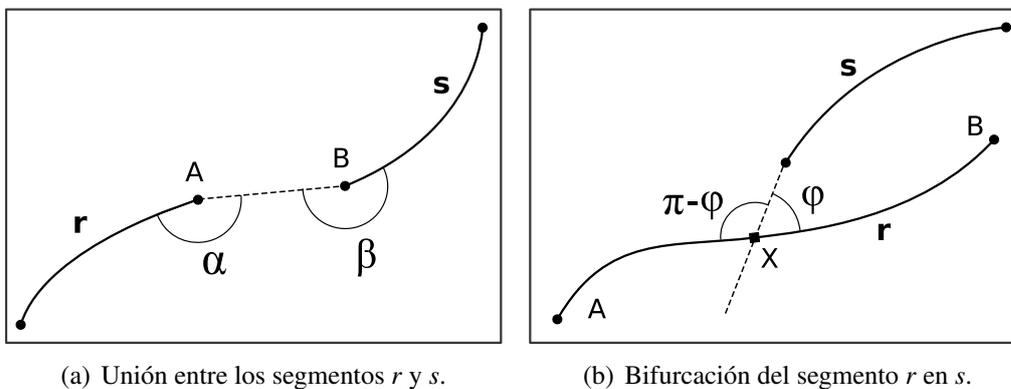


Figura 3.13: Ejemplo de extracción de puntos característicos.

Aprovechando los puntos característicos obtenidos por Minutia, hemos podido solventar el problema de la discontinuidad de las crestas. Con ayuda de esta utilidad, es posible unir de manera coherente muchos de los extremos de las crestas que quedan desconectadas en puntos de bifurcación o cruce. En la figura 3.12 (b) puede apreciarse la mejora obtenida tras la utilización de dicha herramienta, sobre todo en los puntos marcados por las flechas. Además de esto, nos permite obtener una guía más precisa, puesto que afina las líneas de cresta hasta dejarlas con grosor de un solo píxel.

Una vez mejoradas las crestas y, por tanto, aumentada la calidad del proceso de avance del snake, debemos ocuparnos de la estabilización del mismo. Para ello efectuaremos un post-procesado de la imagen de bordes ya que en general los nodos del snake se estabilizan sobre estos, detectando así el contorno de las estructuras vasculares. Por tanto, la calidad de los bordes extraídos a partir de la imagen original determinará la precisión de la segmentación final, jugando un papel muy importante en el proceso global. En estas operaciones de mejora se

evita realizar procesados de la imagen original por ejemplo para eliminación de ruido o realce de vasos, puesto que cualquier actuación de este tipo provocaría un desplazamiento de los bordes, perdiéndose gran precisión en la localización de los mismos.

De igual manera que para la imagen de crestas, se ha estudiado detenidamente el ajuste de parámetros hasta encontrar un conjunto de los mismos que se adecúe a todas las imágenes de entrada. Pese a todo, las retinografías son imágenes problemáticas en cuanto a presencia de ruido, mala iluminación o bajo contraste como hemos explicado, por lo que en la extracción de bordes se presentan a menudo ciertos fallos que afectan negativamente al funcionamiento de nuestro modelo.

Las zonas más críticas para el cálculo de los bordes son las intersecciones y las bifurcaciones de los vasos sanguíneos. En estos puntos, sobre todo cuando el calibre o la tonalidad de un vaso y otro son muy diferentes, el borde del vaso principal no se interrumpe en el punto en el que interseca con el otro. En la zona superior derecha de la figura 3.14(a), se muestra un ejemplo de bordes situado de esta manera. En ocasiones este borde es real, es decir, son dos vasos que se cruzan y en otras no (es una bifurcación), pero en cualquier caso, nos interesa que ambas estructuras vasculares estén unidas para que el contorno deformable pueda fluir por su interior. La imagen de crestas nos permite reducir este tipo de problemas, puesto que se identifican en los puntos donde un borde y una cresta intersecan. Rompiendo el borde en dichos puntos de intersección permitimos al snake avanzar por el nuevo vaso, como se ve en la parte superior derecha de la figura 3.14(b).

Otro problema habitual se produce en las zonas cercanas a la intersección o bifurcación de un segmento de un vaso cuando sus bordes no se detectan correctamente. En la zona inferior izquierda de la figura 3.14(a) puede verse cómo los bordes del vaso que se ramifica hacia arriba no llegan a unirse con los del vaso principal. El snake se bifurca debido a la información de crestas, pero al no haber bordes cercanos se produce un *desbordamiento*: el snake crece incontroladamente saliéndose del área del vaso.

Para solucionar esto, añadimos los bordes de la imagen de segmentación morfológica auxiliar descrita en el apéndice A [ECOP08]. La segmentación morfológica consiste básicamente en incrementar contraste, eliminar ruido y realzar vasos sanguíneos y posteriormente efectuar su segmentación. Este método se basa en el propuesto por Condurache y Aach [CA05], adaptándolo al dominio de las imágenes de fondo de ojo y aprovechando la conectividad del árbol vascular retiniano. En la figura 3.15 se muestran los bordes extraídos de la segmentación morfológica auxiliar, que denominaremos *bordes auxiliares*, superpuestos a la imagen original.

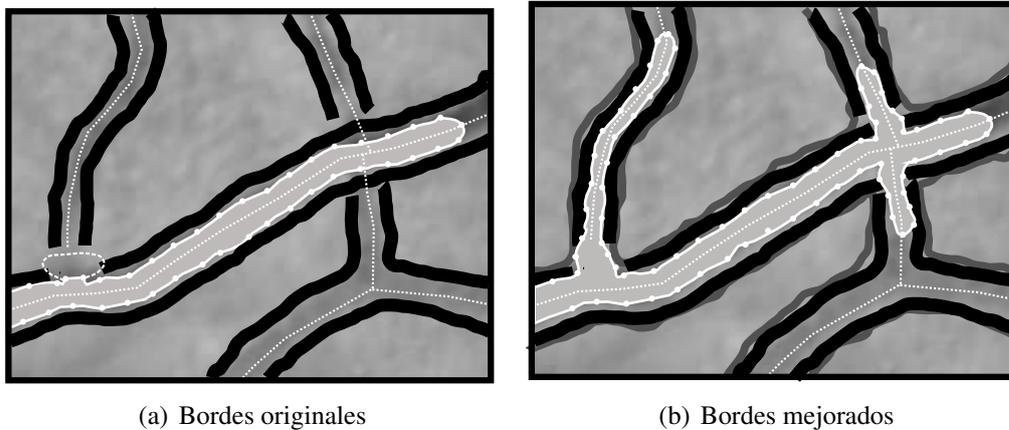


Figura 3.14: Mejora de bordes. La línea punteada blanca representa las crestas, las líneas negras gruesas son los bordes originales, las líneas gris oscuro más finas se corresponden con los bordes de la segmentación morfológica añadidos y el área gris claro bordeada por una línea blanca es la segmentación realizada por el snake. Comparando la zona inferior izquierda de ambas imágenes, se aprecia cómo en la imagen (a) el snake se desborda en la bifurcación sin llegar a segmentar el vaso secundario mientras que en la imagen mejorada (b) sí se segmenta ya que los bordes se han mejorado al añadir los obtenidos por la segmentación morfológica. En la zona superior derecha de la imagen (a) los bordes bloquean al snake impidiéndole entrar el vaso que se cruza con el principal. Esta situación se resuelve en la imagen mejorada (b), ya que se abren los bordes mediante la información de crestas, permitiendo al snake segmentar dicho vaso.

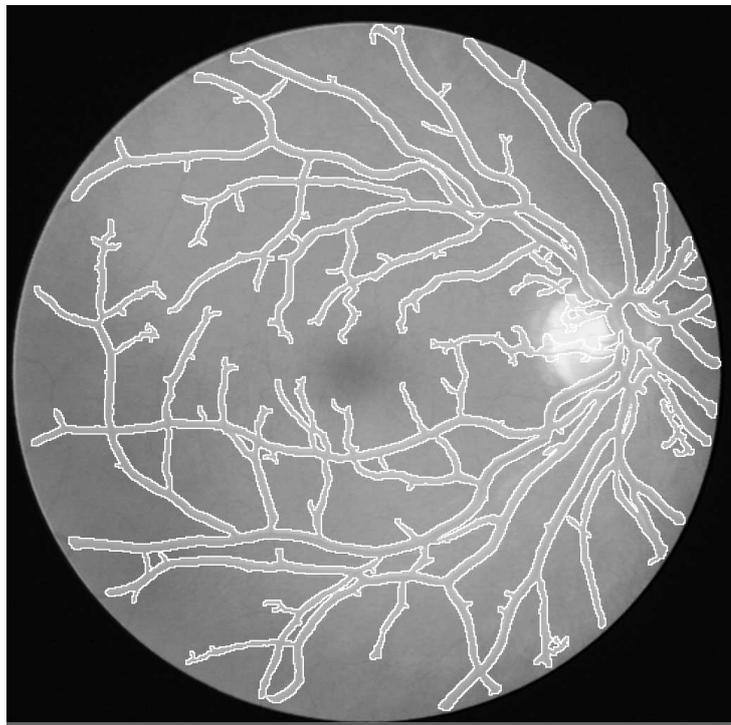


Figura 3.15: Bordes extraídos de la segmentación morfológica auxiliar, representados en blanco y superpuestos a la imagen original.

Estos bordes auxiliares son menos precisos que los de la imagen original y se sitúan hacia el exterior de las estructuras vasculares. De este modo, el snake sigue estando influido principalmente por los bordes originales, excepto en donde éstos presentan discontinuidades. El contorno deformable que se muestra en la figura 3.14(b), puede así avanzar por las ramificaciones gracias a los bordes auxiliares, que están representados por líneas gris oscuro.

Debido a nuestros esfuerzos por mantener una alta sensibilidad en la detección de bordes, es frecuente que aparezcan fragmentos de bordes debidos al ruido. Estos bordes incorrectos dificultan el proceso de segmentación por lo que es necesario su eliminación, especialmente en el interior de los vasos, pues entorpecen el avance del snake. Para suprimirlos se efectúa una sencilla limpieza sobre la imagen de bordes basándonos en el pequeño tamaño que suelen presentar los bordes debidos al ruido. El proceso consiste simplemente en eliminar los bordes muy pequeños mediante la convolución de la imagen de bordes con una ventana del tamaño máximo que consideramos que pueden tener, unos 4 píxeles. Se eliminarán aquellos segmentos de borde que queden contenidos dentro de dicha ventana, es decir, que no superen una cierta longitud. De este modo, el snake fluirá más fácilmente por el interior de los vasos y la segmentación se efectuará de forma más rápida y precisa.

Las retinografías presentan un esquema consistente en un área circular o *FOV* ("Field Of Vision"), en el que se representa la parte de la retina fotografiada sobre un fondo negro. Las zonas límite entre el fondo negro y la imagen de la retina están habitualmente afectadas por distorsiones cromáticas y ruido digital debido al proceso de adquisición, a lo que se suman artefactos de compresión de la imagen. Debido a esto y a la presencia de un salto brusco de intensidad entre la retina y el fondo negro, se producen confusiones en esas zonas, tanto en la detección de bordes como de crestas. En la mayoría de las imágenes aparecen crestas y bordes espurios en las zonas cercanas al borde del FOV como muestran las figuras 3.16 y 3.17 respectivamente.

De cara a la correcta segmentación del árbol vascular, es igual de problemático que no se detecte una cresta o borde como que se detecte erróneamente. La conjunción de las crestas y bordes espurios da lugar a una forma tubular alrededor de la imagen cuya morfología para el contorno activo es semejante a la de un vaso sanguíneo. Así pues debemos evitar que el snake siga dichas crestas, se establezca en los bordes incorrectos y segmente vasos inexistentes.

Las imágenes contra las que testeamos el sistema llevan una máscara asociada que descarta todo lo que está fuera del FOV. Así pues, a efectos de cálculo de precisión no es demasiado importante puesto que muchos de los vasos equívocamente segmentados están fuera del área considerada. En el caso de las crestas,

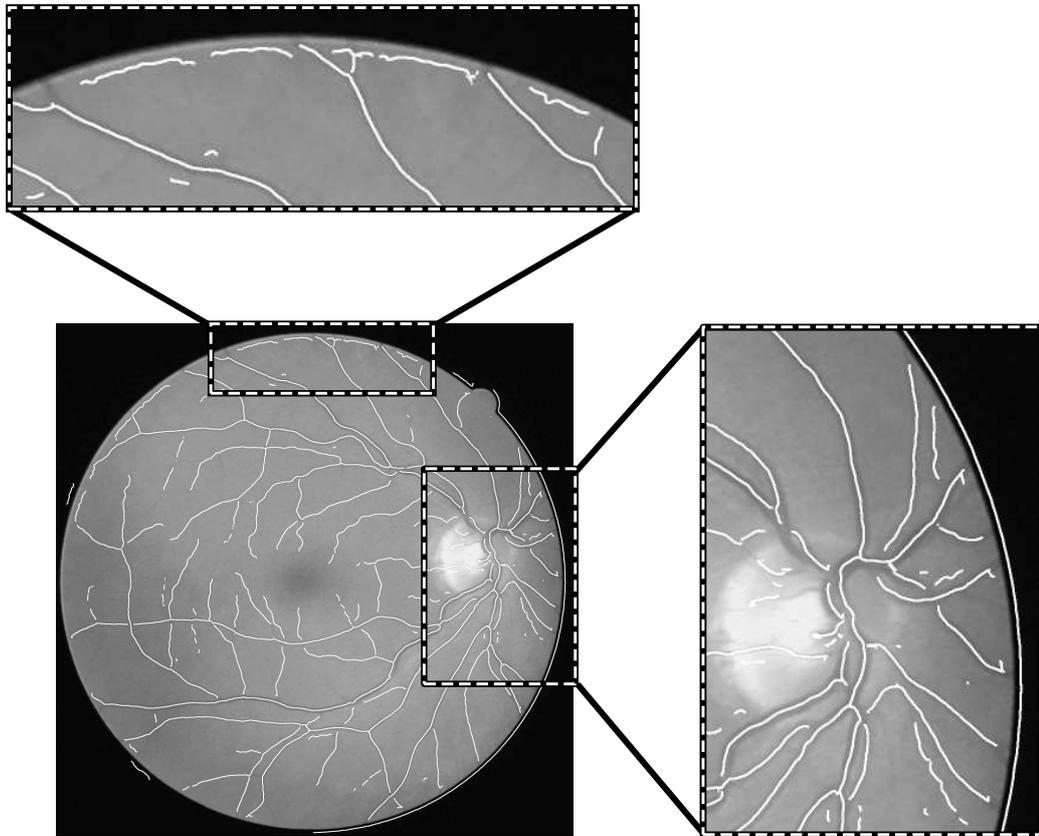


Figura 3.16: Imagen de crestas trazadas en blanco sobre la imagen original. En el detalle de la derecha pueden apreciarse mejor las crestas detectadas erróneamente en la zona externa de la imagen. En el detalle superior se muestran las crestas espurias que aparecen en las zonas cercanas al borde del FOV.

sí provocan segmentaciones erróneas en el área de interés de la imagen. En el detalle superior de la imagen 3.16 se pueden apreciar claramente estas crestas equívocas. Para solucionar este problema simplemente se eliminan las crestas y bordes que están a una cierta distancia del borde de la imagen. De esta manera, el snake se detiene antes de salir de la imagen y evitamos que fluya por vasos inexistentes.

Mediante todos estos procesos se logra una mejora en los términos de energía que gobiernan el snake que tendrán una gran importancia en la estructura del contorno que describiremos a continuación. En el siguiente apartado describiremos las características de los estados y los pesos asociados de los nodos que conforman el contorno, así como otras características específicas de nuestro modelo de snakes.

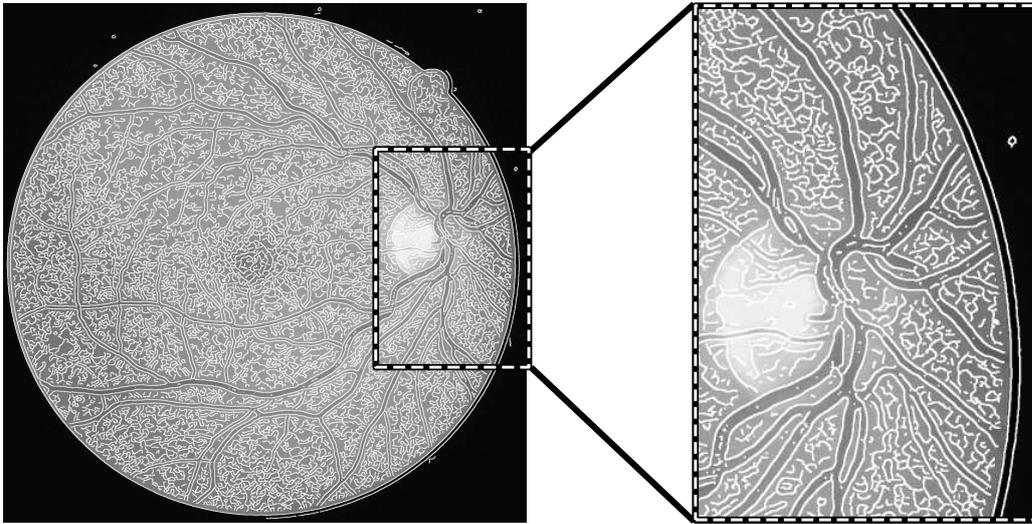


Figura 3.17: Bordes detectados erróneamente en la zona externa de la imagen trazados en blanco sobre la imagen original.

3.2.3. Estructura del Snake

Antes de pasar a describir las etapas de inicialización y evolución del snake (ver figura 3.4) describiremos cómo está estructurado y cómo se clasifican los vértices, denominados *nodos*, que definirán su evolución.

Como ya se mencionó anteriormente, nuestro snake puede verse como un contorno polinómico cerrado compuesto por nodos. Estos nodos en el snake genérico se comportaban de la misma forma, sin embargo en este modelo tendrán ciertas propiedades que los diferencian unos de otros. Cada nodo tiene una posición y un valor de energía asignado en cada momento, pero además tendrá un estado asociado, lo que nos permite aprovechar más información obtenida de la imagen, cuantizado mediante las energías. A mayores, un nodo puede estar activo o inactivo, independientemente de su estado. En este apartado explicaremos en profundidad las características estructurales de nuestro contorno deformable y los nodos que lo componen.

Cada nodo puede estar activo o inactivo independientemente de su estado. Un nodo *activo* es aquel que se desplaza, evoluciona y cambia de estado. Por el contrario, un nodo *inactivo* no puede desplazarse ni cambiar de estado, se quedará fijo en una determinada posición durante todo el proceso de segmentación. Un nodo puede pasar de activo a inactivo, como veremos, pero lo inverso no es posible: cuando un nodo se vuelve inactivo, su estado es irreversible.

Inicialmente, sólo unos cuantos nodos del snake estarán activos: los nodos

semilla. Estos nodos van desplazándose con la evolución del snake y se crearán nuevos nodos. Cada nuevo nodo que se crea en el snake está siempre en estado activo. Este nodo se moverá y cambiará su estado hasta que se vuelva inactivo, desde cualquier estado. Este proceso de desactivación tiene lugar normalmente cuando el nodo llega a un borde, pero también puede suceder cuando no tiene nuevas posiciones a las que moverse (está bloqueado por la energía o mapa de marcado) o debido a las operaciones de control que se explicarán cuando se introduzca el proceso de evolución del snake (apartado 3.4). Los cuadrados negros mostrados en la figura 3.18 representan nodos inactivos que se han estabilizado al alcanzar el borde del vaso. La ejecución del sistema termina automáticamente cuando todos los nodos están inactivos, esto es, cuando el snake alcanza la estabilidad total.

Cada uno de los nodos activos que componen nuestro contorno deformable podrá estar en uno de los tres posibles estados definidos: *normal*, *cresta* y *borde*. La asignación de estados se actualiza en cada iteración según la energía externa y también según la información de sus nodos vecinos, como describiremos a continuación. En la figura 3.18 se muestra un *frente de avance*, es decir, un grupo de nodos activos consecutivos entre dos nodos inactivos. Cada uno de los nodos del frente activo está etiquetado con su estado asociado y con una flecha que señala su dirección de avance.

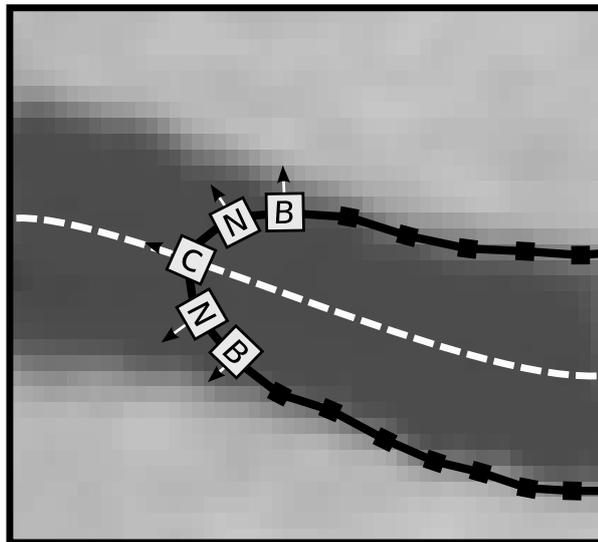


Figura 3.18: Frente de avance típico y los tres estados posibles de un nodo. Los nodos borde están marcados con una B, los nodos normales están representados con una N y los nodos cresta se etiquetan con una C. Los píxeles gris oscuro representan el área del vaso y la línea blanca punteada corresponde a la cresta.

A los nodos situados en la zona central del vaso (sobre las líneas de cresta o

muy alejados de los bordes) se les asigna el estado *cresta*. Son los encargados de hacer avanzar al snake a lo largo de la línea central del vaso, haciéndolo expandirse y fluir en la dirección longitudinal del mismo. Así pues, estarán fuertemente influenciados por el término de energía ϵ_{cresta} ya que se guían por las crestas en su avance. Por ello, el peso del término de energía de la distancia a crestas (δ) será muy alto (ver ecuación 3.2). Al ser los nodos encargados en mayor medida de la expansión del contorno, el peso v de la presión de inflado (ϵ_{dir}) también será elevado. En la figura 3.18 puede observarse un nodo cresta etiquetado con la letra C situado sobre la línea central del vaso y con una dirección de avance, indicada por una flecha, longitudinal a la estructura vascular.

A los nodos que ocupan posiciones cercanas a los límites del vaso se les asigna el estado *borde*. Los nodos en este estado tienden a hacerse estables cuando alcanzan el borde del vaso por el que son atraídos. Estos nodos son responsables de la expansión en anchura del contorno, por lo que se desplazan en dirección transversal al vaso. Como consecuencia, tienden a estabilizarse pronto al alcanzar un punto de borde. Los nodos de borde tienen un peso γ muy significativo (ver ecuación 3.2) para la energía de distancia a bordes ϵ_{borde} ya que pretendemos que alcancen rápidamente el borde del vaso. En la figura 3.18 pueden observarse dos nodos borde etiquetados con la letra B que se sitúan cerca de los bordes del vaso y con una dirección de avance perpendicular a la línea central del vaso, como indica la flecha.

Al resto de los nodos, situados en posiciones intermedias, se les asigna el estado *normal*. Estos contribuyen a la expansión del snake en una dirección intermedia. En general, los nodos normales tienden a convertirse en nodos borde y por tanto estabilizarse, por lo que tendrán unos pesos asociados muy similares a los nodos borde. Estos nodos tan solo pueden evolucionar a nodos cresta en unas situaciones muy concretas, como por ejemplo en las bifurcaciones. En estos casos el vaso se divide y aparece una nueva cresta. Uno de los nodos normales será seleccionado como nodo cresta para guiar el snake en la rama secundaria del vaso. En la figura 3.18 pueden observarse dos nodos normales etiquetados con la letra N que se sitúan en las posiciones intermedias a los nodos cresta y borde, y con una dirección de avance intermedia a la de los otros nodos, como representan las flechas.

El estado de un nodo influye en su comportamiento en el proceso de deformación del snake. Así, según un nodo esté en un estado u otro, su movimiento vendrá determinado en mayor medida por una energía u otra. Este comportamiento está modelado por conjuntos de pesos de términos de energía asociados a cada estado de nodo (ecuación 3.2). Sus valores se muestran en la sección de resultados y han sido estimados considerando en primer lugar el comportamiento supuesto de

ENERGÍAS	PESOS	ESTADO DEL NODO		
		Normal	Borde	Cresta
Presión de Inflado ϵ_{dir}	ν	+	+	++
Energía Diferencia ϵ_{difer}	ω	-	-	-
Energía Borde ϵ_{borde}	γ	++	++	0
Energía Cresta ϵ_{cresta}	δ	-	0	++
Energía Marcador ϵ_{marca}	σ	+++	+++	+++

Tabla 3.1: Pesos de los términos de energía de la ecuación 3.2 en función del estado del nodo. El peso de la energía de marcador σ es el más alto, ya que restringe el movimiento del nodo a zonas no visitadas independientemente de su estado. Los nodos normales y los nodos borde tienen pesos muy similares, dando una importancia alta a la energía de borde ϵ_{borde} . Los nodos en estado cresta están influenciados principalmente por la presión de inflado ϵ_{dir} y la distancia a crestas ϵ_{cresta} .

cada estado de nodo y refinados empíricamente tras la realización de pruebas. La tabla 3.1 muestra una representación simbólica de la ponderación de los diferentes términos de energía para cada estado del nodo.

Para todos los estados de nodo, la energía de marcador ϵ_{marca} es la que tiene el mayor peso (σ). Como se mencionó en el apartado anterior, incluso si los otros términos de energía fuesen menores, el snake no debe avanzar sobre un área ya visitada. El peso ω de la energía de diferencia ϵ_{difer} tendrá una menor importancia, ya que es simplemente una ayuda o pista para decidir la mejor opción de movimiento cuando se produce una igualdad entre los otros factores de energía.

Los nodos cresta y normales tienen más tendencia a moverse a nuevas posiciones que los nodos borde, por lo que tendrán un peso ω de la energía de diferencia ϵ_{difer} mayor. De manera similar, la presión de inflado ϵ_{dir} tendrá un peso (ν) más significativo para los nodos cresta y algo menos para los normales. Los nodos borde se desplazan muy poco, estabilizándose rápidamente, por lo que la influencia de esta energía de expansión será mucho menor. Esta definición de estados nos permitirá un mayor control de la evolución del snake mediante la realización de operaciones de control diseñadas ad-hoc, como veremos en el apartado 3.4 en el que describiremos la evolución del contorno.

Una vez definido el modelo de snake, nos centraremos en su aplicación al dominio de la segmentación de estructuras vasculares en imágenes de fondo de ojo. Comenzaremos describiendo la inicialización del contorno sobre la retinografía y luego explicaremos el proceso de evolución del snake hasta segmentar completa-

mente el árbol arterio-venoso.

3.3. Inicialización

Una vez hemos obtenido las crestas y bordes de la imagen original, así como sus correspondientes mapas de energía, el siguiente proceso consiste en crear el contorno inicial. La figura 3.19 muestra las etapas de la inicialización del snake situadas en el marco del proceso completo de ejecución del modelo.

Como se explicó en el capítulo 1, el árbol vascular de la retina parte del disco óptico y se distribuye radialmente por toda la retina. Esta disposición junto con su estructura conexa y arbórea, hace que desde ese punto de partida sea posible llegar a todos los vasos que formen parte de él, fluyendo a través de los mismos. Así pues, situando un contorno inicial circular y centrado en el disco óptico, este se expandirá por el interior de los vasos sanguíneos, creciendo y bifurcándose, hasta segmentar completamente la vasculatura retinal.

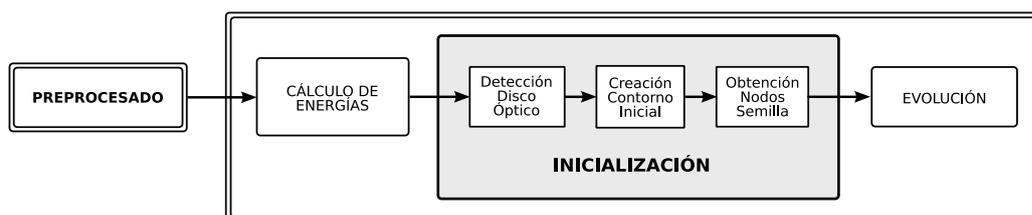


Figura 3.19: Diagrama que representa las operaciones de inicialización situadas en el marco del proceso completo de ejecución del modelo.

El primer paso será pues trazar una circunferencia alrededor del nervio óptico. Esto se realiza de forma automática, mediante la herramienta descrita en el Apéndice A, aunque también se permite el trazado manual. La herramienta de detección automática del disco óptico ha sido desarrollada en nuestro grupo de investigación [BPB⁺06] y se basa en la aplicación de la transformada de Hough circular difusa a las retinografías. El proceso de detección consta de dos fases principales: localización de la región de interés y extracción del disco óptico. La localización de la región de interés se lleva a cabo mediante un algoritmo de clus-terización. A continuación se aplica la transformada de Hough circular difusa a los bordes obtenidos de la región de interés para extraer el disco óptico. Después de detectar el disco óptico y trazar una circunferencia a su alrededor, se obtienen de forma directa las intersecciones de las crestas y dicha circunferencia. La figura 3.20 muestra la circunferencia rodeando el disco óptico, las crestas y las intersecciones entre ambas, marcadas como estrellas.

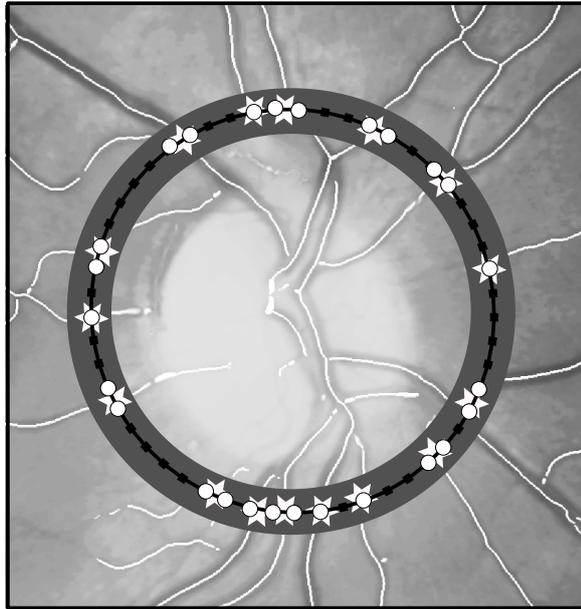


Figura 3.20: Inicialización del Snake. Los puntos marcados con una estrella se corresponden con las intersecciones del círculo inicial dibujado en blanco y negro y las crestas trazadas en blanco. Los nodos semilla, representados como puntos blancos, serán aquellos que se sitúan cerca de las intersecciones (estrellas) y estarán activos inicialmente. El resto de los nodos del contorno inicial, dibujados como puntos negros, están inactivos.

Se crea así un único snake, que se corresponde exactamente con la circunferencia previamente trazada. Este snake está compuesto por nodos distribuidos regularmente en toda su longitud (puntos negros en la figura 3.21). Dichos nodos son en su mayoría inactivos, excepto los situados en las cercanías de las intersecciones con las crestas, que estarán activos. Los nodos inicialmente activos se denominan *nodos semilla*, ya que serán los que comenzarán a evolucionar y avanzar por el interior de los vasos sanguíneos como vemos en la figura 3.21. Estos *nodos semilla* estarán inicialmente en estado normal y al comenzar la evolución se actualizará su estado de acuerdo a su situación. Esta asignación se realiza estudiando el valor de los términos de energía de crestas y bordes para cada uno de los nodos que depende directamente de su posición. La mayoría de ellos estarán situados sobre las crestas por lo que se le asignará el estado cresta. A los que estén situados cerca de los bordes estarán en estado borde y en normal los restantes, situados en posiciones intermedias. La dirección inicial de los nodos será perpendicular al contorno inicial, es decir, se correspondería con una de las líneas que parten radialmente del centro del disco óptico hacia los bordes del mismo. Así cada nodo inicialmente tenderá a moverse hacia el exterior del disco óptico, expandiendo el snake por la retina. Al continuar la evolución del snake, estos estados y direcciones iniciales se

irán modificando según los procesos de actualización y control que se explicarán en la sección 3.4.

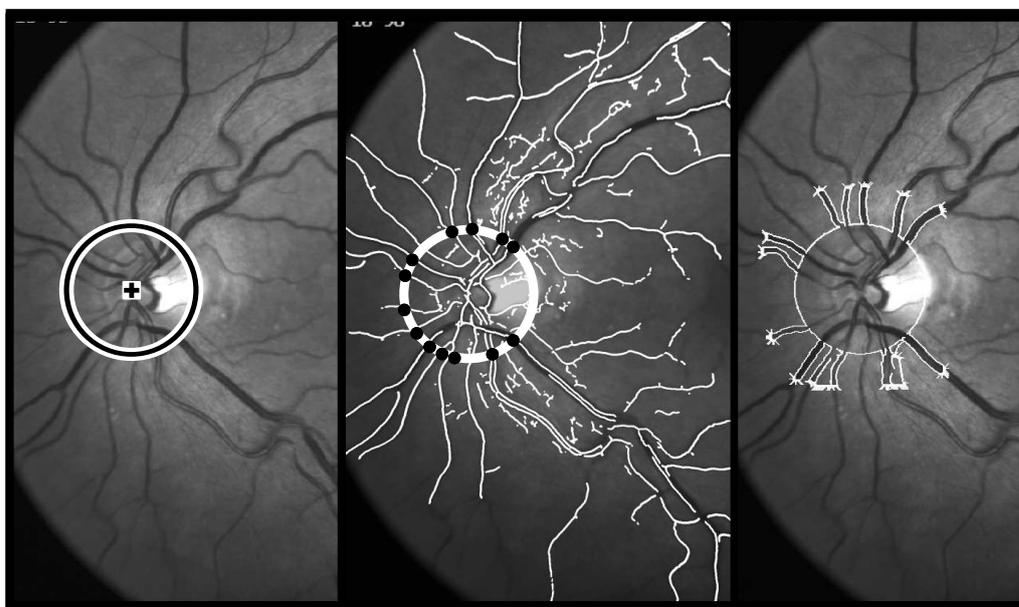


Figura 3.21: Inicialización del snake. A la izquierda se muestra el trazado del contorno circular inicial alrededor del disco óptico. En la figura central se muestra el cálculo de las intersecciones con las crestas que se corresponden con los puntos semilla del snake marcados con círculos negros. En la figura de la derecha se muestra el inicio de la evolución del snake, dibujado en blanco, a partir de los puntos semilla.

Aunque en principio se creaba un snake diferente por cada zona de intersección con las crestas, es decir, aproximadamente uno por vaso, el cambio consistente en tener un sólo snake para todo el árbol arterio-venoso ha constituido un gran avance, aumentando considerablemente la eficiencia del sistema. Además, nos ha permitido simplificar y hacer más intuitiva la lógica del modelo [ECPO06].

En la siguiente sección se explica cómo evoluciona el snake desde este contorno inicial hasta segmentar completamente el árbol vascular de la retina.

3.4. Evolución del Contorno

Una vez creado el contorno inicial, el snake evoluciona iterativamente hasta completar la segmentación, siguiendo un algoritmo basado en minimización local, como se explicó en el apartado 2.2.3. Esta fase de evolución es el último paso en el

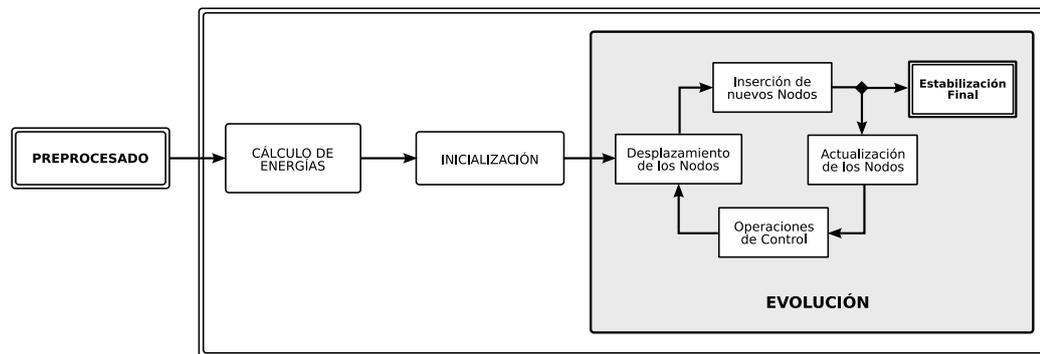


Figura 3.22: Diagrama que representa las operaciones de evolución del contorno situadas en el marco del proceso completo de ejecución del modelo.

proceso completo de segmentación, como se puede ver en la figura 3.22. La figura 3.23 muestra los pasos de cada iteración dentro de este proceso de evolución del snake. El algoritmo consiste básicamente en mover todos los nodos del snake una vez, insertar nuevos nodos, actualizar la energía y el estado de cada nodo y llevar a cabo operaciones de control. Este proceso iterativo continúa hasta que todos los nodos están inactivos y, por tanto, la segmentación del árbol vascular está completa.

