



CIMAT

Centro de Investigación en Matemáticas, A.C.

MÉTODO PARA LA DETECCIÓN DE VELLOS Y VASOS CAPILARES EN IMÁGENES DERMATOSCÓPICAS

T E S I S

Que para obtener el grado de

**Maestro en Ingeniería
De Software**

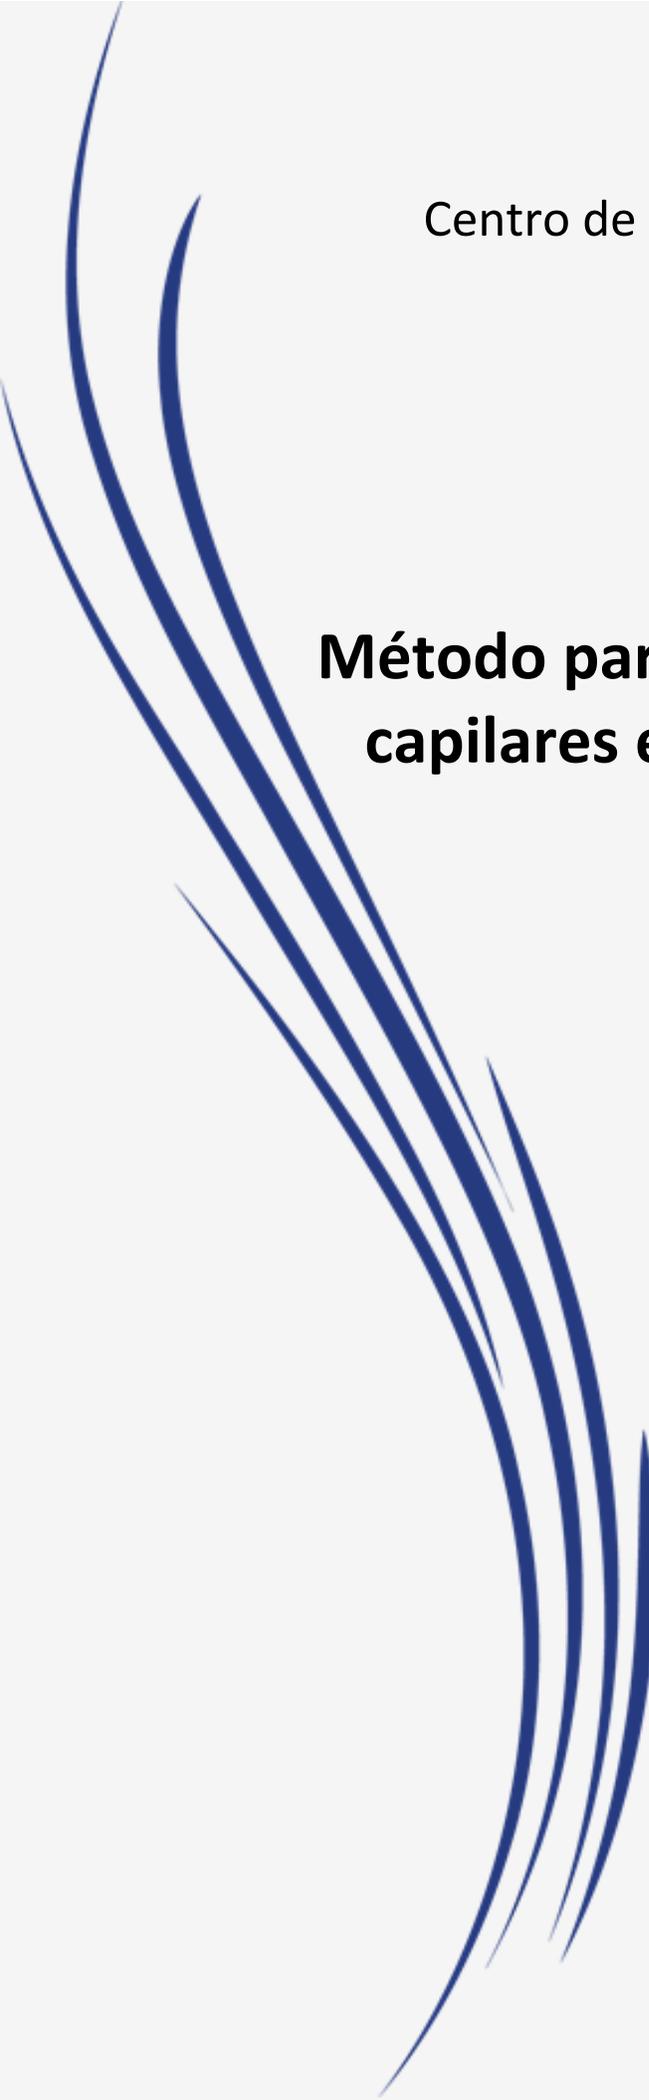
Presenta

Angel Gustavo Lázaro Sánchez

Director de Tesis:

Dr. Carlos Alberto Lara Álvarez

Autorización de la versión final



Centro de Investigación en Matemáticas A.C.

Método para la detección de vellos y vasos capilares en imágenes dermatoscópicas

TESIS

Que para obtener el grado de
Maestro en Ingeniería de Software

Presenta

Angel Gustavo Lázaro Sánchez

Director de Tesis:

Dr. Carlos Alberto Lara Álvarez

CENTRO DE INVESTIGACIÓN EN MATEMÁTICAS A.C.

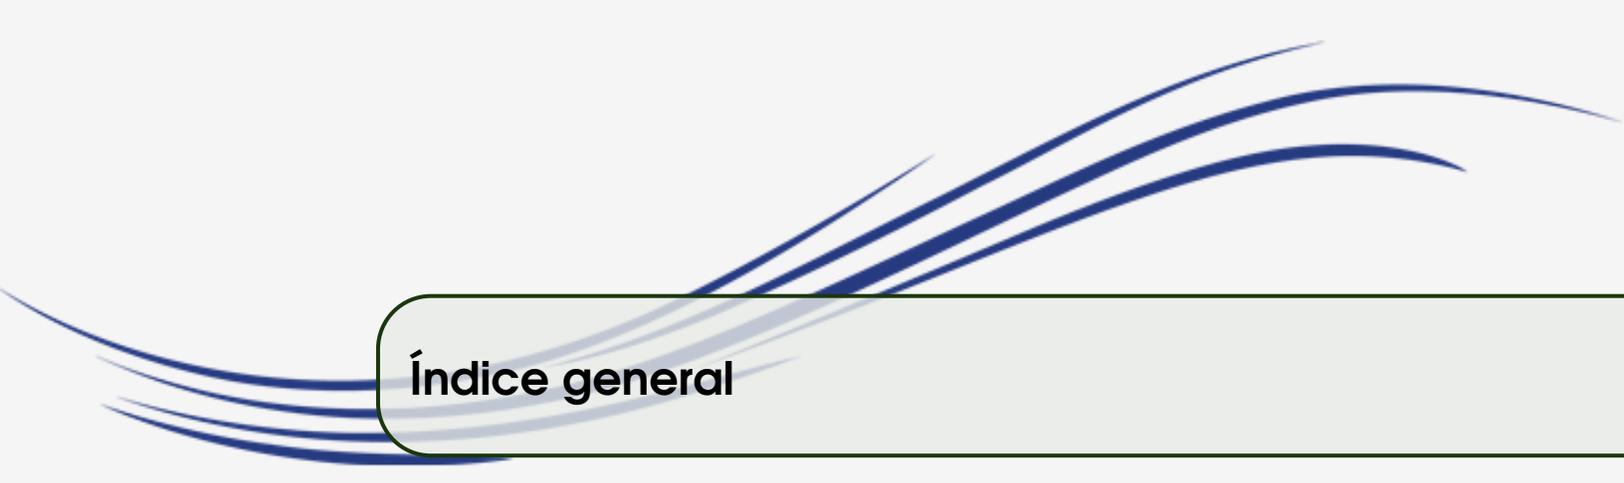
UNIDAD ZACATECAS

Agradecimientos

Antes que nada, agradezco a Dios por su infinita generosidad y a mis padres por ser promotores incondicionales de mis sueños.

También quiero extender mis agradecimientos a los docentes del Centro de Investigación en Matemáticas Unidad Zacatecas, en especial a mi director de tesis Dr. Carlos Alberto Lara Álvarez ya que gracias a su confianza, paciencia y enseñanzas logré concluir la presente tesis.

Finalmente, agradezco al CIMAT Unidad Zacatecas por su calidez humana y al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la financiación de mi postgrado.



Índice general

Índice de figuras	XIII
Índice de Algoritmos	XV
Índice de tablas	XVII
Resumen	XIX
Abstract	XXI
1 Introducción	1
1.1 Justificación	3
1.2 Objetivos	4
1.3 Alcances y limitaciones	4
1.4 Hipótesis	5
1.5 Preguntas de investigación	5
1.6 Narrativa por capítulos	5
2 Estado del arte	7
2.1 Método DullRazor	7

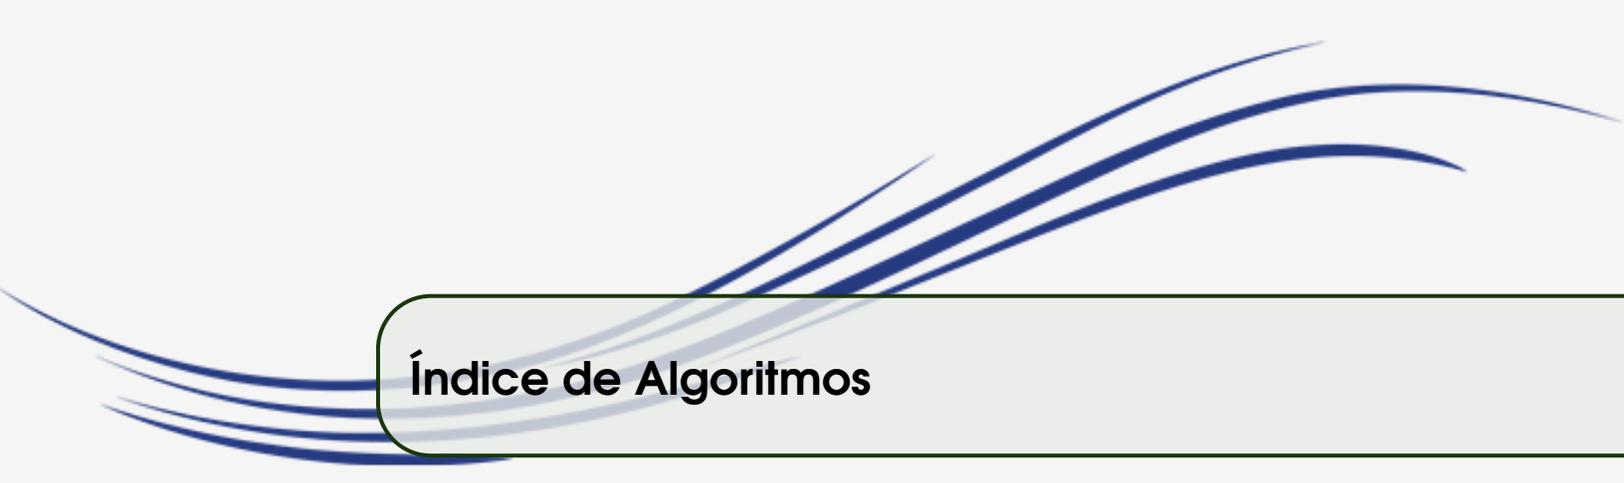
2.2	Método E-shaver	9
2.3	Método basado en la derivada de la función Gaussiana	9
2.4	Resumen de métodos	10
3	Marco teórico	11
3.1	Procesamiento de imágenes	11
3.1.1	Proceso de filtrado	12
3.1.2	Núcleo	12
3.1.3	Convolución	13
3.2	Tipos de imágenes digitales	15
3.3	Espacios de colores	15
3.3.1	Espacio de color RGB	16
3.3.2	Espacios de color basados en el círculo de color de Newton	17
3.3.3	Espacios de color CIE	17
3.4	Operaciones morfológicas	19
3.4.1	Operaciones con imágenes binarias	20
3.4.2	Operaciones con imágenes en escala de grises	25
4	Enfoque propuesto	31
5	Pruebas y resultados	39
5.1	Datos de prueba	39
5.2	Detalles de configuración para la obtención de máscaras con el método DullRazor	40
5.3	Métricas	40