Cada iteración del proceso de evolución del snake consiste en las etapas que detallaremos en los siguientes apartados:

1. **Desplazamiento de los Nodos:** Movemos los nodos del snake que presenten posiciones adyacentes con menor energía, teniendo en cuenta su estado.
2. **Inserción de Nuevos Nodos:** Entre aquellos nodos consecutivos cuya distancia supere un cierto umbral insertamos nuevos nodos, produciéndose un crecimiento del snake.
3. **Actualización:** Según los valores de energía obtenidos y también la información de su vecindad, actualizamos el estado de los nodos siguiendo las indicaciones detalladas en el apartado 3.2.3. Se calcula la energía de cada nodo, en función de su posición, sus pesos asignados según su estado actual y los mapas de energía de crestas y bordes, tal y como se explicó en el apartado 3.2.
4. **Operaciones de Control:** Se realizan operaciones de control para verificar que el desarrollo del contorno está siendo adecuado. Controlaremos, por ejemplo, que el snake no se vea afectado por las discontinuidades del borde y salga hacia el exterior de los vasos o que los nodos crestas que guían el

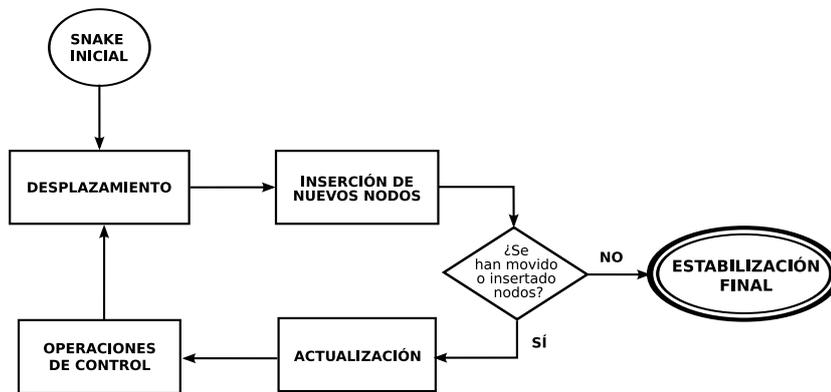


Figura 3.23: Diagrama mostrando el proceso iterativo de evolución del snake. Tras construirse el contorno inicial (SNAKE INICIAL), movemos los nodos del snake (DESPLAZAMIENTO) e insertamos nuevos nodos si fuese necesario (INSERCIÓN DE NUEVOS NODOS). Después, se actualizan las energías y estados de cada nodo (ACTUALIZACIÓN). A continuación se realizan operaciones de control (OPERACIONES DE CONTROL) para verificar que el desarrollo del contorno es adecuado y se efectúan las acciones necesarias. En cada iteración comprobamos si se han desplazado nodos existentes y si se han insertado nuevos nodos. Si ninguna de estas acciones ha tenido lugar en la última iteración, se considera que el snake ha alcanzado la estabilidad y el proceso finaliza. En caso contrario, se repite el proceso cíclicamente.

snake estén correctamente asignados. Si no fuese así se efectúan las acciones necesarias, como bloquear ciertos nodos o reasignar los estados, que describiremos en el último apartado de esta sección.

- 5. Estabilización Final:** En cada iteración comprobamos si se han desplazado nodos existentes y si se han insertado nuevos nodos. Si ninguna de estas acciones ha tenido lugar significa que el snake ha alcanzado una situación de mínima energía y terminaría su evolución. En caso contrario, se vuelve al paso 1 en el que se recalculan las energías y se repite el proceso cíclicamente hasta completar la segmentación.

En los siguientes apartados de esta sección describiremos en detalle cada una de las etapas del algoritmo iterativo de evolución del snake. Comenzaremos con el apartado dedicado al desplazamiento de los nodos del snake y continuaremos presentando el proceso de inserción de nuevos nodos. La actualización consiste básicamente en la aplicación de las fórmulas de cálculo de la energía y asignación de estados descrito en el apartado 3.2 por lo que pasaremos a explicar las operaciones de control que se efectúan sobre el contorno del snake.

3.4.1. Desplazamiento de los Nodos

El desplazamiento de los nodos se corresponde con la fase de *deformación*, mencionada en la descripción del snake genérico. Tras su inicialización, el snake evoluciona para minimizar localmente sus funciones de energía. Para ello el snake moverá en cada iteración sus nodos, uno a uno, a posiciones con menor energía. Cada nodo se mueve según las fuerzas que actúan sobre él, hacia la situación de mínima energía local lo que produce que el contorno entero se expanda y el snake fluya dentro de los vasos cubriendo el árbol vascular.

El avance de los nodos del snake hacia la minimización de energía está determinado por su posición, su estado y por los mapas de energía. La energía para cada posible movimiento de un nodo se calcula considerando los valores de los términos de energía asociados a la posición y los pesos asociados al nodo, que varían en función de su estado. En la figura 3.24 vemos cómo los nodos *cresta* se desplazan longitudinalmente por el vaso, siguiendo el curso de la cresta; los nodos *borde* y los *normales* se mueven en dirección prácticamente perpendicular, tratando de alcanzar los bordes del vaso.

Para cada nodo activo se determina cuáles son las tres posibles posiciones a las que puede desplazarse, según la dirección que tiene asociada determinada por la presión de inflado ϵ_{dir} . En la imagen de la izquierda de la figura 3.25 vemos las ocho posibles direcciones que un nodo puede tener asignadas. Para cada una de las nuevas posiciones obtenemos los valores de los términos de energía y hallamos la energía total sumando dichos valores ponderados por los pesos asociados al estado del nodo.

La energía de bordes ϵ_{borde} , de crestas ϵ_{cresta} y de marcador ϵ_{marca} se obtienen mediante el valor del mapa de energía correspondiente a la nueva posición espacial. Según el estado del nodo (cresta, borde, normal) se ponderarán de una forma u otra los valores de la energía de crestas y bordes: un nodo cresta tendrá menor energía cerca de la cresta y lejos de los bordes, al contrario de lo que sucede con un nodo en estado borde. La energía de marcador, sin embargo, es independiente del estado del nodo pues en cualquier estado le impide ir a posiciones ya visitadas.

Para la energía de diferencia ϵ_{difer} consideramos, además de la posición nueva, la situación espacial de los nodos anterior y posterior al que queremos mover. Se penalizará, en mayor o menor medida según el estado, el hecho de que pase a ocupar una posición semejante a uno de los nodos vecinos directos.

La presión de inflado ϵ_{dir} tiene unos valores fijos para cada una de las tres posiciones, sólo su ponderación v varía con el estado. Es menor para aquellas posiciones que se encuentren situadas en la dirección exacta asignada al nodo, es

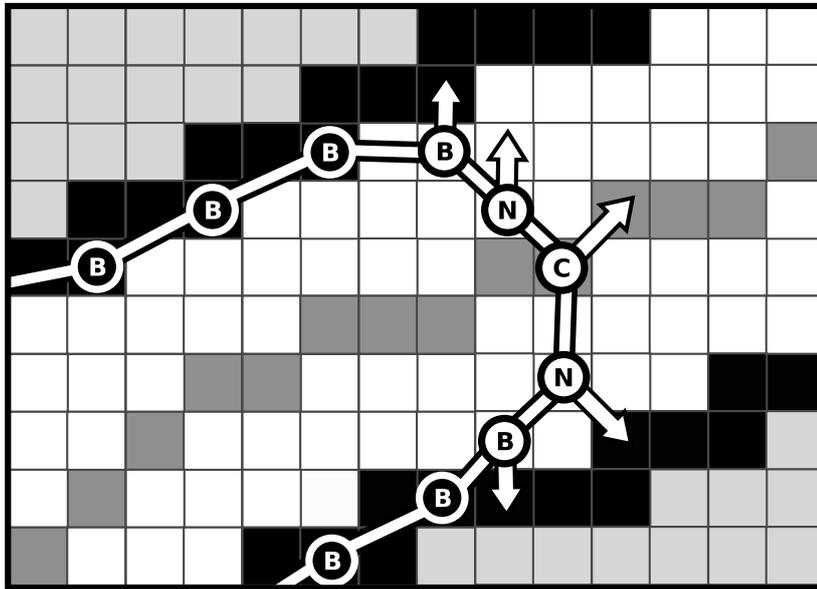


Figura 3.24: Desplazamiento de los nodos según su estado. Cada elemento de la cuadrícula representa una posible posición para un nodo, o lo que es lo mismo, un píxel de la imagen. Los nodos del snake se corresponden con los círculos con fondo negro (inactivos) o blanco (activos). Estos últimos presentan una flecha que indica la posición a la que se desplazarán y que presentará una energía menor. El interior del vaso está representado en color blanco mientras que la zona externa es de color gris. Entre ambas se sitúan los bordes de la imagen, trazados en color negro, hacia los cuales se desplazan los nodos en estado *borde* y los *normales*, identificados con una 'B' y una 'N' respectivamente. Los nodos *cresta*, marcados con una 'C', se mueven siguiendo el curso de la cresta, representada en gris oscuro en la parte central del vaso.

decir, las posiciones 'B' (ver figura 3.25).

Si alguna de estas posiciones presenta una energía menor que la actual del nodo, desplazamos el nodo a la nueva posición. Esto implica actualizar por triangulación el mapa de energía de marcador, añadiendo la nueva área visitada (ver figura 3.11).

El estado del nodo se modificará según esta nueva posición. Así un nodo que estaba en estado normal puede pasar a nodo borde al acercarse más a los bordes de la estructura vascular o a nodo cresta si se acerca a la línea central del vaso. Los nodos borde y cresta no cambian de estado mediante desplazamiento ya que tienden a permanecer cerca de los bordes o crestas respectivamente. En general las modificaciones en su estado serán consecuencia de las operaciones de control que se explican en el apartado 3.4.3.

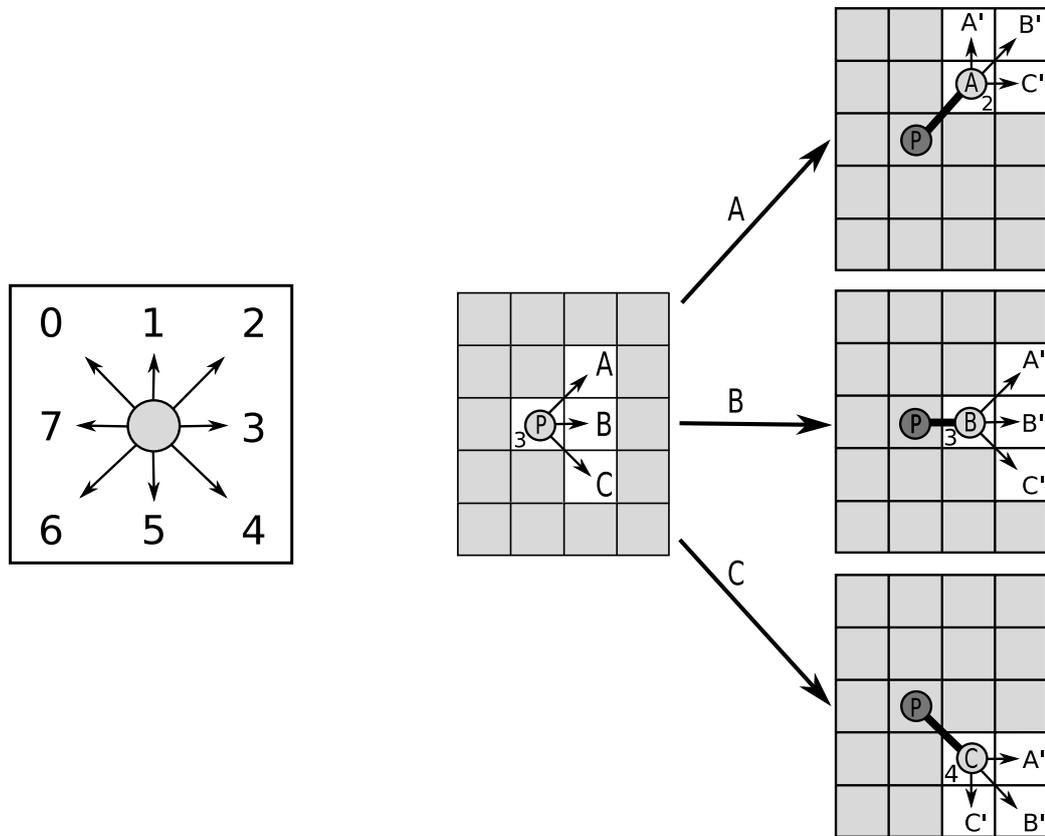


Figura 3.25: Influencia de la presión de inflado ϵ_{dir} en el desplazamiento de los nodos del snake. En la figura de la izquierda se muestran las 8 posibles direcciones que puede determinar la presión de inflado. El diagrama del centro muestra el proceso de avance de un nodo inicialmente en la posición P , con dirección 3 asignada y tres posibles nuevas posiciones A, B y C . Cada una de las tres figuras de la derecha representan la situación que se produciría según a cuál de esas tres nuevas posiciones se desplace el nodo.

La dirección asignada al nodo también se actualiza con cada desplazamiento: si el nodo se ha desplazado a una posición ' A ' o ' C ', se rota la dirección de avance hacia la nueva posición. En la figura 3.25 vemos cómo un nodo inicialmente situado en la posición P y con dirección 3 asignada, puede desplazarse hacia A, B o C . Si la energía total hace que se desplace hacia A , su nueva dirección asignada será 2. Paralelamente, si se desplace a B su dirección seguirá siendo 3 y si se mueve a C , se le asignará dirección 4. Para cada uno de estos casos, presentará tres nuevas posiciones de desplazamiento posibles marcadas en cada figura con A', B' y C' .

3.4.2. Inserción de Nuevos Nodos

El crecimiento del snake se corresponde con la fase de *remuestreo* del snake clásico. Esta etapa consiste básicamente en la inserción de nuevos nodos. Los nuevos nodos se insertan entre aquellos nodos vecinos que presenten una distancia euclídea entre ambos mayor que un cierto umbral. La distancia d_{ij} entre dos nodos vecinos se calcula según la siguiente ecuación:

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3.7)$$

donde x_i e y_i son las coordenadas del nodo i y x_j e y_j son las del nodo inmediatamente posterior. Los dos nodos entre los que se inserta uno nuevo se denominan nodos padre.

Los nuevos nodos se sitúan en el punto medio del segmento que une los dos nodos existentes. Inicialmente cualquier nodo insertado estará activo, aunque uno de los dos nodos entre los que se inserte esté inactivo. La dirección del nuevo nodo será la intermedia entre los dos nodos padres. El estado de los nodos insertados se asigna inicialmente igual al de uno de los padres, ya que luego se actualizará en función de su energía.

La figura 3.26 representa paso a paso este proceso de crecimiento. En la parte izquierda se muestra el desplazamiento de los nodos hacia nuevas posiciones de menor energía según la dirección asignada. En la imagen central vemos la nueva disposición de los nodos y sus direcciones actualizadas. Se calculan en este punto las distancias entre nodos, superándose el umbral *growTh* entre los nodos j y k y entre k y l . Se insertan pues los nuevos nodos n y o en el punto medio de los segmentos \overline{jk} y \overline{kl} respectivamente, como se ve en la figura de la derecha. Las direcciones de estos nodos son las intermedias de sus padres. Así, al nodo n se le asigna la dirección 2, puesto que las de sus padres eran 1 y 3. Equivalentemente, al nodo o se le asigna la dirección 4, por ser 3 y 5 las de sus padres.

En el proceso de crecimiento del snake, el parámetro umbral de distancia *growTh* es de gran importancia. Este límite de distancia debe ser suficientemente bajo para permitir alcanzar un nivel de detalle adecuado en la segmentación. Por otra parte, cuanto menor sea el umbral de distancia, mayor será la complejidad computacional del modelo y el coste temporal asociado. Se debe pues encontrar un valor de este parámetro que nos permita segmentar con una precisión suficiente sin reducir demasiado la eficiencia del sistema. En el capítulo de resultados se muestra el valor seleccionado de forma empírica para el umbral de la distancia entre nodos. Debido a la alta eficiencia del método global nos hemos podido permitir emplear un límite de distancia bastante reducido.

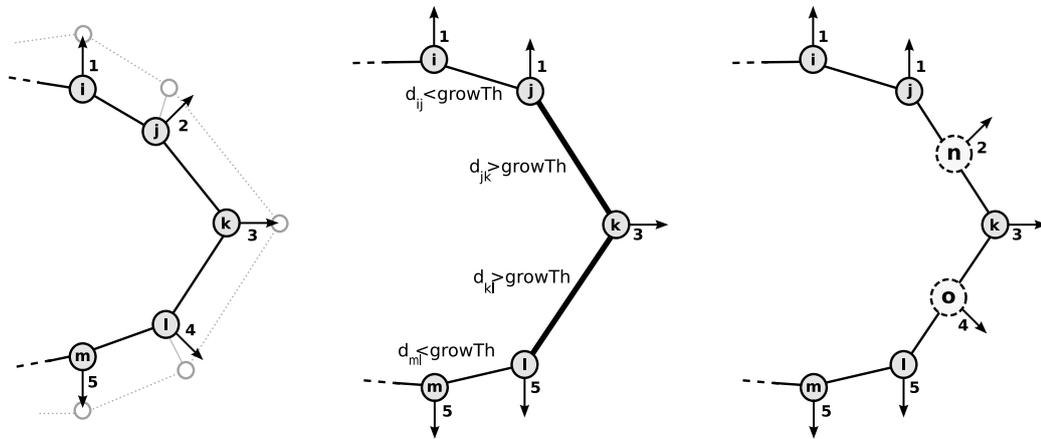


Figura 3.26: Proceso de crecimiento del snake. La imagen de la izquierda muestra el desplazamiento de los nodos a nuevas posiciones. Se actualizan sus direcciones asignadas y las distancias entre nodos son revisadas, superándose el umbral *growTh* entre los nodos *j* y *k* y entre *k* y *l*, como se ve en la imagen central. Se insertan los nuevos nodos *n* y *o* en el punto medio de los segmentos *jk* y *kl* respectivamente, como se ve en la figura de la derecha.

3.4.3. Operaciones de Control

Además de los procesos de crecimiento y deformación, se realizan operaciones de control derivadas de las características estructurales de los vasos. Estas operaciones de control trabajan considerando que el snake está compuesto por secuencias de nodos activos consecutivos, denominados *frentes de avance*. En la imagen izquierda de la figura 3.27 se puede observar un frente de avance compuesto por cinco nodos.

En la figura 3.28 se muestra un esquema general que resume las tres principales operaciones de control que se realizan periódicamente sobre los frentes de avance del snake: controlar la unicidad del nodo cresta, limitar superior e inferiormente el número total de nodos y mantener una distancia máxima a las crestas.

Una de las operaciones de control que se realiza es controlar el número de nodos en estado cresta que contienen los frentes de avance. Cada frente es obligado a contener exactamente un nodo en estado cresta. Este será aquel que presente la mínima distancia a una cresta o la máxima distancia a los bordes. En la figura 3.27 vemos cómo el frente inicial (izquierda) avanza hacia una bifurcación (centro) y se divide al llegar a ella. Así se crea un nuevo frente de avance para segmentar el vaso sanguíneo superior que por tanto debe tener un nodo cresta asociado. Así uno de los nodos inicialmente en estado normal, pasa a ser el nodo cresta (derecha) de este nuevo frente.

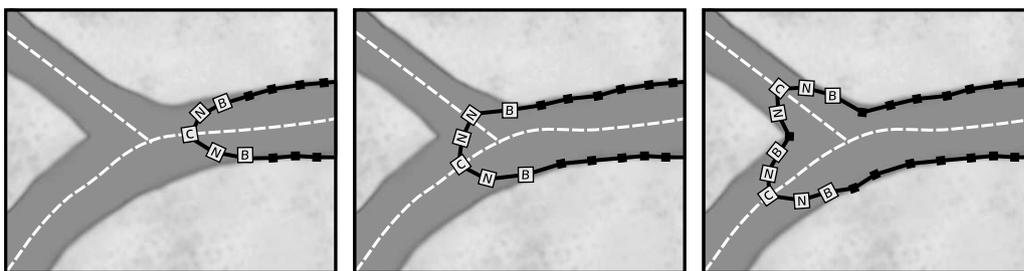


Figura 3.27: Operaciones de control de frentes. Las etiquetas de los nodos indican su estado: *C* corresponde a un nodo en estado cresta, *N* indica un nodo en estado normal y *B* un nodo en estado borde. En la figura de la izquierda se muestra un frente de avance con cinco nodos. En la figura central vemos la evolución de ese frente de avance que crece y se aproxima a una zona de bifurcación. La imagen derecha representa la creación de un nuevo frente de avance con su correspondiente nodo cresta que procede a segmentar el vaso sanguíneo superior.

Otra de las operaciones de control que se realizan periódicamente consiste en comprobar el número de nodos que contiene cada frente. Esto se realiza con el objetivo de evitar *desbordamientos*, es decir, que debido a una discontinuidad del borde el snake salga fuera de los límites del vaso sanguíneo. Esta situación tiene lugar normalmente al final de los vasos o en zonas en que el contraste de las estructuras vasculares no es suficiente.

En la figura 3.29 (a) se muestra esta situación de desbordamiento durante la segmentación de la sección superior. Así pues, cuando un frente se hace demasiado grande, todos sus nodos se inactivan ya que está considerado como un desbordamiento. Esta detección y bloqueo del desbordamiento va acompañada de un proceso de encogimiento o *retracción* del snake. Encoger el snake consiste básicamente en reducir su contorno tratando de eliminar los nodos situados fuera del vaso. En la figura 3.29 (b) puede verse cómo se corrige un fragmento de snake que ha sufrido un desbordamiento.

Los frentes de avance con un número muy reducido de nodos también son bloqueados, ya que esta situación suele corresponder con pequeñas discontinuidades del borde. En la figura 3.30(a) vemos cómo el contorno del snake sale fuera del vaso por una discontinuidad del borde. Esta segmentación errónea es evitada en la figura 3.30(b), en la que se inactivan los nodos de dicha sección del contorno.

Para realizar adecuadamente estas operaciones de control hemos de estimar dos parámetros como referencia en la evaluación del tamaño del frente: la anchura de vaso máxima y mínima. En el conjunto de imágenes sobre las que hemos trabajado las anchuras de vaso máxima y mínima se han estimado en 140 y 3

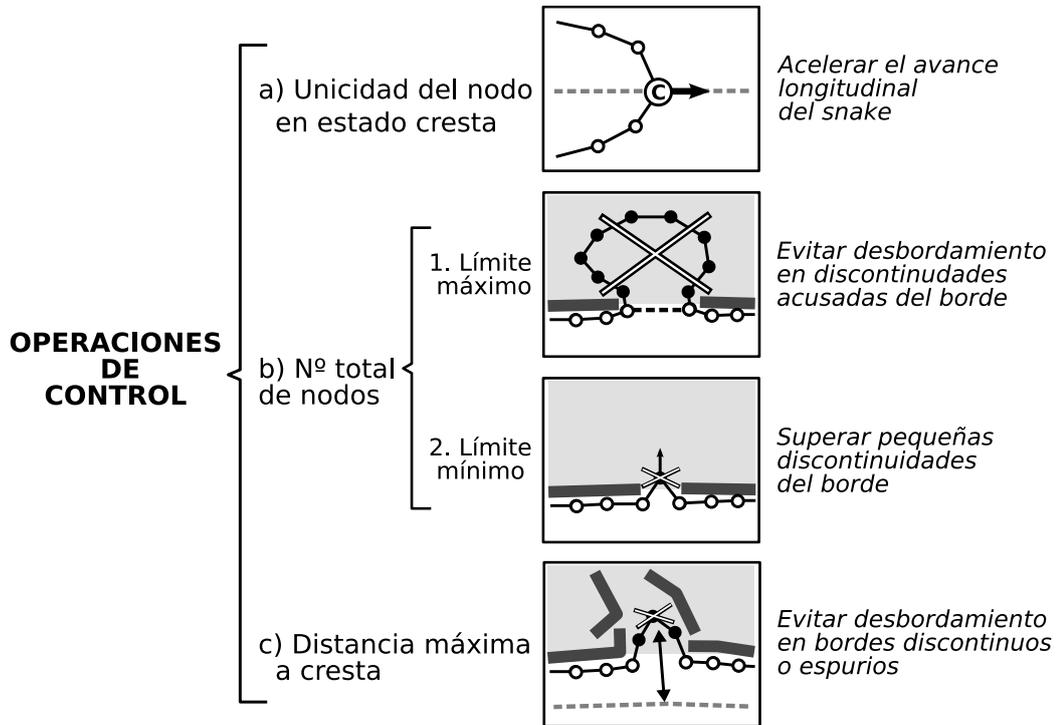


Figura 3.28: Esquema de las operaciones de control realizadas sobre los frentes de avance del snake con figuras representando cada operación y su finalidad (texto en cursiva). La primera de ellas (a) consiste en controlar que en cada frente de avance exista un único nodo cresta. La figura correspondiente muestra un frente de avance en el que hay un único nodo cresta (marcado con una 'C') que sigue el recorrido de la cresta (línea discontinua gris oscuro). Otra de las operaciones es el control del número de nodos de cada frente (b), necesario cuando se producen discontinuidades en el borde (línea gruesa gris oscuro). En las dos figuras del centro vemos dos situaciones opuestas: en la superior (b.1) se muestra un frente bloqueado por tener un número excesivo de nodos (círculos negros), mientras que en la inferior (b.2) se bloquea el avance de un frente que presenta un tamaño demasiado reducido (círculos negros). Por último, se controla la distancia a la cresta del nodo del frente más cercano a la misma (c). En la figura inferior se muestra un frente de avance cuyos nodos son bloqueados (círculos negros) por encontrarse a una distancia excesiva a la cresta (línea gris discontinua).

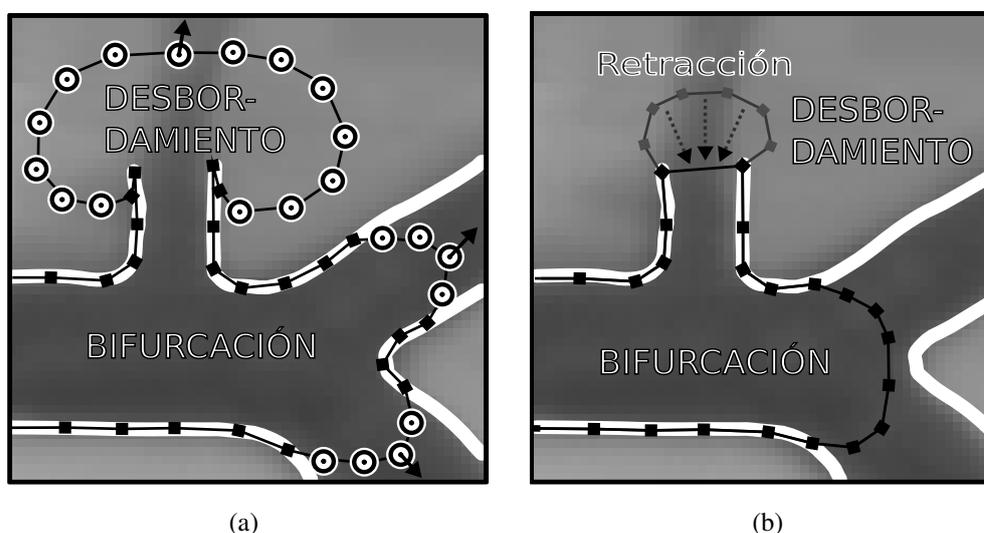


Figura 3.29: Influencia del parámetro de anchura de vaso máxima. En (a) se muestra el caso de un máximo de anchura de vaso muy elevado que produce grandes desbordamientos. En (b) vemos la situación opuesta: un límite máximo muy reducido que no permite al snake segmentar adecuadamente las zonas de intersección, por su mayor anchura.

píxeles respectivamente, como se explica en el apartado 4.3.4. El número máximo y mínimo de nodos de cada frente se estima respectivamente con el resultado de dividir estos parámetros por el umbral de distancia de crecimiento *growTh*. Así, un umbral distancia de 4 píxeles y una anchura de vaso de tamaño 12 píxeles se correspondería con un tamaño de frente de 3 nodos.

En las figuras 3.29 y 3.30 se muestra gráficamente la importancia de estos parámetros y las consecuencias de su incorrecta estimación. La imagen 3.29(a) representa el caso de un máximo de anchura de vaso muy elevado, que segmenta correctamente las zonas más anchas del vaso (bifurcaciones) pero produce grandes desbordamientos en el final de los vasos. En la figura 3.29(b) vemos la situación opuesta: un límite máximo muy reducido que no permite al snake segmentar adecuadamente las zonas de intersección por su mayor anchura, a pesar de que sí bloquea correctamente al snake en cuanto comienza a desbordarse. Paralelamente, en la figura 3.30(a) se representa la situación producida por establecer una anchura de vaso mínima muy reducida: el snake segmenta las estructuras vasculares más estrechas pero sale del vaso por las pequeñas discontinuidades del borde. En la figura 3.30(b) sucede lo contrario, el límite de anchura mínima es muy grande y los capilares más finos no son segmentados, pero se controla el snake en las discontinuidades del borde.

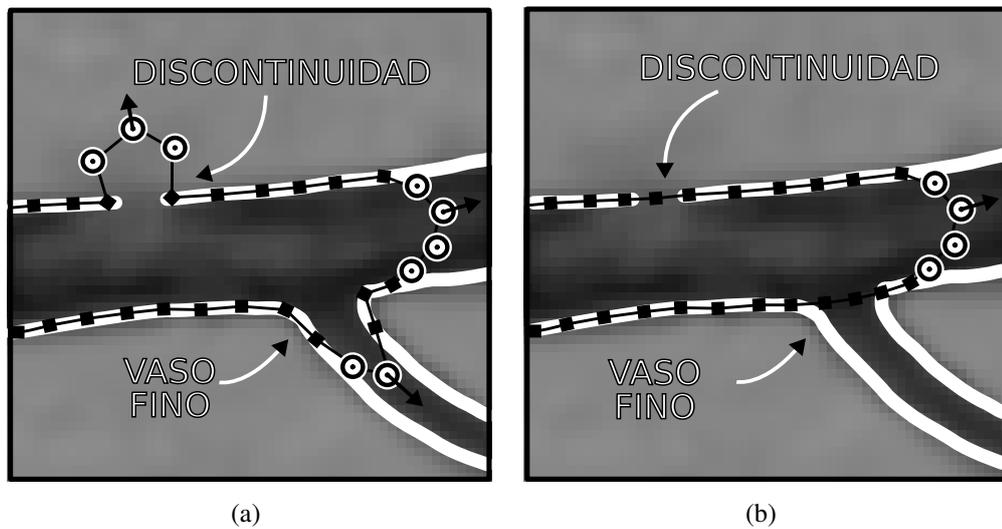


Figura 3.30: Influencia del parámetro anchura de vaso mínima. En (a) se representa la situación producida por establecer una anchura de vaso mínima muy reducida: el snake sale del vaso por las pequeñas discontinuidades del borde. En (b) sucede lo contrario, el límite de anchura mínima es muy grande y los capilares más finos no son segmentados.

Es necesario pues llegar a un compromiso entre los parámetros de anchura de vaso máxima y mínima. Esto supone una dificultad notable dado que la anchura de los vasos es muy variable. Existe una gran diferencia entre los capilares finos y los vasos principales. Además, entre pacientes se acentúan estas diferencias y nuestro modelo debe ser adecuado para todos los vasos de la angiografía y para cualquier paciente. Los valores óptimos han sido estimados realizando un estudio empírico de la anchura de los vasos sobre las retinografías y refinándolo mediante pruebas en ejecución del modelo. En el capítulo de resultados se muestran los parámetros finales seleccionados como un compromiso entre control y eficiencia.

También se realiza una operación de control basada en la información de crestas. Se limita así la distancia a la que puede estar un frente de una cresta. Cuando el snake está avanzando por una zona en la que no se ha detectado una cresta suele corresponderse con regiones externas a las estructuras vasculares. Si esta situación ocurre y el frente supera un cierto límite de distancia a crestas $distLim$, este frente es bloqueado. El valor de dicho parámetro de umbral de distancia a crestas se detalla en la sección de resultados.

A pesar de las mejoras introducidas en la detección de las crestas, estas a menudo presentan discontinuidades en determinadas zonas como bifurcaciones y cruces. Para evitar el bloqueo erróneo de frentes del snake en estas zonas aprove-

chamos la información proporcionada por una segmentación morfológica auxiliar desarrollada dentro de nuestro grupo de investigación. Permitimos pues continuar avanzando al snake en las zonas segmentadas por dicho método como parte de estructuras vasculares, aunque las crestas no hayan sido extraídas en esa zona.

Una vez descrito en detalle el modelo de snakes desarrollado, presentaremos una aplicación concreta para el cálculo preciso y repetible del índice arterio-venoso. Como veremos en el siguiente capítulo, este índice es de gran importancia en el diagnóstico de diversas patologías retinales, como por ejemplo la retinopatía diabética, y puede ser obtenido de manera sencilla a partir del árbol arterio-venoso segmentado por nuestro modelo deformable.

Capítulo 4

Resultados

En este capítulo presentaremos los resultados obtenidos por el sistema desarrollado en esta memoria para la detección automática del árbol vascular sobre un conjunto de retinografías y los compararemos con los obtenidos por otros métodos. Además se incluyen los estudios realizados para la selección de las técnicas más apropiadas en cada etapa y el ajuste de parámetros.

Describiremos en primer lugar la base de datos de retinografías digitales DRIVE [SAN⁺04] de donde han sido tomadas las imágenes sobre las que testeamos el sistema.

Después pasaremos a la fase de preprocesado, centrándonos principalmente en cuantificar, frente a otras alternativas, las mejoras aportadas por el trabajo a nivel de subpíxel y la mayor calidad de la interpolación bicúbica en comparación con otras técnicas de interpolación.

A continuación expondremos los valores de los diferentes parámetros empleados en la ejecución de nuestro sistema. Se incluyen en este punto la configuración del sistema de extracción de crestas, del detector de bordes y de los procedimientos empleados para la mejora de sus respectivos resultados, entre los que destacaremos el aprovechamiento de la segmentación morfológica auxiliar. También se detallan los parámetros que definen el comportamiento de nuestro modelo de snakes, como son los pesos de energías, umbrales de distancia, limitaciones de anchura de vasos, etc.

Para finalizar compararemos nuestro método de segmentación con otras soluciones propuestas en la literatura. Se incluyen además representaciones gráficas de la segmentación realizada por nuestro sistema sobre algunas de las imágenes de la base de datos DRIVE [SAN⁺04].

4.1. Base de Datos de Retinografías DRIVE

Los resultados de segmentación de nuestro sistema han sido obtenidos sobre las imágenes procedentes de la base de datos de retinografías digitales DRIVE para la extracción de estructuras vasculares (Digital Retinal Images for Vessel Extraction) disponible en línea [NvG02]. La base de datos DRIVE [SAN⁺04] se estableció para facilitar los estudios comparativos de la segmentación de vasos en imágenes de retina.

A través de su sitio web, cuya interfaz se muestra en la figura 4.1, se permite a la comunidad investigadora testear sus algoritmos y compartir sus resultados con otros investigadores. En dicha web se proporcionan instrucciones para obtener las imágenes de fondo de ojo y exponer los resultados obtenidos, así como examinar los resultados logrados por diferentes métodos. Desde que se publicó originalmente en 2004 se han aplicado un gran número de algoritmos de segmentación a la base de datos DRIVE [SLCJ⁺06][MC06][SAN⁺04][JM03].

Las fotografías de la base de datos DRIVE se obtuvieron de un programa de exploración masiva de retinopatía diabética en los Países Bajos. La población sobre la que se realizó dicha exploración fue de 400 individuos diabéticos de edades comprendidas entre 25 y 90 años. Se seleccionaron cuarenta retinografías de forma aleatoria, de las cuales 33 no muestran ningún tipo de retinopatía diabética y 7 presentan signos de retinopatía diabética leve en fase temprana. Todas las imágenes han sido comprimidas en formato JPEG.

Las imágenes se adquirieron mediante una cámara Canon CR5 no-midriática 3CCD con 45 grados de campo de visión (FOV). La captura de las imágenes se realizó empleando 8 bits por plano de color a una resolución de 768 x 584 píxeles (nuestro sistema transformará dichas imágenes a escala de grises de 8 bits de profundidad). El campo de visión de cada imagen es circular, con un diámetro de aproximadamente 540 píxeles. Para esta base de datos, se recortaron las imágenes alrededor de dicho campo de visión. En la base de datos se proporciona una imagen de máscara que delinea el campo de visión.

El conjunto de cuarenta imágenes se dividió en dos conjuntos de veinte imágenes, uno de entrenamiento y otro de test. Este último será el que se emplee para testear los resultados de nuestro sistema. Para cada caso de test se dispone de dos segmentaciones manuales. Una de ellas, realizada por un experto, se emplea como punto de referencia o *gold standard*.

La otra segmentación manual se puede utilizar para comparar los resultados del sistema computerizado con los de un observador humano independiente. Un oftalmólogo experimentado instruyó a todos los observadores que han segmentado

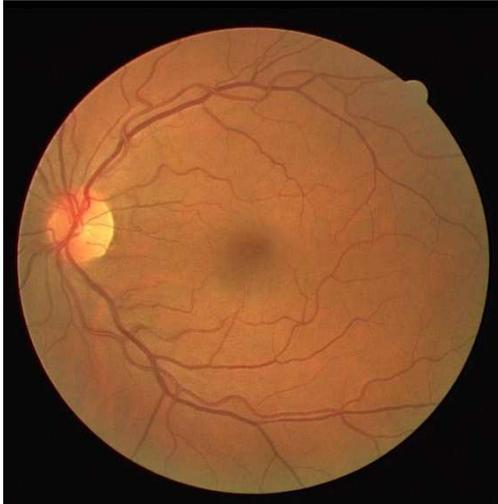
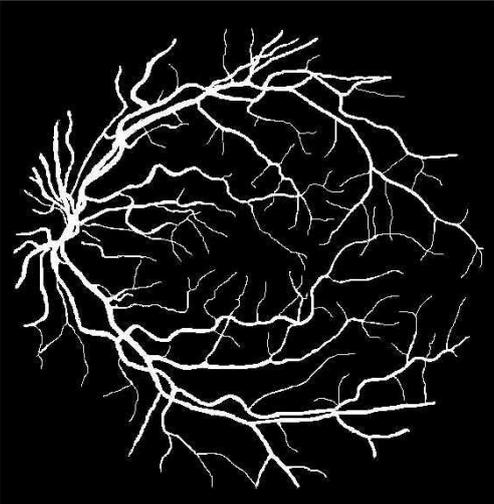

Image Sciences Institute

[ABOUT](#) [PEOPLE](#) [RESEARCH](#) [EDUCATION](#) [CONFERENCES](#) [VACANCIES](#)
[Themes / Publications / Theses Library / Gallery](#) [Databases / Software / Spin-offs](#)

DRIVE: Results Browser

Magnification factor:
 display soft classification when available

Display the following:
 input
 gold standard
 human observer
 Chaudhuri
 Jiang
 Niemeijer
 Perez
 Staal
 Zana

Results for case 1.

Displayed	Sensitivity	Specificity	Accuracy	Az
1. Input				
2. Gold standard				

Notes

1. The images displayed here are for viewing purposes only. Do not use these images and segmentations for experiments, as all images are compressed.

[Search](#) / [Site Map](#) / [Contact Us](#) / [BIS](#) / [Imago](#) / [Utrecht University](#) / [UMC Utrecht](#) / [ISI - Intranet](#)
 This page is maintained by Bram van Ginneken and was last modified on 6/3/2009.
 © 2001-2009 Image Sciences Institute

Figura 4.1: Aplicación web para el examen de resultados de segmentación sobre retinografías de la base de datos DRIVE.

manualmente la vasculatura. A estos observadores se les pidió que marcaran todos los píxeles de los que estuviesen al menos un 70 % seguros de que perteneciesen a un vaso sanguíneo. En la figura 4.2 se puede comparar la segmentación manual llevada a cabo por el experto de referencia (arriba) y por un observador humano independiente (abajo).

Todas las imágenes contenidas en la base de datos se han utilizado para llevar a cabo diagnósticos clínicos. En [SAN⁺04] o [NSvG⁺04] puede consultarse más información sobre esta base de datos.

4.2. Preprocesado

En esta sección se expone la comparación realizada entre las diferentes técnicas de interpolación que se emplean en el preprocesado de la retinografía y las mejoras obtenidas mediante la segmentación auxiliar. Previamente, presentaremos los términos en los que se expresará la calidad de los resultados obtenidos a lo largo de todo el capítulo: precisión, sensibilidad y especificidad. Estos términos se definen respectivamente según las ecuaciones 4.1, 4.2 y 4.3, mostradas a continuación:

$$Precision = \frac{TP + TN}{\#pixeles} \quad (4.1)$$

$$Sensibilidad = \frac{TP}{TP + FN} \quad (4.2)$$

$$Especificidad = \frac{TN}{TN + FP} \quad (4.3)$$

donde TP corresponde a los verdaderos positivos, TN a los verdaderos negativos, FP a los falsos positivos y FN a los falsos negativos. La figura 4.3 muestra un esquema de los diferentes tipos de error y acierto que se pueden obtener. El término $\#pixeles$ representa el número de píxeles de la imagen que han sido clasificados.

Así pues, los verdaderos positivos corresponden a los píxeles correctamente clasificados como parte de un vaso y los verdaderos negativos a píxeles clasificados como parte del fondo de forma correcta. Los posibles errores serían pues los falsos positivos, que se producen cuando se clasifica un píxel como formando parte de un vaso cuando pertenece al fondo e, inversamente, los falsos negativos, que indican los píxeles pertenecientes a un vaso que se han clasificado como parte del fondo.

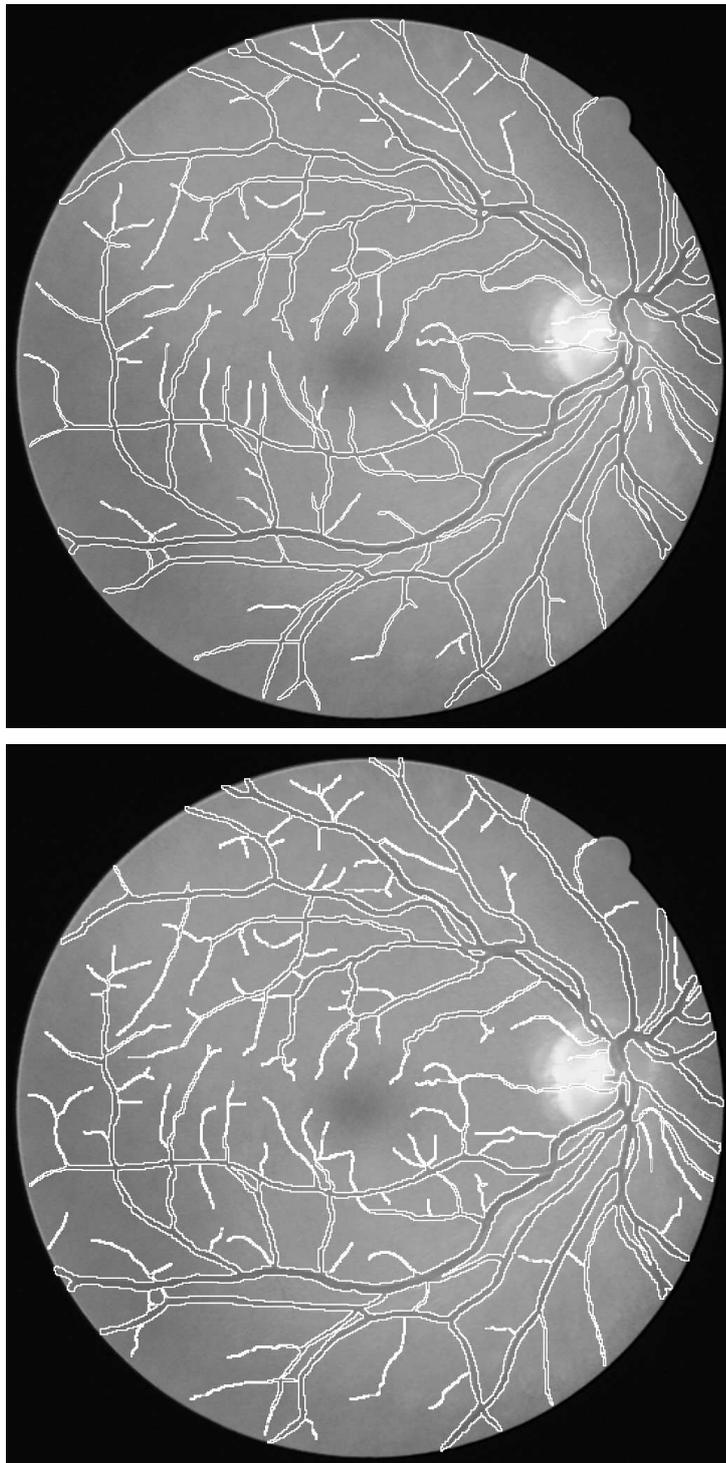


Figura 4.2: Comparación de resultados mediante segmentación manual por el experto de referencia (arriba) y por un observador humano independiente (abajo). El contorno final se representa en blanco sobre la imagen original.

		Valor Real		TOTAL
		Vaso p	No-Vaso n	
Valor obtenido	Vaso p'	Verdadero Positivo (TP)	Falso Positivo (FP)	P'
	No-Vaso n'	Falso Negativo (NP)	Verdadero Negativo (TN)	N'
TOTAL		P	N	

Figura 4.3: Tipos de error en la clasificación binaria de píxeles de una imagen como pertenecientes bien a un vaso o bien al fondo. Los verdaderos positivos (TP) son píxeles correctamente clasificados como parte de un vaso y los verdaderos negativos (TN) son los clasificados como parte del fondo acertadamente. Los falsos positivos (FP) son los píxeles clasificados como formando parte de un vaso incorrectamente y los falsos negativos (FN), los clasificados erróneamente como pertenecientes al fondo. El número total de píxeles clasificados será $P + N$, o equivalentemente $P' + N'$.

La *precisión* es una medida estadística que indica lo bien que un test de clasificación binaria identifica o excluye correctamente una condición. En este caso se clasifican los píxeles de una retinografía según cumplan la condición de pertenecer a un vaso sanguíneo o no. La *sensibilidad* es una medida estadística que cuantifica hasta qué punto un test de clasificación binaria identifica correctamente una condición, es decir, la pertenencia a un vaso. La *especificidad* indica en qué medida un test de clasificación binaria identifica correctamente los casos negativos, aquellos que no cumplen la condición estudiada, lo que en este dominio particular son los píxeles pertenecientes al fondo de ojo.

Una vez definidas las medidas estadísticas que serán empleadas, justificaremos la decisión de trabajar a nivel de subpíxel mostrando de forma cuantitativa y cualitativa las mejoras que esto supone. Para finalizar expondremos los resultados obtenidos en la comparación de los resultados obtenidos empleando diferentes técnicas de interpolación para la ampliación de la imagen de fondo de ojo que se realiza previamente al proceso de segmentación.

Nivel	Precisión	Sensibilidad	Especificidad
Píxel	0.9247	0.6582	0.9607
Subpíxel	0.9352	0.7436	0.9614

Tabla 4.1: Comparación de la segmentación trabajando a nivel de píxel y de subpíxel. Los resultados se expresan en términos de precisión, sensibilidad, y especificidad.

Nivel	Tiempo de Ejecución (s)						
	T_{res}	T_{cr}	T_{crEn}	T_{borde}	T_{bordEn}	T_{snk}	T_{tot}
Píxel	0.0	2.0	0.1	2.0	0.2	0.6	5.0
Subpixel	4.9	10.0	0.4	14.3	1.2	9.2	34.4

Tabla 4.2: Comparación del tiempo de ejecución medio en segundos para el sistema de detección de vasos propuesto, trabajando a nivel de píxel y subpíxel. T_{res} corresponde con la ampliación de la imagen original al doble de su tamaño. La extracción lleva un tiempo T_{cr} para las crestas y T_{borde} para los bordes. T_{crEn} y T_{bordEn} corresponden al cálculo de las imágenes de energía para las crestas y los bordes, respectivamente. La evolución del snake en sí está representada por T_{snk} . T_{total} es el tiempo de procesamiento total necesario para llevar a cabo el proceso de segmentación de la imagen al completo.

4.2.1. Mejora aportada por Nivel de Subpíxel

En este apartado se detallan los niveles de precisión, sensibilidad y especificidad alcanzados trabajando a nivel de píxel y de subpíxel (tabla 4.1). También se incluyen las medidas de tiempo de ejecución para cada una de dichas versiones del proyecto (tabla 4.2) e imágenes mostrando los resultados obtenidos (figura 4.4).

La tabla 4.2 muestra una comparación del tiempo de ejecución medio en segundos por imagen para el sistema de detección de vasos propuesto, trabajando a nivel de píxel y subpíxel. Los costes computacionales de los procesos de segmentación morfológica auxiliar y detección automática del disco óptico se han excluido de este cómputo por ser equivalentes para ambos sistemas, al realizarse sobre la imagen sin ampliar. Como puede observarse, el tiempo de procesamiento total necesario para llevar a cabo el proceso de segmentación de la imagen al completo (T_{total}) es bastante mayor a nivel de subpíxel. T_{res} corresponde con la ampliación de la imagen original al doble de su tamaño, necesaria sólo para el nivel subpíxel. Aunque este proceso se ha optimizando, eliminando las áreas externas al FOV, incrementa considerablemente el tiempo de procesado.

Al ser la imagen de mayor tamaño, también el cálculo de las crestas, bordes y

sus mapas de energía asociados será más costoso computacionalmente. Este hecho se muestra en los tiempos de extracción de las crestas (T_{cr}) y los bordes (T_{borde}), así como los tiempos de cálculo de los mapas de energía para las crestas y los bordes, T_{crEn} y T_{bordEn} , respectivamente.

El tiempo dedicado a la evolución del snake en sí está representado por T_{snk} y es también mayor para el nivel subpíxel. Este hecho se debe a que la complejidad del modelo se incrementa, como explicamos en el apartado 3.1.2.

Aun así, la eficiencia del modelo a nivel subpíxel continúa siendo muy elevada y por tanto válida para multitud de aplicaciones. El valor de sensibilidad alcanzado trabajando a nivel de píxel es insuficiente (ver tabla 4.1), debido principalmente a que muchos vasos finos no se segmentan. En la figura 4.4 puede apreciarse claramente este hecho, ya que la segmentación obtenida trabajando a nivel de subpíxel (abajo) es capaz de detectar muchas más estructuras vasculares que si trabajamos a nivel de píxel (arriba). Esta mejora afecta sobre todo a los vasos delgados, aunque también puede ayudar a obtener una mejor segmentación de estructuras vasculares de calibre mayor.

La decisión sobre el nivel de precisión ha de ser un compromiso entre exactitud en la detección y eficiencia del proceso. Por lo tanto, será necesario realizar el proceso de segmentación a nivel subpíxel para alcanzar una precisión suficiente, aunque ello suponga incrementar el coste computacional del modelo.

4.2.2. Comparación entre Métodos de Interpolación

Una vez tomada la decisión de trabajar a nivel de subpíxel, debemos seleccionar un método para ampliar la imagen original al doble de su tamaño. Se han considerado los tres métodos de ampliación más habituales, descritos en el apéndice A: directo, mediante interpolación lineal y mediante interpolación bicúbica.

El método directo no emplea ningún tipo de interpolación, sino que directamente asigna el valor del píxel original más cercano a cada nuevo píxel. De este modo su eficiencia es muy alta pero la calidad visual de los resultados es mala. La interpolación lineal es bastante eficiente pero sus resultados son mucho menos precisos que los de la interpolación bicúbica. Esta última presenta una complejidad computacional mucho mayor que las otras dos.

En la tabla 4.3 se comparan los diferentes métodos de interpolación en el modelo sin segmentación auxiliar. La tabla 4.4 muestra los resultados empleando los diferentes métodos de interpolación en el modelo que incluye segmentación auxiliar.

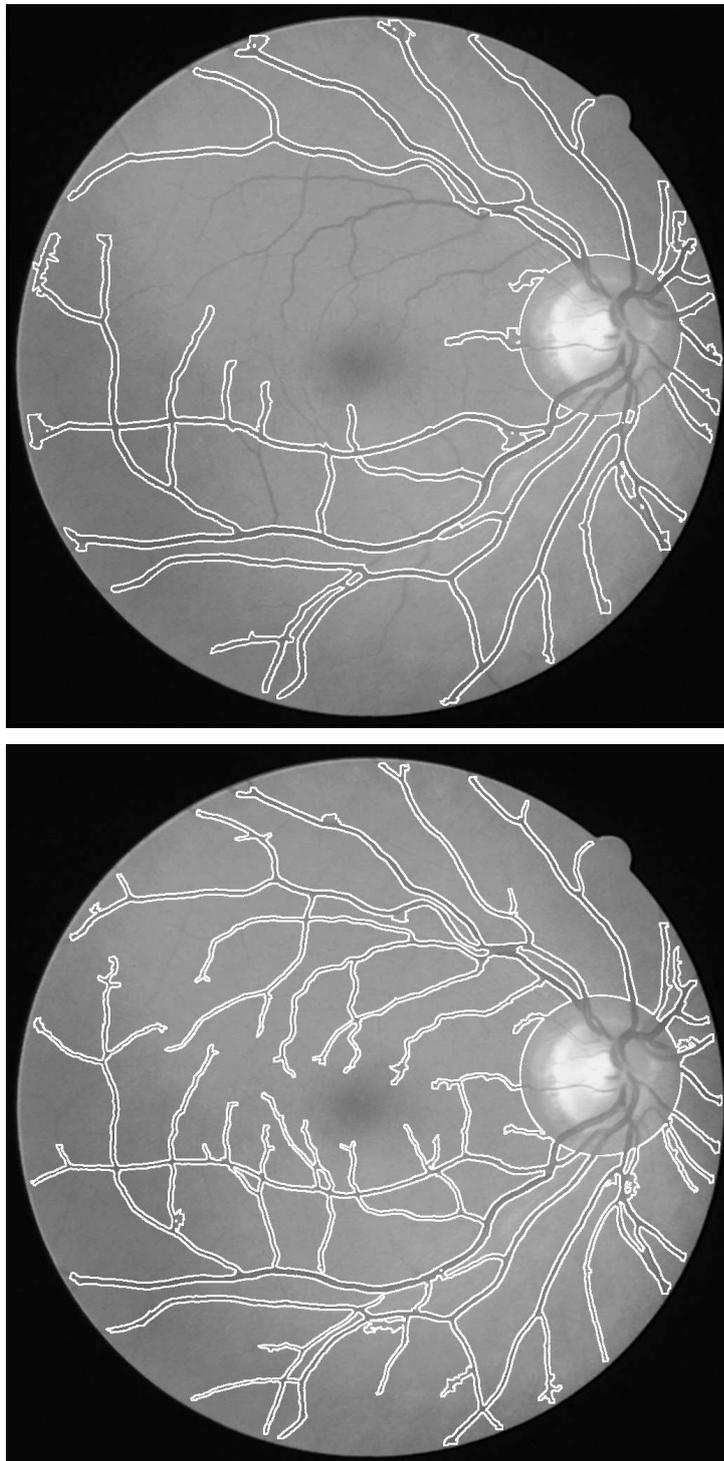


Figura 4.4: Comparación del proceso de segmentación trabajando a nivel de píxel y subpíxel. El contorno final se representa en blanco sobre la imagen original. Arriba: Segmentación a nivel píxel. Abajo: Segmentación a nivel subpíxel. Comparando las parejas de figuras se ve cómo es necesario trabajar a nivel de subpíxel para no perder los vasos finos e incluso alguno de calibre mayor.



Figura 4.4: (Cont.)

Interpolación	Precisión	Sensibilidad	Especificidad	Tiempo
Bicúbica	0.9308	0.7004	0.9625	5.02
Lineal	0.9297	0.6985	0.9612	0.85
Directa	0.9298	0.6980	0.9616	0.53

Tabla 4.3: Modelo sin Segmentación Auxiliar. Comparación de la segmentación empleando diferentes métodos de interpolación. Los resultados se expresan en términos de precisión, sensibilidad, especificidad y tiempo de interpolación en segundos.

Interpolación	Precisión	Sensibilidad	Especificidad	Tiempo
Bicúbica	0.9352	0.7437	0.9614	5.02
Lineal	0.9341	0.7445	0.9600	0.85
Directa	0.9351	0.7454	0.9611	0.53

Tabla 4.4: Modelo con Segmentación Auxiliar. Comparación de la segmentación empleando diferentes métodos de interpolación. Los resultados se expresan en términos de precisión, sensibilidad, especificidad y tiempo de interpolación en segundos.

La mejora aportada por la interpolación bicúbica se hace mucho más patente en el modelo que no emplea segmentación auxiliar. La precisión alcanzada es más alta que cuando utilizamos interpolación lineal o realizamos una ampliación directa. A nivel de la sensibilidad el incremento es aun mayor, como puede verse en la tabla 4.3.

En el modelo que sí emplea segmentación auxiliar, la aportación es más leve según muestra la tabla 4.4. Esto es debido a que este último modelo es más robusto, y así la influencia del método de interpolación es mucho menor.

La eficiencia del modelo es suficientemente alta como para poder permitirse un coste computacional algo mayor en el proceso de ampliación de la imagen. La interpolación bicúbica supone una variación pequeña debido a la mencionada optimización del algoritmo, que consiste básicamente en ignorar las zonas externas al FOV. Por tanto, emplearemos la interpolación bicúbica por obtener los mejores resultados, ya que aunque en este caso concreto la mejora aportada no es muy elevada en términos globales, sí lo es a la hora de estimar con alta precisión los calibres vasculares. Una pequeña variación de dos o tres píxeles en la estimación de la anchura de un vaso puede afectar considerablemente a los parámetros calculados a partir de dicha medida y los procesos diagnósticos que se basen en este.

Por otra parte, el hecho de que en el modelo sin segmentación auxiliar la influencia sea más elevada, indica que para otras imágenes en que las que la segmentación morfológica sea de baja calidad, sí será necesario emplear la técnica de interpolación bicúbica.

4.3. Parámetros del modelo

En esta sección se detallan los valores concretos de los parámetros con los que se ha configurado nuestro sistema para la obtención de los resultados que exponemos en las siguientes secciones. En general, se ha parametrizado el sistema tratando de que su comportamiento sea adecuado para efectuar una segmentación satisfactoria de cualquiera de las imágenes del conjunto de entrenamiento. Describiremos los valores fijados para las diferentes etapas de obtención de crestas, bordes y la segmentación morfológica auxiliar, además de los parámetros con los que ha sido configurado el snake.

4.3.1. Parámetros de Detección y Mejora de Crestas

La tabla 4.5 muestra los parámetros de configuración del extractor de crestas, cuyo funcionamiento se describe en el apéndice A.

SD es la escala de segmentación que determina el valor de una función de suavizado gaussiano y se emplea un valor bastante bajo para filtrar el ruido pero sin perder definición en la imagen para que las crestas se sitúen de forma precisa aunque esto implique la presencia de algunas crestas espurias debidas al ruido. Por razones semejantes se emplea un valor bastante reducido para la escala de integración *SI* que representa el valor de otra función de suavizado gaussiano. *CNFD* define el valor de confianza, que se mantendrá a un nivel suficientemente bajo para que se detecten adecuadamente las crestas incluso en imágenes de baja calidad, pese a que esto pueda provocar que en las imágenes de mayor calidad se reduzca la especificidad.

THRK determina el nivel de gris mínimo de las crestas y se le ha asignado un valor que antepone la sensibilidad del sistema al rendimiento y la discriminación del ruido. El valor de *WHC* indica que el algoritmo de extracción de crestas debe calcular tanto las crestas como los valles, manteniéndose así la generalidad en cuanto al tipo de imágenes. La longitud mínima de la cresta, representada por *BMIN*, implica una sensibilidad bastante alta, para no perder ninguna cresta aunque no se descarte tanto ruido.

EXTRACCIÓN DE CRESTAS

Parámetro	Valor
Escala de Segmentación (SD)	4.5
Escala de Integración (SI)	8
Confianza (CNFD)	0.08
Umbral de Cresta (THRK)	0.019
Crestas y Valles (WHC)	1
Longitud Mínima de Cresta (BMIN)	170

Tabla 4.5: Valores de los parámetros principales del extractor de crestas que le permiten alcanzar una elevada sensibilidad de detección. *SD* y *SI* presentan valores bajos para filtrar el ruido sin perder definición en la imagen. *CNFD* tiene un valor adecuado incluso para imágenes de baja calidad. *THRK* está configurado para aumentar la sensibilidad del sistema. El valor de *WHC* indica que se extraen las crestas y los valles, permitiendo generalidad en el tipo de imágenes. *BMIN* está expresado en píxeles e implica una sensibilidad bastante alta.

MEJORA DE CRESTAS

Parámetro	Valor
Máxima Distancia entre Segmentos (maxDist)	54
Máximo Ángulo de Unión (maxDiffAngle)	2.35 (rad)
Máximo Ángulo de Bifurcación (maxForkJointAngle)	$0,61 * \pi$ (rad)
Máxima Distancia de Unión (linkLim)	30
Radio Exterior de Eliminación de Crestas (radiusExternCr)	24

Tabla 4.6: Valores de los parámetros principales empleados para mejorar las imágenes de crestas. *maxDist* determina la distancia máxima en píxeles entre dos extremos de un segmento de cresta para que se estudien las relaciones entre ambos. El ángulo máximo para considerar unión (*maxDiffAngle*) es de 135° , mientras que para cruce o bifurcación (*maxForkJointAngle*) su valor es de aproximadamente 110° . *linkLim* indica el límite de distancia máxima en píxeles para unir dos puntos extremos de un cruce, bifurcación o unión. *radiusExternCr* establece el radio en píxeles con respecto al borde del FOV dentro del que se eliminan las crestas existentes.

En suma, hemos configurado el extractor de crestas para que alcance una sensibilidad de detección bastante alta. Podemos permitir que algunas crestas sean falsas, es decir, debidas al ruido, ya que el resto de información obtenida de la imagen (bordes y segmentación morfológica) permite descartar posteriormente aquellas que se sitúen fuera de las estructuras vasculares.

La tabla 4.6 muestra los parámetros empleados en la mejora de las imágenes de crestas. Los tres primeros parámetros corresponden a la configuración de la herramienta Minutia descrita en el apartado 3.2.2. El valor de *maxDist* determina la distancia máxima entre dos extremos de un segmento de cresta para que se estudien las relaciones entre ambos. El siguiente parámetro, *maxDiffAngle*, corresponde al umbral de ángulo para considerar unión y su valor equivale a unos 135° . El máximo ángulo para que un cruce o bifurcación sea considerado válido viene indicado por *maxForkJointAngle*, cuyo valor es de aproximadamente unos 110° .

Los otros dos parámetros relativos al proceso de mejora de crestas son *linkLim* y *radiusExternCr*. El primero representa el límite de distancia para unir dos puntos extremos que formen parte de un cruce, bifurcación o unión. El segundo indica el radio con respecto al borde del FOV dentro del que se eliminan las crestas existentes, para evitar crestas espurias que aparecen en esas zonas, como se explica en el apartado 3.2.2.

4.3.2. Parámetros de Detección y Mejora de Bordes

La tabla 4.7 muestra los parámetros que configuran el extractor de bordes de Canny, cuyo funcionamiento se describe en la sección 2.3.

El primer parámetro, *sigma*, indica el tamaño del filtro gaussiano para eliminar ruido. Se ha escogido un valor relativamente bajo para evitar la pérdida de detalles al suavizar la imagen. Los parámetros *tHigh* y *tLow* corresponden respectivamente a los umbrales alto y bajo que definen la función de histéresis. Este conjunto de parámetros confiere al sistema de extracción de bordes una alta sensibilidad.

La tabla 4.8 recoge los parámetros utilizados en el proceso de mejora de las imágenes de bordes que se describe en el apartado 3.2.2. El valor de *limEnhanceEdges* indica el área de eliminación de bordes en torno a un punto de cresta cuando se produce una intersección entre líneas de cresta y bordes. El tamaño de la ventana para limpiar la imagen de bordes de pequeños fragmentos debidos al ruido está definido por *cleanWin*. El parámetro *radiusExternEd* indica el radio con respecto al borde del FOV dentro del que se eliminan los bordes existentes para evitar los bordes espurias que aparecen en esas zonas.

EXTRACCIÓN DE BORDES

Parámetro	Valor
Tamaño de Gaussiana (sigma)	4
Umbral de Histéresis Alto (tHigh)	0.6
Umbral de Histéresis Bajo(tLow)	0.4

Tabla 4.7: Valores de los parámetros principales del extractor de bordes de Canny para lograr una alta sensibilidad. *sigma* indica un reducido tamaño del filtro gaussiano para no suavizar demasiado la imagen. *tHigh* y *tLow* corresponden respectivamente a los umbrales alto y bajo de intensidad que definen la función de histéresis, manteniéndose una alta sensibilidad.

MEJORA DE BORDES

Parámetro	Valor
Radio de Borrado en Cresta (limEnhanceEdges)	2
Tamaño de Ventana de Limpieza (cleanWin)	4
Radio Exterior de Eliminación de Bordes (radiusExternEd)	14

Tabla 4.8: Valores de los parámetros principales empleados para mejorar las imágenes de bordes. *limEnhanceEdges* está expresado en píxeles e indica el radio de eliminación de bordes en torno a las crestas. *cleanWin* define el tamaño de la ventana en píxeles para eliminar los bordes debidos al ruido. *radiusExternEd* indica el radio en píxeles con respecto el borde del FOV dentro del que se eliminan bordes por considerarlos espurios.

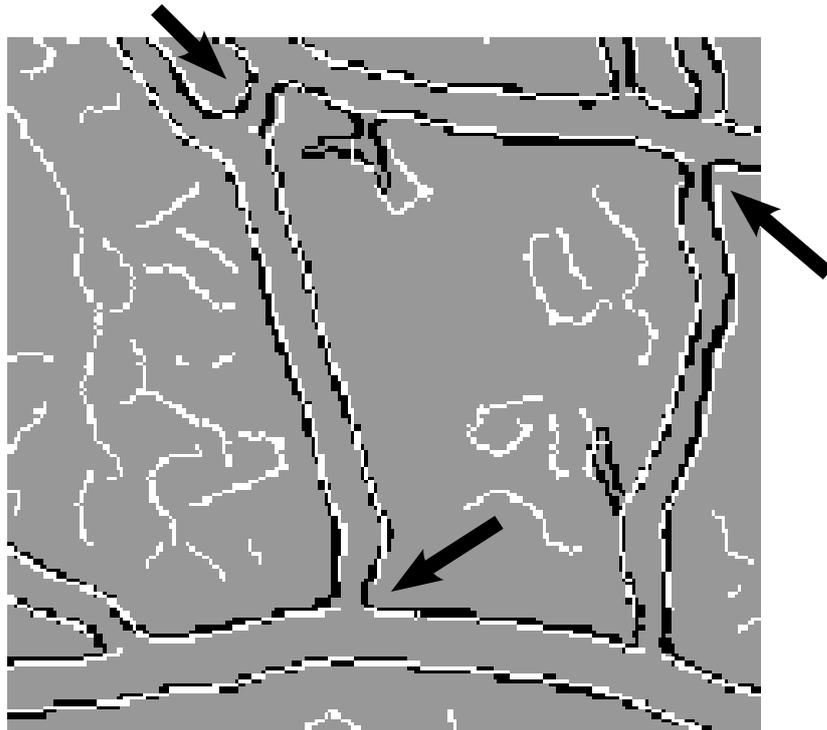


Figura 4.5: Mejora aportada sobre la imagen de bordes mediante la segmentación morfológica. En la figura vemos cómo los bordes extraídos de la segmentación morfológica (en negro) mejoran los bordes obtenidos directamente de la retinografía (en blanco). Esta mejora es más notable en los cruces e intersecciones señalados con flechas, donde los bordes auxiliares evitan las discontinuidades existentes.

Los resultados de la segmentación morfológica se emplean en la mejora de la imagen de bordes. Como se explica en el apartado 3.2.2, los bordes obtenidos de la segmentación auxiliar se añaden a la imagen de bordes original para cerrar discontinuidades. Con esto se evita que el snake se desborde en las zonas de intersección o cruce y pueda continuar segmentando los vasos que se ramifican o intersecan a uno dado. Así pues, se segmentan un mayor número de estructuras vasculares con lo que se incrementa la sensibilidad del modelo. En la figura 4.5 vemos cómo los bordes extraídos de la segmentación morfológica mejoran los obtenidos directamente de la retinografía, especialmente en los cruces e intersecciones, donde los bordes auxiliares evitan las discontinuidades existentes.

La segmentación auxiliar también juega un papel importante en las operaciones de control descritas en el apartado 3.4.3. Gracias a esta técnica, la evolución del contorno continúa su expansión a través de los tramos de los vasos con crestas no detectadas que sí fueron segmentadas correctamente por la segmentación morfológica. De este modo se evita el bloqueo erróneo de frentes del snake, pudiendo segmentarse más vasos e incrementando así la sensibilidad del modelo.

La cuantificación de las mejoras obtenidas gracias al aprovechamiento de la segmentación morfológica auxiliar se recoge en la tabla 4.9. Como vemos, la calidad de los resultados es mayor en el sistema que sí aprovecha esta técnica, sobre todo en términos de sensibilidad, por las causas mencionadas. La parametrización de ambos sistemas es prácticamente equivalente.

En la figura 4.6 también se aprecia esta mayor sensibilidad. En las imágenes superiores, correspondientes al modelo que no aprovecha la segmentación auxiliar, se puede observar cómo quedan muchas ramificaciones vasculares importantes sin segmentar. Sin embargo, con la ayuda de la segmentación morfológica se consiguen segmentar más vasos sanguíneos, obteniéndose unos resultados de mayor calidad, como los mostrados en las figuras inferiores.

En cuanto al coste computacional que supone el empleo de la segmentación auxiliar, este es muy bajo, ya que representa sólo unos 4 segundos del total. El resto de incremento de tiempo entre ambos métodos, unos 3 segundos, es debido a la mayor sensibilidad que conlleva una superficie de segmentación más amplia. Por tanto, las mejoras aportadas por la segmentación morfológica en nuestro sistema compensan el leve incremento del tiempo de ejecución asociado.

En la tabla 4.9 se compara la calidad y coste computacional de la ejecución del modelo empleando la segmentación auxiliar y sin ella, técnica que se describe detalladamente en el Apéndice A. La parametrización de esta herramienta se resume en la tabla 4.10 que como vemos se corresponde con una configuración intermedia para adecuarse a la calidad de las imágenes que no presentan excesivo

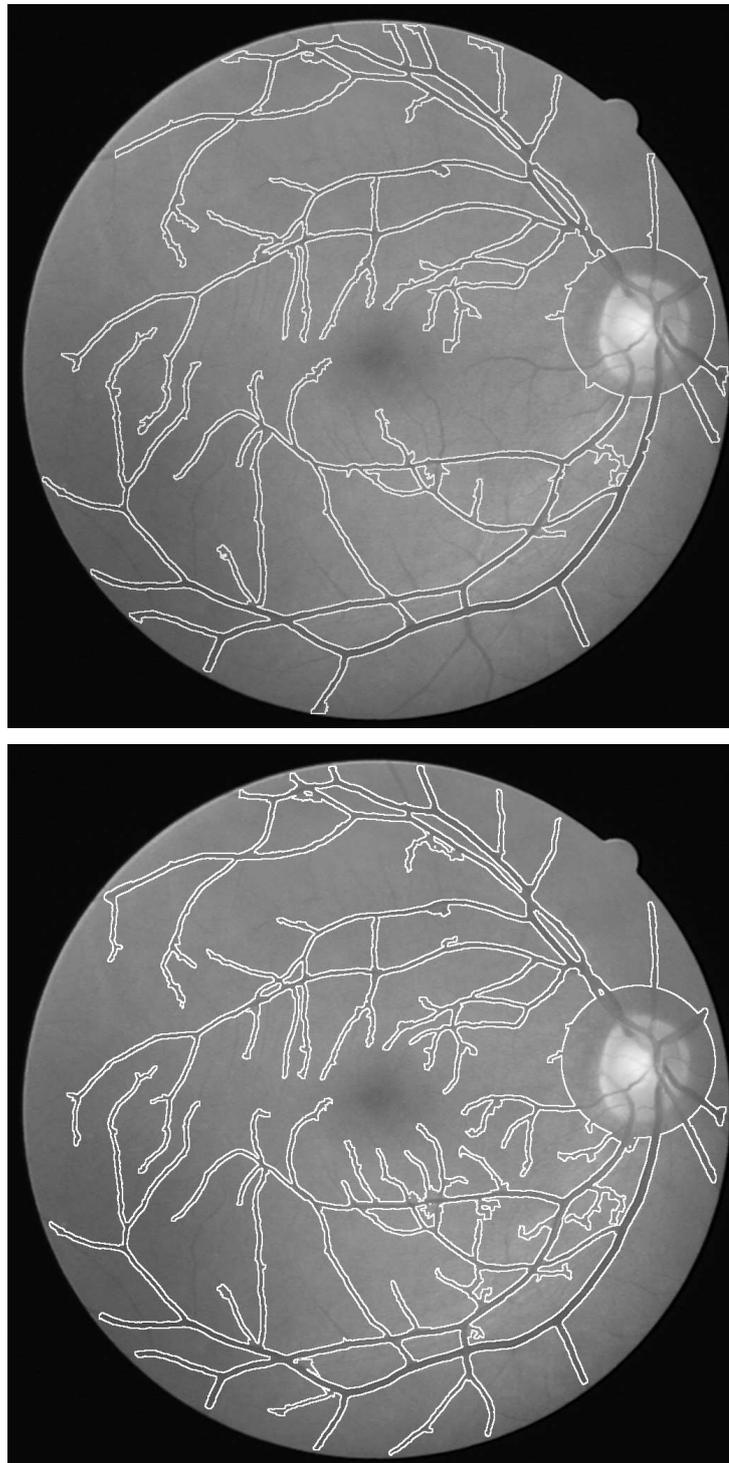


Figura 4.6: Comparación de resultados empleando la segmentación auxiliar (abajo) y sin ella (arriba). El contorno final se representa en blanco sobre la imagen original.

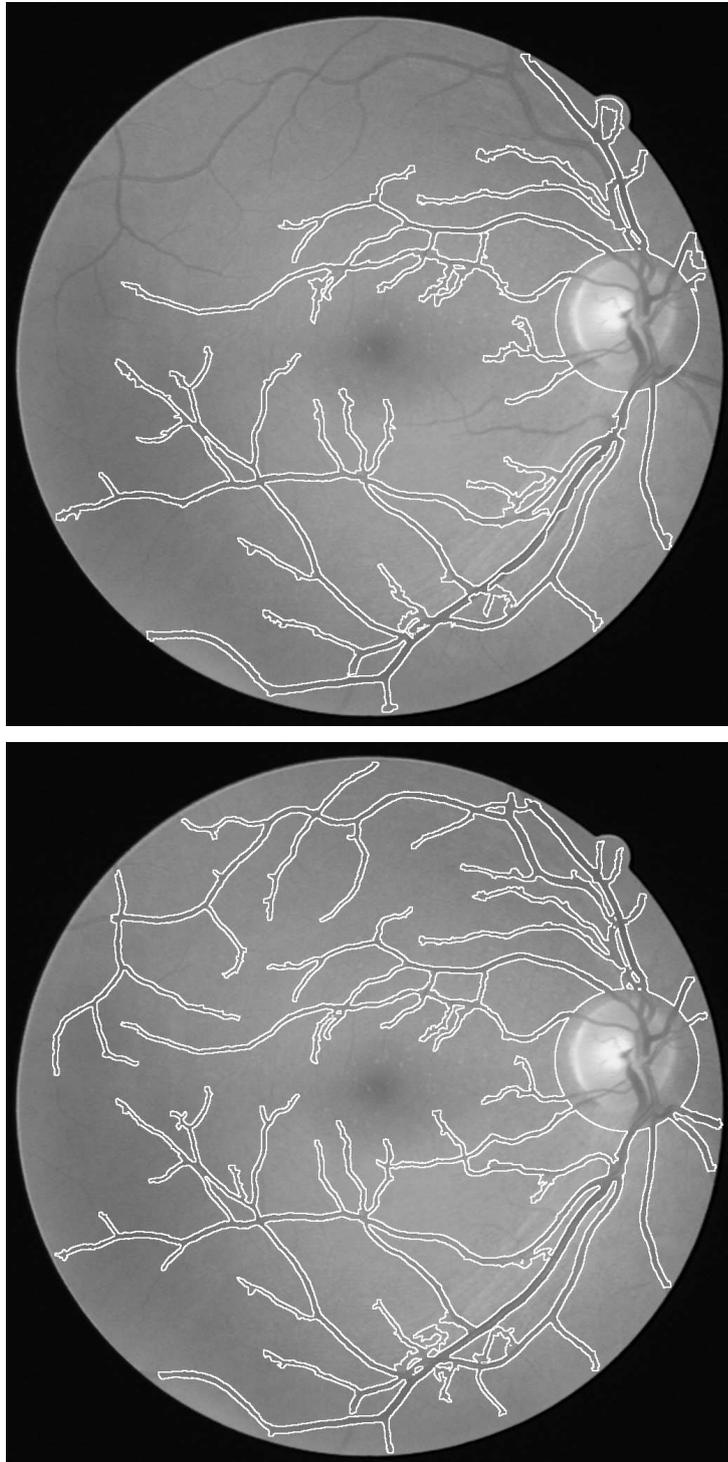


Figura 4.6: (Cont.)

Segmentación Auxiliar	Precisión	Sensibilidad	Especificidad	Tiempo en segundos
NO	0.9308	0.6994	0.9625	31.7
SI	0.9352	0.7437	0.9614	38.4

Tabla 4.9: Comparación de la segmentación empleando la segmentación morfológica auxiliar y sin ella. Los resultados se expresan en términos de precisión, sensibilidad, especificidad y tiempo en segundos.