5.4	Análisis estadístico	42
5.5	Resultados del experimento	42
5.6	Conclusiones	42
6	Conclusión y trabajo futuro	43
6.1	Discusión	43
6.2	Conclusiones	44
6.3	Trabajo futuro	44
	Bibliografía	a
	Glosario	e

Índice de figuras

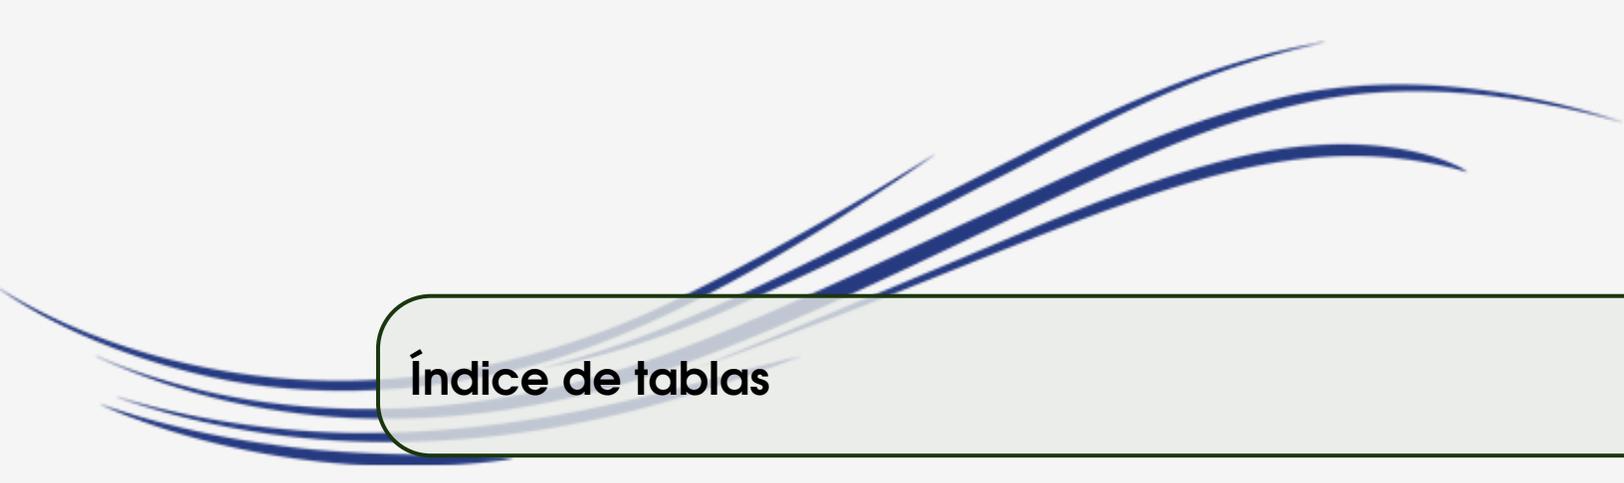
2.1	Errores comunes en la detección de objetos con el método DullRazor	8
3.1	Ejemplo de convolución	14
3.2	Cálculos aritméticos de la convolución	14
3.3	Espacio de color RGB	16
3.4	Espacio de color CIE XYZ	18
3.5	Ejemplo de Erosión binaria	20
3.6	Cálculo de la Erosión binaria	21
3.7	Ejemplo de Dilatación binaria	22
3.8	Cálculo de la Apertura binaria	23
3.9	Ejemplo de Apertura binaria	23
3.10	Cálculo del Cierre binario	24
3.11	Ejemplo de Cierre binario	25
3.12	Ejemplo de la Dilatación en escala de grises	26
3.13	Cálculo de la Dilatación en escala de grises	27
3.14	Ejemplo de Erosión en escala de grises	28
3.15	Cálculo de la Erosión en escala de grises	28
4.1	Kernel DoG que se usa en el método propuesto	32
4.2	Ejemplo de la aplicación del método propuesto a una imagen dermatoscópica para encontrar objetos no deseados	34

5.1 Comparación de resultados obtenidos por el método DullRazor y el método
propuesto 41



Índice de Algoritmos

1	Creación de máscara binaria con el método DullRazor	8
2	Creación de la máscara binaria con el método propuesto	36
3	Refinamiento de los objetos con el método propuesto	38



Índice de tablas

4.1	Promedios de la medida F_1 , con diferentes valores para σ_1 y σ_2	33
4.2	Comparación de promedios de la medida F_1 , con diferentes valores de umbralización	33

Resumen

La eliminación de estructuras no deseadas (v.g., vellos y vasos capilares) es un proceso importante para mejorar la detección de enfermedades y lesiones de la piel mediante imágenes dermatoscópicas. Existen técnicas basadas en operaciones morfológicas que no logran detectar todas las estructuras no deseadas, debido a la cantidad limitada de elementos estructurantes que usan. Inicialmente, la técnica propuesta aplica una convolución con un núcleo de Diferencia de Gaussianas (DoG, del inglés *Difference of Gaussians*) para encontrar objetos lineales; por lo general, esta convolución solo encuentra porciones de las estructuras. Para encontrar los objetos completos, la técnica propuesta aplica a cada objeto por separado múltiples convoluciones con núcleos de diferentes parámetros. El método propuesto se compara con el método DullRazor, para ello, se generaron manualmente máscaras binarias que indican dónde se encuentran las estructuras no deseadas en las imágenes dermatoscópicas. Éstas imágenes pertenecen a la base de datos PH² adquiridas en el Hospital de Pedro Hispano. Los resultados muestran que el método propuesto (con una medida F_1 de 0.6912) supera al método DullRazor (con una medida F_1 de 0.3675).

Palabras clave: Imágenes dermatoscópicas, detección de vellos, cáncer de piel, kernel DoG, segmentación con vellos, preprocesamiento de imágenes.

Abstract

Removing hairs and capillaries is an important stage to improve detection of diseases from dermoscopic images. There are techniques based on morphological operations that omit unwanted objects because they use a limited number of angles in their fixed-size structuring elements. The proposed technique applies a convolution with a difference of Gaussians (DoG) kernel to find linear objects; usually, the initial convolution only finds portions of the unwanted objects. To find complete objects, the proposed approach applies localized convolutions by varying the DoG parameters, in such way that missing pixels are found. The proposed method was compared with the well-known DullRazor method. To do this dermoscopic images were marked manually to obtain the ground truth. The images are from the PH² dataset acquired at Pedro Hispano Hospital. Results show that the proposed approach (which achieves an F_1 -measure of 0.6912) outperforms the DullRazor method (which achieves an F_1 -measure of 0.3675).

Keywords: Dermoscopic images, hair detection, skin cancer, DoG kernel, Hair segmentation, image preprocessing.

1. Introducción

Según la Sociedad Americana contra el Cáncer (American Cancer Society, 2018), el cáncer de piel es una de las enfermedades con mayor incidencia en Estados Unidos. Éste es por mucho, el más común entre todos los tipos de cáncer.

En México, Rodrigo Roldán Marín, director de la Clínica de Oncodermatología de la Facultad de Medicina de la UNAM, afirma, que el cáncer de piel es el segundo tipo de cáncer más frecuente en México (UNAM DGCS, 2018). Existen dos grupos de cáncer de piel, el melanoma y el tipo no melanoma, siendo el primero el más agresivo y que a pesar de los avances que se han tenido en cuanto a tratamientos, lo único que ayuda es la detección en etapas tempranas.

Si el melanoma se detecta en etapas tempranas, la tasa de supervivencia a 5 años de los pacientes es de 98%. Si éste se disemina a un ganglio linfático, la tasa de supervivencia se reduce a 62% (Richter and Khoshgofaar, 2017). Por lo tanto, la detección y el tratamiento en etapas tempranas juega un papel crucial para reducir la tasa de mortalidad causada por este padecimiento.

La detección temprana de melanoma consiste en inspeccionar la piel y reconocer posibles lesiones problemáticas que requieran intervención (Weinstock, 2006). Rayner et al (2018) indican que los métodos que se utilizan en la detección temprana de melanoma son: 1) la examinación de la piel, que consiste en la revisión a simple vista de la superficie de la piel por un médico o por el mismo paciente; 2) la Dermatoscopia, es una técnica no invasiva que permite al médico realizar un examen microscópico en las lesiones de la piel que no se ven

Capítulo 1. Introducción

a simple vista (Vestergaard et al, 2008); y 3) El mapeo corporal digital, éste es un método práctico para detectar nuevas lesiones y su evolución (Benvenuto-Andrade et al, 2005).

La principal ventaja de la examinación de la piel es la facilidad con la que se realiza (Wurm and Soyer, 2010); sin embargo, el beneficio depende de la experiencia del examinante (Piccolo et al, 2002).

La precisión del diagnóstico mediante la dermatoscopia es mayor que con la examinación a simple vista cuando se realiza en el entorno clínico (Vestergaard et al, 2008). Por otro lado, el seguimiento en el mapeo corporal digital detecta cambios sutiles en nevos que son indetectables por otros métodos (Feit et al, 2004). Sin embargo, en el caso de lesiones nodulares no debería realizarse el seguimiento, ya que si son malignos, éstos tienden a crecer más rápido que otro tipo de melanoma y pequeños retardos en el tratamiento pueden incrementar el riesgo de una prognosis pobre (Wurm and Soyer, 2010).

En la actualidad existen sistemas automatizados que realizan diagnósticos de manera parcial o total mediante la interpretación de contenido multimedia (v.g., imágenes, audio). A estos procedimientos se les conoce como *Diagnóstico Asistido por Computadora* (CAD, del inglés *Computer-Aided Diagnosis*).