SEGMENTACIÓN MORFOLÓGICA

Parámetro	Valor
Tamaño de Ventana de Filtrado $W_f \times W_f$	4×4
Porcentaje de Vasos por Imagen P_{vasos}	6 %
Porcentaje de Fondo por Imagen P_{fondo}	87 %
Umbral Mínimo de Filtrado por Tamaño T_f	100

Tabla 4.10: Valores de los parámetros principales para la obtención de la segmentación morfológica auxiliar. Se ha seleccionado una configuración intermedia para adecuarse a la calidad de las imágenes que no presentan excesivo ruido, alcanzándose un compromiso entre sensibilidad y eficiencia. El tamaño del filtro de mediana ha sido ajustado para que se elimine la mayor parte del ruido sin perder de precisión. Los porcentajes de vasos y fondo por imagen han sido estimados para no ser excesivamente restrictivos pero sin que se clasifiquen como vasos demasiadas estructuras debidas al ruido o lesiones. El número mínimo de píxeles para el filtrado por tamaño se ha seleccionado intentando reducir el número de posibles confusiones con lesiones o hemorragias pero sin perder vasos finos o capilares.

ruido, alcanzándose un compromiso entre sensibilidad y eficiencia. El tamaño de la ventana de filtrado de mediana ha sido ajustado para que se elimine la mayor parte del ruido sin difuminar la imagen en exceso, con la pérdida de precisión asociada. Los porcentajes de vasos y fondo por imagen han sido estimados estudiando las características de las imágenes de forma que no sean excesivamente restrictivos pero sin que se clasifiquen como vasos demasiadas estructuras debidas al ruido o lesiones . El número mínimo de píxeles para el filtrado por tamaño limita la cantidad de estructuras aisladas que serán incluidas en el resultado final y su valor se ha seleccionado para evitar confusiones con lesiones o hemorragias, sin perder vasos finos o capilares.

DETECTOR DEL DISCO ÓPTICO	
Parámetro	Valor
Límite de Distancia entre Centroides (ϵ)	350
Tamaño de la Región de Interés ($m \times n$)	350×350
Ventana de Vecindad ($w_a \times w_b$)	6×6
Radio Mínimo (r_{min})	75
Radio Máximo (r_{max})	125
Ventana de Centro Válido ($c_a \times c_b$)	80×80
Decaimiento de Gaussiana (β)	10

Tabla 4.11: Valores de los parámetros principales para la detección automática del disco óptico.

4.3.3. Parámetros de Detección Automática del Disco Óptico

La detección automática del disco óptico, que constituye el punto de partida del contorno deformable que se describe en esta memoria, se realiza mediante el algoritmo desarrollado por nuestro grupo de investigación [BPB⁺06]. El proceso de detección empleado consiste en la localización de la región de interés mediante un algoritmo de clusterización seguida de la extracción del disco óptico. Esta extracción se realiza aplicando la transformada de Hough circular difusa a los bordes obtenidos de la región de interés.

La configuración del detector del disco óptico ha sido ajustada a las características particulares del conjunto de imágenes para lograr una adecuada detección del mismo. La tabla 4.11 muestra los valores de los parámetros utilizados para la definición del contorno inicial del snake (ver apartado 3.3). El límite de distancia entre centroides ϵ juega un papel muy importante en el algoritmo de clustering ya que establece un límite de distancia euclídea entre los centroides de clústeres de cara a la fusión de los mismos. El valor establecido se ha fijado en 350 píxeles teniendo en cuenta el tamaño máximo que puede ocupar el área del disco óptico, relacionado directamente con la resolución de la imagen. El tamaño de la región de interés $m \times n$ también se ha determinado considerando dichos factores y se ha estimado que un área de 350×350 píxeles sería suficiente para contener el disco óptico.

El tamaño de la ventana de vecindad $w_a \times w_b$ determina qué bordes de vaso serán eliminados en las zonas cercanas a una cresta, en caso de que la dirección de ambas estructuras sea semejante. Con esto se pretende eliminar los bordes que no se correspondan al disco óptico y facilitar así la detección del mismo. Esta

distancia entre crestas y bordes del vaso se fijado en 6×6 considerando la anchura media de los vasos en la zona del disco óptico.

Para reducir el coste computacional de la transformada de Hough circular difusa se aprovechan las características conocidas del disco óptico, restringiendo el radio y la posición del círculo detectado. Los radios válidos deben encontrarse en un rango comprendido entre r_{min} y r_{max} , que se han estimado en 75 y 125 píxeles respectivamente. Estos valores se han establecido a partir del estudio de las dimensiones máximas y mínimas de los discos ópticos del conjunto de imágenes. La posición del centro del círculo se restringe al área centrada en la región de interés correspondiente a la ventana de dimensiones $c_a \times c_b$, a la que dada la resolución de las imágenes, se le ha asignado el valor de 80×80 píxeles. Por último, el decaimiento de gaussiana β que determina la contribución de cada píxel al array acumulador descrito en [BPB⁺06], se ha estimado en 10.

En el apartado 5 del apéndice A se puede encontrar una descripción más detallada de esta herramienta y del papel de dichos parámetros en el funcionamiento de la misma.

4.3.4. Parámetros del Snake

En este apartado se detallan los parámetros seleccionados para la configuración del modelo basado en contornos deformables que hemos desarrollado.

Como se indicó en el capítulo 3, la energía global que afecta al snake estará definida como la suma del siguiente conjunto de energías y factores de peso:

$$\epsilon_{snake} = \gamma \epsilon_{borde} + \delta \epsilon_{cresta} + \nu \epsilon_{dir} + \sigma \epsilon_{marca} + \omega \epsilon_{difer} \quad (4.4)$$

La tabla 4.12 muestra los valores de los pesos de los términos de energía de la ecuación 4.4 en función del estado del nodo (cresta, borde, normal).

El peso de la energía de marcador (σ) es el más alto para todos los estados. Esto se debe a que deseamos restringir el movimiento del nodo a zonas no visitadas independientemente de su estado. La energía de la diferencia ϵ_{difer} , por el contrario, tiene un peso asociado (ω) bastante reducido puesto que únicamente constituye un refuerzo de la precisión de la segmentación.

Los nodos normales y los nodos borde tienen pesos muy similares, ya que en general, los nodos normales evolucionan a nodos borde. Estos nodos dan una importancia alta a la energía de borde ϵ_{borde} , debido a que se encargan principalmente de la expansión del snake en anchura. Por ello, la importancia de la presión de inflado ϵ_{dir} y de la energía de crestas ϵ_{cresta} es muy baja.

ENERGÍAS	PESOS	ESTADO DEL NODO		
		Normal	Borde	Cresta
Presión de Inflado ϵ_{dir}	ν	0.025	0.020	0.052
Energía Diferencia ϵ_{difer}	ω	0.003	0.001	0.003
Energía Borde ϵ_{borde}	γ	0.062	0.079	0.000
Energía Cresta ϵ_{cresta}	δ	0.010	0.000	0.045
Energía Marcador ϵ_{marca}	σ	0.900	0.900	0.900

Tabla 4.12: Valores de los pesos de los términos de energía de la ecuación 4.4 en función del estado del nodo. El peso de la energía de marcador σ es el más alto, ya que restringe el movimiento del nodo a zonas no visitadas independientemente de su estado. Los nodos normales y los nodos borde tienen pesos muy similares, dando una importancia alta a la energía de borde ϵ_{borde} . Los nodos en estado cresta están influenciados principalmente por la presión de inflado ϵ_{dir} y la distancia a crestas ϵ_{cresta} .

Los nodos en estado cresta son los principales responsables del crecimiento del snake a lo largo de los vasos. Así pues, están influenciados principalmente por la presión de inflado ϵ_{dir} (peso ν) y la distancia a crestas ϵ_{cresta} (peso δ).

Otros parámetros del snake que determinan su comportamiento se exponen en la tabla 4.13. El parámetro *growTh* determina el umbral de distancia entre nodos para la inserción de un nuevo nodo. Su valor indica el nivel de definición que puede alcanzar el contorno activo, tal y como se explica en el apartado 3.4.2 dedicado al crecimiento del snake.

Los límites de anchura máxima y mínima de los vasos que van a ser segmentados, se corresponden con *maxWidth* y *minWidth* respectivamente y son fundamentales en las operaciones de control de frentes, como se describe en el apartado 3.4.3. Aunque el calibre vascular raramente supera los 40 píxeles, es preciso darle un margen amplio al umbral *maxWidth* para que el snake no se bloquee en situaciones en las que se produce un anheamiento debido a una bifurcación o en la que la anchura del frente no se calcule de forma exacta, es decir, perpendicularmente al vaso, a causa de la disposición de los nodos. En el apartado 3.4.3 se explica también el papel del umbral de distancia a crestas, representado por el parámetro *distLim*. Dicho umbral limitará la expansión del snake a aquellas estructuras que tengan una cresta en su proximidad, que se corresponderán con los vasos sanguíneos.

MODELO DE SNAKES

Parámetro	Valor
Límite de Anchura Máxima (maxWidth)	140
Límite de Anchura Mínima (minWidth)	3
Umbral de Distancia a Crestas (distLim)	3
Umbral de Crecimiento (growTh)	3

Tabla 4.13: Valores de los parámetros principales que determinan el comportamiento del modelo de contornos activos. *maxWidth* y *minWidth* están expresados en píxeles y son fundamentales en las operaciones de control de frentes, así como el umbral de distancia a crestas, representado por *distLim*. *growTh* determina el umbral de distancia en píxeles entre nodos para la inserción de un nuevo nodo e indica el nivel de definición del snake, que en este caso es elevado.

4.4. Comparación con otros Métodos

En este apartado se comparan nuestros resultados con los obtenidos por otras aproximaciones existentes sobre el conjunto de imágenes de test de la base de datos DRIVE [SAN⁺04]. Cada una de estas soluciones se encuentra descrita en la sección 1.2. Los resultados mostrados en la tabla 4.14 se compararon tomando como referencia la misma segmentación efectuada por un experto humano. Esta segmentación de referencia viene proporcionada por la base de datos de imágenes DRIVE para cada una de la imágenes del conjunto de test.

Además de comparar con otros métodos automáticos, se incluyen los resultados obtenidos por un segundo observador humano independiente, que también procede de la base de datos de imágenes DRIVE. Mediante esta comparación se obtiene una idea de la limitación real en cuanto a calidad de resultados que existe en el dominio concreto de la segmentación vascular retiniana. Así pues, los resultados de un método automático tendrán una calidad suficiente si consiguen alcanzar un nivel de coincidencia con el experto semejante al obtenido por el segundo observador. Como muestra la tabla 4.14, el observador humano independiente obtiene una sensibilidad bastante baja, lo cual indica que existe una dificultad de segmentación en los vasos muy finos y zonas de borde que es inherente al dominio de aplicación.

La calidad de los resultados se expresa para todos los métodos en términos de precisión, definida en la ecuación 4.1. Para aquellos métodos en los que dicha información se encuentra disponible se muestra su sensibilidad y especificidad, definidos respectivamente según las ecuaciones 4.2 y 4.3, mostradas al inicio del

	Preci- sión	Sensibi- lidad	Especifi- cidad	Área ROC	Tiempo (seg.)
SNAKE PROPUESTO	0.9321	0.7426	0.9600	—	38.4
Soares y col. [SLCJ ⁺ 06]	0.9466	—	—	0.9614	180.0
Mendoça y col. [MC06]	0.9463	0.7315	0.9781	—	150.0
Staal y col. [SAN ⁺ 04]	0.9441	0.7190	0.9770	0.9520	900.0
Jiang y col. [JM03]	0.9212	—	—	0.9114	—
Martinez-P. y col. [MPHS ⁺ 99]	0.9181	—	—	—	—
Chaudhuri y col. [CCK ⁺ 89]	0.8773	—	—	0.7878	—
2ºObservador [SAN ⁺ 04]	0.9473	0.7760	0.9725	—	7200.0

Tabla 4.14: Resultados de diferentes métodos de segmentación existentes, el método propuesto (Snake) y un observador independiente (2ºObservador), comparándolos con la misma segmentación realizada por un experto (*gold standard*).

apartado 4.2.

Se indica asimismo el área bajo la curva ROC para los casos en que se ha publicado esta medida. Las curvas ROC (Receiver Operating Characteristic) [HM82] presentan la sensibilidad en función de los falsos positivos (complementario de la especificidad) para distintos puntos de corte. Un parámetro para evaluar la bondad del clasificador es el área bajo la curva, que tomará valores entre 1 (valor ideal) y 0,5 (clasificador inapropiado). Esta área puede interpretarse como la probabilidad de que, ante un par de píxeles, uno perteneciente a un vaso y otro al fondo, el método los clasifique correctamente. Por tanto, las curvas ROC son útiles para conocer el rendimiento global de un clasificador [Faw05]. Así pues, en los sistemas basados en clasificadores es posible obtener la curva ROC modificando el umbral de aceptación. Para nuestro modelo basado en contornos deformables esto no es posible ya que sería necesaria una modificación de parámetros excesivamente compleja.

El modelo desarrollado en esta memoria parte de un contorno inicial circular centrado en el disco óptico. La evolución del contorno deformable será hacia fuera de esa circunferencia, por lo que el interior de la misma no es segmentada. Esto no es relevante para la aplicación final concreta aquí presentada, el cálculo del índice arterio-venoso, ya que las secciones de vasos evaluadas suelen tomarse a distancias mucho mayores del nervio óptico. Sin embargo, los otros métodos automáticos objeto de la comparación y el observador humano independiente sí efectúan una segmentación completa del árbol vascular. Con el objeto de que dicha comparación de métodos sea lo más exacta posible, se ha desarrollado una

técnica para segmentar el árbol vascular en el interior del disco óptico.

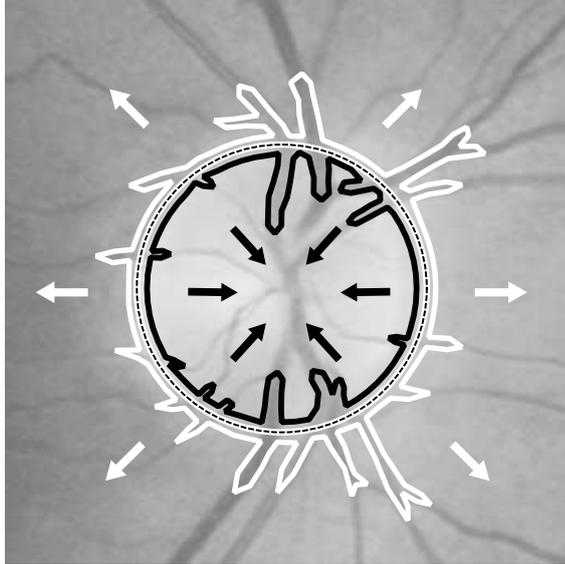


Figura 4.7: Proceso de segmentación total de la retinografía incluido el disco óptico, para obtener una comparación exacta de nuestros resultados con los de otros métodos. Se generan dos snakes a partir del mismo contorno inicial (línea discontinua), uno (en blanco) evoluciona hacia el exterior del disco óptico y otro (en negro) hacia el interior.

Para lograr una segmentación completa, incluido el disco óptico, empleamos dos snakes, como se muestra en la figura 4.7. Estos dos snakes se generan a partir del mismo contorno inicial, representado por una línea negra discontinua. Uno de los snakes, trazado en blanco en la imagen, evoluciona normalmente hacia el exterior del disco óptico y segmenta la mayor parte de la retinografía. El otro contorno, representado en negro, segmentará la parte restante correspondiente al disco óptico, creciendo en dirección contraria, es decir, hacia el interior de su contorno inicial.

En la tabla 4.14 podemos apreciar las diferencias en cuanto a la calidad de resultados, así como el coste computacional de los diferentes métodos de segmentación. Además de la precisión alcanzada en los resultados, hemos de tener en cuenta el tiempo necesario para segmentar cada imagen. El coste computacional es fundamental de cara a la aplicación práctica real, ya que el médico debe poder obtener los resultados lo más pronto posible. Por ello, un buen método de segmentación de la vasculatura retiniana ha de guardar un equilibrio entre precisión y eficiencia.

El observador humano es el que alcanza una precisión más elevada, pero precisa de unas dos horas para llevar a cabo la segmentación del árbol vascular al

completo.

La aproximación mediante la transformada de Gabor y clasificación supervisada propuesta por Soares y col. [SLCJ⁺06], alcanza una precisión muy cercana al observador independiente, así como una elevada área bajo la curva ROC. Sin embargo, su coste computacional es excesivo, necesiéndose varios minutos para procesar cada imagen, sin contar el tiempo de entrenamiento previo.

Algo más eficiente es la solución basada en combinación de detección de crestas y reconstrucción morfológica presentada por Mendonça y col. [MC06]. Por otro lado, su precisión es ligeramente menor y su sensibilidad es inferior a la alcanzada por nuestro método.

Staal y col. [SAN⁺04] proponen un método de clasificación basado en primitivas, que obtiene resultados de alta calidad (semejante a los métodos anteriores) pero su coste computacional es muy elevado: alrededor de 14 minutos por imagen.

La aproximación por umbral local de Jiang y col. [JM03] y la aproximación por análisis de espacio escalar y crecimiento de regiones desarrollada por Martínez-Pérez y col. [MPHS⁺99] no proporcionan datos acerca de su coste computacional. En cualquier caso, obtienen resultados menos precisos que nuestro sistema.

Chaudhuri y col. [CCK⁺89], con su solución basada en filtros emparejados, alcanzan una precisión demasiado baja para una aplicación real. Tampoco en este caso se ha publicado información acerca de la eficiencia del método.

Nuestro sistema basado en snakes alcanza una precisión suficiente para su aplicación real siendo además muy reducido su coste computacional. No hemos encontrado ningún otro método que alcance unos resultados de calidad similar sobre una retinografía en menos de 40 segundos. Su sensibilidad es alta teniendo en cuenta las características del dominio y los valores alcanzados por los otros métodos e incluso por el observador humano. Su especificidad es algo menor que la presentada por las otras soluciones, pero continúa siendo suficiente para su aplicación práctica.

Las figuras 4.8, 4.10 y 4.12 muestran algunos ejemplos en los que se compara, sobre la misma retinografía, la segmentación realizada por un humano experto con la obtenida por un observador humano independiente y la ejecución completa del modelo desarrollado. Estas últimas han sido obtenidas empleando la técnica descrita en el apartado anterior para poder segmentar el interior del disco óptico.

En las imágenes superiores de las figuras 4.8, 4.10 y 4.12, se aprecia falta de acuerdo total existente entre los expertos. Este hecho constata la notable dificultad

de esta tarea y establece un límite a la precisión de un sistema de segmentación del árbol vascular de la retina: nunca podrá aspirar a tener una concordancia mayor con el experto de referencia de la que este tiene con otros observadores humanos.

Así, en una primera observación de las imágenes inferiores de las figuras 4.8, 4.10 y 4.12 pudiera parecer que existe una discrepancia notable entre la segmentación realizada por el experto de referencia y la de nuestro método. Sin embargo, comparando estas imágenes con las superiores correspondientes, se puede observar que las diferencias del modelo de snakes con respecto al experto de referencia se asemejan bastante a las presentes entre ambos expertos independientes.

Por otra parte, los vasos no detectados con la segmentación mediante contornos deformables desarrollada se corresponden casi totalmente a capilares muy finos. Esto puede comprobarse observando las figuras 4.9, 4.11 y 4.13, en las que se han destacado los vasos más finos (uno o dos píxeles de anchura aproximada) de las mismas retinografías. La técnica aplicada para la visualización de los resultados hace que en ocasiones parezcan más anchos de lo que son. A pesar de esta anchura tan reducida, bastantes capilares son detectados en gran medida gracias a la ampliación de la imagen, que permite al snake avanzar por su interior. Sin embargo, la contribución de la correcta segmentación de dichos vasos finos a un parámetro global como la precisión o la especificidad es muy bajo como para tener una gran influencia.

La tabla 4.15 detalla la evaluación completa del modelo sobre el conjunto de imágenes de test de la base de datos de imágenes DRIVE. Los valores presentados en dicha tabla demuestran que los vasos no detectados corresponden a una proporción muy pequeña, ya que los valores de precisión y especificidad son elevados. Estos capilares tan finos no suelen utilizarse para el cálculo del calibre retiniano, que se obtiene a partir de los vasos principales. Como se mencionó en el apartado anterior, incluso entre expertos humanos existen diferencias en la clasificación de los píxeles correspondientes a capilares muy finos. Otra de las discrepancias frecuentes entre expertos tiene lugar a la hora de clasificar los píxeles situados en los bordes de los vasos. Estas zonas serán así mismo críticas para los sistemas de segmentación automática. Esta situación se refleja en unos valores de sensibilidad que, en comparación con los de especificidad y precisión, no son tan altos, coincidiendo en su rango de valores tanto para estos sistemas como para los observadores humanos. La mayoría de nuestros esfuerzos de mejora sobre el sistema inicial se han dirigido a incrementar los valores de sensibilidad obtenidos ya que dada la proporción de píxeles pertenecientes a vaso y píxeles de fondo, es el parámetro más significativo a la hora de evaluar la calidad de la segmentación.

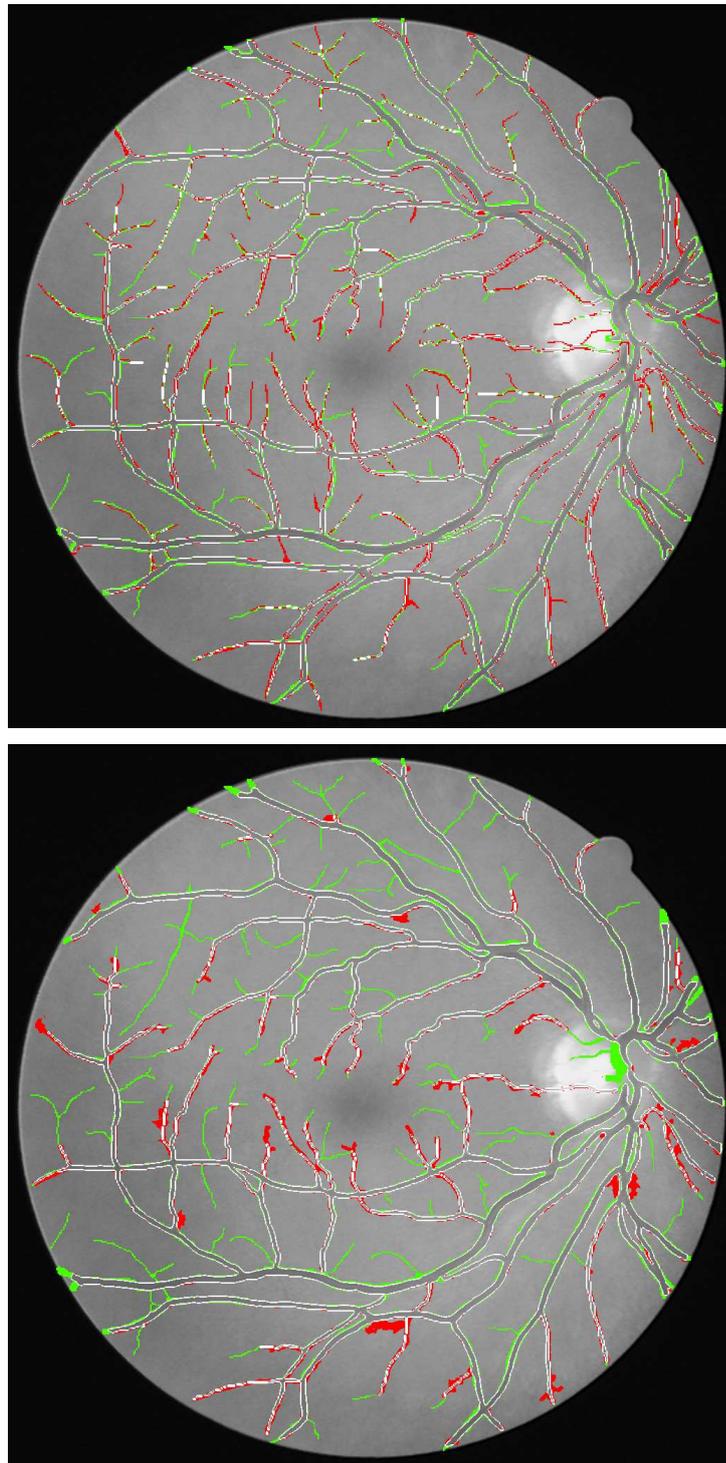


Figura 4.8: Comparación de la segmentación realizada por el experto de referencia con la obtenida por un observador independiente (imagen superior) y por nuestro modelo (imagen inferior). La parte coincidente con el experto de referencia se muestra en blanco. Se han marcado en rojo las zonas segmentadas por el método comparado y no por el experto de referencia (falsos positivos). Las verdes se corresponden con vasos detectados por el experto de referencia y no por el método comparado (verdaderos negativos).

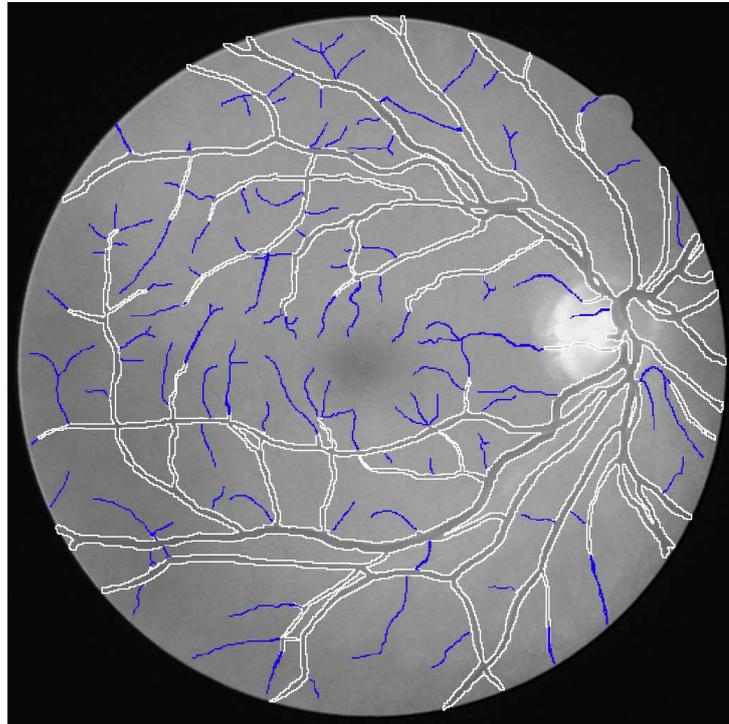


Figura 4.9: Segmentación manual del experto de referencia (en blanco) superpuesta a la imagen original, sobre la que se han marcado en azul los vasos más finos (1 ó 2 píxeles de anchura).

Imagen n°	Precisión	Sensibilidad	Especificidad	Imagen n°	Precisión	Sensibilidad	Especificidad
01	0.9264	0.7844	0.9479	11	0.9198	0.7122	0.9507
02	0.9334	0.7580	0.9644	12	0.9332	0.7628	0.9576
03	0.9251	0.7026	0.9628	13	0.9216	0.7245	0.9542
04	0.9315	0.7209	0.9640	14	0.9317	0.7877	0.9510
05	0.9354	0.6959	0.9730	15	0.9352	0.7160	0.9606
06	0.9310	0.6976	0.9693	16	0.9355	0.7578	0.9622
07	0.9314	0.6924	0.9679	17	0.9348	0.7435	0.9617
08	0.9292	0.6711	0.9663	18	0.9389	0.8215	0.9541
09	0.9402	0.6917	0.9733	19	0.9401	0.8391	0.9540
10	0.9356	0.7493	0.9608	20	0.9344	0.8231	0.9477

Tabla 4.15: Resultados obtenidos en la segmentación de cada una de las imágenes de test de la base de datos DRIVE. Los resultados se expresan en términos de precisión, sensibilidad y especificidad.

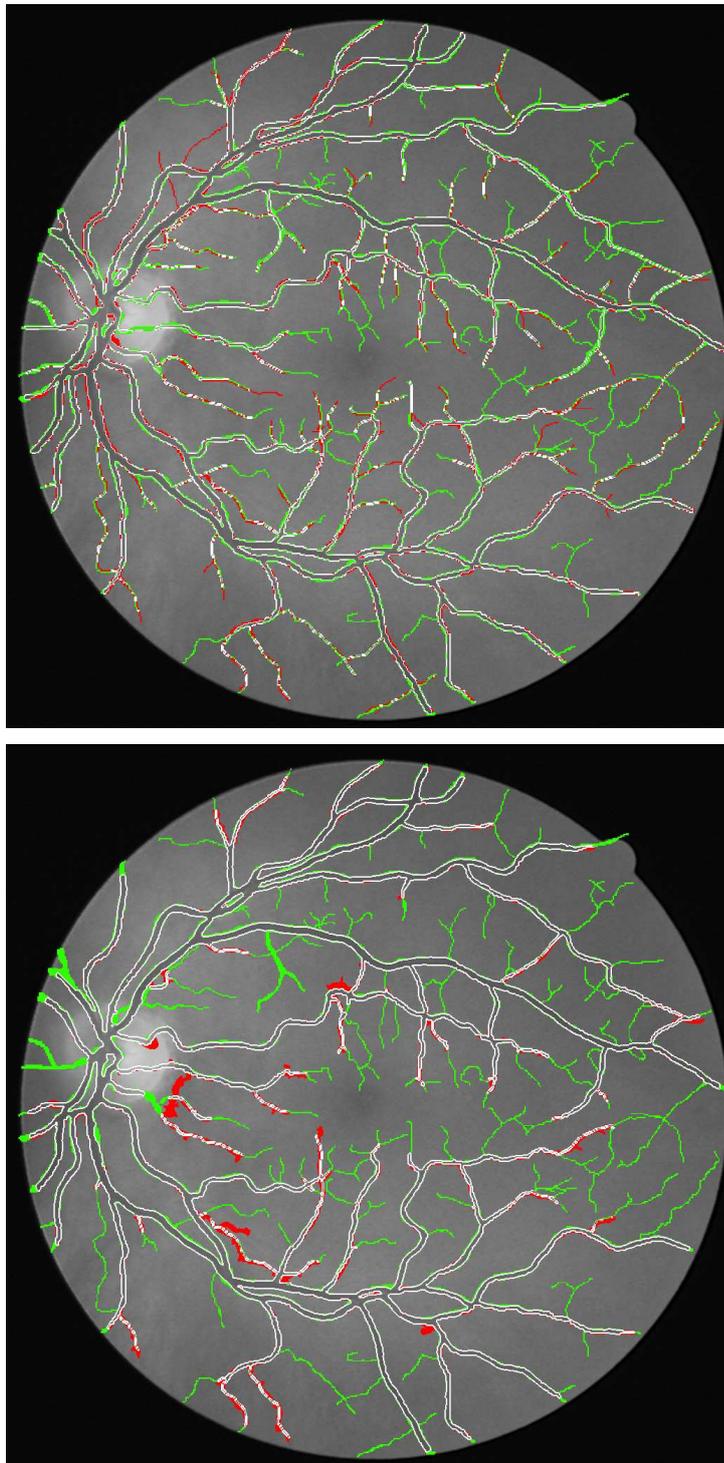


Figura 4.10: Comparación de la segmentación realizada por el experto de referencia con la obtenida por un observador independiente (imagen superior) y por nuestro modelo (imagen inferior). La parte coincidente con el experto de referencia se muestra en blanco. Se han marcado en rojo las zonas segmentadas por el método comparado y no por el experto de referencia (falsos positivos). Las verdes se corresponden con vasos detectados por el experto de referencia y no por el método comparado (verdaderos negativos).

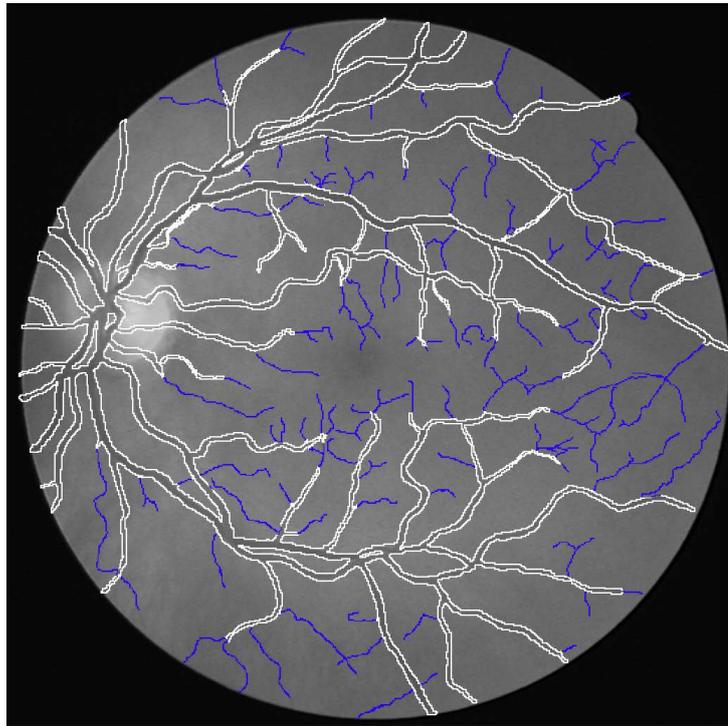


Figura 4.11: Segmentación manual del experto de referencia (en blanco) superpuesta a la imagen original, sobre la que se han marcado en azul los vasos más finos(1 ó 2 píxeles de anchura).

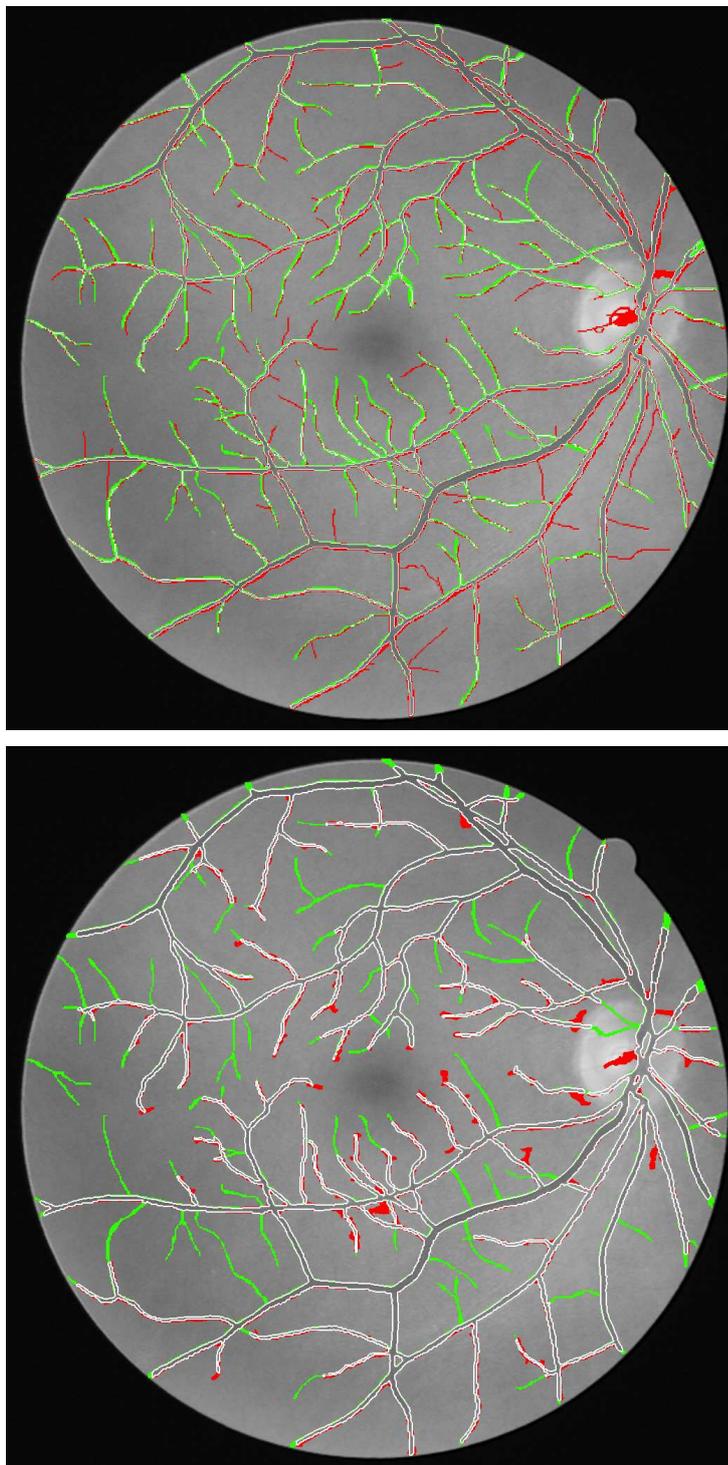


Figura 4.12: Comparación de la segmentación realizada por el experto de referencia con la obtenida por un observador independiente (imagen superior) y por nuestro modelo (imagen inferior). La parte coincidente con el experto de referencia se muestra en blanco. Se han marcado en rojo las zonas segmentadas por el método comparado y no por el experto de referencia (falsos positivos). Las verdes se corresponden con vasos detectados por el experto de referencia y no por el método comparado (verdaderos negativos).

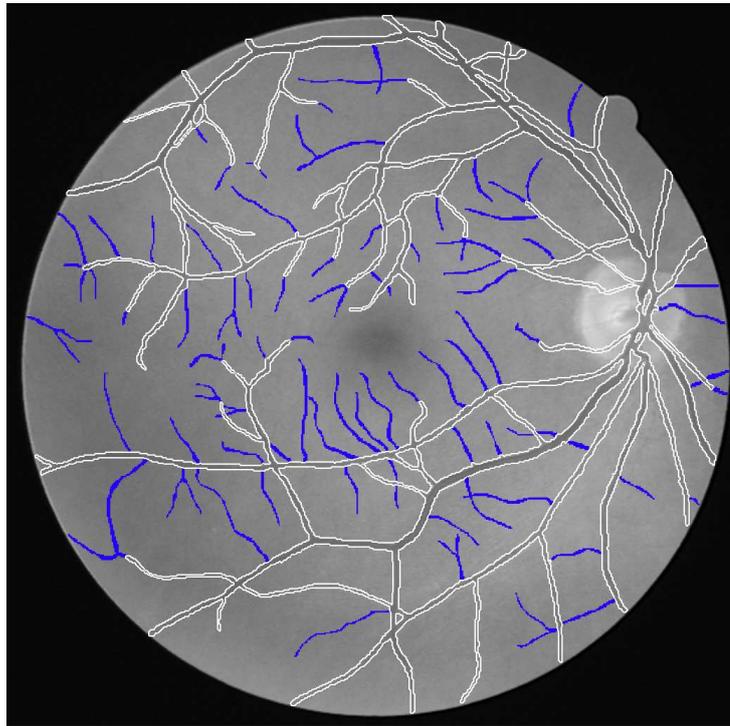


Figura 4.13: Segmentación manual del experto de referencia (en blanco) superpuesta a la imagen original, sobre la que se han marcado en azul los vasos más finos(1 ó 2 píxeles de anchura).

Capítulo 5

Aplicación: Cálculo del Índice AV

En el presente capítulo explicaremos la importancia del índice arteriovenoso (AV), a continuación describiremos la aplicación desarrollada y expondremos un ejemplo completo y paso a paso de la obtención del índice AV. Por último, presentaremos los resultados obtenidos y las conclusiones extraídas durante el desarrollo y prueba de esta aplicación.

El índice arterio-venoso es un parámetro crucial en el estudio de la retinopatía diabética, ya que permite evaluar las alteraciones producidas por esta enfermedad sobre las estructuras vasculares retinianas y el efecto de la medicación sobre las mismas. Este índice representa la relación entre la anchura de los vasos sanguíneos aferentes y eferentes de la retina. Las medidas relacionadas con el calibre vascular retiniano se emplean tanto en el diagnóstico como en el seguimiento de la evolución de la retinopatía diabética [ADR⁺06] [WKSc02]. También puede ser empleado en la detección y análisis de otras patologías que afecten a la red vascular retinal (arteriosclerosis, hipertensión, etc.).

La retinopatía diabética es la complicación más frecuente de la diabetes, enfermedad que afecta a un número alto y creciente de pacientes en nuestro país. Se manifiesta cuando los vasos sanguíneos de la retina se ven afectados y se encuentra entre las principales causas de ceguera. Según datos publicados por la Federación Europea de Diabetes en 2006, España está por encima de la media europea en porcentaje de prevalencia de la diabetes (un 10,1 % en España frente a un 8,9 % de media en la UE). En términos absolutos (número de personas), España ocupa el quinto lugar con cerca de tres millones de pacientes diabéticos.

La diabetes [JVGE08] afecta a la retina porque los altos valores de azúcar (glucosa) en la sangre debidos a la falta de insulina, engrosan las paredes de los pequeños vasos sanguíneos, pero al mismo tiempo las debilitan y en consecuencia

las tornan más proclives a la deformación y a las fugas de sangre. El alcance de la retinopatía y la pérdida de la visión se encuentran en relación directa con el control de las concentraciones de azúcar en sangre y, más importante aún, con el tiempo que la persona lleva padeciendo la diabetes.

Estadísticamente el 15 % de los pacientes diabéticos manifiestan esta complicación después de 5 años de diagnosticada la enfermedad y casi todos la desarrollarán cuando hayan padecido la enfermedad durante más de veinte años. El riesgo de ceguera en personas diabéticas es 25 veces superior al resto de la población, por lo que es primordial el desarrollo de técnicas automáticas para la detección de esta enfermedad en etapas tempranas.

Un sistema de detección fiable y eficiente sería de gran utilidad para evaluar cambios morfológicos en la vasculatura retinal, ya que es un proceso subjetivo y muy costoso cuando es realizado por un humano. Mediante dicho sistema se podría disponer del árbol arterio-venoso extraído de las imágenes de retina de un paciente, obtenidas tras un cierto intervalo de tiempo, y valorar las alteraciones que se han producido de forma eficiente, automática y repetible.

La automatización permitiría realizar periódicamente la detección de retinopatías a la población diabética de forma masiva, de cara a diagnosticar la retinopatía en su fase inicial. Esta detección temprana es fundamental porque las pérdidas de visión son generalmente irreversibles y esta sería una manera de frenar el avance de la enfermedad e incrementar la efectividad del tratamiento

5.1. Sistema para el Cálculo del Índice AV

En esta sección realizaremos una descripción general de la aplicación desarrollada para el cálculo del índice AV. Dedicaremos un apartado especial a la técnica empleada para la estimación de la anchura de un vaso sanguíneo en un determinado punto. Para ofrecer una mejor explicación del funcionamiento global de la aplicación, incluiremos al final de esta sección un ejemplo de ejecución completo, ilustrado con capturas de pantalla.

Aunque el sistema de segmentación del árbol vascular de la retina ha sido implementado en C++, en esta aplicación hemos aprovechado la funcionalidad que nos ofrece Java para el desarrollo de interfaces. Esto además facilitará su integración futura en el sistema SIRIUS, plataforma de integración de servicios de análisis de la retina desarrollada por nuestro grupo de investigación que describiremos en el apartado 5.2.1. La comunicación entre los módulos C++ y la interfaz Java se resuelve mediante el protocolo de llamada a procedimiento remoto XML-RPC.

La figura 5.1 muestra la interfaz de la aplicación. Consiste básicamente en una zona de representación de la imagen y una barra de botones inferior. La imagen

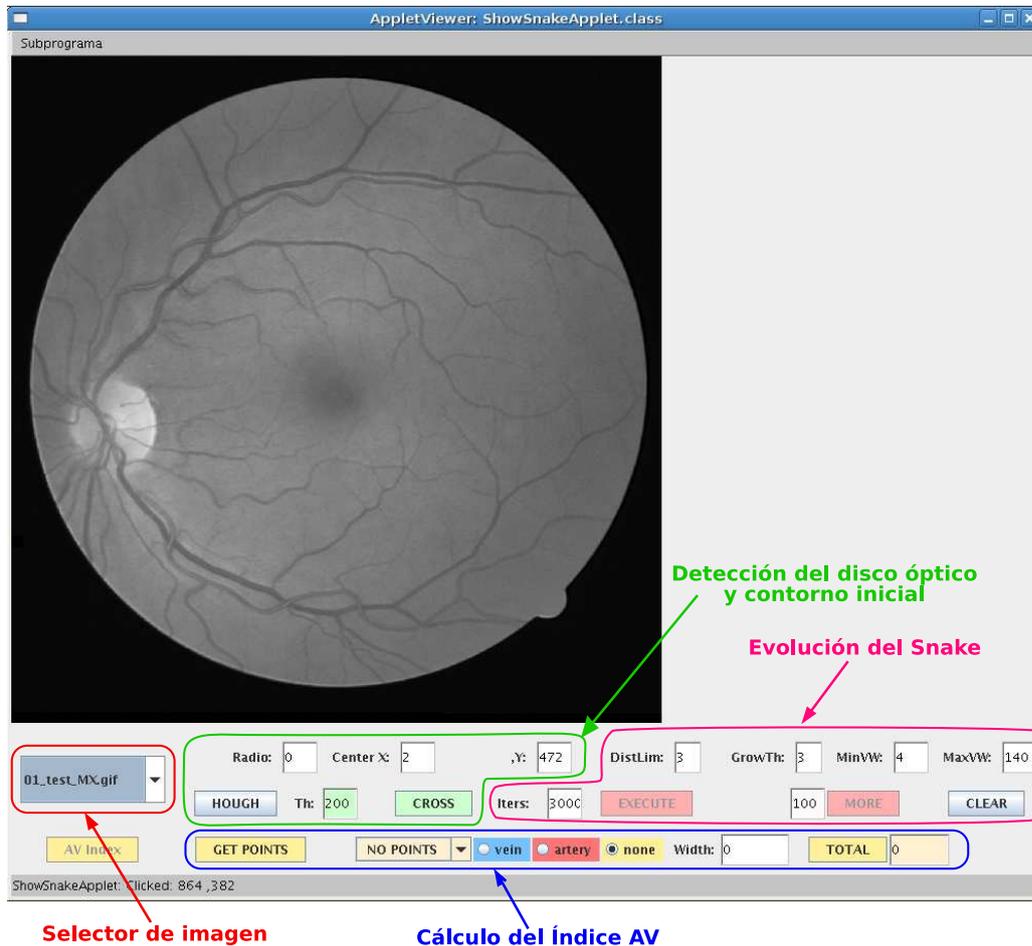


Figura 5.1: Vista de la interfaz gráfica de la aplicación desarrollada para el cálculo del índice arterio-venoso.

mostrada, sobre la que vamos a trabajar, se elige mediante el selector de imágenes situado en la parte izquierda de la barra de botones.

Una vez seleccionada la imagen, iniciamos el proceso de segmentación del árbol vascular marcando el contorno inicial alrededor del disco óptico. Este círculo inicial puede trazarse manualmente mediante el ratón o el teclado. También puede emplearse el método automático de detección del disco óptico descrito en el apéndice A. A partir de ese círculo inicial, obtenemos los puntos semilla del snake y una vez introducidos los parámetros adecuados, podemos comenzar la evolución del mismo. Se permite ajustar la configuración del contorno en términos de anchura de vaso, distancia a crestas, crecimiento, iteraciones, etc .

Tras finalizar la segmentación del árbol vascular, el primer paso para obtener el índice AV es trazar un círculo centrado en el disco óptico de radio suficientemente grande (el doble del disco óptico, por ejemplo). Se obtienen así diversos puntos de intersección con los vasos sanguíneos segmentados. El usuario selecciona cuales de esos puntos corresponden a vasos sanguíneos de interés e indica de qué tipo son (venas o arterias). Para que el índice AV esté correctamente calculado, la selección de vasos debe ser equilibrada, escogiéndose el mismo número de venas y arterias en cada circunferencia. Normalmente se marcan por parejas arteria-vena de calibre semejante. Se estiman a continuación las anchuras de cada uno de los vasos seleccionados mediante el algoritmo que se explicará en el apartado siguiente. Para obtener el índice AV simplemente se aplica la siguiente fórmula sobre los calibres vasculares estimados:

$$\text{IndiceAV} = \frac{\text{Calibre arterial medio}}{\text{Calibre venoso medio}} = \frac{\frac{\sum_{i=1}^n a_i}{n}}{\frac{\sum_{j=1}^m v_j}{m}}, \quad n \simeq m \quad (5.1)$$

donde a_i representa el grosor de la arteria i , n es el número de arterias seleccionadas, v_j representa el grosor de la vena j y m es el número de venas seleccionadas.

Al final de esta sección, en el apartado 5.1.2, se muestra la realización de este proceso completo, paso a paso e incluyendo capturas de pantalla. Previamente a dicho ejemplo de ejecución, explicaremos cómo se realiza el proceso de estimación de la anchura de un vaso segmentado en un punto.

5.1.1. Estimación Puntual del Calibre Vascular

Para obtener el índice AV es necesario obtener la anchura de cada vaso detectado cuya cresta interseque con la circunferencia de análisis. En la figura 5.2 se muestran una serie de imágenes que representan el proceso de estimación del calibre vascular que explicaremos a continuación.

Dado el punto de intersección con el radio de análisis P , la anchura del vaso debe medirse perpendicularmente a la dirección en que discurre la vena o arteria. La cresta nos da una buena aproximación ya que se dispone longitudinalmente a las estructuras vasculares. Así pues, el primer paso consiste en trazar una perpendicular \bar{s} a dicha cresta en el punto P , como se muestra en la figura 5.2(a).

Aunque la cresta presenta la misma dirección que el vaso, a menudo su posición no está exactamente centrada en el mismo. Así, calculamos A y B , los puntos de corte de la recta perpendicular \bar{s} con el borde del vaso, y hallamos el punto medio entre ambos. En la imagen 5.2(b) se muestra la obtención del punto medio

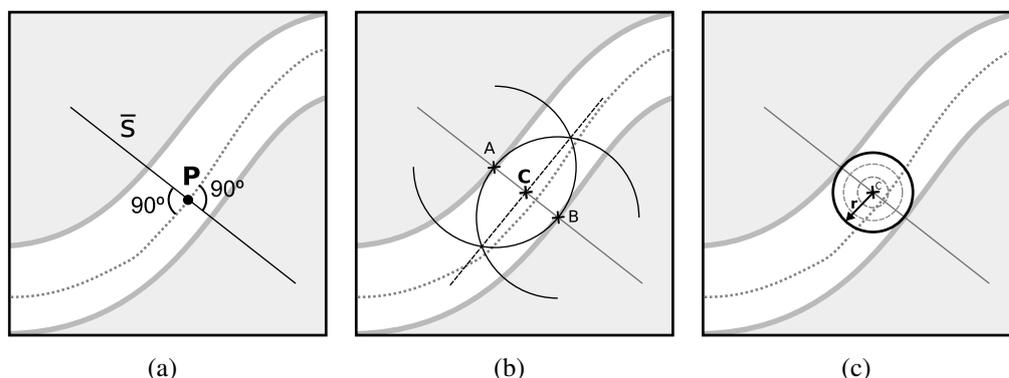


Figura 5.2: Descripción del proceso de estimación del calibre vascular. La estructura vascular segmentada se representa en blanco, el fondo de ojo en gris y la cresta es la línea punteada de color gris oscuro. (a) Punto P de intersección del círculo trazado por el usuario y la cresta. En este punto se traza la perpendicular a la cresta \bar{s} . (b) Puntos de cruce con el borde del vaso A y B sobre la recta \bar{s} . A continuación se halla el punto medio C del segmento \overline{AB} . (c) Representación del último paso, consistente en trazar círculos centrados en C aumentando su radio progresivamente. El calibre del vaso será el doble de r , siendo r el radio del mayor círculo que contiene sólo píxeles pertenecientes a la vena, permitiéndose un pequeño margen de error.

C del segmento \overline{AB} .

Una vez obtenido el punto central del vaso C , trazamos círculos centrados en él cada vez más grandes. Aumentamos el tamaño de radio mientras que los puntos interiores al círculo hayan sido segmentados como parte de un vaso. Se permite un pequeño número de puntos (el 5% de los píxeles contenidos en el círculo) pertenecientes al exterior a causa de las leves irregularidades que pudieran suceder en la segmentación. En la figura 5.2(c) se representa este último paso, el calibre o anchura del vaso será el doble de r , siendo r el radio del mayor círculo que contiene casi exclusivamente puntos pertenecientes a la vena.

Este método puede calificarse de fiable y robusto, ya que obtiene aproximaciones al calibre vascular suficientemente precisas, incluso en casos potencialmente problemáticos. En la figura 5.3 se muestran varios ejemplos de situaciones en las que la estimación de la anchura de vaso es complicada y nuestro método resuelve con notable éxito.

El primer ejemplo se muestra en la figura 5.3(a) y corresponde a la estimación del calibre en las proximidades de una bifurcación. El método logra obtener una medida aproximada a pesar del engrosamiento en la zona de ramificación.

En la imagen 5.3(b) se observa la existencia de un pequeño desbordamiento

del snake en el proceso de segmentación. Este problema prácticamente no afecta a la medida obtenida por el método de estimación del calibre vascular propuesto. Por tanto, el calibre estimado no se verá afectado por las pequeñas irregularidades, manteniéndose constante a lo largo de tramos del vaso.

En la figura 5.3(c) la perpendicular al vaso ha sido estimada incorrectamente debido a que la cresta no discurriría exactamente de forma paralela a la estructura vascular en ese punto. Aun así, el punto central del vaso se halla bien situado y por tanto el calibre del vaso obtenido será correcto.

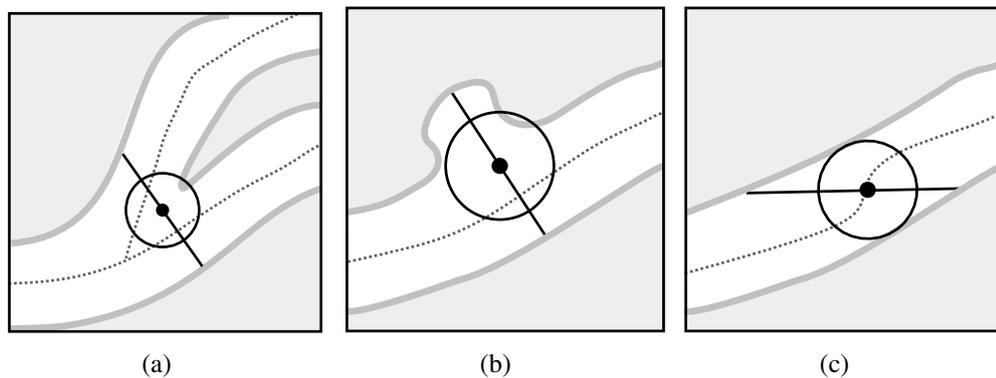


Figura 5.3: Ejemplos de situaciones en las que la estimación de la anchura de vaso es complicada y nuestro método resuelve con notable éxito. En (a) vemos una bifurcación. En (b) se representa el caso de un pequeño desbordamiento del snake en el proceso de segmentación. En (c) vemos el caso de una perpendicular al vaso mal estimada debido a que la cresta no discurre perfectamente longitudinal a la estructura vascular en ese punto.

5.1.2. Ejemplo Completo Paso a Paso

En este apartado se muestra una serie de capturas de pantalla correspondientes al proceso completo de ejecución, paso a paso desde la localización del disco óptico hasta la obtención del índice AV.

Las principales etapas de este proceso de estimación del índice AV a partir de una imagen de fondo de ojo son las siguientes:

1. Detección del disco óptico: En la figura 5.4 vemos cómo se traza automáticamente un círculo alrededor del nervio óptico mediante el método descrito en el apéndice A.4. Este círculo será el contorno inicial del snake, que también puede trazarse manualmente empleando el ratón y/o el teclado. Su

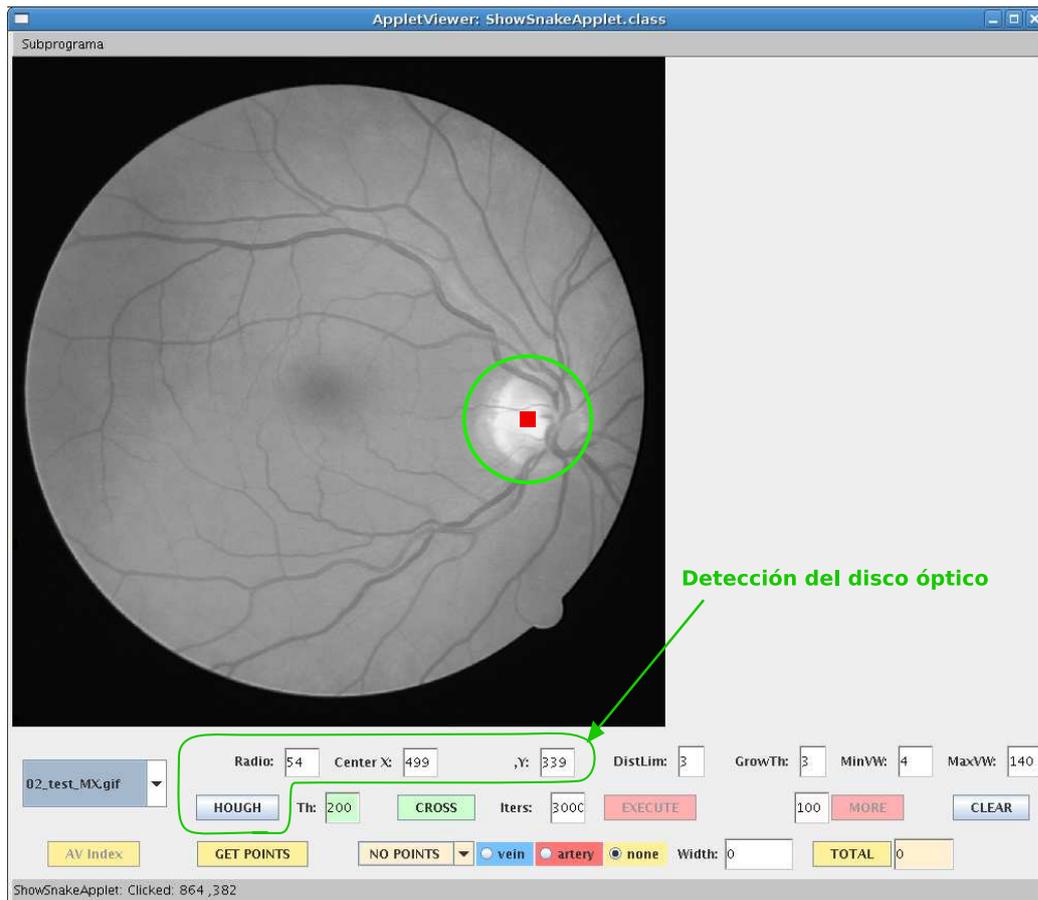
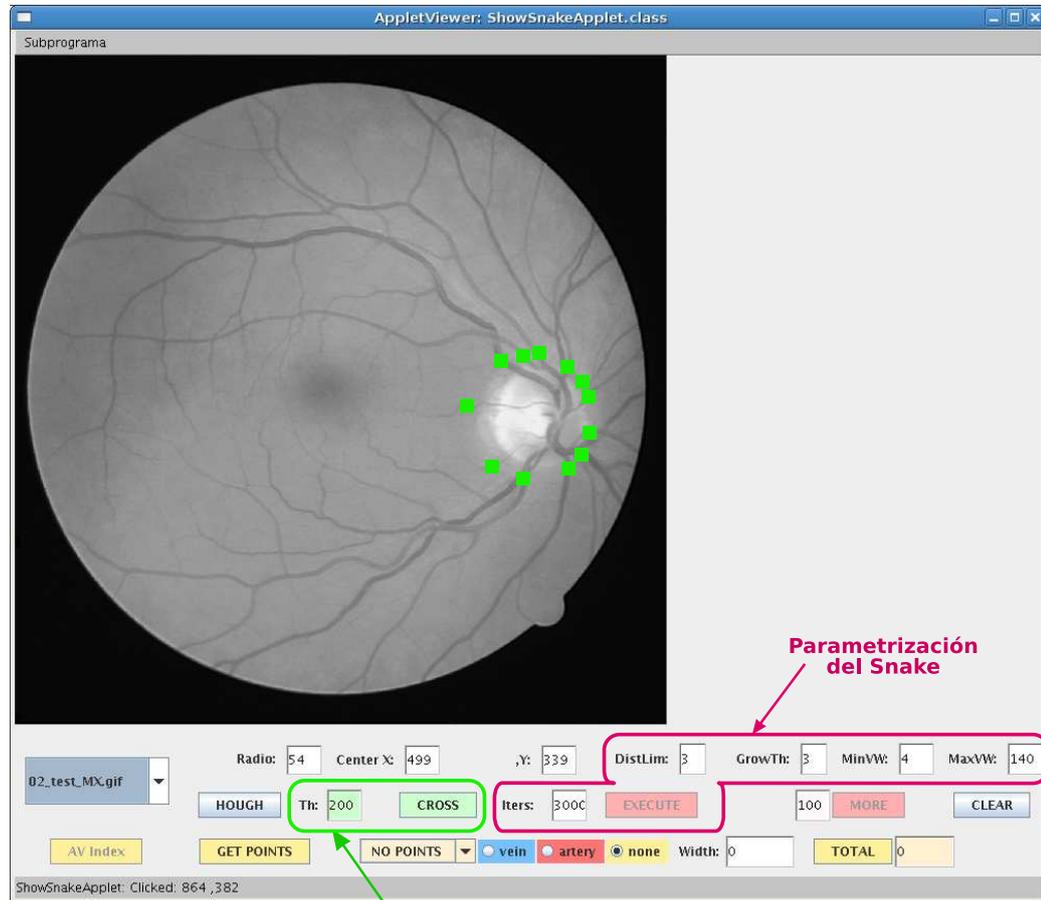


Figura 5.4: Detección del disco óptico. El centro se representa por un cuadrado rojo y el radio por un círculo verde. En las zonas marcadas de la interfaz vemos las coordenadas numéricas del centro y radio detectados automáticamente al pulsar sobre el botón *HOUGH*.

centro se representa con un cuadrado rojo y el círculo está dibujado en verde claro.



Obtención de los Puntos Semilla

Figura 5.5: Obtención de los puntos semilla representados en verde. Las intersecciones del contorno inicial y las crestas que constituyen los nodos semilla del snake inicial se obtienen al pulsar el botón *CROSS*. En *Th* se introduce el umbral de nivel de gris para eliminar puntos pertenecientes a crestas espurias. Los campos destinados a la parametrización del snake permiten ajustar la configuración de los parámetros siguientes: límite de distancia a crestas y bordes (*DistLim*), umbral de crecimiento (*GrowTh*), anchura de vaso mínima y máxima (*minVW* y *maxVW*) y número de iteraciones (*Iters*).

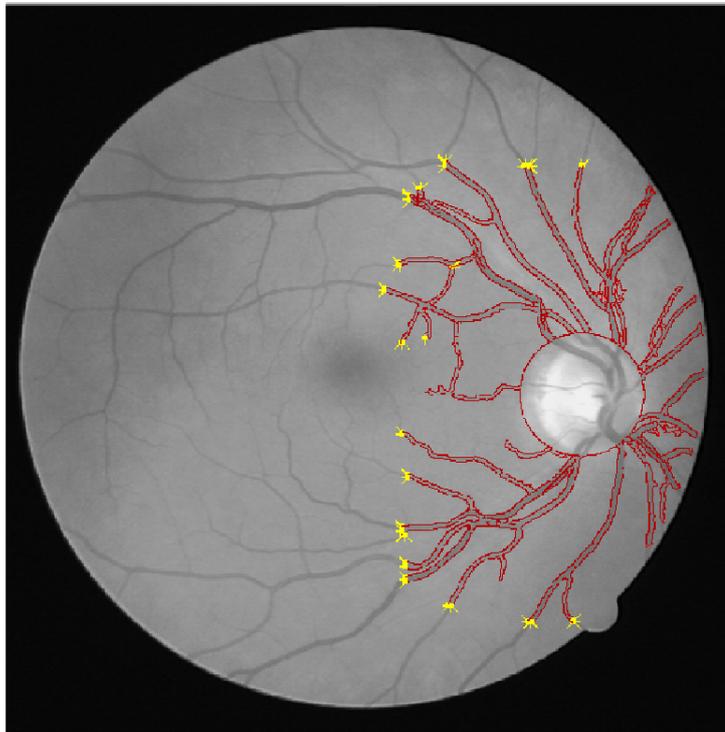
2. Obtención de los puntos semilla del snake: En la figura 5.5 se muestran los puntos de intersección con las crestas del contorno circular trazado en el paso anterior. Los puntos, representados en verde oscuro, se obtienen casi instantáneamente. Puede definirse un cierto umbral de gris *Th* para evitar

que se consideren los puntos pertenecientes a crestas espurias, ya que en general presentan tonalidades más claras.

3. Parametrización e inicialización del snake: En la figura 5.5 vemos cómo han sido cubiertos los campos destinados a la parametrización del snake y que debe hacerse previamente al inicio de su evolución. Se permite ajustar la configuración de los parámetros siguientes: límite de distancia a crestas y bordes (*DistLim*), umbral de crecimiento (*GrowTh*), anchura de vaso mínima y máxima (*minVW* y *maxVW*) y número de iteraciones (*Iters*). Los puntos obtenidos en el apartado anterior son los puntos semilla del contorno inicial (marcados en color amarillo) que comienzan a desplazarse a lo largo de los vasos, como se muestra en la figura 5.6(a).
4. Evolución del snake: El snake continúa creciendo desde el contorno inicial, fluyendo a través de las estructuras vasculares y guiado por las crestas. En las figuras 5.6(b) y 5.6(c) vemos los nodos que conforman los frentes de avance del snake (marcados en amarillo) y los nodos que se han estabilizado al alcanzar un borde (correspondientes a la línea roja).
5. Estabilización del snake: el proceso de evolución del snake finaliza cuando éste se estabiliza, desactivándose todos sus nodos al alcanzar un borde. En la figura 5.6(d) vemos cómo el árbol vascular ha sido segmentado al completo y no queda ningún frente de avance activo en el snake.
6. Definición del radio de análisis: Una vez segmentado el árbol vascular, se inicia el proceso de cálculo trazando un círculo de radio mayor que el del disco óptico (generalmente el doble o más) y centrado en el mismo. La figura 5.7 muestra un radio de análisis de algo más del triple del tamaño del disco óptico.
7. Obtención de los puntos de intersección: Tras definir la circunferencia de análisis, se obtienen los puntos de intersección de la misma con las crestas de los vasos. Como se muestra en la figura 5.8, sólo los puntos situados sobre vasos previamente segmentados serán susceptibles de participar en la estimación del índice AV. En este caso, se han obtenido 13 puntos que se representan en color amarillo y numerados.
8. Selección y clasificación de los vasos: El usuario seleccionará aquellos puntos que considere de interés y les asignará el tipo de vaso que les corresponde. La estimación de la anchura de los vasos se realiza progresivamente según van siendo seleccionados mediante el ratón o el menú desplegable. En la figura 5.9 vemos cómo han sido seleccionados diez de los trece puntos iniciales, de los cuales la mitad (1, 3, 5, 9 y 12) han sido clasificados por

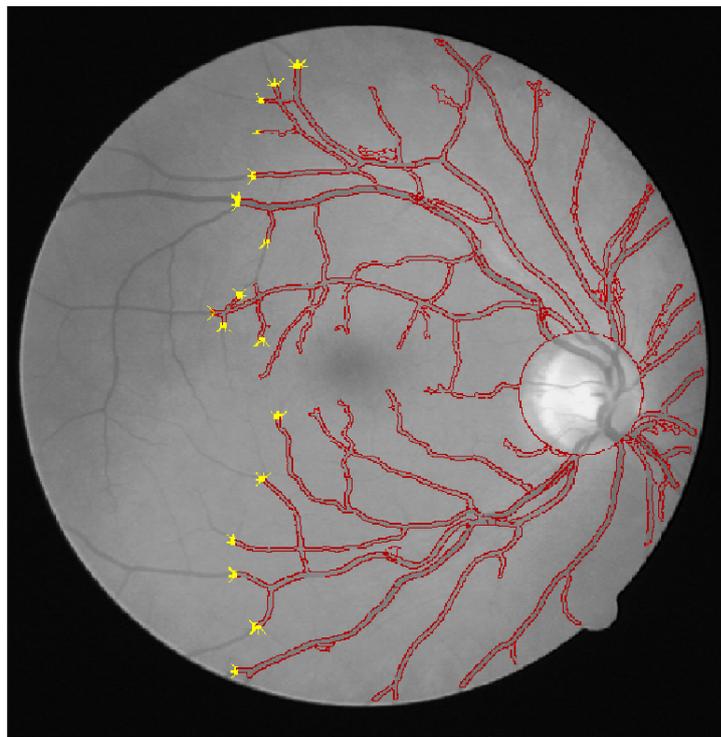


(a)

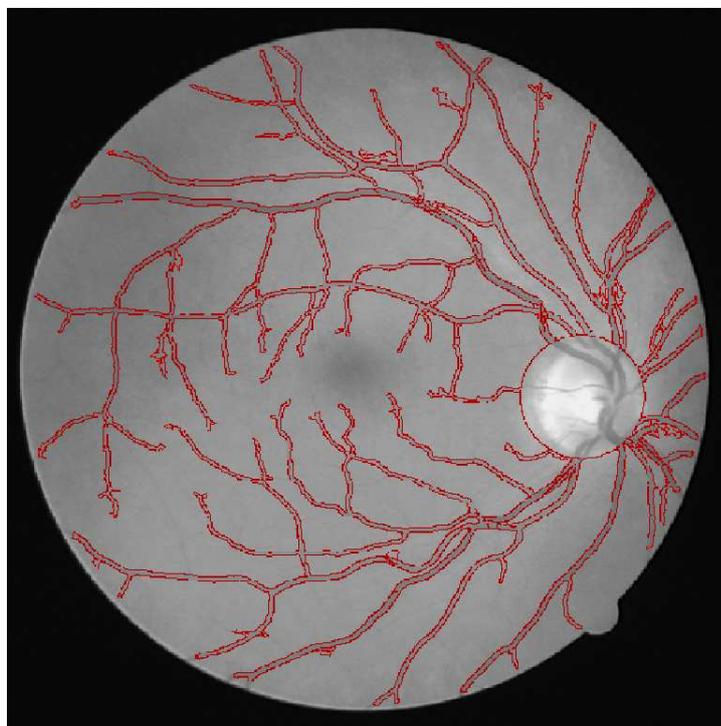


(b)

Figura 5.6: Evolución del snake. Desde el contorno inicial (a), el snake va evolucionando (b y c), hasta estabilizarse completamente (d). Los puntos amarillos corresponden a los nodos activos de los frentes de avance y la línea roja a las zonas del contorno que ya se han estabilizado.



(a)



(b)

Figura 5.6: (Cont.)

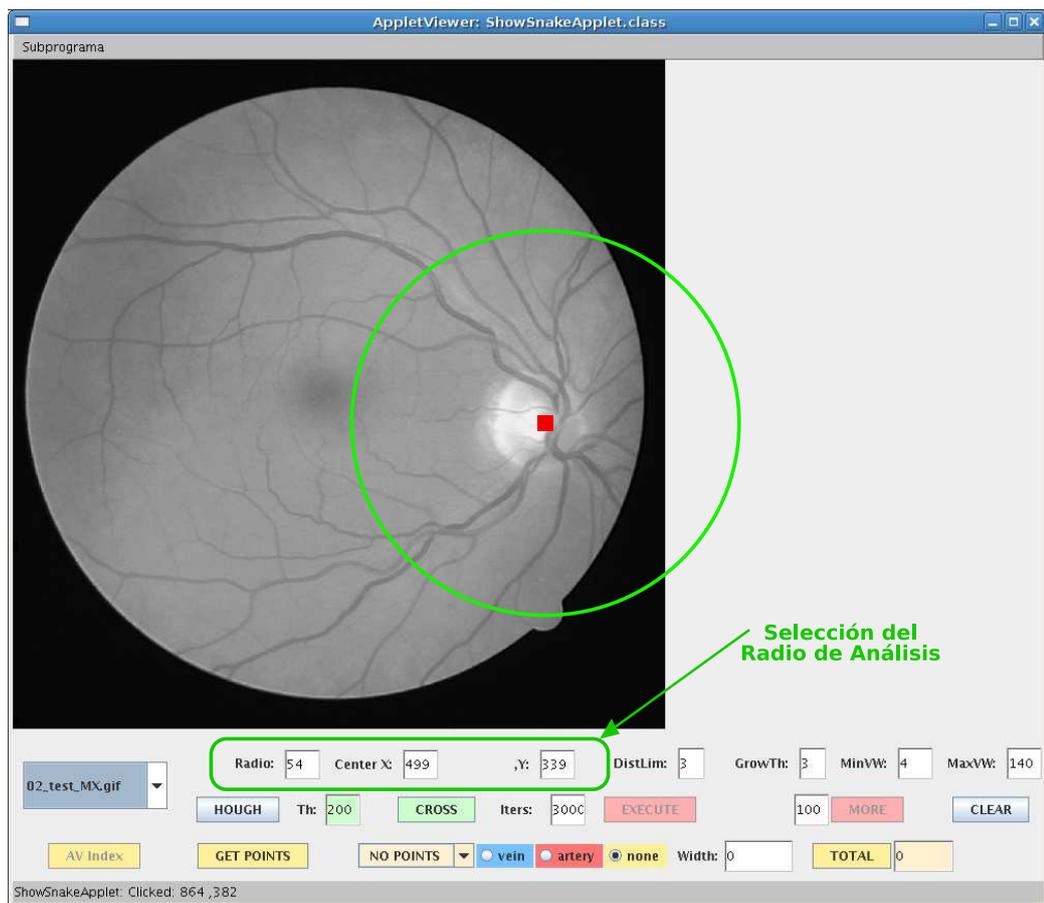
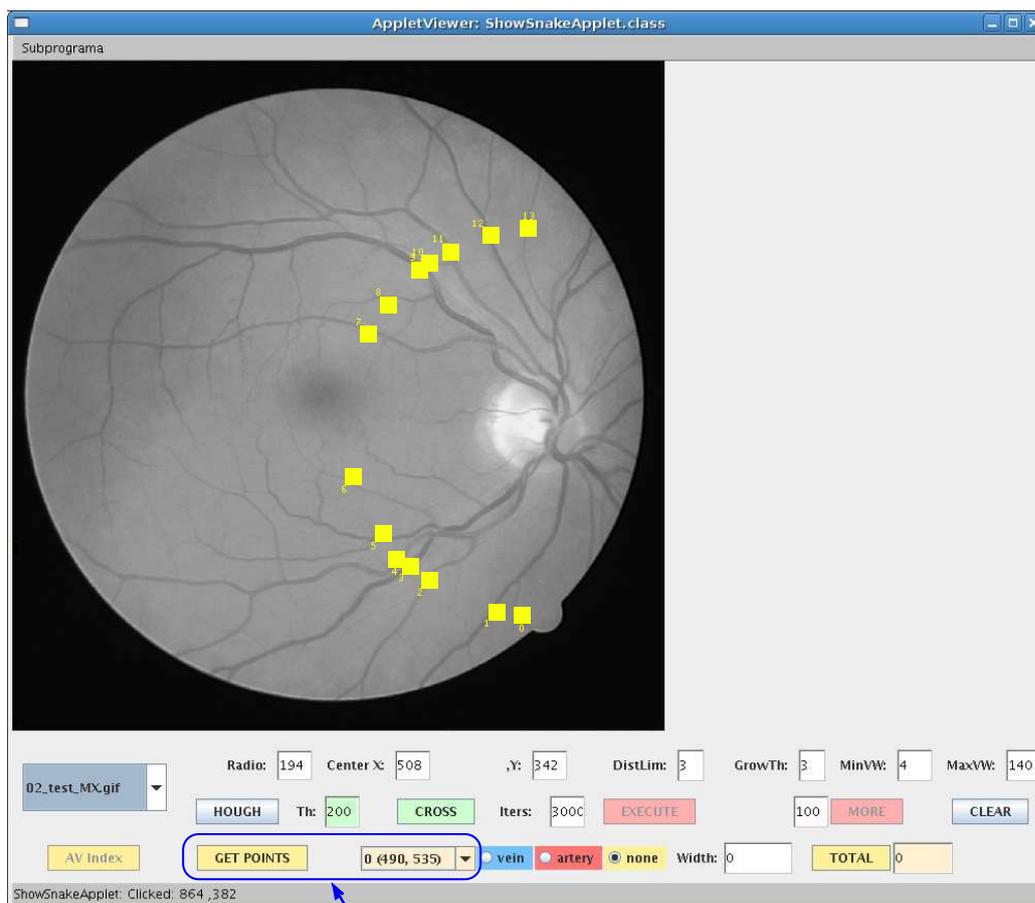


Figura 5.7: Cálculo del índice AV: definición del radio de análisis.



Obtención de Puntos Vasculares

Figura 5.8: Cálculo del índice AV: obtención de los puntos de intersección.