El CAD de enfermedades en la piel es una línea de investigación importante en la imagen médica que es especialmente valioso en comunidades en donde se dificulta la presencia de dermatólogos de tiempo completo (Fornaciali et al, 2014). Aunque el CAD ha adquirido mucha importancia, existen pocos sistemas que realizan el diagnóstico de melanoma en etapas tempranas con total independencia. Estos sistemas tiene una tendencia a sobre-diagnosticar el melanoma (Wurm and Soyer, 2010).

El proceso general del CAD (Wighton et al, 2011) en enfermedades de la piel consiste en: i) adquirir imágenes, ii) aplicar filtros, iii) segmentar la lesión, iv) extraer características, y v) clasificar. La segunda fase, la aplicación de filtros, tiene como objetivo eliminar ruido y objetos no deseados (v.g., vellos y vasos capilares) que ocultan características

relevantes en las imágenes. La eliminación de objetos no deseados es importante debido a que éstos pueden afectar la adecuada realización de los procesos posteriores, especialmente la segmentación.

Existen diversos métodos para eliminar objetos no deseados; sin embargo, son poco eficientes. Los problemas que presentan son: 1) la detección incompleta de estructuras no deseadas, 2) la omisión de estructuras no deseadas, 3) la agregación de nuevos ruidos y 4) la eliminación de características propias de la lesión.

Esta tesis propone un nuevo método que detecta vellos, vasos capilares y lesiones de una manera más eficiente que otros métodos propuestos con anterioridad. Esto se logra mejorando la identificación de objetos; permitiendo marcar objetos no deseados y descartar aquellos que forman parte de las características propias de las lesiones.

1.1 Justificación

La importancia de la detección de melanoma en etapas tempranas es crucial para disminuir la mortalidad de los pacientes que lo padecen sin embargo, en muchos casos no es posible contar con dermatólogos de tiempo completo para llevar a cabo exámenes de piel. Por otro lado, los métodos de diagnóstico total asistidos por computadora de melanoma en etapas tempranas no son suficientemente eficientes.

Una manera de lograr mejores resultados en la detección de este padecimiento es aumentar la precisión y exhaustividad en los procesos primarios del proceso general del CAD de enfermedades de la piel; como es el caso del preprocesamiento de imágenes para la detección de cáncer en la piel. Mejorando la detección de objetos, se pueden eliminar los objetos no deseados y preservar las características propias de la lesión eficientemente.

1.2 Objetivos

El objetivo general de esta tesis es desarrollar una nueva técnica para mejorar la precisión en la eliminación de objetos no deseados respecto a las técnicas existentes.

Para abordar el objetivo general se plantearon los siguientes objetivos específicos:

- Revisar el estado del arte mediante una búsqueda sistemática de artículos relevantes en la detección de cáncer de piel mediante imágenes.
- Identificar los procesos que se llevan a cabo en la detección de cáncer de piel.
- Clasificar y evaluar las técnicas usadas en éstos artículos.
- Diseñar y desarrollar una nueva técnica para lograr una mejor precisión respecto a las técnicas existentes.

1.3 Alcances y limitaciones

A continuación se describe el alcance del método propuesto en la tesis con la finalidad de delimitar su funcionamiento:

- Dada una imagen dermatoscópica, se realiza la detección de vellos y vasos capilares. El resultado es una imagen binaria con 1's en los pixeles de los objetos detectados y 0's en los pixeles de las áreas que se omiten.

Para la correcta detección de vellos y vasos capilares se consideran las siguientes limitaciones:

- Uso de imágenes dermatoscópicas con resolución de 768×560 pixeles.
- Los pixeles de la piel en la vecindad de los pixeles de los vellos o vasos capilares son más claros que la de éstos.

1.4 Hipótesis

Se puede desarrollar un método que detecte vellos y vasos capilares, y omita las características propias de las lesiones de manera más eficiente que los métodos propuestos anteriormente.

1.5 Preguntas de investigación

Las preguntas que propiciaron esta investigación son:

- P1** ¿Cuáles son los procesos que se llevan a cabo en la detección de cáncer de piel?
- P2** ¿Cuáles son las técnicas existentes de preprocesamiento de imágenes para la detección de cáncer en la piel?
- P3** ¿En qué consisten las técnicas propuestas anteriormente?
- P4** ¿Cómo se puede mejorar la detección de los objetos de las técnicas propuestas anteriormente?

1.6 Narrativa por capítulos

El resto de esta tesis se organiza de la siguiente manera: El Capítulo 2 consiste en describir el estado del arte (métodos utilizados para llevar a cabo el preprocesamiento en la detección de cáncer de piel). En el Capítulo 3 se exponen diversos temas que conforman el marco teórico. En el Capítulo 4 se presenta la propuesta de detección de artefactos no deseados. El Capítulo 5 describe cómo se llevo a cabo la comparación del método propuesto con el método DullRazor. Finalmente, en el Capítulo 6 se presentan las conclusiones y trabajo futuro.

2. Estado del arte

El preprocesamiento es una etapa importante para el CAD del melanoma que consiste en transformar la imagen con el objetivo de mejorarla para el proceso siguiente. Una de las tareas con mayor importancia en el preprocesamiento de imágenes para la detección de melanoma es eliminar todos aquellos objetos que ocultan información de la lesión tales como los bordes y la textura. Para eliminar de manera eficiente los objetos no deseados, es necesario detectarlos. A continuación se describen los principales métodos de detección de objetos no deseados.

2.1 Método DullRazor

Existen muchos métodos que eliminan objetos no deseados; por ejemplo, DullRazor (Lee et al, 1997) es un método muy conocido basado en operaciones morfológicas. Este método utiliza imágenes dermatoscópicas en el espacio de color RGB.

El algoritmo 1 muestra el proceso que se lleva en DullRazor para obtener la máscara binaria de vellos. Como primer paso, se separan los componentes RGB de la imagen (línea 1). Posteriormente, a cada componente se le aplica tres operaciones morfológicas de cierre; cada operación con un elemento estructurante distinto (en 0° , 45° y 90°). Se selecciona el resultado que provea la máxima respuesta (línea 2). Después, se obtiene la diferencia entre el resultado máximo obtenido y su correspondiente componente (línea 3). Esta diferencia se binariza con un parámetro de umbral predefinido (línea 4) y finalmente se unen las tres máscaras binarias resultantes (línea 5). Finalmente, el método realiza la selección de los

Capítulo 2. Estado del arte

Data: \mathcal{I}_{rgb} , una imagen rgb; \mathcal{S}_0 , \mathcal{S}_{45} y \mathcal{S}_{90} , elementos estructurantes en 0° , 45° y 90° respectivamente; \mathcal{T} , un parámetro de umbralización para binarizar

Result: \mathcal{B}_f , una máscara binaria

- 1 $[\mathcal{C}_r, \mathcal{C}_g, \mathcal{C}_b] \leftarrow$ obtener el componente rojo, verde y azul de \mathcal{I}_{rgb} ;
- 2 $[\mathcal{M}_r, \mathcal{M}_g, \mathcal{M}_b] \leftarrow$ obtener la máximas respuestas de la operaciones de Cierre entre \mathcal{C}_r , \mathcal{C}_g y \mathcal{C}_b , y los elementos estructurantes \mathcal{S}_0 , \mathcal{S}_{45} y \mathcal{S}_{90} ;
- 3 $[\mathcal{D}_r, \mathcal{D}_g$ y $\mathcal{D}_b] \leftarrow$ obtener las diferencias entre \mathcal{C}_r y \mathcal{M}_r , \mathcal{C}_g y \mathcal{M}_g , y \mathcal{C}_b y \mathcal{M}_b ;
- 4 $[\mathcal{B}_r, \mathcal{B}_g, \mathcal{B}_b] \leftarrow$ binarizar \mathcal{D}_r , \mathcal{D}_g y \mathcal{D}_b con el parámetro \mathcal{T} ;
- 5 $\mathcal{B}_f \leftarrow$ obtener la máscara de vellos mediante la unión de \mathcal{B}_r , \mathcal{B}_g y \mathcal{B}_b ;

Algoritmo 1: Creación de máscara con DullRazor



Figura 2.1: Errores de detección de objetos con el método DullRazor. (a) imagen original, (b) errores de detección de objetos no deseados con el método DullRazor.

objetos que prevalecen en la máscara.

La complejidad temporal del método es reducida, porque las operaciones morfológicas de cierre que se aplican a los componentes de la imagen utilizan pocos elementos estructurantes; sin embargo, en cada componente solo se utiliza uno de los resultados (el que aporta mayor respuesta). En muchos casos, ésto no es suficiente para cubrir por completo todas las orientaciones de los artefactos. Este método presenta otro problema cuando los objetos

están en áreas con tonalidades similares; en estas condiciones los objetos son indetectables por DullRazor (Fig. 2.1). En la figura 2.1 (b), los trazos marcados en rojo son las estructuras detectadas por el método DullRazor. El círculo amarillo muestra la omisión de un vello. Los círculos verdes, indican ejemplos de objetos parcialmente detectados y los círculos azules muestran ejemplos de características propias de las lesiones que se deben omitir.

2.2 Método E-shaver

El método E-shaver (Kiani and Sharafat, 2011) selecciona objetos no deseados con dos máscaras: la primera, se enfoca en detectar porciones de objetos sin ruido; la segunda, generalmente contiene objetos completos pero con ruido. La orientación principal (estimada por una transformada de Radon) sirve para decidir entre el kernel de Prewitt horizontal o el vertical. Se aplica una convolución con este kernel al componente L del espacio de color CIE-Luv de la imagen. Aunque este algoritmo detecta vellos más eficientemente que el DullRazor también usa kernels en orientaciones de 0° y 90° ; por lo que algunas estructuras no deseadas se detectan parcialmente o tienen algunos píxeles ruidosos.

2.3 Método basado en la derivada de la función Gaussiana

Abbas et al (2011) proponen un método que detecta vellos, vasos capilares y marcas de reglas; este método aplica convoluciones con un kernel basado en la Derivada Gaussiana para la detección de vellos y marcas de regla y otro kernel basado en una función Gaussiana para la detección de estructuras más gruesas tales como vasos capilares. La imagen resultante se binariza y procesa con técnicas morfológicas (v.g., reconstrucción de líneas cortadas, eliminación de píxeles no deseados, eliminación de ruido en estructuras) para refinar estructuras pobremente definidas. El refinamiento sugerido en este método crea estructuras para la reconstrucción de objetos sin embargo, también puede generar nuevos ruidos. A

Capítulo 2. Estado del arte

diferencia de este proceso, la fase de refinamiento propuesto en esta tesis configura el kernel de forma iterativa para encontrar estructuras débilmente definidas. Esto evita agregar estructuras no existentes a la máscara.

2.4 Resumen de métodos

El preprocesamiento es una etapa importante en la secuencia general de detección de melanoma mediante imágenes. En la medida en que el resultado del preprocesamiento mejore, los siguientes procesos serán más eficientes. Una de las funciones clave del preprocesamiento en la detección de melanoma, es la de eliminar artefactos que ocultan información de la lesión. Es por esto que han surgido varios métodos que realizan esta tarea.