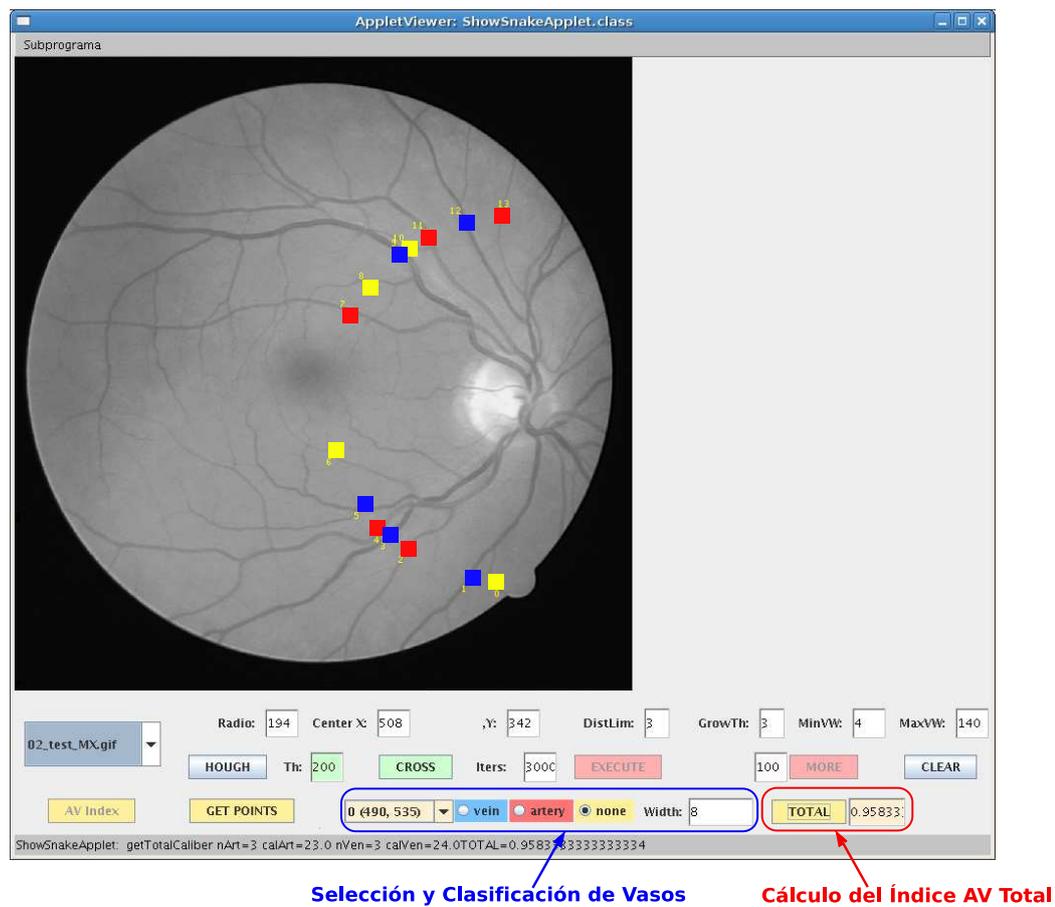


Figura 5.9: Selección y clasificación de los vasos de interés, estimación de su anchura y cálculo final del índice AV.

el usuario como venas (en color azul) y la otra mitad (2, 4, 7, 11 y 13) como arterias (en color rojo). Los demás vasos no se consideran buenas medidas y permanecen en color amarillo.

9. Cálculo del índice AV total: Por último, el usuario pulsará sobre el botón *TOTAL* para aplicar la fórmula de obtención del índice AV sobre la selección de vasos marcada. En la figura 5.9 el índice AV obtenido es de 0.958.

5.2. Validación de Resultados

En esta sección comenzaremos presentando el sistema SIRIUS desarrollado por nuestro grupo de investigación para el análisis de imágenes de fondo de ojo, en el que se han ido incluyendo diversas técnicas para el cálculo del índice AV y en el que será integrado el método presentado en este trabajo. A continuación mostraremos los resultados obtenidos por nuestro sistema y los compararemos con las técnicas de referencia disponibles en SIRIUS. Por último, valoraremos razonadamente la calidad de dichos resultados y expondremos los aspectos en los que se centrarán nuestros esfuerzos futuros.

5.2.1. SIRIUS

SIRIUS (System for the Integration of Retinal Images Understanding Services) es una herramienta integrada desarrollada en nuestro grupo de investigación cuya interfaz se muestra en la figura 5.10. Este sistema proporciona a la investigación en oftalmología un conjunto de procesos automáticos y un método para calcular, almacenar y analizar los resultados.

SIRIUS permite realizar una gestión personalizada de imágenes sobre las que aplicar diversas técnicas de análisis de imagen médica. Los servicios actualmente disponibles para el cálculo automático del índice AV son el método lineal y el snake local. Dichas técnicas han superado procesos de valoración realizados por oftalmólogos, quedando afirmada así su fiabilidad y precisión. SIRIUS es accesible vía web, pudiendo trabajar con él de forma remota desde cualquier equipo o sistema operativo.



Figura 5.10: Sistema SIRIUS (System for the Integration of Retinal Images Understanding Services) desarrollado en nuestro grupo de investigación.

5.2.2. Comparación de Resultados

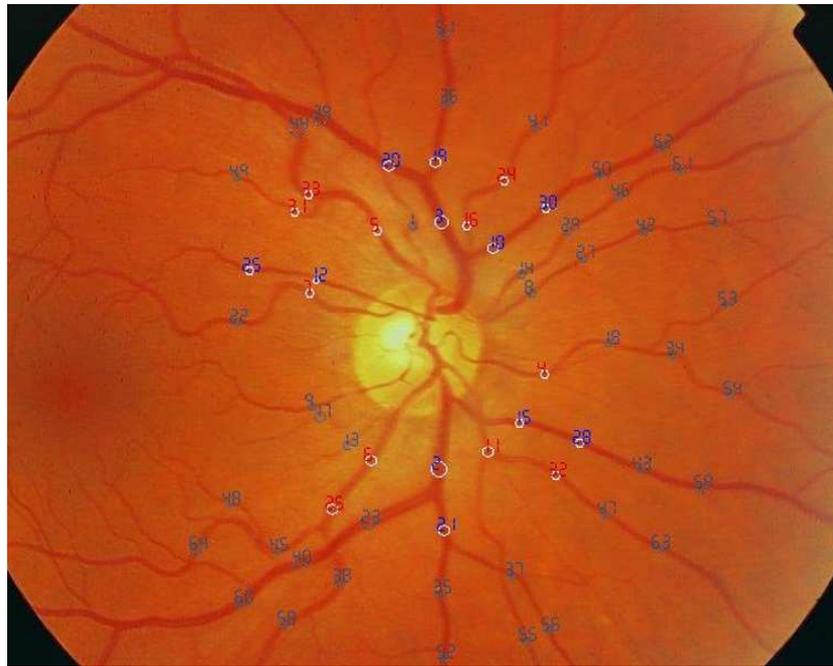
En este apartado se muestran los resultados obtenidos en la estimación del índice AV empleando el modelo propuesto en el sistema SIRIUS [CPB⁺05]. Los valores obtenidos pueden considerarse de referencia ya que han sido validados por oftalmólogos y actualmente están siendo utilizados en estudios clínicos. Las mediciones del índice AV se han realizado sobre varias imágenes procedentes de dichos estudios. Los radios de análisis y los vasos han sido seleccionados en SIRIUS por expertos médicos que han asimismo validado las estimaciones del índice AV obtenidas por este sistema. Se han seleccionado los mismos vasos y un radio de análisis semejante para la estimación mediante el modelo de snakes propuesto.

La tabla 5.1 presenta una comparativa de los resultados obtenidos para el cálculo del índice AV por nuestro modelo y por SIRIUS. En ella se indica, además de la estimación obtenida, la imagen sobre la que se ha realizado el cálculo, el número de radios de análisis, el número de arterias y venas seleccionadas y el calibre medio arterial y venoso estimado por ambos sistemas. Los resultados obtenidos por nuestro método y por la técnica de referencia son semejantes y, aunque no constituyen una validación exhaustiva, son ilustrativos de la suficiente capacidad del modelo desarrollado para estimar el índice AV de manera precisa y fiable. Los calibres estimados de los vasos difieren levemente como reflejan los valores de calibres medios arteriales y venosos. Esta diferencia no es significativa ya que lo importante es la relación entre dichas anchuras, que se reflejan en el índice AV que sí es semejante en ambos ejemplos.

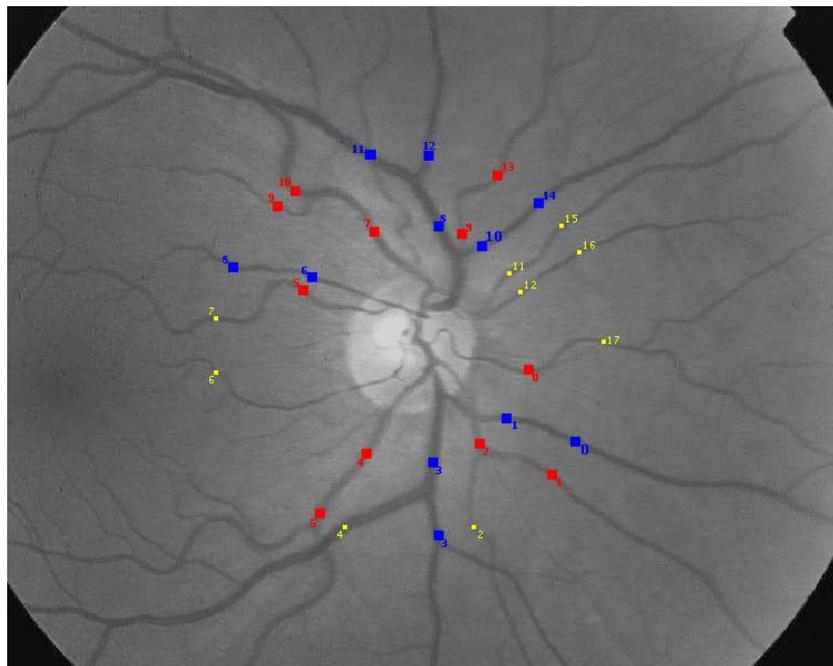
La figura 5.11(a) muestra un ejemplo de estimación del índice AV empleando la técnica integrada en SIRIUS. En la figura 5.11(b) vemos este mismo ejemplo ejecutado por la aplicación desarrollada que se basa en nuestro modelo. En estas figuras se observa la coincidencia de los puntos y vasos seleccionados para el índice AV por nuestra aplicación y la técnica de referencia, efectuada con dos radios de análisis en este caso.

Los prometedores resultados obtenidos por esta aplicación demuestran la validez del modelo de snakes en que se basa para la estimación del calibre vascular.

Los valores de índice AV obtenidos son muy semejantes a los de las técnicas de referencia. De todas formas, el valor absoluto, tanto de las estimaciones de calibre vascular como del índice AV total, no es lo más importante a la hora de evaluar la calidad de una técnica. Lo prioritario para los oftalmólogos es la repetibilidad de la estimación obtenida, puesto que en general se estudian las variaciones de dicho valor para un paciente frente al paso del tiempo o la administración de



(a)



(b)

Figura 5.11: Ejemplo de cálculo del índice AV: (a) Empleando la técnica integrada en SIRIUS y (b) por la aplicación desarrollada que se basa en nuestro modelo. En ambas imágenes los puntos de arterias seleccionados se muestran en rojo y los de arterias en azul.

	Imagen 1 (S003I1)	Imagen 2 (S0046D1)	Imagen 3 (S0046I1)	Imagen 4 (S0013I1)
Radios de Análisis	3	2	2	3
Nº Arterias	14	11	10	9
Nº Venas	12	11	10	9
Calibre Arterial Medio (SIRIUS)	5.768	5.618	5.524	5.176
Calibre Arterial Medio (Snake)	5.929	5.182	5.200	5.111
Calibre Venoso Medio (SIRIUS)	6.715	6.517	6.776	8.030
Calibre Venoso Medio (Snake)	6.917	6.090	6.400	7.778
Índice AV (SIRIUS)	0.8590	0.8620	0.8152	0.6446
Índice AV (Snake)	0.8571	0.8507	0.8125	0.6479

Tabla 5.1: Resultados de cálculo del índice AV por nuestro modelo y empleando la técnica de referencia. Los calibres medios se expresan en píxeles.

un tratamiento. Por tanto, lo fundamental es que si no se producen variaciones vasculares, el índice AV obtenido no varíe y, por otra parte, que las alteraciones producidas por diversos factores en el árbol vascular de la retina se reflejen en el índice AV estimado.

Para validar este sistema de manera exhaustiva es necesario un proceso de evaluación y ajuste con la colaboración de oftalmólogos, que se realizará cuando se integre este método en el sistema SIRIUS. Esto permitirá además a los oftalmólogos realizar las pruebas sobre una interfaz adaptada a sus necesidades, ya que la aquí presentada está orientada al desarrollo y prueba técnica del sistema.

En la actualidad, la herramienta de cálculo del índice AV integrada en SIRIUS está siendo utilizada en un proyecto para la evaluación de fármacos para hipertensos subvencionado por el Laboratorio Boehringer (Estudio observacional, prospectivo, multicéntrico, para evaluar los cambios en la microcirculación retiniana en pacientes hipertensos tratados con telmisartán (Estudio POSTEL)). Gracias a ello, disponemos de los datos reales contra los que validar cualitativamente nuestro sistema. Sin embargo, la supuesta mejora en la precisión de las mediciones realizadas exigirá un trabajo más exhaustivo de validación médica.

Conclusiones

En este capítulo se presentan las conclusiones alcanzadas durante la realización del presente trabajo, así como las posibles líneas de investigación para continuar con su desarrollo en el futuro.

La utilidad del índice arterio-venoso para la diagnosis de ciertas patologías ha sido probada facultativamente, sin embargo, no existe todavía un método automático que garantice la fiabilidad de sus resultados en un tiempo razonable. En esta tesis se ha desarrollado una nueva metodología de segmentación precisa y rápida del árbol vascular retiniano. Las principales aportaciones a este dominio son la detección de vasos finos que se ha logrado y la precisión alcanzada en la estimación del diámetro vascular. Una de las posibles aplicaciones que se ha presentado en este trabajo es el cálculo del índice AV de forma objetiva, precisa, rápida y eficiente.

Los resultados obtenidos corroboran la calidad de la segmentación, tanto en precisión como en coste computacional. Actualmente, no hemos encontrado ninguna otra aproximación al problema que alcance nuestros valores de precisión en un tiempo tan reducido. Si bien existen métodos algo más precisos que el nuestro, sus requerimientos en cuanto a tiempo de ejecución son elevadísimos comparados con el que hemos desarrollado.

Los principales problemas que nos ha planteado la segmentación del árbol arterio-venoso pueden agruparse según la naturaleza de su origen.

En primer lugar están los problemas derivados de la propia topología de los vasos sanguíneos retinales. Las bifurcaciones y, sobre todo, los cruces presentes en las estructuras vasculares dificultan el proceso de segmentación. Este tipo de situaciones complejas ha sido solucionado con los procesos de mejora de imágenes de crestas y bordes descritos en el apartado 3.2.2. En este momento estamos trabajando en la clasificación de cruces y bifurcaciones.

La falta de homogeneidad en cuanto al grosor de los vasos obliga a ampliar los rangos de anchura de las estructuras objeto de la detección. Esto provoca que el

sistema deba presentar una mayor generalidad en dicho aspecto y se incrementan las probabilidades de confusión con otras estructuras, como lesiones.

En estrecha relación con este último aspecto, está el tema de la variabilidad presente entre diferentes individuos. A pesar de haber desarrollado un sistema muy adaptable y robusto, en ciertas situaciones se presentan anomalías anatómicas que dificultan la correcta detección de los vasos. En determinados pacientes las venas y arterias retinales son excesivamente gruesas o tortuosas, lo que añadido al problema del reflejo central descrito en la introducción, dificulta el proceso de evolución del snake.

La adquisición también provoca dificultades a la hora de realizar la segmentación del árbol arterio-venoso retinal. A menudo nos encontramos con imágenes que presentan un alto nivel de ruido, un contraste bajo o una iluminación muy diversa. En ocasiones, aparecen regiones con iluminación escasa o excesiva, aunque la imagen global no sea completamente defectuosa, lo que dificulta la localización de los vasos contenidos en ellas. Mediante el uso de diferentes fuentes de información (crestas, bordes, segmentación morfológica, etc), junto con una configuración altamente sensible en la extracción de crestas y bordes, se logra superar este tipo de dificultades.

Los problemas ocasionados por el mal encuadre son, sin embargo, difícilmente solventables por nuestro modelo. En la figura 6.1, vemos el caso de una retinografía en la que un vaso sanguíneo sale del FOV aproximadamente por la línea blanca de guiones hasta volver a entrar en él. El snake no podría alcanzar siempre el segundo tramo de ese vaso por romperse la continuidad. En este caso concreto sí es posible la segmentación completa puesto que el segundo tramo se cruza con otros que parten del nervio óptico.

Todas esas características problemáticas de las retinografías provocan los malos resultados en las técnicas empleadas en este modelo. La extracción de bordes y la detección de crestas se ven afectadas negativamente por este tipo de situaciones. Para paliar estas dificultades hemos desarrollado diversas técnicas de mejora de las imágenes de bordes y crestas, descritas en el apartado 3.2.2.

En la detección de bordes, las situaciones problemáticas son causadas generalmente por la poca calidad de las imágenes. Así nos encontramos a menudo con regiones en las que las estructuras arterio-venosas no están bien definidas, afectando sobre todo a los límites del vaso y los capilares finos. De este modo hay bordes que no son detectados debido a la mala iluminación o un bajo contraste que hace que el fondo de ojo tenga un nivel de gris similar al del vaso. Cuando los márgenes en las estructuras vasculares están borrosos y el gradiente es muy suave, puede que los bordes sean ignorados por el filtro de Canny. Incluso cuando estos

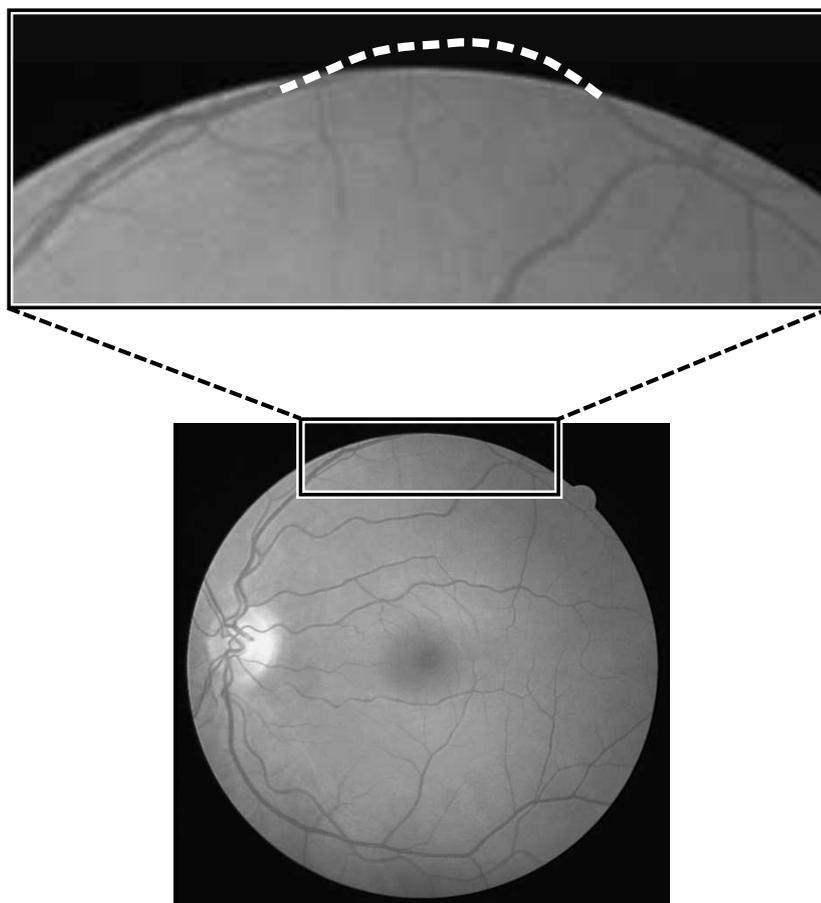


Figura 6.1: Retinografía en la que el encuadre dificulta el funcionamiento del modelo. En el detalle superior se aprecia cómo un vaso sanguíneo continuaría fuera del FOV aproximadamente por la línea blanca de guiones hasta volver a entrar en él. El snake no podría alcanzar el segundo tramo de ese vaso por romperse la continuidad.

bordes sí son detectados, existe el riesgo de que la ubicación de los bordes generados no sea precisa. Por este motivo se mejora la imagen de bordes empleando los bordes extraídos mediante la segmentación morfológica auxiliar.

El ruido complica también la extracción de bordes, sobre todo el que se produce en el interior de las estructuras vasculares. El ruido extravenoso sólo afecta en el caso de que se produzcan discontinuidades, e incluso en ese caso, puede ser corregido por las operaciones de control. En ocasiones hay una discontinuidad que hace que el snake salga fuera del vaso y el ruido crea estructuras en el fondo semejantes a las vasculares que podrían confundir al modelo. Esto se ha solucionado mediante la limitación de la distancia a crestas. De este modo el sna-

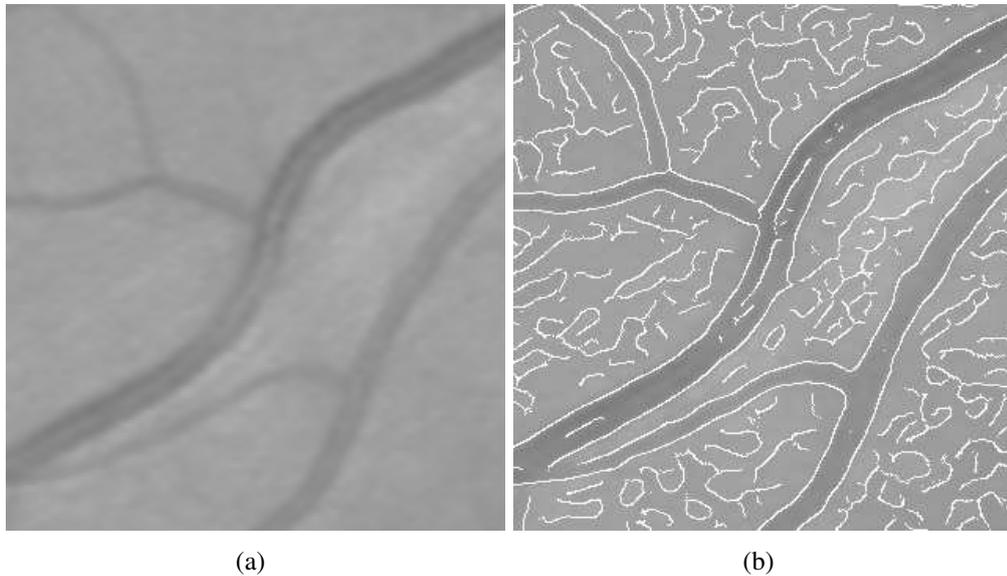


Figura 6.2: Problemas en la detección de bordes. (a) Detalle ampliado de una retinografía original en la que se aprecia el reflejo intravenoso presente de forma especialmente acusada en uno de los vasos. (b) Imagen de bordes sin mejorar, trazada en blanco sobre la imagen original en la que se muestra cómo se ha detectado erróneamente un borde en el interior del vaso debido al reflejo central.

ke sólo avanzará por aquellas estructuras que contengan crestas, es decir, lo que corresponde al interior de los vasos.

El ruido intravenoso es debido principalmente al reflejo central presente en algunos vasos, el solapamiento de varias estructuras vasculares o a la desviación brusca de gradiente que se produce a veces en el interior de un vaso. Este ruido provoca la aparición de bordes espurios en el interior de los vasos, que entorpecen el avance del snake. La figura 6.2 ilustra una situación de este tipo en la que un borde de dimensión considerable es detectado erróneamente en una parte de un vaso sanguíneo que presenta un reflejo intravenoso muy acusado. Para solucionar este tipo de situaciones se lleva a cabo una mejora posterior sobre la imagen de bordes obtenida aprovechando las crestas extraídas. Como las crestas se sitúan en el centro de los vasos, eliminamos todos aquellos bordes que estén muy próximos a las crestas permitiendo así que el snake segmente el vaso sin ser frenado por bordes erróneos.

Como se mencionó antes, la extracción de crestas se ve a menudo dificultada por las características particulares de las retinografías y las estructuras vasculares. Las crestas juegan un papel muy importante en el proceso de segmentación de los

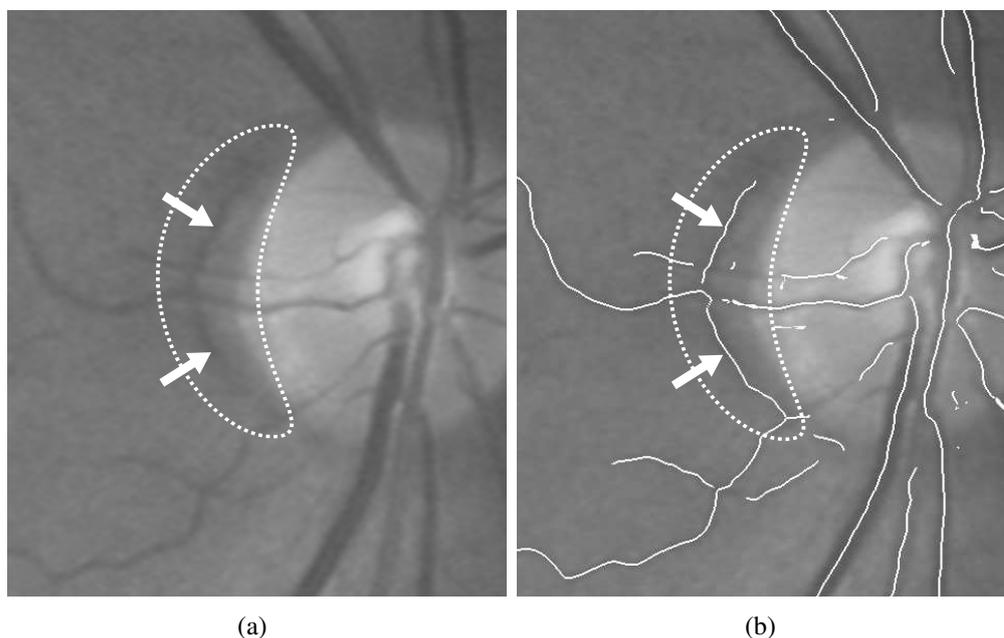


Figura 6.3: Problemas en la detección de crestas. (a) Detalle ampliado de una retinografía en la que se aprecia una zona oscura y alargada en la proximidad del disco óptico. (b) Imagen de crestas trazada en blanco sobre la imagen original en la que se muestra cómo se ha detectado erróneamente una cresta sobre la zona mencionada.

vasos por lo que recae una gran responsabilidad en la parametrización del detector de crestas y la mejora de la imagen obtenida por el mismo.

A pesar de nuestros esfuerzos en la configuración del detector de crestas, hay segmentos de vasos en los que las crestas no son detectadas adecuadamente. Esto se ha solucionado en la mayoría de los casos mediante la unión de segmentos de crestas cercanos, empleando la herramienta Minutia, desarrollada en nuestro grupo de investigación, como se explica en el apartado 3.2.2. Además, se evita el bloqueo del snake por ausencia de crestas mediante el aprovechamiento de la segmentación auxiliar, descrito en el mismo apartado. De este modo, el snake puede continuar avanzando por las zonas en que no hay crestas detectadas pero que han sido clasificadas como vasos por la segmentación morfológica.

El problema de las crestas espurias es de más difícil solución. Si estas se presentan en zonas aisladas no plantean mayor dificultad al no ser alcanzadas por el snake. Sin embargo, cuando aparecen cerca de otros vasos, se provoca una situación de confusión en el snake que intentará continuar avanzando en la dirección marcada por estas. El extractor de crestas es de una gran efectividad, por lo que esta situación afortunadamente no es muy común y se da solamente en casos aisla-

dos. La figura 6.3 ilustra una situación de este tipo en la que una cresta es detectada erróneamente en una zona de la retinografía cercana al disco óptico que presenta una estructura oscura y alargada.

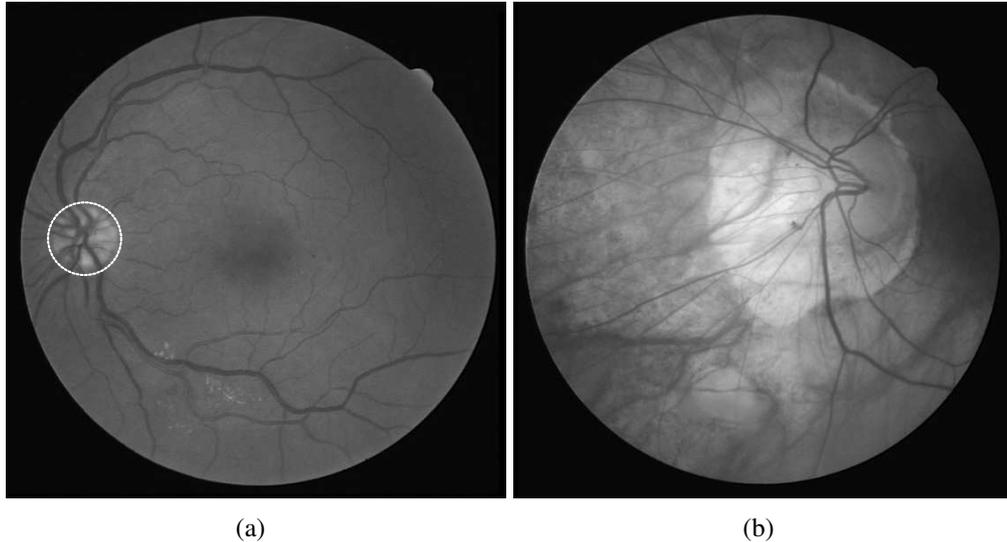


Figura 6.4: Retinografías que presentan dificultad a la hora de detectar automáticamente el disco óptico. La imagen (a) presenta una gran cantidad de vasos en la zona del disco óptico marcada con un círculo blanco punteado. La imagen (b) presenta un deformidad anatómica en el disco óptico que afecta gravemente a su forma habitual.

El sistema de localización automática del disco óptico está siendo mejorado por otros componentes del grupo de investigación. Se está optimizando el proceso para poder obtener resultados con mayor eficiencia. Su funcionamiento es bueno en la mayoría de los casos pero en determinadas ocasiones la localización no es correcta. Esto último sucede cuando existe un excesivo número de vasos sanguíneos dentro del disco óptico, como es el caso de la retinografía mostrada en la figura 6.4(a). Otra situación que hace que el sistema de detección tenga dificultades en la detección del disco óptico es la presencia de ciertas deformidades anatómicas. En la figura 6.4(b) se muestra el caso de un disco óptico cuya forma es muy distinta a la habitual. Este último caso es excepcional, a la vez que difícil de solucionar, puesto que sería complejo detectar el disco óptico incluso para un experto humano.

El modelo de contornos deformables nos permite integrar múltiples fuentes de información (técnicas de extracción de bordes, crestas, segmentación morfológica auxiliar, etc) de manera que los errores aparecidos en la aplicación de una de ellas se compensen con la información aportada por otra. Por ejemplo, en el caso de las crestas, aunque estas no hayan sido extraídas correctamente en un vaso, este

puede ser segmentado morfológicamente y, por tanto, detectado correctamente por el snake. En el caso de los bordes, si alguna bifurcación queda cerrada por un borde erróneo, las crestas permitirán al snake atravesar dicho borde y segmentar la nueva ramificación.

Este modelo presenta sin embargo una gran dificultad en la configuración tanto de las técnicas empleadas como del snake en sí. Debe mantenerse un equilibrio, de forma que no sólo debe ser adecuada para todos los vasos de una misma imagen con sus diferentes grosores, sino que debe ser aplicable a cualquier retinografía, con diferentes características de contraste, iluminación, encuadre, etc. Los parámetros son además ligeramente interdependientes unos de otros: por ejemplo, si bajamos la sensibilidad en la extracción de crestas, debemos ampliar el límite de distancia a las mismas que permitimos al snake.

El modelo genérico de snakes presenta la desventaja de ser dependiente de la inicialización. En este caso concreto, gracias a la estructura radial del árbol vascular retinal, el trazado de un círculo alrededor del disco óptico constituye una técnica robusta y eficaz para crear un contorno inicial. Como se explicó en la sección 3.3, las crestas de los vasos a detectar deben intersectar con dicha circunferencia. En ocasiones puede suceder que las crestas de un vaso no se detecten en la zona del círculo inicial. Esto no suele suponer un problema, ya que normalmente los vasos medianamente importantes se cruzan en algún punto con otras estructuras vasculares y el snake puede segmentarlos de esta manera.

En nuestro modelo de snakes no consideramos la energía interna clásica que limita su flexibilidad y elasticidad. Esto confiere a nuestro snake una mayor libertad para adaptarse a las formas tortuosas que tienen a menudo las estructuras vasculares retinales. Además simplifica en gran medida la complejidad computacional del cálculo de energía del contorno, permitiéndonos tener una mayor densidad de nodos y por tanto mayor precisión. Sin embargo, tiene la desventaja de hacer que el snake sea más sensible al ruido. La aparición de bordes o crestas espurios debido al ruido puede afectar a la evolución del snake haciendo que este segmento como vasos zonas pertenecientes al fondo de ojo. Gracias a la integración de diferentes informaciones extraídas de la imagen podemos solucionar estos problemas, lográndose una gran robustez en la obtención de resultados.

Por último, el problema de la no segmentación de los capilares demasiado finos es debido en ocasiones a la incapacidad del detector de crestas, pero también al modelo, ya que el snake necesita una anchura mínima de vaso por la que discorrir. Si se disminuye demasiado dicha anchura mínima, nos arriesgamos a que el snake se desborde ante cualquier pequeña discontinuidad que pueda presentar el borde.

Como ejemplo de la utilidad del método presentado, hemos desarrollado una aplicación para la medida del índice arterio-venoso. Como se ha explicado en el capítulo correspondiente, este índice es esencial para el diagnóstico de la retinopatía diabética así como otras patologías retinales o que afectan a las estructuras vasculares. Las principales dificultades encontradas a la hora de obtener el calibre vascular, base del cálculo del índice arterio-venoso, son las siguientes:

- Medición del calibre en zonas de cruces y bifurcaciones de vasos sanguíneos, ya que puede ser muy heterogénea.
- Delimitación de estructuras vasculares que discurren paralelas y próximas, especialmente cuando presentan unos niveles de gris parecidos.
- Estimación de la anchura de los vasos con un reflejo acentuado, a pesar de que su detección sea correcta.
- Bordes espurios en el interior del vaso que en ocasiones no son eliminados.

La figura 6.5 muestra dichos problemas situados sobre una retinografía y mostrados en detalle en la serie de imágenes a la derecha. La imagen de detalle superior ilustra el caso de la dificultad de estimación del calibre vascular en una bifurcación. En la imagen de detalle central se muestra cómo puede ser erróneamente medido el calibre vascular cuando dos venas discurren contiguas. En la imagen de detalle inferior se representa la dificultad creada por el reflejo intravenoso en la estimación de la anchura de un vaso.

Los resultados obtenidos por nuestro sistema son semejantes a los proporcionados por diversas técnicas de referencia (evaluadas por oftalmólogos). Así pues, este método podría ser potencialmente empleado en el ámbito médico en un futuro y será integrado en el sistema de análisis de retinografías SIRIUS descrito en el quinto capítulo de esta memoria. Además de su utilización para el cálculo del índice arterio-venoso, nuestro modelo podría ser empleado en muchas otras aplicaciones médicas de análisis vascular retinal.

Existe la posibilidad de realizar un tratamiento previo de las imágenes médicas que permita aislar aquellas estructuras cuya información es relevante en cada proceso concreto y eliminando las que no lo sean. Esto sería de gran ayuda para los facultativos, puesto que reduciría la complejidad de la tarea de análisis y el tiempo empleado en la misma. Por ejemplo, la extracción del árbol arterio-venoso puede aprovecharse para eliminar las estructuras vasculares de la retinografía y facilitar el estudio del fondo de ojo. De este modo sería mucho más sencillo detectar y analizar otros síntomas que provocan ciertas patologías en la retina, como

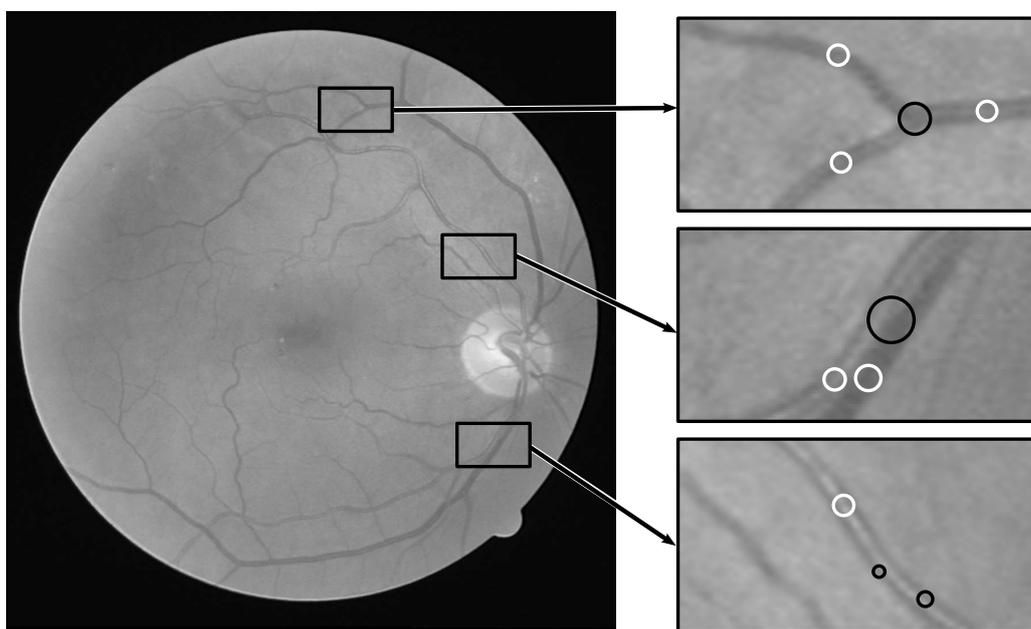


Figura 6.5: Principales dificultades encontradas a la hora de estimar el calibre vascular: bifurcaciones (arriba), venas contiguas (centro) y reflejo intravenoso (abajo). Los círculos negros se corresponden a los calibres erróneamente calculados y los círculos blancos a los correctos.

la diabetes o la arteriosclerosis. Entre estos síntomas se destacan los mencionados en la introducción de esta memoria: hemorragias, exudados y microaneurismas.