El método más usado de acuerdo a la literatura es el DullRazor de Lee et al (1997). Este se basa en la operación morfológica de cierre; usa tres kernels, cada uno posibilita la detección de estructuras que están en un rango de ángulos. Este rango no cubre los 360° . Este enfoque lo hace propenso a omitir algunas estructuras. Otro método es el E-shaver de Kiani and Sharafat (2011), que basa la detección en el operador de Prewitt; uno vertical y otro horizontal. Al igual que DullRazor este método omite estructuras que están en ciertos ángulos. Finalmente, el método propuesto por Abbas et al (2011) que se basa en convoluciones usando un kernel de Derivada de Gaussiana, realiza una fase de refinamiento que liga estructuras que probablemente están desconectadas. Esto posibilita la adición de ruidos.

A diferencia de estos métodos, el método propuesto que está basado en convoluciones con kernel de Diferencia de Gaussianas, realiza una detección de estructuras en los 360° , además de contar con una fase de refinamiento la cual re-define las estructuras débiles sin generar nueva información que no se encuentre en la imagen origen.

3. Marco teórico

Este capítulo tiene la finalidad de situar el problema dentro de un conjunto de conocimientos y ofrecer una conceptualización adecuada de los términos que se utilizan en la tesis.

3.1 Procesamiento de imágenes

Con el propósito de incrementar la calidad de las imágenes o simplificar la búsqueda de información en éstas, se ha desarrollado un conjunto de técnicas que se conocen como procesamiento de imágenes (Proakis et al, 2007).

El procesamiento de imágenes se usa principalmente para: i) mejorar la percepción humana; las imágenes digitales se usan para guardarlas o modificarlas (v.g., teledetección, imagen médica, fotográficas, etc.), ii) sistemas de percepción automática; tiene que ver con la adquisición de imágenes para realizar procesos partiendo de ellas (v.g., movimiento de robots guiados por sistemas de visión o los procesos de inspección en la industria.)(Alegre et al, 2003).

De acuerdo a la información que se toma para llevar a cabo la transformación, el procesamiento de imágenes se puede dividir en: i) procesamiento global, en donde la imagen entera se procesa como un único bloque; ii) procesamiento local, en donde el valor del pixel de salida depende de los pixeles vecinos de la imagen de entrada; iii) procesamiento de punto, en donde el valor del pixel de salida depende del pixel ubicado en la misma posición de la imagen de entrada.

Capítulo 3. Marco teórico

3.1.1 Proceso de filtrado

Al conjunto de técnicas de procesamiento de imágenes cuyo objetivo es mejorar características de las imágenes para su uso en una aplicación específica, se le conoce como proceso de filtrado. La finalidad de este proceso consiste en: i) eliminar ruido o píxeles no deseados, ii) suavizar las imágenes; lo cual consiste en atenuar la variabilidad de intensidades entre píxeles de un área determinada. iii) destacar bordes de objetos, iv) detectar cambios drásticos de intensidades entre píxeles consecutivos.

El proceso de filtrado se puede realizar en el dominio de la frecuencia o del espacio. En teoría, todos los filtros en el dominio de frecuencias pueden implementarse en el dominio espacial.

En el dominio de la frecuencia el procesamiento de imagen se efectúa de la siguiente manera: i) se aplica la Transformada de Fourier a la imagen, ii) se multiplica alguna función de filtrado, iii) al resultado se le aplica la Transformada Inversa de Fourier.

En el dominio del espacio las operaciones se realizan directamente en la imagen, a diferencia del dominio de la frecuencia, en donde las operaciones tienen lugar en una transformada de la imagen.

Se pueden clasificar los filtros en el dominio del espacio en: i) filtros lineales; con éstos, el valor de un píxel de salida es una combinación lineal de los valores de los píxeles en el vecindario del píxel de entrada., ii) filtros no lineales; son los que no cumplen con la condición del filtro lineal.

3.1.2 Núcleo

Los filtros lineales están basados en núcleos (kernels). Un núcleo es una matriz de coeficientes como el que se muestra a continuación:

$$G_x = \begin{pmatrix} +1 & 0 & -1 \\ +1 & 0 & -1 \\ +1 & 0 & -1 \end{pmatrix}$$

El filtrado lineal se lleva a cabo cuando se realiza una convolución a la imagen usando un determinado núcleo.

3.1.3 Convolución

La notación de la convolución de f y g es $f * g$. Se define como la integral del producto de ambas funciones después de desplazar una de ellas una distancia t .

$$(f * g)(t) \doteq \int_{-\infty}^{\infty} f(\eta)g(t - \eta)d\eta \quad (3.1)$$

En el caso de funciones discretas que es en la forma en la que se manejan las imágenes, la convolución se define como:

$$f[m] * g[m] = \sum_n f[n]g[m - n] \quad (3.2)$$

La convolución discreta de una imagen A por un núcleo B genera una nueva imagen C , como en el ejemplo de la figura 3.1.

Capítulo 3. Marco teórico

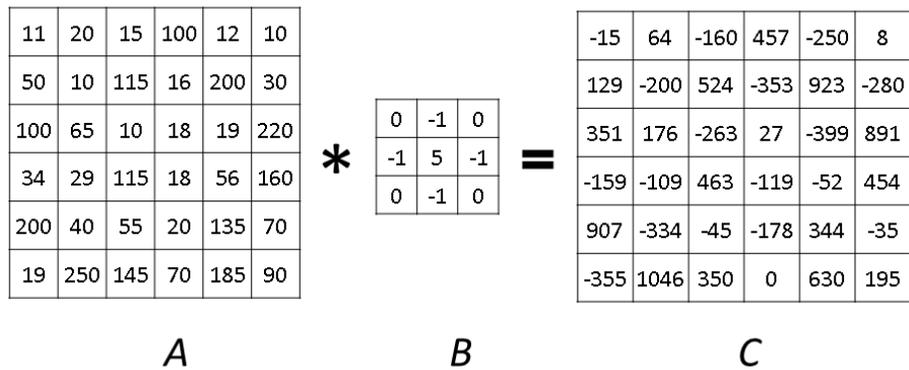


Figura 3.1: Ejemplo de convolución entre la imagen A y el núcleo B.

En la convolución, el núcleo hace un barrido por toda la imagen (Fig. 3.2), y en cada posición realiza una suma de las multiplicaciones de cada valor del núcleo por los correspondientes valores de la imagen. Este resultado es el que toma el pixel que se ubica en la posición del origen del núcleo en la nueva imagen. Por lo general la posición origen del núcleo esta en el centro. En el ejemplo de la figura 3.2, el origen del núcleo se localiza en donde está el numero cinco en rojo.

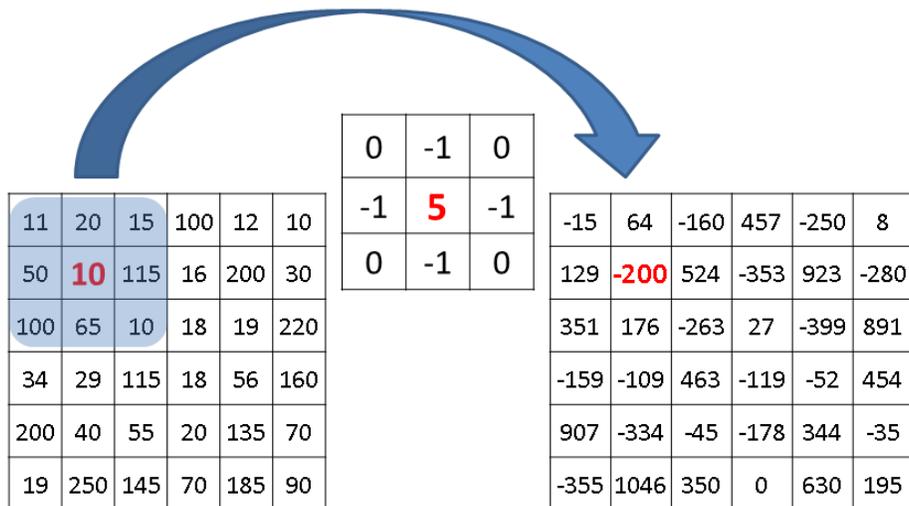


Figura 3.2: Cálculos aritméticos de la convolución.

Para realizar el cálculo de la convolución cuando el núcleo se encuentra ubicado en la columna 2, renglón 2, se realiza la operación aritmética $(11 \times 0) + (20 \times -1) + (15 \times 0) +$

$(50 \times -1) + (10 \times 5) + (115 \times -1) + (100 \times 0) + (65 \times -1) + (10 \times 0)$. El resultado (en rojo) es -200 que se ubica en la posición del origen del núcleo en la nueva imagen.

3.2 Tipos de imágenes digitales

Debemos considerar cuatro tipos de imágenes:

- I) **Binaria.** Cada pixel de este tipo de imágenes solo puede tener uno de dos valores; uno o cero. Por lo tanto solo se requiere un bit para almacenar cada pixel.
- II) **Escala de grises.** Cada pixel de este tipo de imágenes puede tener un valor de 0 a 255 en donde el cero representa a el color negro y el 255 el blanco; por lo que cada pixel necesita un byte para su almacenamiento.
- III) **Color verdadero, o RGB.** Cada pixel se representa por una cantidad de rojo (R, del ingles *Red*), una cantidad de verde (G, del ingles *Green*) y una cantidad de azul (B, del ingles *Blue*). Cada cantidad puede tener un valor de 0 a 255; por lo tanto, cada pixel puede tener $255^3 = 16,777,216$ posibles colores. Por lo que cada pixel puede almacenarse en 24 bits.
- IV) **Indexada.** Casi todas las imágenes solamente usan un subconjunto de los mas de 16 millones de colores posibles; es por eso que por conveniencia de almacenamiento y manejo de archivos a cada imagen se le asocia una paleta de colores, que no es mas que una lista de los colores que utiliza. Por lo tanto, a cada pixel se le asocia el indice del color en la lista.

3.3 Espacios de colores

Un modelo de color es un sistema de coordenadas en el que los colores se pueden especificar y medir. La colección de todos los colores definidos en un modelo de color forma el espacio de color correspondiente (Xiang and Joy, 1994).

Capítulo 3. Marco teórico

3.3.1 Espacio de color RGB

El modelo de color RGB define los colores en un sistema de coordenadas cartesianas en 3D en términos de los tres componentes: rojo, azul y verde. Cada componente puede tomar valores en el rango de 0 a 1.0. Esto da como resultado un espacio de color cúbico. Cuando se codifica en una representación digital usando un byte por cada componente, el espacio de color se convierte en una paleta de $256 \times 256 \times 256$ colores (Xiang and Joy, 1994).

La gama de colores del espacio RGB se puede representar mediante un cubo (Fig. 3.3) en donde cada componente describe una dimensión.