La geometría de segmentación obtenida podría emplearse para comparar de forma automática y objetiva el estado del árbol vascular en diferentes momentos del tiempo mediante alguna técnica de análisis geométrico.

Fuera ya del ámbito médico, dada la unicidad del árbol arterio-venoso de la retina para cada individuo, los resultados obtenidos por nuestro sistema de segmentación vascular podrían incluirse asimismo en utilidades de autenticación biométrica.

El curso futuro de nuestra investigación se dirige principalmente hacia una mayor automatización del proceso de obtención del calibre vascular. Hay algunas etapas que todavía se realizan de forma manual como es el caso de la asignación de parámetros. La configuración del sistema es compleja y fundamental para el correcto funcionamiento del modelo sobre una imagen particular, por lo que si se realizase de forma automática aportaría una mejora notable tanto a la eficiencia como a la eficacia del proceso. Otro de los aspectos que sería interesante automatizar, es la distinción entre arterias y venas. Es una tarea muy difícil para la

que todavía no se ha encontrado una solución definitiva; sólo se han desarrollado algunas aproximaciones a la misma [Abd01], [GR03] [LHLW03], siendo muy reducida la bibliografía sobre este tema.

A pesar de que el funcionamiento actual del sistema es satisfactorio, consideramos que quedan abiertas posibilidades de mejora de calidad de los resultados obtenidos. Por ejemplo, el sistema actual no realiza ningún preprocesado complejo de la imagen original, simplemente se transforma a escala de grises y se amplía su tamaño. Hemos descartado en principio la aplicación de técnicas de realce o mejora de la imagen, porque cualquier modificación de la imagen original conlleva una pérdida de precisión, además de un incremento en el coste computacional.

Por otra parte, el modelo de contornos deformables empleado presenta una gran facilidad para integrar información extraída de la imagen de muy diversa procedencia. Gracias a esta característica, será posible beneficiarnos de las nuevas técnicas de análisis de imágenes de fondo de ojo que se desarrollen en el curso de la investigación.

En cuanto al coste computacional del sistema desarrollado, podemos afirmar que es muy bajo en comparación con otras técnicas existentes en el ámbito de la segmentación vascular retiniana. A causa de esto, no hemos efectuado una optimización exhaustiva de todos los procesos implicados. Sería factible plantearse el empleo de técnicas de optimización o la paralelización posible de las etapas independientes del proceso global, en caso de que su aplicación final requiriese una eficiencia aun mayor. Este sería el caso de su uso para el procesado de grandes volúmenes de imágenes, para lo cual sería también importante el mencionado avance en la automatización del sistema.

Apéndice A

Procesos Auxiliares al Modelo

En este capítulo se incluyen las descripciones detalladas de algunas de las técnicas más relevantes empleadas en el modelo de contornos deformables desarrollado. En primer lugar describiremos la técnica de interpolación bicúbica, que se emplea en la fase de preprocesado para aumentar la retinografía al doble de su tamaño, evitando en lo posible las pérdidas de precisión. El siguiente apartado lo dedicaremos a la extracción de crestas, que son fundamentales en el proceso de segmentación, ya que actúan como energía del modelo, además de utilizarse en la mejora de la imagen de bordes, en la inicialización del contorno y en las operaciones de control que se efectúan durante la evolución del snake. A continuación, nos centraremos en la técnica de extracción de bordes, a partir de los cuales se obtendrá una de las energías que gobernarán el comportamiento del snake. También explicaremos la técnica de segmentación morfológica, que se aprovecha como elemento auxiliar en la mejora de la imagen de bordes y en las operaciones de control de la evolución del modelo. Por último, presentaremos el proceso de detección automática del disco óptico. Estas dos últimas técnicas mencionadas, así como la extracción de crestas, han sido desarrolladas en nuestro grupo de investigación.

A.1. Interpolación Bicúbica

Si se desea alcanzar una alta precisión en la segmentación del árbol vascular hemos de trabajar a nivel de subpíxel. En el apartado 3.1.2 se explica la necesidad de dicho nivel de trabajo, acorde con lo publicado en el artículo [ECPO08]. Para ello es necesario remuestrear la imagen al doble de su tamaño original. Esta ampliación debe realizarse cuidadosamente, intentando conservar la información de la imagen intacta y no perder precisión en el proceso. Agrandar una imagen

plantea el problema de asignar valores a los nuevos píxeles de la imagen partiendo de los originales. La interpolación es el proceso de calcular valores numéricos desconocidos (intensidad de los nuevos píxeles) a partir de otros ya conocidos mediante la aplicación de algoritmos concretos. Hay varios tipos de interpolación que producen resultados muy diversos en cuanto a calidad y coste computacional. En este trabajo hemos considerado tres procedimientos de interpolación:

- **Interpolación directa.** Realmente no se realiza ninguna interpolación, simplemente se asigna el valor de píxel más cercano al nuevo píxel. Los resultados no son muy precisos pero el coste computacional es muy bajo.
- **Interpolación lineal.** Es un método bastante sencillo que se basa en hacer el promedio de los 4 píxeles vecinos.
- **Interpolación bicúbica.** Es más compleja ya que considera los valores de 16 píxeles vecinos, como describiremos en detalle a continuación, pero alcanza unos resultados mucho mejores.

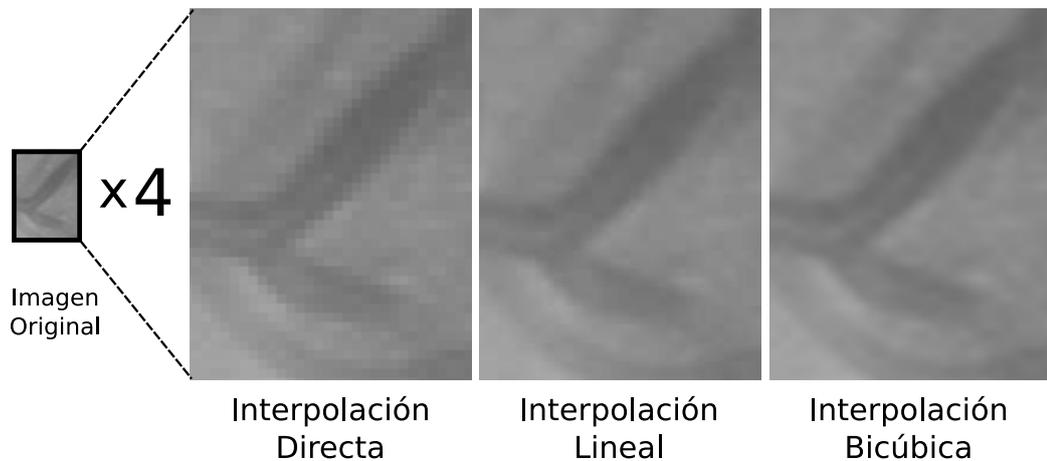


Figura A.1: Resultados de la ampliación de un detalle de la imagen original al cuádruple de su tamaño mediante diferentes algoritmos de interpolación.

En la figura A.1 puede verse un ejemplo de ampliación empleando cada uno de los métodos antes citados. Se ha realizado una ampliación al cuádruple del tamaño de la foto original para mostrar más claramente los efectos de la aplicación de cada uno de los algoritmos, aunque realmente en nuestro sistema sólo precisaremos duplicar sus medidas. La ampliación sin interpolación a la izquierda muestra claramente la pérdida de definición de la imagen que aparece *pixelizada*. En el centro vemos cómo los resultados obtenidos mediante la interpolación lineal son bastante mejores pero se aprecia un suavizado considerable que provoca una

mayor dificultad para distinguir las formas originales. Por último, a la derecha, podemos comprobar la idoneidad de la interpolación bicúbica puesto que la definición y calidad originales se mantienen en mayor medida que con cualquiera de los otros métodos, produciéndose menos *artefactos de interpolación*.

Se ha seleccionado la interpolación bicúbica como algoritmo de remuestreo de la imagen original. En la bibliografía existente sobre el tema [PKT83] se propone dicho método de interpolación como superior a los demás en cuanto a preservación de las características de la imagen. Los resultados obtenidos empleando este método son mucho mejores que los obtenidos por las otras dos. La interpolación bicúbica es de una mayor complejidad computacional pero sus resultados compensan el descenso de la eficiencia que provoca.

La interpolación bicúbica es un método de interpolación ampliamente utilizado en el tratamiento digital de imágenes que se basa en realizar un promedio de los 16 píxeles adyacentes. Existen variantes de esta, como la bicúbica enfocada o suavizada, pero emplearemos la versión estándar del algoritmo puesto que nos interesa conservar la mayor información posible de la imagen original, más que su apariencia visual.

Esta interpolación es una extensión de la interpolación cúbica para calcular puntos de datos en una rejilla regular y obtiene una superficie interpolada que es suave en todas las direcciones. Se puede llevar a cabo tanto mediante polinomios de Lagrange como *splines cúbicas* o un algoritmo de convolución.

Básicamente el resultado de la interpolación bicúbica son polinomios de grado 3 para cada intervalo de puntos. Supongamos que los valores de la función f y las derivadas f_x , f_y y f_{xy} son conocidas en las cuatro esquinas $(0,0)$, $(1,0)$, $(0,1)$ y $(1,1)$, como se muestra en el esquema de la figura A.2. La superficie interpolada se define así para cada punto $p(x,y)$ como:

$$p(x,y) = \sum_{i=0}^3 \sum_{j=0}^3 a_{ij} x^i y^j \quad (\text{A.1})$$

El problema de la interpolación consiste básicamente en determinar los 16 coeficientes a_{ij} . Emparejar $p(x,y)$ con los valores de la función produce cuatro ecuaciones:

$$f(0,0) = p(0,0) = a_{00} \quad (\text{A.2})$$

$$f(1,0) = p(1,0) = a_{00} + a_{10} + a_{20} + a_{30} \quad (\text{A.3})$$

$$f(0,1) = p(0,1) = a_{00} + a_{01} + a_{02} + a_{03} \quad (\text{A.4})$$

$$f(1,1) = p(1,1) = \sum_{i=0}^3 \sum_{j=0}^3 a_{ij} \quad (\text{A.5})$$

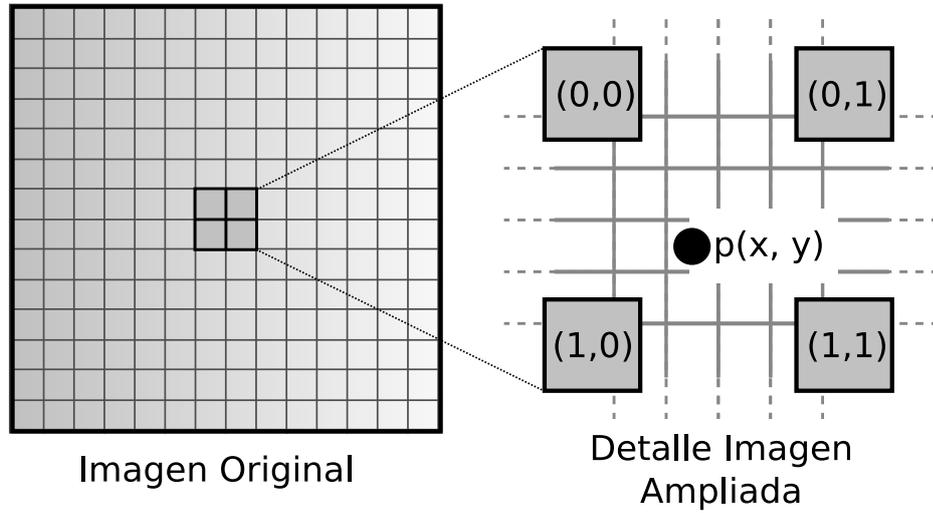


Figura A.2: Representación del proceso de interpolación de una imagen. A partir de cuatro puntos o píxeles de la imagen original mostrada a la izquierda, construimos una imagen ampliada de la cual vemos un fragmento a la derecha. Para obtener esta nueva imagen ampliada es necesario calcular el valor de los nuevos píxeles, como $p(x,y)$ a partir de los valores originales de $(0,0)$, $(0,1)$, $(1,0)$ y $1,1)$

De igual modo se definen las ecuaciones para las derivadas parciales en las direcciones x e y :

$$f_x(0,0) = p_x(0,0) = a_{10} \quad (\text{A.6})$$

$$f_x(1,0) = p_x(1,0) = a_{10} + 2a_{20} + 3a_{30} \quad (\text{A.7})$$

$$f_x(0,1) = p_x(0,1) = a_{10} + a_{11} + a_{12} + a_{13} \quad (\text{A.8})$$

$$f_x(1,1) = p_x(1,1) = \sum_{i=1}^3 \sum_{j=0}^3 a_{ij}i \quad (\text{A.9})$$

$$f_y(0,0) = p_y(0,0) = a_{01} \quad (\text{A.10})$$

$$f_y(1,0) = p_y(1,0) = a_{01} + a_{11} + a_{21} + a_{31} \quad (\text{A.11})$$

$$f_y(0,1) = p_y(0,1) = a_{01} + 2a_{02} + 3a_{03} \quad (\text{A.12})$$

$$f_y(1,1) = p_y(1,1) = \sum_{i=0}^3 \sum_{j=1}^3 a_{ij}j \quad (\text{A.13})$$

y cuatro ecuaciones para la derivada parcial cruzada xy :

$$f_{xy}(0,0) = p_{xy}(0,0) = a_{11} \quad (\text{A.14})$$

$$f_{xy}(1,0) = p_{xy}(1,0) = a_{11} + 2a_{21} + 3a_{31} \quad (\text{A.15})$$

$$f_{xy}(0,1) = p_{xy}(0,1) = a_{11} + 2a_{12} + 3a_{13} \quad (\text{A.16})$$

$$f_{xy}(1,1) = p_{xy}(1,1) = \sum_{i=1}^3 \sum_{j=1}^3 a_{ij}ij \quad (\text{A.17})$$

donde las expresiones expuestas arriba emplean las siguientes identidades:

$$p_x(x,y) = \sum_{i=1}^3 \sum_{j=0}^3 a_{ij}ix^{i-1}y^j \quad (\text{A.18})$$

$$p_y(x,y) = \sum_{i=0}^3 \sum_{j=1}^3 a_{ij}x^i jy^{j-1} \quad (\text{A.19})$$

$$p_{xy}(x,y) = \sum_{i=1}^3 \sum_{j=1}^3 a_{ij}ix^{i-1} jy^{j-1} \quad (\text{A.20})$$

Este procedimiento genera una superficie $p(x,y)$ en la unidad cuadrada $[0,1] \times [0,1]$ que es continua y sus derivadas parciales también lo son. La interpolación bicúbica en una rejilla regular de tamaño arbitrario puede realizarse mediante la unión de superficies bicúbicas como éstas, asegurándose de que las derivadas parciales coinciden en los límites. Si las derivadas parciales son desconocidas, típicamente se aproximan mediante los valores de la función en puntos vecinos a las esquinas de la unidad cuadrada, es decir, empleando diferencias finitas.

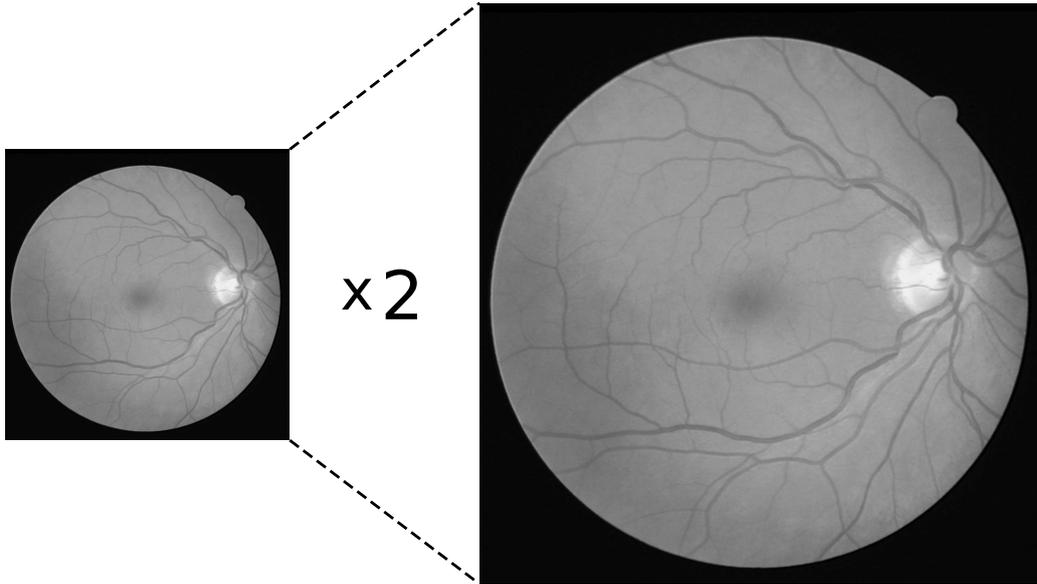


Figura A.3: Resultado de la ampliación de la imagen original al doble de su tamaño mediante interpolación bicúbica.

Las retinografías presentan un área negra alrededor de la imagen de la retina que no contiene ningún tipo de información relevante. Así pues, hemos efectuado una optimización al algoritmo original, omitiendo en el proceso de interpolación esta área. Con ello se ha reducido en gran medida el coste computacional derivado del empleo de este tipo de interpolación, a la vez que se mantiene la calidad de

los resultados obtenidos en el área de interés de la imagen. La figura A.3 muestra el resultado de la ampliación de una retinografía al doble de su tamaño mediante interpolación bicúbica.

A.2. Extracción de Crestas

Las crestas obtenidas de la imagen constituyen una de las energías fundamentales para nuestro modelo de contorno deformable. El snake se guía principalmente siguiendo estas crestas en su avance longitudinal a través de los vasos. Las crestas juegan también un papel crucial en la inicialización del snake, definiendo los puntos semilla del contorno. Además, la imagen de crestas se emplea para mejorar la imagen de bordes al eliminar los bordes espurios que puedan bloquear el avance del snake en el interior de los vasos según un criterio de distancia a crestas. Por todo ello, la imagen de crestas debe ser obtenida de la forma más precisa posible y es un paso irreversible del proceso de segmentación: si no se detecta la cresta correspondiente a un determinado vaso sanguíneo, este quedará probablemente sin segmentar. En la presente sección describiremos las características de la imagen de crestas y el proceso de extracción de la misma. En [CPM⁺04] puede encontrarse una presentación más detallada del sistema de obtención de crestas aquí empleado.

A.2.1. Definición de Crestas

Aunque existen multitud de definiciones matemáticas de crestas y valles (puede encontrarse una revisión exhaustiva de las mismas en [Peñ00]), consideraremos una cresta como una zona contigua de puntos de la imagen que conforma un nivel máximo o mínimo con respecto a sus puntos colindantes.

Si se interpreta la imagen de la retina como un paisaje o superficie tridimensional, los vasos pueden ser considerados como elevaciones o valles sobre el terreno. Dicho de otro modo, las venas y arterias serán las zonas de la imagen en las que su nivel de gris denota la presencia de mínimos o máximos con respecto a sus regiones de vecindad, y que además se encuentran confinadas en torno a una estructura alargada o tubular. Este hecho nos permitirá guiar el contorno activo a lo largo de los vasos sanguíneos a partir de la posición de las crestas. La figura A.4 muestra los resultados de la extracción de crestas superpuestos a la imagen original.

Por tanto, es necesario que la imagen de crestas se componga de crestas continuas y bien delimitadas, que realmente se correspondan con venas o arterias de

la retina. Además, el método que construye esta imagen de crestas debe ser capaz de discriminar el ruido, tanto el procedente de la textura del fondo de ojo como el surgido durante la adquisición de la retinografía.

A continuación, describiremos más detalladamente el algoritmo de extracción de crestas que se ha empleado. Este modelo se basa en la teoría del *Conjunto de Niveles de Curvatura Extrínseca* (LSEC o Level Set Extrinsic Curvature [Peñ00]) que presenta ciertas propiedades y parámetros de control que lo hacen adecuado para resolver el problema de la detección de vasos sanguíneos.

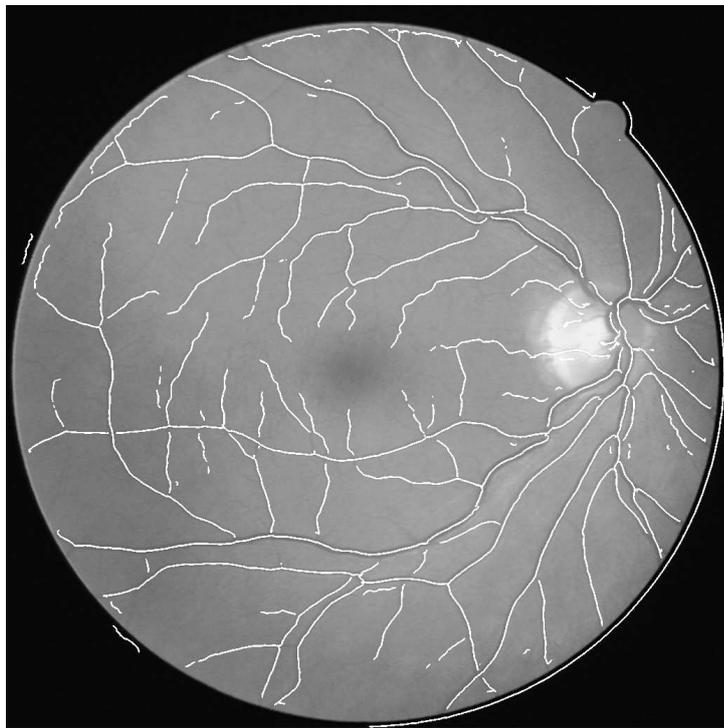


Figura A.4: Resultados de la extracción de crestas, representados en blanco y superpuestos a la imagen original. Los valores de los parámetros empleados son: Escala de Segmentación (**SD**) = 4.5, Escala de Integración (**SI**) = 8, Confianza (**CNFD**) = 0.08, Umbral de Cresta (**THRK**) = 0.019, Crestas y Valles (**WHC**) = 1, Longitud Mínima de Cresta (**BMIN**) = 170.

A.2.2. Descripción del Método de Extracción

Dada una función $L : R^d \rightarrow R$, el conjunto de nivel para una constante l está formado por el conjunto de puntos $\{x \mid L(x) = l\}$. En imágenes bidimensionales, L puede considerarse como un relieve topográfico en el que sus curvas de nivel son

los conjuntos de nivel (*levelset*) que estamos definiendo. Los mínimos negativos de la curva de nivel k forman los valles, mientras que las crestas son los máximos positivos.

$$k = (2L_x L_y L_{xy} - L_y^2 L_{xx} - L_x^2 L_{yy})(L_x^2 + L_y^2)^{-3/2} \quad (\text{A.21})$$

Sin embargo, la discretización del LSEC no está bien definida en ciertos casos, lo cual provoca que existan riesgos de que aparezcan discontinuidades inesperadas en el medio de los objetos. Por tanto, se suele emplear el operador *Conjunto de Niveles de Curvatura Extrínseca Multinivel con Tensor Estructural* (MLSEC-ST o Multilocal Level Set Extrinsic Curvature with Structure Tensor), tal y como se define en [SLLV00]:

$$k = -\text{div}(\bar{w}) = -\sum_{i=1}^d \frac{\delta \bar{w}^i}{\delta x^i}, d = 2; \quad (\text{A.22})$$

donde \bar{w}^i es el componente en la posición i de \bar{w} , el campo vectorial del gradiente normalizado de $L : R^d \rightarrow R$. Este último se define según la siguiente ecuación:

$$\bar{w} = \begin{cases} w/\|w\| & \iff \|w\| > 0 \\ O_d & \iff \|w\| = 0 \end{cases} \quad (\text{A.23})$$

donde O_d es el vector cero d -dimensional.

Aunque las ecuaciones A.21 y A.22 son equivalentes en el dominio continuo, en el dominio discreto, cuando se aproximan las derivadas por diferencias finitas centradas sobre la imagen suavizada mediante un operador Gaussiano, la ecuación A.22 produce unos resultados mucho mejores.

El primer paso del algoritmo de extracción consiste en minimizar el impacto del ruido, para ello se convolucionan la imagen original con una distribución gaussiana de desviación típica SD . Una vez hecho esto, se calculan las imágenes de diferencias con respecto a los ejes x e y , lo que proporciona regiones con mayores magnitudes en sus gradientes. Calculamos entonces el producto de estas imágenes intermedias, filtrando sus imprecisiones mediante otra gaussiana de desviación SI . Estas imágenes actúan como entrada a un elemento matemático llamado *tensor estructural* [SLLV00], cuyo objetivo conceptual consiste en unificar bordes paralelos y próximos en una única cresta relevante [Peñ00].

Una vez que disponemos de las secuencias de puntos que ha generado el *tensor*, podemos discriminar las crestas y/o los *valles* (proceso guiado por el parámetro WHC que describiremos en el siguiente apartado). Por último, se filtran las crestas resultantes midiendo su fuerza y su longitud.

A.2.3. Ajuste de Parámetros

El contraste, la definición y la iluminación de la imagen son factores que afectan fuertemente al cálculo de crestas. Es necesario destacar que la extracción de crestas es un proceso de cálculo de bordes basado en la aplicación de un operador diferencial, y no un proceso de segmentación que marque e identifique los vasos sanguíneos de la imagen. Por esta razón, cualquier característica del ojo que destaque en la imagen debido a condiciones ambientales o de iluminación en el momento de la captura, será extraída como una cresta y puede conducir a resultados erróneos.

El ajuste de los parámetros que controlan el proceso de extracción de crestas trata de minimizar las posibilidades de que esto ocurra, jugando así un papel crucial a la hora de localizar la ubicación exacta de los vasos sanguíneos en el proceso de segmentación.

Los parámetros del algoritmo de extracción de crestas son los siguientes:

- **SD. Escala de Segmentación.** Este parámetro determina el valor de una distribución gaussiana de suavizado que se aplica sobre la imagen de entrada. Sirve para filtrar el ruido y otros efectos de la imagen derivados de su captura.
- **SI. Escala de Integración.** La Escala de Integración determina el valor de otra distribución Gaussiana que se encarga de marcar las diferencias entre las cumbres y los valles (principalmente alrededor de los llamados *puntos de silla* [SLLV00]).
- **CNFD.** Este parámetro se emplea para definir el valor que tomará la confianza durante el proceso de ajuste. La confianza se usa en unas estructuras matemáticas internas (*tensores*) que utiliza el algoritmo.
- **THRK.** Su valor determina el mínimo de las crestas. Las crestas que tomen un valor inferior a este parámetro se eliminan y no se tienen en cuenta durante el proceso de detección de vasos. Sirve para mejorar el rendimiento y discriminar ruido.
- **WHC.** Indica si el algoritmo de extracción de crestas debe calcular únicamente las crestas, los valles o ambos. Por defecto se extraen ambos, ya que así se generaliza el proceso de detección sobre el tipo de imágenes a emplear.

- **BMIN.** Este parámetro indica la longitud mínima de la cresta para ser considerada relevante. Las que no sobrepasan este umbral son eliminadas directamente de la imagen de crestas resultante, por lo que también se pueden utilizar para descartar ruido.

Existe un procedimiento automático desarrollado en nuestro grupo de investigación para el ajuste de estos parámetros en función del contraste de la imagen. En nuestro sistema no hemos hecho uso de él por simplificación y porque en general era suficiente con poner unos valores bastante sensibles para todas las imágenes. El resto de informaciones (bordes y segmentación auxiliar) ya actúan como discriminadores de crestas no relevantes.

A.3. Extracción de Bordes

Tras realizar pruebas con otros filtros (Sobel, Laplace...), el algoritmo de Canny [Can86] fue seleccionado para obtener los bordes de la imagen original.

El algoritmo de Canny está considerado como uno de los mejores métodos de detección de contornos. Tiene como principal ventaja su gran adaptabilidad para poder ser aplicado a diversos tipos de imágenes, además de no disminuir su efectividad ante la presencia de ruido en la imagen original.

Este método para la detección de bordes se basa en tres criterios:

- Se ha de evitar la eliminación de bordes importantes y no suministrar falsos bordes.
- La distancia entre la posición real y la localizada del borde se debe minimizar.
- La respuesta ha de integrar las respuestas múltiples correspondientes a un único borde.

En el tratamiento de imágenes se trabaja con píxeles (ámbito discreto), así que en el algoritmo de Canny se utilizan máscaras de convolución que representan aproximaciones en diferencias finitas.

El algoritmo de Canny implementado en este sistema consiste básicamente en los siguientes pasos:

1. Convolución de la imagen con un filtro gaussiano separable.
2. Obtención de la orientación del gradiente en cada píxel: calculamos las primeras derivadas d_x y d_y empleando las máscaras $[-1,0,1]$ y $[1,0,-1]$.

3. Cálculo de la magnitud del gradiente: $\sqrt{d_x d_x + d_y d_y}$.
4. Supresión no máxima: en este paso se logra el adelgazamiento del ancho de los bordes, obtenidos con el gradiente, hasta lograr bordes de un píxel de ancho.
5. Histéresis de umbral: aplicamos una función de histéresis basada en dos umbrales para reducir la posibilidad de aparición de contornos falsos.

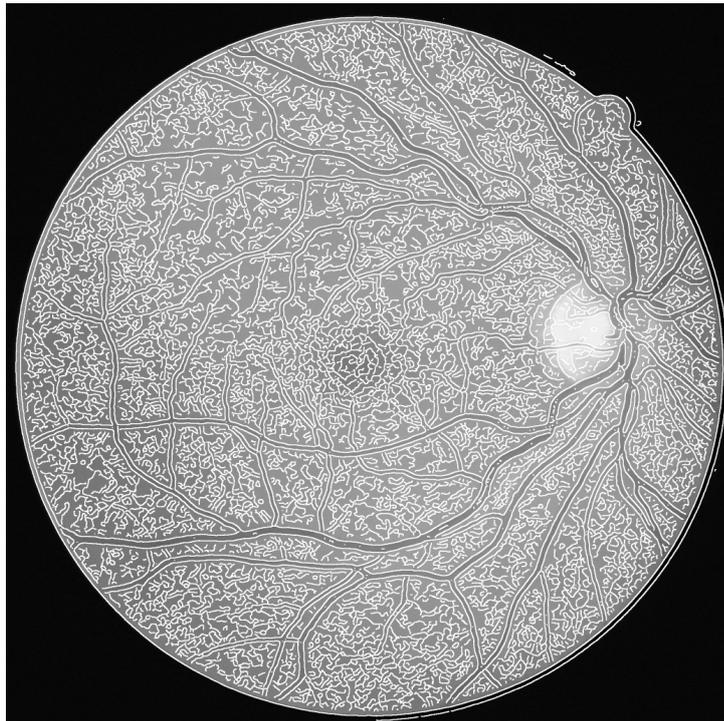


Figura A.5: Resultados de la extracción de bordes, representados en blanco y superpuestos a la imagen original. Los valores de los parámetros empleados son: Tamaño de Gaussiana (**sigma**) = 4, Umbral de Histéresis Alto (**tHigh**) = 0.6, Umbral de Histéresis Bajo(**tLow**) = 0.4.

Para la obtención del gradiente, lo primero que se realiza es la aplicación de un filtro gaussiano a la imagen original con el objetivo de suavizar la imagen y tratar de eliminar el posible ruido existente. Este suavizado se obtiene promediando los valores de intensidad de los píxeles en el entorno de vecindad con una máscara de convolución de media cero y desviación estándar **sigma**. Cuanto mayor sea el tamaño de la máscara gaussiana **sigma**, más intenso es el suavizado y mayor cantidad de ruido se elimina. Sin embargo, si aumentamos **sigma** demasiado difuminamos los bordes y perdemos detalles de la imagen, por lo que disminuiría la precisión de la detección final de los bordes.

La primera derivada toma el valor cero en todas las regiones donde no varía la intensidad y tiene un valor constante en toda la transición de intensidad. Puesto que los puntos de contorno son zonas de píxeles en las que existe un cambio brusco de nivel de gris, suponen un cambio de intensidad que se manifiesta como un cambio brusco en la primera derivada. Esta característica es aprovechada para detectar un borde, constituyendo una de las bases del algoritmo de Canny. Para cada píxel se obtiene la magnitud y módulo (orientación) del gradiente, obteniendo así dos imágenes.

Las dos imágenes generadas en el paso anterior sirven de entrada para generar una imagen con los bordes adelgazados mediante la supresión no máxima de puntos de borde. El procedimiento es el siguiente: se consideran cuatro direcciones identificadas por las orientaciones 0° , 45° , 90° y 135° con respecto al eje horizontal. Para cada píxel se encuentra la dirección que mejor se aproxime a la dirección del ángulo de gradiente. Posteriormente 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 en el paso anterior. De ser así se asigna el valor 0 a dicho píxel, en caso contrario se asigna el valor que tenga la magnitud del gradiente, obteniendo iterativamente la imagen con los bordes adelgazados.

La imagen obtenida en el paso anterior suele contener máximos locales creados por el ruido, que eliminaremos empleando la histéresis del umbral. El proceso consiste en tomar dicha imagen, la orientación de los puntos de borde de la imagen y dos umbrales, el primero **tLow** más pequeño que el segundo **tHigh**. Para cada punto de la imagen se debe localizar el siguiente punto de borde no explorado que sea mayor al segundo umbral. A partir de dicho punto sigue las cadenas de máximos locales conectados en ambas direcciones perpendiculares a la normal del borde, siempre que sean mayores al primer umbral. Así se marcan todos los puntos explorados y se almacena la lista de todos los puntos en el contorno conectado, eliminando las uniones en forma de Y de los segmentos que confluyan en un punto.

En este sistema los parámetros del filtro han sido ajustados de tal forma que resulten apropiados en promedio para todas las imágenes. En nuestro caso podemos permitirnos una sensibilidad bastante alta ya que las crestas permiten eliminar gran parte de los bordes no relevantes o debidos al ruido. La figura A.5 muestra los resultados de la extracción de bordes sobre una retinografía, en la que vemos un gran número de bordes detectados a causa de la alta sensibilidad utilizada.

A.4. Segmentación Morfológica Auxiliar

El sistema presentado en este trabajo se sirve de la segmentación morfológica de los vasos retinales que ha sido desarrollada en nuestro grupo de investigación [Fre07]. La segmentación obtenida con estas técnicas es extremadamente rápida, completamente automática y bastante precisa. Pese a esto, la calidad de los resultados logrados no es suficiente para satisfacer los requisitos de la aplicación final. Aunque detecta correctamente los vasos principales, la precisión en la segmentación de los bordes de los mismos no es suficiente para realizar medidas precisas de calibres vasculares. A menudo clasifica píxeles de fondo de las zonas cercanas a un vaso como pertenecientes al mismo haciendo que la estructura vascular segmentada presente un calibre mayor del real. Este error es excesivo para que sea posible su utilización en una de las principales aplicaciones de nuestro sistema como es la estimación precisa de la anchura de los vasos para el cálculo posterior de parámetros médicos. Otro problema que presenta esta técnica es que no logra segmentar la mayoría de los vasos finos.

Sin embargo, dicha segmentación puede ser aprovechada por nuestro modelo para mejorar el funcionamiento del mismo. En el presente trabajo nos referimos a esta técnica de segmentación como *segmentación auxiliar*, puesto que la información que proporciona es una ayuda para la obtención de la segmentación objetivo.

A continuación describiremos brevemente esta metodología de segmentación morfológica, pudiendo encontrarse un análisis en profundidad de la misma en [Fre07].

Esta segmentación consiste en un algoritmo basado en el propuesto por Condurache y Aach [CA05], que presentaron una metodología para la extracción del árbol vascular de imágenes en múltiples formatos y correspondientes a distintos órganos del cuerpo. Esta metodología se adapta a nuestro dominio de aplicación concreto, las imágenes de fondo de ojo, para mejorar sus resultados explotando la característica de conectividad del árbol vascular retiniano.

El proceso de segmentación puede dividirse en dos etapas principales: realce de la red vascular y extracción del árbol arterio-venoso. La figura A.6 muestra un esquema del proceso completo de segmentación morfológica.

La etapa de realce de la red vascular consiste a su vez en dos fases:

1. **Preprocesado de la imagen.** En esta fase se pretende aumentar la diferencia de contraste entre los vasos y el fondo mediante un filtro *Tophat*. A continuación se aplica un filtro de mediana de tamaño $W_f \times W_f$ para eliminar el ruido del fondo y reducir el reflejo vascular. De esta manera, se evita

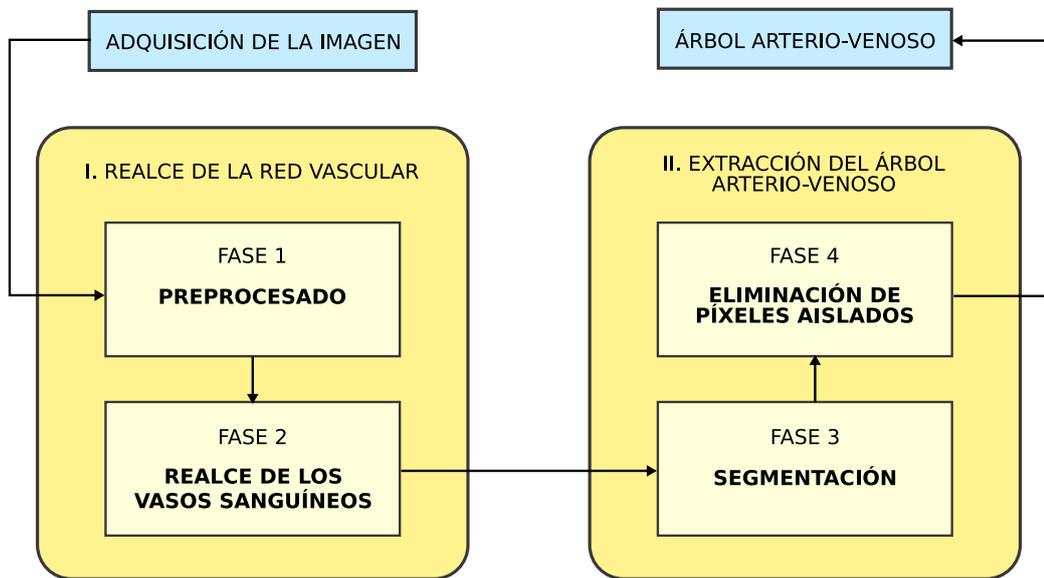


Figura A.6: Esquema de la segmentación morfológica auxiliar.

en la medida de lo posible la inclusión en el resultado de estructuras ajenas a la red vascular y asegura una correcta segmentación de la totalidad de la superficie de los vasos.