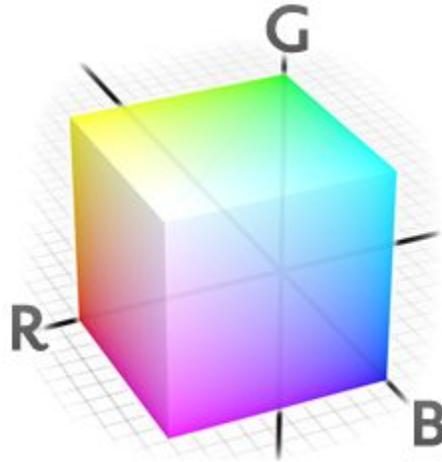


Figura 3.3: Espacio de color RGB.

La principal desventaja del espacio de color RGB en aplicaciones con imágenes es una alta correlación entre sus componentes; aproximadamente 0.78 para r_{BR} (correlación cruzada entre el canal B y el R), 0.98 para r_{RG} y 0.94 para r_{GB} (Palus, 1998). Otro problema del espacio RGB es que para el ser humano no es intuitiva la visualización de un color con los tres componentes R, G y B. Además la diferencia de dos colores que percibe el ser humano y la distancia euclidiana en el espacio RGB tienen poca correlación (Tkalcic and Tasic, 2003). Finalmente, el sistema RGB es dependiente del dispositivo que lo usa; esto significa que si por ejemplo, proyectamos una imagen en dos monitores, los colores de la

imagen proyectada en cada monitor podrían no ser iguales.

3.3.2 Espacios de color basados en el círculo de color de Newton

Isaac Newton, uno de los precursores en la ciencia del color, configuró el círculo de color que lleva su apellido (Cotton, 1995). Este describe los colores mediante los componentes de matiz y saturación (en inglés *Hue* y *Saturation* respectivamente.). Esta es la manera más natural en la que el cerebro humano organiza los colores.

Una familia de espacios de colores utiliza este principio. Estos describen los siguientes componentes:

Matiz: este componente indica el color (v.g. rojo, azul, amarillo, etc.).

Saturación: es el grado de ausencia de blanco. Un color extremadamente saturado solo tiene un componente espectral a diferencia de color sin saturación que tiene mucho blanco agregado.

Brillo (en inglés Brightness): es una medida de la intensidad de luz.

Los espacios de color de esta familia por lo general son una transformación lineal del espacio RGB (Ford and Roberts, 1998).

Uno de los espacios de color de esta familia es el HSL que debido a que es una transformación lineal del espacio RGB hereda todas sus desventajas como son la dependencia de dispositivo y la no linealidad. Para tener resultados consistentes en este espacio, se debe conocer la relación exacta que tiene con el espacio RGB ya que existen muchos espacios HSL definidos en la literatura (Ford and Roberts, 1998).

3.3.3 Espacios de color CIE

La Comisión Internacional de la Iluminación (CIE, del francés *Commission internationale de l'éclairage*) es la autoridad internacional en luz, iluminación, color y espacios de color. En 1931, CIE estableció el observador colorimétrico estándar CIE 1931; éste es un conjunto de funciones de mapeo de colores de lo que el promedio de personas ve.

Capítulo 3. Marco teórico

El ser humano tiene tres células receptoras de color que se estimulan mediante distintos rangos de longitud de onda. Estos tienen picos de sensibilidad espectral pequeños (S, del inglés *Short*, 420 nm - 440 nm), medianos (M, del inglés *Middle*, 530 nm - 540 nm), y largos (L, del inglés *Long*, 560 nm - 580 nm). Por lo tanto, en principio se requieren tres parámetros para describir cualquier sensación de color humano.

CIE estandarizó los valores XYZ como valores triestímulos que pueden describir cualquier color que se pueda percibir por un observador humano promedio (el observador colorimétrico estándar CIE 1931).

Los valores de triestímulo XYZ son análogos, pero diferentes, a las respuestas de las células LMS del ojo humano. Se define a Y como iluminación y el plano XZ contiene todas las combinaciones cromáticas posibles en esa iluminación. En la figura 3.4 se muestra la cromaticidad del espacio CIE XYZ; el borde grueso indica las longitudes de onda expresadas en nanómetros.

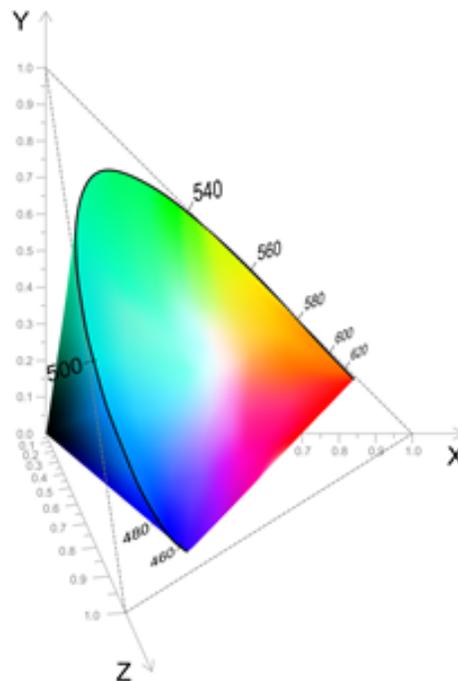


Figura 3.4: Espacio de color CIE XYZ.

Espacios de color CIE 1976 $L^* u^* v^*$ y CIE 1976 $L^* a^* b^*$

Los espacios de color CIE 1976 $L^* u^* v^*$ y CIE 1976 $L^* a^* b^*$ fueron propuestos por la CIE en 1976. La principal diferencia entre estos dos espacios es el modelo de adaptación cromática. El objetivo principal de la CIE era proporcionar un espacio perceptualmente igual. Esto significa que debe existir una fuerte correlación de la percepción humana y la distancia euclidiana de los espacios, sobre la diferencia de dos colores.

CIE 1976 $L^* a^* b^*$ define tres parámetros en el modelo: la luminosidad de color (L^*), que puede tomar valores desde 0 (oscuro) hasta 100 (máxima iluminación); su posición entre rojo y verde (a^*), cuyos los valores negativos indican verde y los positivos rojo; su posición entre amarillo y azul (b^*), cuyos los valores negativos indican azul y los positivos amarillo.

Al igual que con CIE 1976 $L^* a^* b^*$ el parámetro L en el espacio CIE 1976 $L^* u^* v^*$ representa la iluminación y u^* y v^* definen la cromaticidad.

3.4 Operaciones morfológicas

La morfología matemática esta basada en la teoría de conjuntos, teoría de retículos, tipología y funciones aleatorias (Wikipedia, 2018). Una de sus aplicaciones es el análisis y tratamiento de imágenes digitales.

Al conjunto de operaciones no lineales que tiene que ver con la forma o morfología de las características de la imagen se le conoce como procesamiento morfológico de imágenes. Originalmente se desarrolló para imágenes binarias, posteriormente se extendió para imágenes en escala de grises.

Las operaciones morfológicas por lo general toman como entrada una imagen digital y un elemento estructurante. Estos se combinan mediante una operación de unión, intersección, inclusión, complemento, etc..

El elemento estructurante es una matriz binaria que sondea a una imagen mediante un

Capítulo 3. Marco teórico

operador. Con el objetivo de analizar o realizar tratamientos sobre la imagen.

En morfología binaria, una imagen es vista como un subconjunto del espacio euclidiano \mathbb{Z}^d , dada una dimensión d .

3.4.1 Operaciones con imágenes binarias

Sea E un espacio euclidiano y A una imagen binaria en E .

Erosión

La definición de la Erosión de una imagen binaria A por un elemento estructurante B es:

$$A \ominus B = \{z \in E | B_z \subseteq A\} \quad (3.3)$$

donde B_z es la traslación de B por el vector z , esto es, $B_z = \{b + z | b \in B\}, \forall z \in E$.

También se puede expresar la erosión de A por B como:

$$A \ominus B = \bigcap_{b \in B} A_{-b}. \quad (3.4)$$

La erosión binaria de una imagen A por un elemento estructurante B genera otra imagen binaria C , como en el ejemplo de la figura 3.5.

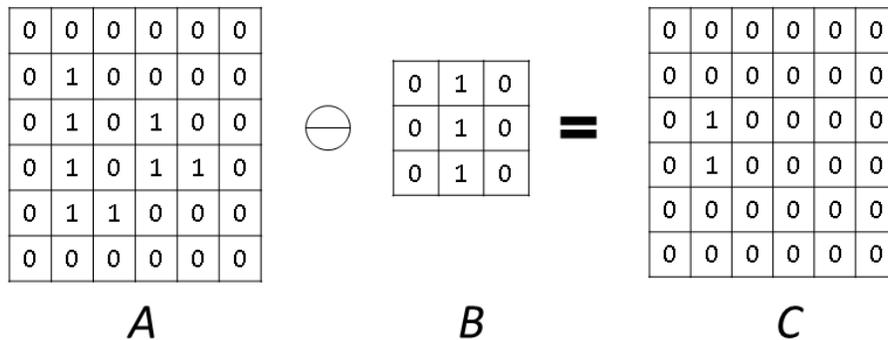


Figura 3.5: Ejemplo de la Erosión binaria entre la imagen A y el elemento estructurante B.

Cuando todos los 1's del elemento estructurante logran coincidir con los de la ventana

analizada de la imagen, el resultado del pixel de la imagen resultante ubicado en las mismas coordenadas del pixel central del elemento estructurante es 1, en caso contrario 0. En este caso particular, el elemento estructurante recorrió toda la imagen y solo hubieron dos coincidencias (Fig. 3.6).

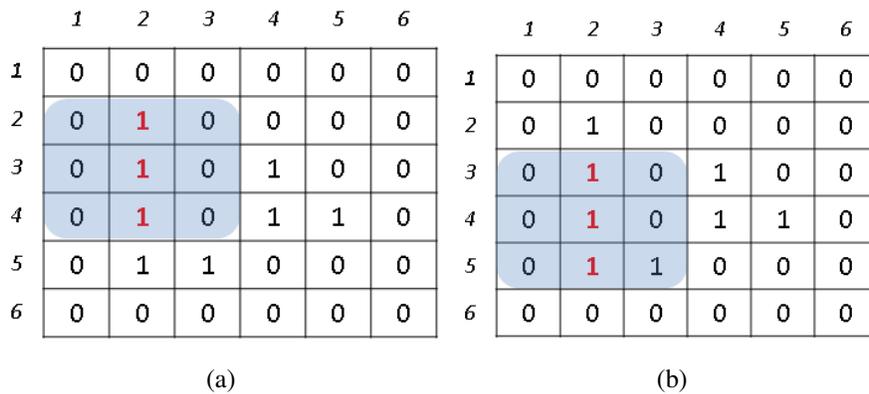


Figura 3.6: (a) coincidencia de la imagen con el elemento estructurante centrado en la columna dos registro tres, (b) coincidencia de la imagen con el elemento estructurante centrado en la columna dos registro cuatro.

Dilatación

La definición de la Dilatación de A por el elemento estructurante B es:

$$A \oplus B = B \oplus A = \bigcup_{b \in B} A_b \tag{3.5}$$

También se puede expresar la dilatación como $A \oplus B = \{z \in E \mid (B^s)_z \cap A \neq \emptyset\}$, donde B^s denota la simetría de B , que es, $B^s = \{x \in E \mid -x \in B\}$.

La dilatación binaria de una imagen A por un elemento estructurante B genera otra imagen binaria C , como en el ejemplo de la figura 3.7.

Capítulo 3. Marco teórico

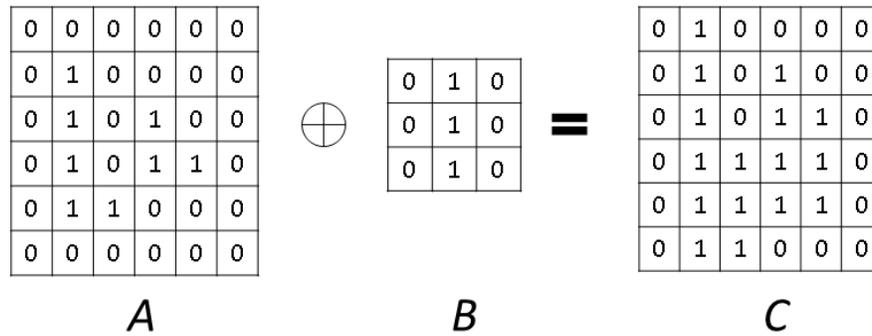


Figura 3.7: Ejemplo de la Dilatación binaria entre la imagen A y el elemento estructurante B.

Cuando por lo menos un 1 del elemento estructurante logra coincidir con los de alguna ventana de la imagen, el resultado del pixel de la imagen resultante ubicado en las mismas coordenadas del pixel central del elemento estructurante es 1, en caso contrario 0.

Apertura

La operación de Apertura se obtiene al aplicarle a la imagen A una operación de erosión y al resultado aplicarle una operación de dilatación con el mismo elemento estructurante B.

La apertura de A y B se define como:

$$A \circ B = (A \ominus B) \oplus B \quad (3.6)$$

También se puede definir la Apertura como:

$$A \circ B = \bigcup_{B_x \subseteq A} B_x \quad (3.7)$$

La apertura binaria de una imagen A por un elemento estructurante B genera otra imagen binaria D, como en el ejemplo de la figura 3.8.

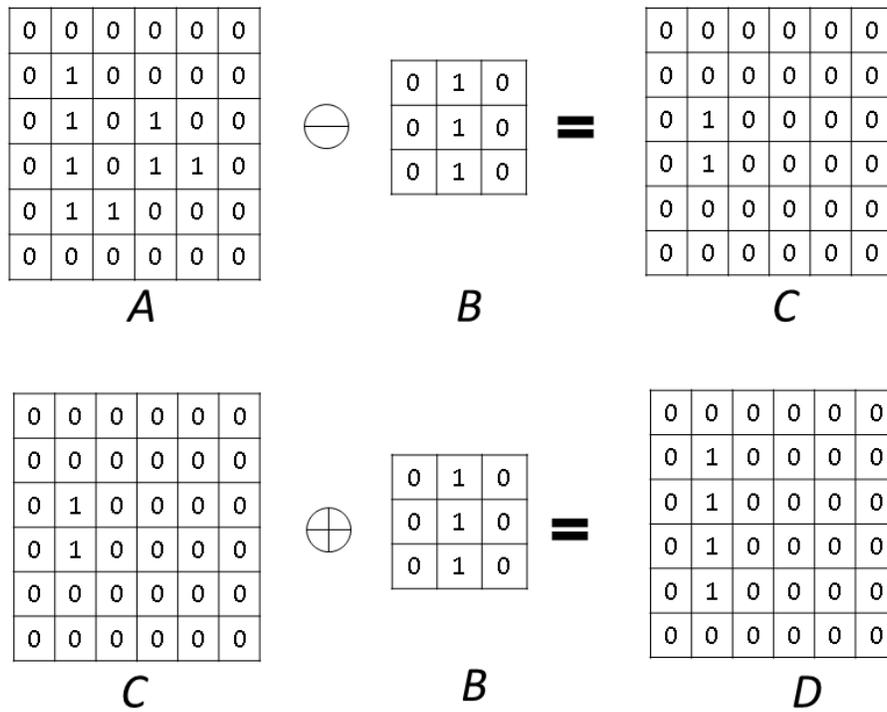


Figura 3.8: Cálculo de la Apertura binaria entre la imagen A y el elemento estructurante B.

Por lo tanto (Fig. 3.9),

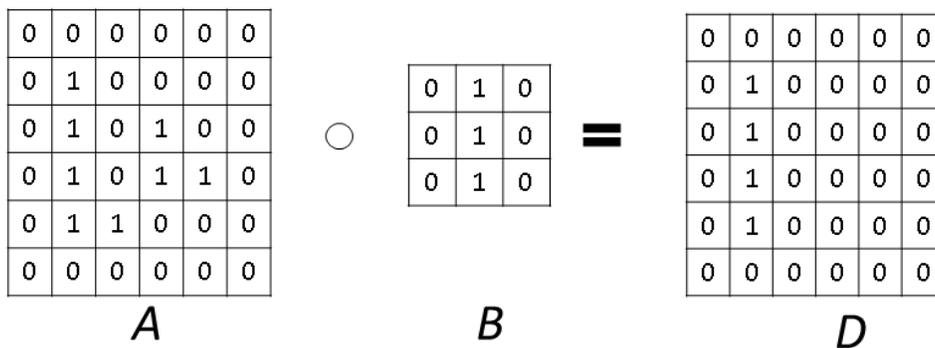


Figura 3.9: Ejemplo de la Apertura binaria entre la imagen A y el elemento estructurante B.

Cierre

La operación de Cierre se obtiene al aplicarle a la imagen A una operación de dilatación y al resultado aplicarle una operación de erosión con el mismo elemento estructurante B.

El cierre de A y B se define como:

Capítulo 3. Marco teórico

$$A \bullet B = (A \oplus B) \ominus B \quad (3.8)$$

También se puede expresar como $A \bullet B = (A^c \circ B^s)^c$, donde X^c denota el complemento de X respecto a E ($X^c = \{x \in E | x \notin X\}$). Lo anterior significa que el cierre es el complemento del lugar geométrico de las traslaciones de la simetría del elemento estructurante fuera de la imagen A . El cierre binario de una imagen A por un elemento estructurante B genera otra imagen binaria D , como en el ejemplo de la figura 3.10.

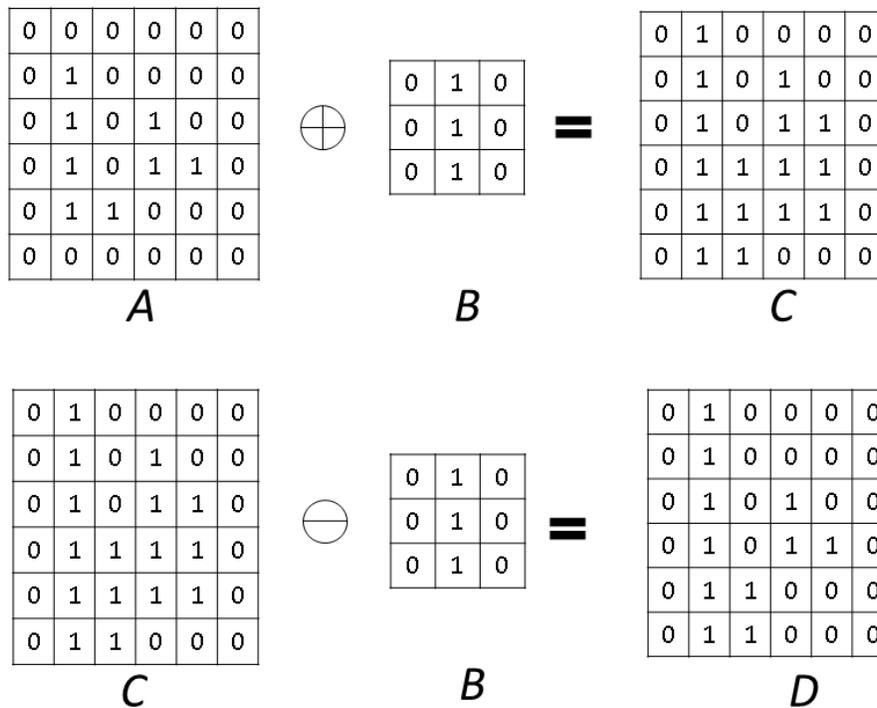


Figura 3.10: Cálculo del Cierre binario entre la imagen A y el elemento estructurante B.

Por lo tanto (Fig. 3.11),

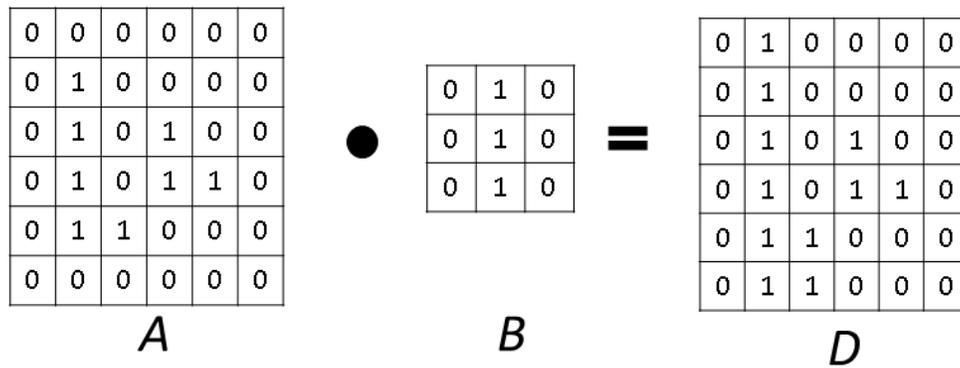


Figura 3.11: Ejemplo del Cierre binario entre la imagen A y el elemento estructurante B.

3.4.2 Operaciones con imágenes en escala de grises

En el caso de la morfología en escala de grises, las imágenes se tratan como funciones que se mapean en un espacio euclidiano E en $\mathbb{R} \cup \{\infty, -\infty\}$. De la misma manera los elementos estructurantes son funciones que se conocen como funciones estructurantes.

Dilatación

La definición de la dilatación en escala de grises entre una imagen $f(x)$ y una función estructurante $b(x)$ es:

$$(f \oplus b)(x) = \sup_{y \in E} [f(y) + b(x - y)] \tag{3.9}$$

En el caso de usar funciones estructurantes planas $b(x)$ la definición de la dilatación se reduce como se muestra a continuación.

$$(f \oplus b)(x) = \sup_{z \in B^s} f(x + z) \tag{3.10}$$

Capítulo 3. Marco teórico

siendo $b(x)$ de la forma

$$b(x) = \begin{cases} 0, & x \in B, \\ -\infty, & \text{en otro caso} \end{cases} \quad (3.11)$$

donde $B \subseteq E$.

La dilatación en escala de grises de una imagen A por un elemento estructurante B genera una nueva imagen en escala de grises C , como se muestra en el ejemplo de la figura 3.12.