2. **Realce de los vasos sanguíneos.** Para lograr una mejor segmentación, realizamos aquí las estructuras vasculares considerando sus características morfológicas. Esto se lleva a cabo mediante la asignación a cada píxel de la probabilidad de pertenencia a una estructura vascular, técnica basada en la aproximación multiescala empleada en el algoritmo de Condurache y Aach [CA05]. Al finalizar esta fase, aquellos píxeles con mayor probabilidad de formar parte de un vaso sanguíneo presentarán un nivel de gris menor, es decir, serán más oscuros que aquellas estructuras que se consideran pertenecientes al fondo.

En este punto disponemos de una imagen mucho más adecuada para efectuar sobre ella la extracción del árbol-arterio-venoso. Esta etapa se divide en una primera segmentación que se refina posteriormente mediante la eliminación de píxeles aislados

1. **Segmentación del árbol arterio-venoso.** Se efectúa una selección por umbralización basada en histéresis de los píxeles según su nivel de gris, que representa su probabilidad de pertenencia a la red vascular o al fondo. Los dos umbrales necesarios para llevar a cabo esta selección P_{vasos} y P_{fondo} se

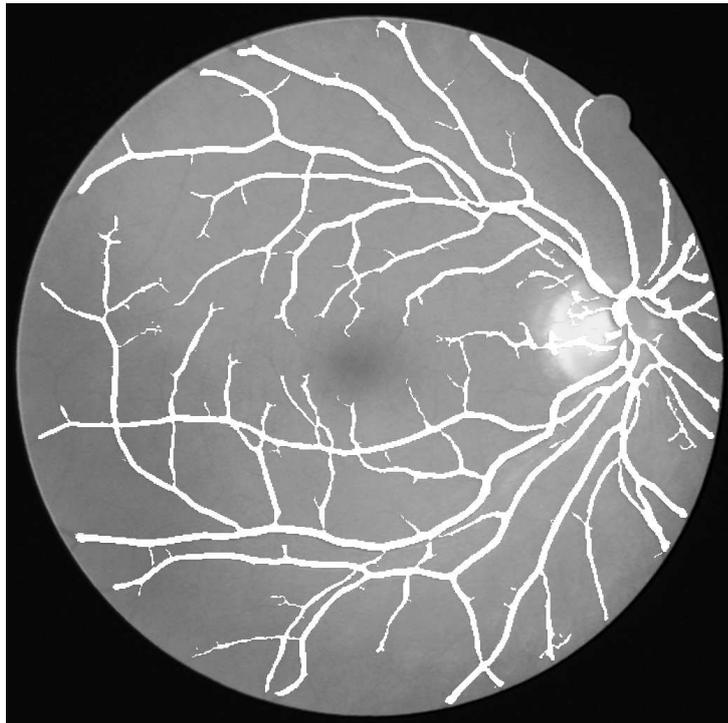


Figura A.7: Resultados de la segmentación morfológica auxiliar, representada en blanco y superpuesta a la imagen original. Los valores de los parámetros empleados son: Tamaño de Ventana de Filtrado ($W_f \times W_f$) = 4×4 , Porcentaje de Vasos por Imagen (P_{vasos}) = 6 %, Porcentaje de Fondo por Imagen (P_{fondo}) = 87 %, Umbral Mínimo de Filtrado por Tamaño (T_f) = 100.

obtienen mediante un método de cálculo que emplea una regla basada en percentiles motivada empíricamente.

2. **Eliminación de píxeles aislados.** En esta fase se persigue eliminar los píxeles erróneamente clasificados como pertenecientes a un vaso sanguíneo y que habitualmente corresponden a ruido o lesiones vasculares presentes en la imagen original. Para suprimir estos grupos de píxeles separados de la red vascular aprovechamos la característica de conectividad de la misma. Etiquetamos pues las clases de píxeles conectados y quitamos aquellos que no superen un umbral mínimo de tamaño T_f . Este proceso de mejora nos permite ser menos restrictivos en el anterior proceso de segmentación, simplificándose así mismo la parametrización del sistema (podemos emplear un solo conjunto de parámetros).

La configuración de esta herramienta consiste principalmente en los siguientes parámetros:

- **Tamaño de la ventana de filtrado de mediana $W_f \times W_f$:** Determina el grado de suavizado de la imagen para que eliminar el ruido en la fase de preprocesado de la imagen.
- **Porcentaje de la imagen ocupado por vasos sanguíneos P_{vasos} :** Se corresponde con el umbral fuerte de selección empleado en la fase de segmentación y debe ajustarse para seleccionar exclusivamente píxeles pertenecientes a la red vascular y evitar así que se consideren como vasos estructuras debidas al ruido o lesiones .
- **Porcentaje de la imagen ocupado por el fondo P_{fondo} :** Se corresponde con el umbral débil de selección empleado en la fase de segmentación y define la restrictividad en el proceso de clasificación junto con el porcentaje de la imagen ocupado por vasos sanguíneos.
- **Número mínimo de píxeles para el filtrado por tamaño T_f :** Limita la cantidad de estructuras aisladas que serán incluidas en el resultado final durante la fase de eliminación de píxeles aislados para evitar confusiones con lesiones o hemorragias.

En la sección de resultados se detallan los valores concretos de estos parámetros que han sido ajustados considerando las características del conjunto de imágenes sobre el que trabajaremos.

La figura A.7 muestra los resultados de esta segmentación auxiliar que emplearemos en diferentes puntos de nuestra metodología. En lo relativo a la evolución

del contorno, incitará a su expansión, habitualmente guiada por las crestas, a través de los vasos sanguíneos donde estas últimas no hayan podido ser detectadas. Esto se explica en detalle en el capítulo 3 dedicado al modelo desarrollado y su comportamiento. Además, obtendremos los bordes de la segmentación auxiliar resultante y se los añadiremos a la imagen de bordes obtenida desde la fotografía original según se explicó en el apartado anterior. Con esto se consiguen cerrar muchas de las discontinuidades que aparecen frecuentemente en los bordes situados cerca de una intersección o cruce de estructuras vasculares.

A.5. Detección Automática del Disco Óptico

El disco óptico se presenta como un área muy brillante en las retinografías como se muestra en la imagen izquierda de la figura A.8. El disco óptico constituye la región de entrada de los vasos sanguíneos a la retina y se expanden radialmente desde dicho punto. Así pues, constituye un punto de partida ideal para nuestro contorno deformable.

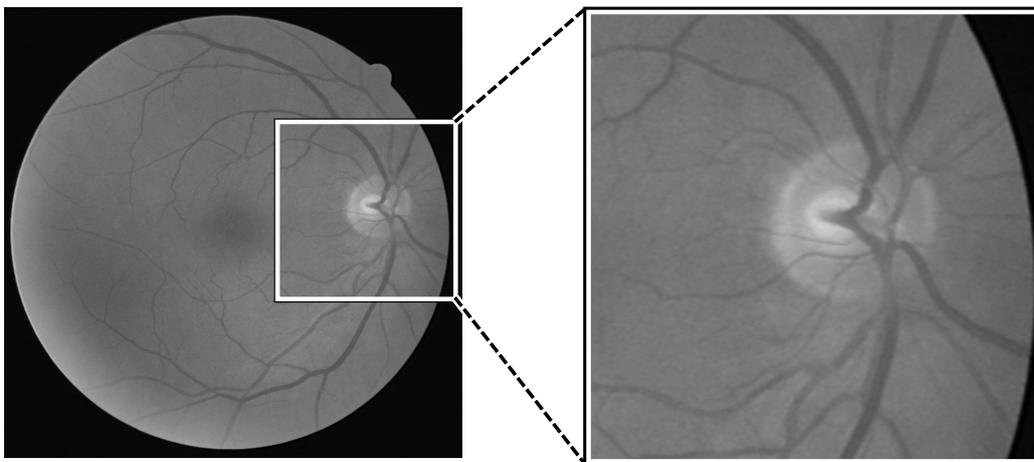


Figura A.8: Localización de la región de interés del disco óptico mediante clusterización. La imagen de la izquierda se corresponde con la retinografía original y la de la derecha con la región de interés que contiene al disco óptico.

La detección automática del disco óptico se realiza mediante el algoritmo desarrollado por nuestro grupo de investigación [BPB⁺06]. Este sistema efectúa la extracción y localización del disco óptico empleando la transformada de Hough circular difusa sobre retinografías. Otras técnicas de extracción desarrolladas presentan una precisión demasiado baja [LBG01] o poseen un coste computacional excesivamente elevado [MHT99][LHS⁺04][CF04].

El proceso de detección empleado consta de dos fases principales: localización de la región de interés y extracción del disco óptico, como se representa en la figura A.9. La localización de la región de interés, es decir, dónde se sitúa el disco óptico, se lleva a cabo mediante un algoritmo de clusterización. A continuación se aplica la transformada de Hough circular difusa a los bordes obtenidos de la región de interés para extraer el disco óptico.

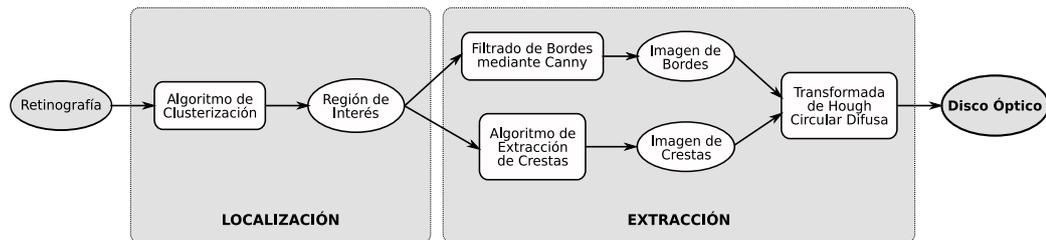


Figura A.9: Fases principales del algoritmo de localización y extracción del disco óptico.

Este sistema aprovecha que la intensidad del disco óptico es mucho mayor que el fondo de la retina. La región de interés se localiza buscando el mayor conjunto de píxeles con los mayores niveles de gris. Se seleccionan primero los píxeles más claros y se agrupan por cercanía mediante un algoritmo de clusterización. Se define para ello un límite de distancia euclídea entre centroides ϵ que determina qué clústeres se agruparán en uno.

Se obtienen así varios clústeres de píxeles con su centroide asociado. De entre ellos, escogemos el clúster que contenga el máximo número de píxeles. La región de interés estará centrada en el centroide de dicho clúster. Las dimensiones del área cuadrada que define la región de interés $m \times n$ se determinan en función de la resolución de la imagen. En la figura A.8 se muestra una retinografía a la izquierda, cuya región de interés detectada aparece ampliada en la parte derecha de la figura.

Una vez obtenida la región de interés, se lleva a cabo la extracción del disco óptico. Dado que el disco óptico presenta una estructura circular, el proceso de extracción consiste básicamente en buscar formas circulares. Para esto se aplica la transformada de Hough circular difusa a los bordes de la región de interés.

La imagen de bordes de la región de interés se obtiene mediante el filtro de Canny [Can86]. La transformada de Hough circular difusa puede no extraer correctamente el disco óptico, ya que hay vasos en su interior. Es necesario pues eliminar de la región de interés los vasos sanguíneos si queremos obtener resultados precisos aplicando dicha transformada. La eliminación de dichos vasos se realiza detectándolos mediante el algoritmo de extracción de crestas descrito en

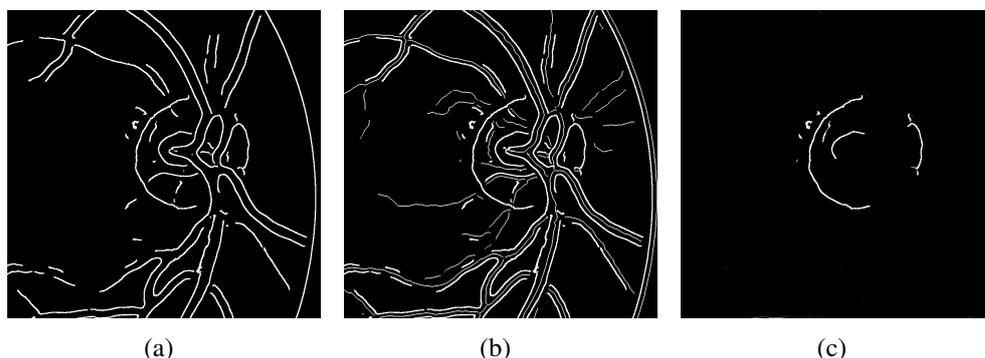


Figura A.10: Eliminación de los bordes correspondientes a vasos sanguíneos en la región de interés: (a) Imagen de bordes original. (b) Imagen de bordes con las crestas añadidas representadas por líneas finas. (c) Imagen de bordes final tras la eliminación de los vasos.

[CPM⁺04]. Una vez obtenida la imagen de crestas, suprimimos aquellos bordes que se encuentren a una determinada distancia de una cresta y además presenten la misma dirección que esta. Esta distancia entre crestas y bordes del vaso viene determinada por el tamaño de la ventana de vecindad $w_a \times w_b$ que se ajusta considerando la anchura de los vasos. En la figura A.10(a) se puede ver la imagen original de bordes a la izquierda y con la imagen de crestas superpuestas en el centro. La figura A.10(c) muestra el resultado de la eliminación de los vasos interiores.

Tras eliminar los bordes de las estructuras vasculares de la región de interés, pasamos a aplicar la transformada de Hough circular difusa [Hou62]. Esta transformada se utiliza habitualmente para la detección de formas geométricas que pueden definirse mediante ecuaciones paramétricas. El proceso consiste en generar un array acumulador que almacena el número de votos que recibe una forma particular.

La transformada de Hough específica para la detección de círculos está basada en la ecuación paramétrica del círculo:

$$(x_i - a)^2 - (y_i - b)^2 = r^2 \quad (\text{A.24})$$

y un array acumulador tridimensional $A(a, b, r)$, siendo (a, b) las coordenadas del centro del círculo y r su radio.

Para reducir su coste computacional se aprovechan las características conocidas del disco óptico. Así, el círculo detectado debe satisfacer unas restricciones en cuanto al radio y la posición dentro de la región de interés. Los radios válidos deben encontrarse en un rango comprendido entre los valores r_{min} y r_{max} que serán

estimados en cada caso a partir del estudio de las dimensiones máximas y mínimas de los discos ópticos del tipo de imágenes sobre el que se trabaja. Se define además el tamaño de la ventana centrada en la región de interés $c_a \times c_b$ en la que debe estar contenido el centro del círculo.

Con el objetivo de generar el array acumulador, se calcula la contribución de cada píxel $p = (x_i, y_i)$ del borde al array acumulador. En primer lugar, se determina el ángulo θ_p a partir del operador de Sobel. Después, se construye el espacio de votación del píxel. La contribución de cada píxel al array acumulador no es homogénea para todo el área de votación, sino que se define por una función gaussiana cuyo decaimiento viene definido por el parámetro β . Tras procesar todos los píxeles del borde, se obtiene finalmente un valor máximo del array acumulador (a, b, r) que corresponde con el disco óptico. Este método se describe en detalle en [BPB⁺06].

Los resultados finales de este sistema fueron evaluados por especialistas en imágenes que no contenían excesivas estructuras vasculares en el interior del disco óptico y en las que no existían patologías de tamaño y nivel medio de gris similar al del disco óptico. Se obtuvo un porcentaje de aciertos casi total: 100 % en localización y 98 % en extracción. En la figura A.11 podemos ver el resultado de detección del disco óptico sobre una angiografía.



Figura A.11: Resultado de la extracción del disco óptico marcado sobre una retinografía original. Los parámetros utilizados son: Límite de Distancia entre Centroides (ϵ) = 350, Tamaño de la Región de Interés ($m \times n$) = 350×350 , Ventana de Vecindad ($w_a \times w_b$) = 6×6 , Radio Mínimo (r_{min}) = 75, Radio Máximo (r_{max}) = 125, Ventana de Centro Válido ($c_a \times c_b$) = 80×80 , Decaimiento de Gaussiana (β) = 10.

Bibliografía

- [Abd01] N. Abdul. *Artery/Vein Classification in Retinal Imagery*. Masters Thesis, Electrical and Computer Engineering Department, Clemson University, 2001.
- [ADR⁺06] E. Alibrahim, K.C. Donaghue, S. Rogers, S. Hing, A. Jenkins, A. Chan, and T. Wong. *Retinal Vascular Caliber and Risk of Retinopathy in Young Patients with Type 1 Diabetes*. *Ophthalmology*, 113:1499–503, 2006.
- [AMDVP07] C. Alonso-Montes, P. Dudek, D. L. Vilarino, and M. G. Penedo. *On Chip Implementation of a Pixel-Parallel Approach for Retinal Vessel Tree Extraction*. 18th European Conference on Circuit Theory and Design ECCTD, 511-514, 2007.
- [BD62] R. Bellman and S. Dreyfus. *Applied Dynamic Programming*. Princeton University Press, 32(4): 399-406, 1962.
- [Ber00] D.P. Bertsekas. *Dynamic Programming and Optimal Control*. Athena Scientific. 2nd Ed, Vols. 1-2, 2000.
- [Bes89] J. Besag. *Towards Bayesian Image Analysis*. *Journal of Applied Statistics*, 16(3):395-407, 1989.
- [BHU00] P. Brigger, J. Hoeg, and M. Unser. *B-Spline Snakes : A Flexible Tool for Parametric Contour Detection*. *IEEE Transactions on Image Processing*, 9(9): 1484-1496, 2000.
- [BPB⁺06] M. Blanco, M.G. Penedo, N. Barreira, M. Penas, and M.J. Carreira. *Localization and Extraction of the Optic Disc using the Fuzzy Circular Hough Transform*. *Artificial Intelligence and Soft Computing*. LNAI 4029:713-721, 2006.

- [CA05] A. P. Condurache and T. Aach. *Vessel Segmentation in Angiograms using Hysteresis Thresholding*. Proceedings of the 9th IAPR Conference on Machine Vision Applications, 269-272, 2005.
- [CAM⁺97] A.C. Clermont, L.P. Aiello, F. Mori, L.M. Ailello, and S.E. Bursell. *Vascular Endothelial Growth Factor and Severity of Non-Proliferative Diabetic Retinopathy mediate Retinal Haemodynamics in Vivo: a Potential Role for Vascular Endothelial Growth Factor in the Progression of Non-Proliferative Diabetic Retinopathy*. American Journal of Ophthalmology, 4(124):433-446, 1997.
- [Can86] J. Canny. *A Computational Approach to Edge-Detection*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 8(6):679-689, 1986.
- [CC93] L. Cohen and I. Cohen. *Finite-element Methods for Active Contour Models and Balloons for 2-D and 3-D Images*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 15(11):1137-1147, 1993.
- [CCK⁺89] S. Chaudhuri, S. Chatterjee, N. Katz, M. Nelson, and M. Goldbaum. *Detection of Blood Vessels in Retinal Images using Two-Dimensional Matched Filters*. IEEE Transactions on Medical Imaging, 8(3): 263-269, 1989.
- [CF04] T. Chanwimluang and G. Fan. *An efficient Algorithm for Extraction of Anatomical Structures in Retinal Images*. IEEE International Conference on Image Processing, 1093-1096, 2004.
- [CIHK96] V. Chalana, D.T. Inker, D.R. Haynor, and Y. Kim. *A Multiple Active Contour Model for Cardiac Boundary Detection on Echocardiographic Sequences*. IEEE Transactions on Medical Imaging, 15(3): 290-298, 1996.
- [CKS97] V. Caselles, R. Kimmel, and G. Sapiro. *Geodesic Active Contours*. International Journal of Computer Vision, 22(1):61-79, 1997.
- [CPB⁺05] I. G. Caderno, M. G. Penedo, N. Barreira, C. Mariño, and F. González. *Precise Detection and Measurement of the Retina Vascular Tree*. Pattern Recognition and Image Analysis: Advances in Mathematical Theory and Applications, 15(2): 523-526, 2005.

- [CPM⁺04] I.G. Caderno, M.G. Penedo, C. Mariño, M.J. Carreira, F. Gómez-Ulla, and F. González. *Automatic Extraction of the Retina AV Index*. Proceedings International Conference in Image Analysis and Recognition, 2:132-140, 2004.
- [CR04] E. Coto and O. Rodríguez. *T-Snakes and the Delaunay Triangulation for generation of anatomical structure meshes suitable for the Finite Element Method*. Actas de Ponencias del Congreso Internacional de Métodos Numéricos en Ingeniería y Ciencias Aplicadas, 11-18, 2004.
- [dJIW⁺07] F.J. de Jong, M.K. Ikram, J.C. Witteman, A. Hofman, P.T. de Jong, and M.M. Breteler. *Retinal vessel diameters and the role of inflammation in cerebrovascular disease*. Annals of Neurology, 61(5):491-495., 2007.
- [ECOP08] L. Espona, M.J. Carreira, M. Ortega, and M.G. Penedo. *Retinal Vessel Tree Segmentation Using a Deformable Contour Model*. 19th International Conference on Pattern Recognition, 2008.
- [ECPO06] L. Espona, M.J. Carreira, M.G. Penedo, and M. Ortega. *Vascular Tree Segmentation in Retinal Angiographies: A Snake Model-Approach*. WSEAS Transactions on Computers, 10(5): 2285-2292, 2006.
- [ECPO08] L. Espona, M.J. Carreira, M.G. Penedo, and M. Ortega. *Comparison of Pixel and Subpixel Retinal Vessel Tree Segmentation using a Deformable Contour Model*. LNCS, 13th Iberoamerican Congress in Pattern Recognition, CIARP, 5197, 683-690, 2008.
- [EDWc89] S.M. Eames, J. Dimmit, J.N. West, and col. *Usefulness of Ophthalmology in Mild to Moderate Hypertension*. Lancet 1: 1103– 1106, 1989.
- [Faw05] T. Fawcett. *An Introduction to ROC Analysis*. Pattern Recognition Letters, 27: 861-874, 2005.
- [Fre07] M. Freire. *Extracción del Árbol Arterio-Venoso del Ojo mediante Técnicas de Procesado Digital de Imágenes*. Proyecto Fin de Carrera Ingeniería Informática. Departamento de Computación, Universidade da Coruña, 2007.

- [GGO00] G. A. Giraldi, L. M. Goncalves, and A. F. Oliveira. *Dual Topologically Adaptable Snakes*. Proceedings of the 5th Joint Conference on Information Sciences (JCIS'2000), (2):103-107, 2000.
- [GMT⁺96] M. Goldbaum, S. Moezzi, A. Taylor, S. Chatterjee, J. Boyd, E. Hunter, and R. Jain. *Automated diagnosis and image understanding with object extraction, object classification, and inferencing in retinal images*. Proceedings International Conference Image Processing, 3:695–698, 1996.
- [GN97] S.R. Gunn and M. S. Nixon. *A Robust Snake Implementation; A Dual Active Contour*. IEEE Transactions Pattern Analysis and Machine Intelligence, 1(19):63-68, 1997.
- [GR03] E. Grisan and A. Ruggeri. *A divide et impera strategy for automatic classification of retinal vessels into arteries and veins*. Proceedings of the 25th Annual International Conference of the IEEE. Engineering in Medicine and Biology Society , 1: 890- 893, 2003.
- [HBKc99] L.D. Hubbard, R.J. Brothers, W.N. King, and col. *Methods for Evaluation of Retinal Microvascular Abnormalities Associated with Hypertension/Sclerosis in the Atherosclerosis Risk in Communities Study*. Ophthalmology, 106:2269–80, 1999.
- [HM82] J.A. Hanley and B.J. McNeil. *The Meaning and Use of the Area under a Receiver Operating Characteristic (ROC) Curve*. Radiology, 143: 29-36, 1982.
- [Hor99] M. S. Horritt. *A statistical active contour model for SAR image segmentation*. Image and Vision Computing 17(3-4): 213-224, 1999.
- [Hou62] P.V.C. Hough. *Method and Means for Recognizing Complex Pattern*. U.S. Patent, 06954, 1962.
- [IdJVc04] M.K. Ikram, F.J. de Jong, J.R. Vingerling, and col. *Are Retinal Arteriolar or Venular Diameters Associated with Markers for Cardiovascular Disorders? The Rotterdam Study*. Investigative Ophthalmology and Visual Science, 45:2129–34, 2004.
- [JM03] X. Jiang and D. Mojon. *Adaptive Local Thresholding by Verification-Based Multithreshold Probing with Application to Vessel Detection in Retinal Images*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 25(1):131-137, 2003.

- [JVGE08] M. Jansa, M. Vidal, R. Gomis, and E. Esmatjes. *La diabetes. Guía Interactiva para Pacientes con Enfermedades de Larga Duración*. Forumclínic. Fundación BBVA. [http : //www.forumclinic.org/enfermedades/la – diabetes/archivospdf/es.pdf](http://www.forumclinic.org/enfermedades/la-diabetes/archivospdf/es.pdf), 2008.
- [KHS75] E.M. Kohner, A.M.P. Hamilton, and S.J. Saunders. *The Retinal Blood Flow in Diabetes*. *Diabetologia*, 11:27-33, 1975.
- [KKM⁺06] R. Klein, B.E.K. Klein, S.E. Moss, T.Y. Wong, and A. R. Sharrett. *Retinal vascular caliber in persons with type 2 diabetes : The wisconsin epidemiological study of diabetic retinopathy: XX*. *Ophthalmology*, 113(9):1488-1498, 2006.
- [KKMc07] S. Kaushik, A. Kifley, P. Mitchell, and col. *Age, Blood Pressure, and Retinal Vessel Diameter: Separate Effects and Interaction of Blood Pressure and Age*. *Investigative Ophthalmology and Visual Science*, 48:557–61, 2007.
- [KLA97] A.K. Klein, F. Lee, and A.A. Amini. *Quantitative Coronary Angiography with Deformable Spline Models*. *IEEE Transactions on Medical Imaging*, 16(5): 468-482, 1997.
- [KQ04] C. Kirbas and F. Quek. *A Review of Vessel Extraction Techniques and Algorithms*. *ACM Computing Surveys* 36:81-121, 2004.
- [KTKS00] I. Kompatsiaris, D. Tzovaras, V. Koutkias, and M. G. Strintzis. *Deformable boundary detection of stents in angiographic images*. *IEEE Transactions on Medical Imaging*, 19:652-661, 2000.
- [KWT88] M. Kass, A. Witkin, and D. Terzopoulos. *Active Contour Models*. *International Journal of Computer Vision*, 1(2):321-331, 1988.
- [LBG01] M. Lalonde, M. Beaulieu, and L. Gagnon. *Fast and robust Optic Disc Detection using Pyramidal Composition and Hausdorff-based Template Matching*. *IEEE Transactions on Medical Imaging*, 20: 1193-1200, 2001.
- [LGB00] M. Lalonde, L. Gagnon, and M.C. Boucher. *Non-Recursive Paired Tracking for Vessel Extraction from Retinal Images*. *Proceedings of Conference Vision Interface*, 2000.
- [LHLW03] H. Li, W. Hsu, M.L. Lee, and H. Wang. *A piecewise Gaussian model for profiling and differentiating retinal vessels*. *Proceedings*

- of the International Conference on Image Processing(ICIP 2003), 1: 1069-72, 2003.
- [LHS⁺04] J. Lowell, A. Hunter, D. Steel, A. Basu, R Ryder, E. Fletcher, and L. Kennedy. *Optic Nerve Head Segmentation*. IEEE Transactions on Medical Imaging, 23: 256-264, 2004.
- [LL02] Y. Lee and S. Lee. *Geometric Snakes for Triangular Meshes*. Computer Graphics Forum (Eurographics 2002), 21(3): 229–238, 2002.
- [MC06] A.M. Mendoça and A. Campilho. *Segmentation of Retinal Blood Vessels by Combining the Detection of Centerlines and Morphological Reconstruction*. IEEE Transactions on Medical Imaging, 25(9):1200-1213, 2006.
- [MH80] D. Marr and E. Hildreth. *Theory of Edge Detection*. Proceedings of Roy. Soc. Lonfon, B.207: 187-217, 1980.
- [MHT99] F. Mendels, C. Henegahan, and J.P. Thiran. *Identification of the Optic Disc Boundary in Retinal Images using Active Contours*. Proceedings of the Irish Machine and Image Processing Conference, 103-105, 1999.
- [Mor02] S. Morris. *Pathway Extraction using Snakes with GPS Initialization*. 2nd International Conference on Geographic Information Science, 257-260, 2002.
- [MPHS⁺99] M. Martínez-Pérez, A. Hughes, A. Stanton, S. Thom, A. Bharath, and K. Parker. *Scale-space Analysis for the Characterisation of Retinal Blood Vessels*. Medical Image Computing and Computer-Assisted Intervention (MICCAI'99), 90-97, 1999.
- [MPP⁺06] C. Mariño, M. G. Penedo, M. Penas, M. J. Carreira, and F. Gonzalez. *Personal authentication using digital retinal images*. Pattern Analysis and Applications, 9:21–33, 2006.
- [MT96] T. McInerney and D. Terzopoulos. *Deformable Models in Medical Image Analysis: a Survey*. Medical Image Analysis, 1(2):91-108, 1996.
- [N06] M. Niemeijer. *Automatic Detection of Diabetic Rethinopatý in Digital Fundus Photographs*. PhD Thesis. Image Sciences Institute, University Medical Center Utrecht, 2006.

- [NS95] R. Nekovei and Y. Sun. *Back-Propagation Network and its Configuration for Blood Vessel Detection in Angiograms*. IEEE Transactions on Neural Networks, 6(1):64-72, 1995.
- [NSvG⁺04] M. Niemeijer, J. Staal, B. van Ginneken, M. Loog, and M.D. Abràmoff. *Comparative Study of Retinal Vessel Segmentation Methods on a new Publicly Available Database*. Proceedings of the SPIE. Medical Imaging 2004: Image Processing, 5370:648-656, 2004.
- [NvG02] M. Niemeijer and B. van Ginneken. *Digital Retinal Images for Vessel Extraction: DRIVE Database*. <http://www.isi.uu.nl/Research/Databases/DRIVE/>, 2002.
- [NWS⁺08] T.T. Nguyen, J.J. Wang, A.R. Sharrett, F.M. Islam, R. Klein, B.E. Klein, M.F. Cotch, and T.Y. Wong. *Relationship of retinal vascular caliber with diabetes and retinopathy: the Multi-Ethnic Study of Atherosclerosis (MESA)*. Diabetes Care, 31(3):544-549, 2008.
- [OMP⁺06] M. Ortega, C. Mariño, M. G. Penedo, M. Blanco, and F. González. *Personal Authentication based on Feature Extraction and Optic Nerve Location in Digital Retinal Images*. WSEAS Transactions on Computers, 5(6):1169-1176, 2006.
- [OPEG07] M. Ortega, M. G. Penedo, L. Espona, and F. González. *Biometric Authentication Based on Feature Extraction in Digital Retinal Images*. 1st Spanish Workshop on Biometrics (SWB 07), 2007.
- [PAM⁺05] N. Patton, T. Aslam, T. MacGillivray, A. Pattie, I. Deary, and B. Dhillon. *Retinal vascular image analysis as a potential screening tool for cerebrovascular disease: a rationale based on homology between cerebral and retinal microvasculatures*. Journal of Anatomy, 206(4):319-348, 2005.
- [PC02] H.K. Park and M.J. Chung. *A New External Force for Active Contour Model: Virtual Electric Field*. Proceedings of IASTED International Conference on Visualization, Imaging and Image Processing, 103-106, 2002.
- [Peñ00] A.M.L. Peña. *Multilocal Methods for Ridge and Valley Delineation Analysis*. PhD. Thesis, Universitat Autònoma de Barcelona, 2000.

- [PKT83] J.A. Parker, R.V. Kenyon, and D.E. Troxel. *Comparison of Interpolating Methods for Image Resampling*. IEEE Transactions on Medical Imaging, 2(1): 31-9, 1983.
- [PTBLK05] T.D. Phaml, D. T. Tran, M. Brown, and R. Lee Kennedy. *Image Segmentation of Retinal Vessels by Fuzzy Models*. Proceedings of International Symposium on Intelligent Signal Processing and Communication Systems, 2005.
- [QJ03] P. Quelhas and B. James. *Vessel segmentation and branching detection using an adaptive profile Kalman filter in retinal blood vessel structure analysis*. Lecture Notes in Computer Ccience, 2652: 802-809, 2003.
- [RAH97] P. Radeva, A. A. Amini, and J. Huang. *Deformable B-solids and implicit snakes for 3D localization and tracking of SPAMM MRI data*. IEEE/SIAM Joint Workshop on Mathematical Methods in Biomedical Image Analysis. Computer Vision and Image Understanding, 66(2): 95-254, 1997.
- [RB96] D. Rueckert and P. Burguer. *A Multiscale Approach to Contour Fitting for MR Images*. Technical report, Imperial College of Science, Technology and Medicine, 1996.
- [RML98] U. Rost, H. Munkel, and C.-E. Liedtke. *Knowledge-Based Configuration of Image Processing Algorithms*. Proceedings International Conference on Computational Intelligence and Multimedia Applications (ICCIMA'98), 180-185, 1998.
- [RSM95] P. Radeva, J. Serrat, and E. Marti. *A Snake for Model Based Segmentation*. Proceedings of IEEE International Conference on Computer Vision (ICCV'95), 816-21, 1995.
- [SAN⁺04] J.J. Staal, M.D. Abramoff, M. Niemeijer, M.A. Viergever, and B. van Ginneken. *Ridge Based Vessel Segmentation Iin Color Images of the Retina*. IEEE Transactions on Medical Imaging, 23(4):501-509, 2004.
- [SD89] L.H. Staib and J.S. Duncan. *Parametrically deformable contour models*. IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'89), 98-103, 1989.

- [SLCJ⁺06] J.V.B. Soares, J.J.G. Leandro, R.I.M. Cesar Jr., H.F. Jelinek, and M.J. Cree. *Retinal Vessel Segmentation Using the 2-D Gabor Wavelet and Supervised Classification*. IEEE Transactions on Medical Imaging, 25(9): 1214-1222, 2006.
- [SLLV00] J. Serrat, A. López, D. Lloret, and L. Villanueva. *Multilocal Creaseness based on Extrinsic Curvature*. Computer Vision and Image Understanding, 77:111-114, 2000.
- [SLW⁺08] C. Sun, G. Liew, J.J. Wang, P. Mitchell and S.M. Saw, T. Aung, E.S. Tai, and T.Y. Wong. *Retinal Vascular Caliber, Blood Pressure, and Cardiovascular Risk Factors in an Asian Population: The Singapore Malay Eye Study*. Investigative Ophthalmology and Visual Science, 49:1784-1790, 2008.
- [Sto94] G. Storvik. *A Bayesian Approach to Dynamic Contours Through Stochastic Sampling and Simulated Annealing*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 16(10):976-986, 1994.
- [SWWc04] W. Smith, J.J. Wang, T.Y. Wong, and col. *Retinal Arteriolar Narrowing is Associated with 5-Year Incident Severe Hypertension: The Blue Mountains Eye Study*. Hypertension, 44:442-7, 2004.
- [SZG06] S.Huang, M. Zhou, and G. Geng. *An Improved Geometric Deformable Model for Color Image Segmentation*. IEEE Proceedings of the International Conference on Artificial Reality and Telexistence, 513-517, 2006.
- [Ter87] D. Terzopoulos. *On Matching Deformable Models to Images: Direct and Iterative Solutions*. Topical Meeting on Machine Vision, Optical Society of America, Technical Digest Series, 1:160-167, 1987.
- [TM00] D. Terzopoulos and T. McInerney. *T-Snakes: Topology Adaptive Snakes*. Medical Image Analysis, 4(2):73-91, 2000.
- [TOB⁺00] R. Toledo, X. Orriols, X. Binefa, P. Redeva, J. Vitriá, and J.J. Villanueva. *Tracking Elongated Structures using Statistical Snakes*. Proceedings IEEE Conference on Computer Vision and Pattern Recognition, 1(1):157-162, 2000.

- [TP98] Y. A. Tolias and S. M. Panas. *A fuzzy vessel tracking algorithm for retinal images based on fuzzy clustering*. IEEE Transactions on Medical Imaging, 17(2):263–273, 1998.
- [UPPJ04] U. Uludag, S. Pankanti, S. Prabhakar, and A. K. Jain. *Biometric cryptosystems: issues and challenges*. Proceedings IEEE, 92: 948–960, 2004.
- [VVL⁺04] K. A. Vermeer, F. M. Vos, H. G. Lemij, , and A. M. Vossepoel. *A model based method for retinal blood vessel detection*. Computers in Biology and Medicine, 34(3): 209–219, 2004.
- [WKK⁺03] T.Y. Wong, R. Klein, B.E.K. Klein, S.M. Meuer, and L.D. Hubbard. *Retinal Vessel Diameters and Their Associations with Age and Blood Pressure*. Investigative Ophthalmology and Visual Science, 44:4644-4650, 2003.
- [WKK⁺06] T.Y. Wong, A. Kamineni, R. Klein, S.A. Richey, B.E. Klein, D.S. Siscovick, Cushman M., and Duncan B.B. *Quantitative retinal venular caliber and risk of cardiovascular disease in older persons: The cardiovascular health study*. Archives of internal medicine, 166(21):2388-2394, 2006.
- [WKS_c02] T.Y. Wong, R. Klein, A.R. Sharrett, and col. *Retinal Arteriolar Narrowing and Risk of Diabetes Mellitus in Middle-Aged Persons*. Journal of the American Medical Association, 287:2528–33, 2002.
- [WT06] Y. Wang and E.K. Teoh. *Object Contour Extraction Using Adaptive B-Snake Model*. Journal of Mathematical Imaging and Vision, 24(3): 295–306, 2006.
- [XAYP00] C. Xu, Jr. A. Yezzi, and J. L. Prince. *On the Relationship between Parametric and Geometric Active Contours*. Proceedings of 34th Asilomar Conference on Signals, Systems, and Computers, 483-489, 2000.
- [XP97] CY. Xu and J. L. Prince. *Gradient Vector Flow: A New External Force for Snakes*. IEEE Proceedings of Conference on Computer Vision Pattern Recognition (CVPR'97), 66-71, 1997.
- [XP98] CY. Xu and J. L. Prince. *Generalized gradient vector flow external forces for active contours*. Signal Processing, 71:131-139, 1998.

- [ZQ00] X.C. Zhao and F.H. Qi. *Automatic image segmentation based on deformable models and pixel affinity statistic*. Journal of Infrared and Millimeter Waves, 19: 33-3, 2000.