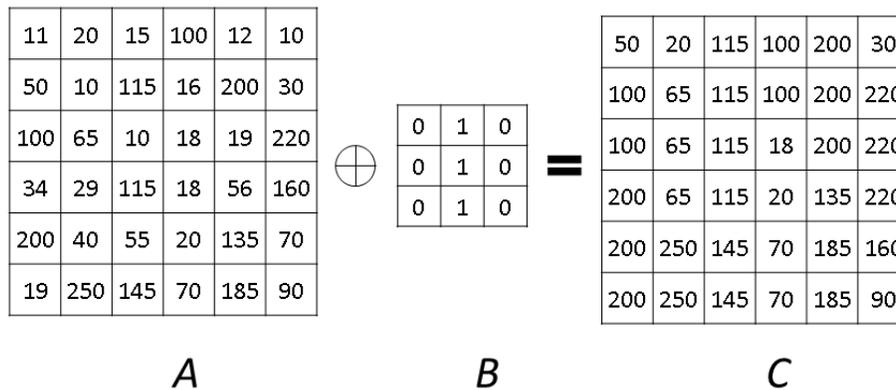


Figura 3.12: Ejemplo de la Dilatación en escala de grises entre la imagen A y el elemento estructurante B.

Se busca el máximo de los valores de los pixeles de la imagen ubicados en las posiciones donde se encuentran los 1's de la función estructurante. Este valor es el que toma el pixel de la imagen resultante que se ubica en la posición del origen de la función estructurante (véase Fig. 3.13).

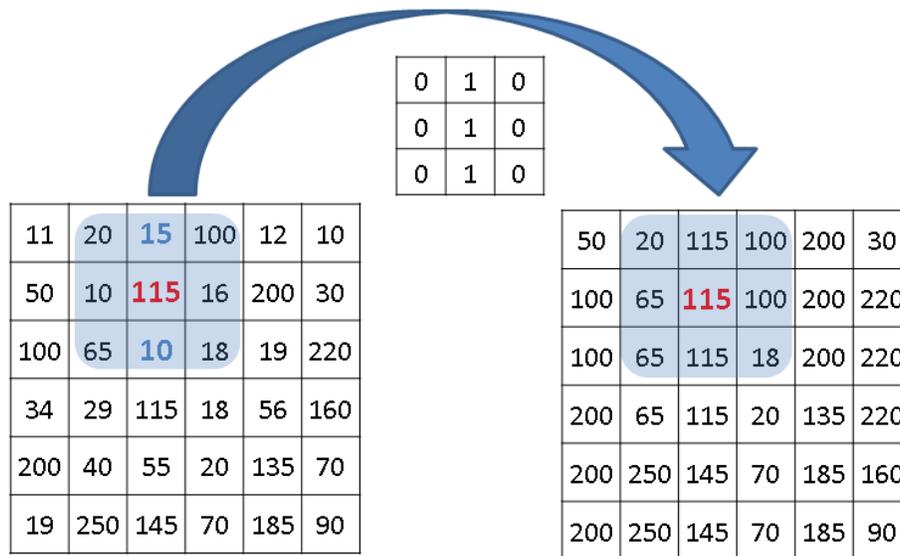


Figura 3.13: Cálculo de la Dilatación en escala de grises.

En el ejemplo de la figura 3.13, la función estructurante tiene su origen en la columna 3, registro 2. Los valores 15, 115 y 10 (en rojo y azul) son los que coinciden con las posiciones en donde se encuentran los 1's de la función estructurante. De esos tres valores el 115 (en rojo) es el máximo, por lo que es el resultado del pixel de la imagen generada.

Erosión

La erosión en escala de grises de una imagen $f(x)$ por una función estructurante $b(x)$ se define como:

$$(f \ominus b)(x) = \inf_{y \in E} [f(y) - b(y - x)] \quad (3.12)$$

En el caso de usar funciones estructurantes planas $b(x)$ la definición de la erosión se reduce como se muestra a continuación.

$$(f \ominus b)(x) = \inf_{z \in B} f(x + z) \quad (3.13)$$

Capítulo 3. Marco teórico

La erosión en escala de grises de una imagen A por un elemento estructurante B genera una nueva imagen en escala de grises C , como se muestra en el ejemplo de la figura 3.14.

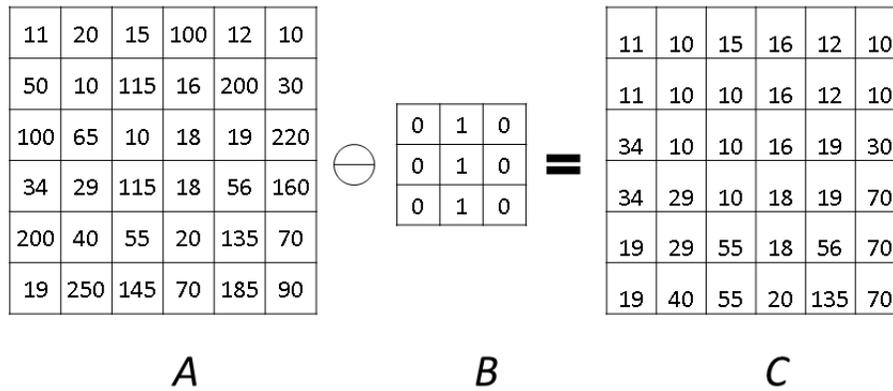


Figura 3.14: Ejemplo de la Erosión en escala de grises entre la imagen A y el elemento estructurante B .

Se busca el mínimo de los valores de los pixeles de la imagen ubicados en las posiciones donde se encuentran los 1's de la función estructurante. Este valor es el que toma el pixel de la imagen resultante que se ubica en la posición del origen de la función estructurante (véase Fig. 3.15).

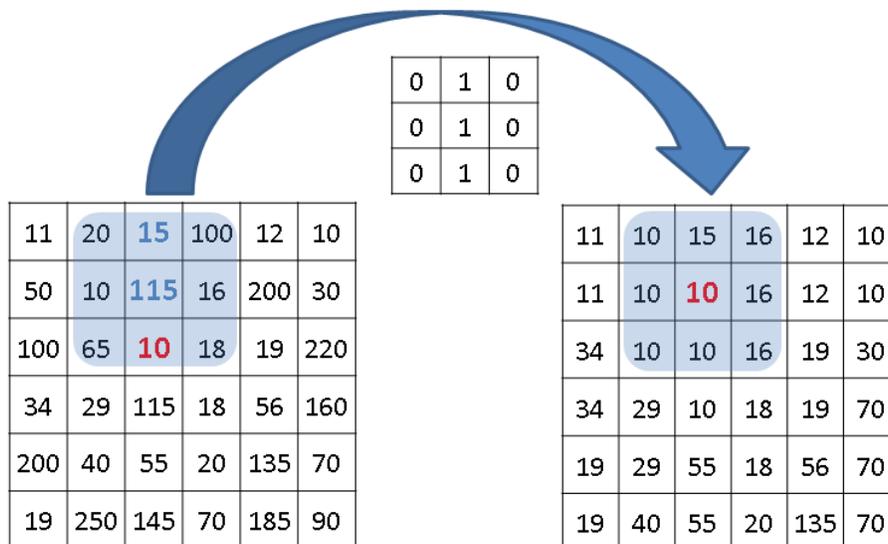


Figura 3.15: Cálculo de la Erosión en escala de grises.

En el ejemplo de la figura 3.15, la función estructurante tiene su origen en la columna 3, registro 2. Los valores 15, 115 y 10 (en rojo y azul) son los que coinciden con las posiciones en donde se encuentran los 1's de la función estructurante. De esos tres valores el 10 (en rojo) es el mínimo, por lo que es el resultado del pixel con posición en el origen de la función estructurante de la imagen generada.

La operación de Apertura y de Cierre en escala de grises se realizan de una manera análoga que las operaciones de Apertura y Cierre binaria, con las respectivas operaciones de Dilatación y Erosión en escala de grises.

Apertura

La definición de la operación de apertura en escala de grises entre una imagen $f(x)$ por una función estructurante $b(x)$ es:

$$f \circ b = (f \ominus b) \oplus b \quad (3.14)$$

Cierre

El cierre en escala de grises de una imagen $f(x)$ por una función estructurante $b(x)$ se define como:

$$f \bullet b = (f \oplus b) \ominus b \quad (3.15)$$

4. Enfoque propuesto

En este capítulo se describe el método propuesto para la detección de objetos no deseados en imágenes dermatoscópicas. Además, se explica el procedimiento que se usó para encontrar los valores óptimos de los parámetros involucrados en la técnica.

Método propuesto para la detección de objetos no deseados

El método propuesto utiliza imágenes dermatoscópicas. En el algoritmo 2, las imágenes se convierten al espacio de color CieLab (línea 1) para obtener el componente de iluminación $l \in [0, 100]$ (línea 2); los pixeles con valor de iluminación bajo forman parte de las estructuras objetivo. Posteriormente, se le aplica a la imagen una convolución con un kernel de función de DoG (línea 3). La función DoG se obtiene mediante la sustracción de dos funciones Gaussianas con diferente desviación estándar. La ecuación que describe esta función es:

$$\begin{aligned} DoG &= G_{\sigma_1} - G_{\sigma_2} \\ &= \frac{1}{\sqrt{2\pi}} \left[\frac{1}{\sigma_1} e^{-\frac{(x^2+y^2)}{2\sigma_1^2}} - \frac{1}{\sigma_2} e^{-\frac{(x^2+y^2)}{2\sigma_2^2}} \right] \end{aligned} \quad (4.1)$$

Donde σ_1 y σ_2 son las desviaciones estándar.

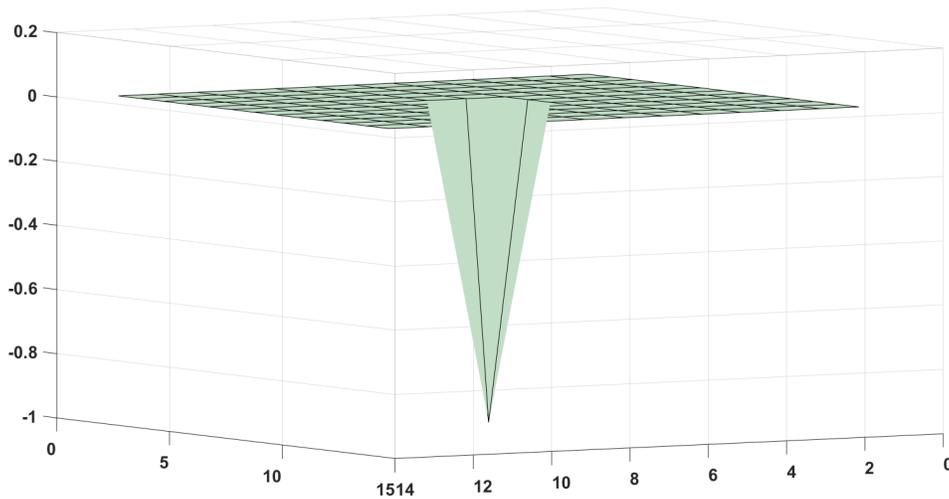


Figura 4.1: El kernel DoG con parámetros $\sigma_1 = 10200$, $\sigma_2 = 0.2$ y $k_s = 13$.

La función que describe al kernel (Fig. 4.1) forma un cono invertido, cuando $\sigma_1 \gg \sigma_2$, donde la parte más pronunciada es un valor negativo y el resto de los valores son positivos.

Para que el método propuesto detecte objetos no deseados de forma óptima se requiere encontrar los valores de los parámetros σ_1 y σ_2 del kernel DoG, y el parámetro de umbralización \mathcal{T} , que maximicen la medida $F_1 \in [0, 1]$ (donde cero representa el peor valor y uno el mejor). Para reducir la complejidad de este procedimiento, se analizó por separado el parámetro \mathcal{T} y los parámetros σ 's.

Para definir los valores de los parámetros σ_1 y σ_2 , se seleccionaron 16 imágenes dermatoscópicas de la base de datos PH², como se describe en la sección 5.1. Se calcularon las medidas F_1 de las imágenes como se indica en la sección 5.3 y se promediaron. Este proceso se llevó a cabo de manera iterativa con varias combinaciones de valores para σ_1 y σ_2 . Los siguientes valores de σ_1 y σ_2 que se probaban eran los próximos a aquellos que habían devuelto el mejor promedio de F_1 .

La tabla 4.1 muestra los promedios de la medida F_1 de las últimas pruebas de valores para σ_1 y σ_2 . Los encabezados de las columnas (en negrita), corresponden a los valores de

σ_1 ; los valores (en negrita) al inicio de los renglones, corresponden a σ_2 ; y los valores en el centro, corresponden a los promedios de la medida F_1 . Por lo tanto, el mejor promedio de la medida F_1 (0.7055) es cuando $\sigma_1 = 100200$ y $\sigma_2 = 0.20$.

	σ_1		
σ_2	100100	100200	100300
0.15	0.6989	0.6777	0.6995
0.20	0.6846	0.7055	0.6846
0.25	0.6873	0.6794	0.6958
0.30	0.6765	0.6787	0.6852

Tabla 4.1: Promedios de la medida F_1 , usando distintos valores para σ_1 y σ_2

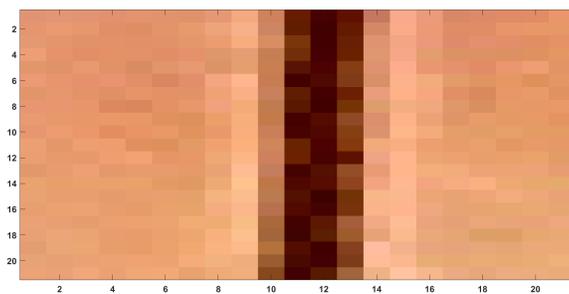
Antes de definir σ_1 y σ_2 , se definió el parámetro \mathcal{T} . Se usó un método análogo al usado para definir los valores para σ_1 y σ_2 ; en este caso los valores que se probaron fueron para el parámetro \mathcal{T} y de la misma manera, se buscaron los mejores promedios de la medida F_1 para encontrar el mejor valor para \mathcal{T} .

Los encabezados de las columnas (en negrita) de la tabla 4.2, muestran los últimos valores que se probaron para \mathcal{T} , y los valores del renglón alineados con M_{F_1} , indican los promedios de la medida F_1 . Por lo tanto, el mejor promedio de la medida F_1 (0.693) es cuando $\mathcal{T} = 2.2$.

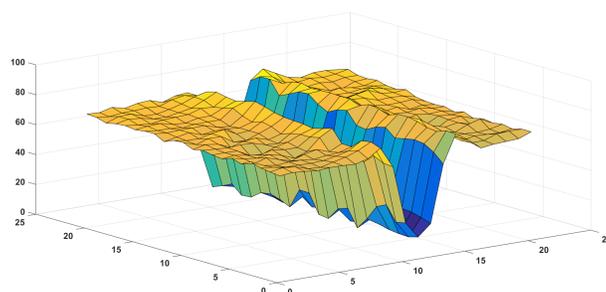
\mathcal{T}	2.0	2.1	2.2	2.3	2.4
M_{F_1}	0.649	0.663	0.693	0.677	0.686

Tabla 4.2: Comparación de promedios de la medida F_1 , usando distintos valores de umbralización

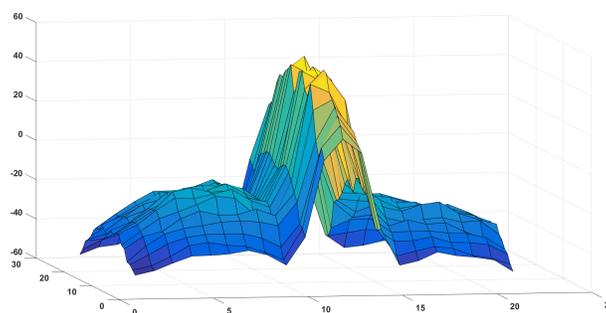
Capítulo 4. Enfoque propuesto



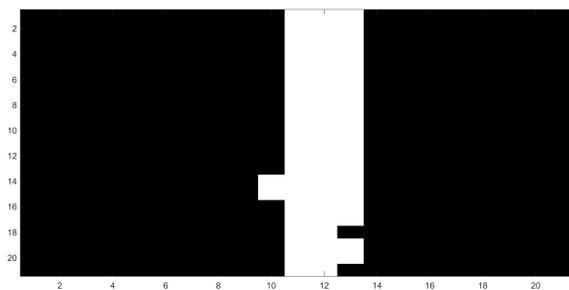
(a)



(b)



(c)



(d)

Figura 4.2: (a) ventana de imagen dermatoscópica, (b) gráfica 3D del componente de iluminación, (c) gráfica 3D del resultado de la convolución, (d) máscara binaria.

La figura 4.2 muestra en una gráfica 3D el componente de iluminación (b) de una ventana de imagen dermatoscópica con tamaño 21×21 (a). A este se le aplica una convolución y su resultado se muestra en una gráfica 3D (c). La convolución se realiza utilizando el kernel DoG (Fig. 4.1). Finalmente, el resultado de la convolución se binariza (d) con un parámetro de umbralización predefinido.

En el ejemplo de la figura 4.2, cuando el kernel está centrado en un pixel que forma parte del vello, el resultado de la convolución es un valor positivo de gran magnitud; ésto se da por tres razones:

1. El valor del valle que forma la función DoG se multiplica por un valor de iluminación bajo (por lo general estos valores de pixel se encuentran en vellos y vasos capilares); obteniendo un valor negativo de baja magnitud.
2. Las partes positivas de la función DoG se multiplican por valores de alta magnitud de iluminación (comúnmente son pixeles de piel); obteniendo valores positivos con magnitud media.
3. El área de piel que abarca el kernel es por lo general mucho mayor que la del vello o de los vasos capilares; por lo tanto, se obtendrán muchas contribuciones de valores positivos con magnitud media.

Después de aplicar la convolución, la imagen resultante se binariza mediante un valor de umbralización pre definido (línea 4). Esta máscara binaria detecta eficientemente la mayoría de los objetos no deseados, sin embargo, los objetos delgados no quedan bien definidos en la mayoría de los casos; por esta razón se aplica el refinamiento (algoritmo 3). Para llevar a cabo el refinamiento, se obtienen los pixeles conectados (línea 5); existen muchas librerías de visión de computadora que proveen esta función. Después, se aplican filtros para determinar cuáles son los artefactos objetivos como vellos y vasos capilares (línea 6). Cada objeto se convierte en una nueva versión refinada (línea 8); si el objeto refinado continúa siendo un artefacto objetivo (línea 9),

Capítulo 4. Enfoque propuesto

entonces éste reemplaza la versión anterior (línea 10), de lo contrario, se descarta (línea 12). Finalmente, la lista de objetos se convierte en una máscara binaria (línea 15).

```
Data:  $\mathcal{I}_{\text{rgb}}$ , una imagen rgb;  $\sigma_1$  y  $\sigma_2$ , desviaciones estándar de las funciones Gaussianas 1 y 2 respectivamente;  $k_s$ , tamaño del núcleo;  $\mathcal{T}$ , un umbral para binarizar.  
  
Result:  $\mathcal{M}_{\text{bin}}$ , una máscara binaria  
1  $\mathcal{I}_{\text{lab}} \leftarrow$  convertir  $\mathcal{I}_{\text{rgb}}$  al espacio de color CIE L* a* b*;  
2  $\mathcal{I}_{\text{lum}} \leftarrow$  obtener el componente de iluminación de  $\mathcal{I}_{\text{lab}}$ ;  
3  $\mathcal{I}_{\text{con}} \leftarrow$  aplicar una convolución a  $\mathcal{I}_{\text{lum}}$  con un núcleo DoG y parámetros  $\sigma_1$ ,  $\sigma_2$  y  $k_s$  ;  
4  $\mathcal{M}_{\text{bin}} \leftarrow$  binarizar  $\mathcal{I}_{\text{con}}$  con el umbral  $\mathcal{T}$  ;  
5  $CC \leftarrow$  obtener los componentes conectados de  $\mathcal{M}_{\text{bin}}$  ;  
6  $targetObjects \leftarrow$  filtrar los objetos no deseados  $CC$  ;  
7 foreach  $Obj$  in  $targetObjects$  do  
8    $refinedObj \leftarrow$  refinar  $Obj$  con el algoritmo 3 usando  $\mathcal{I}_{\text{lum}}$ ,  $\mathcal{M}_{\text{bin}}$ ,  $\sigma_1$ ,  $\sigma_2$ ,  $k_s$  y  $\mathcal{T}$  ;  
9   if  $refinedObj$  es un objeto no deseado then  
10      $Obj \leftarrow refinedObj$  ;  
11   else  
12     eliminar  $Obj$  de  $targetObjects$  ;  
13   end  
14 end  
15  $\mathcal{M}_{\text{bin}} \leftarrow$  convertir  $targetObjects$  a una imagen binaria ;
```

Algoritmo 2: Creación de máscara con el método propuesto

Proceso de refinamiento

Cuando una estructura tiene mucha probabilidad de ser un vello o vaso capilar se somete a un proceso de refinamiento (algoritmo 3), el cual consiste en: ubicar el objeto dentro de la máscara binaria, almacenar la ventana concéntrica al objeto con un margen predefinido en una variable (línea 2). Almacenar en otra variable otra ventana en la misma ubicación que la ventana anterior pero esta vez desde el componente de iluminación de la imagen original (línea 1). $\frac{m_{k_s} - k_s}{2} + 1$ convoluciones se le aplican a la ventana del componente de iluminación con un kernel de DoG. Se incrementa el tamaño de kernel en dos en cada convolución (línea 8); estos tamaños son siempre números impares para que el pixel a modificar siempre este ubicado en el centro. El resultado de cada convolución se binariza (línea 6). Se aplica una operación de unión a las ventanas binarias resultantes (línea 7). Finalmente, se obtiene el objeto refinado (línea 10).

Data: Obj , un objeto no deseado; \mathcal{I}_{lum} , componente de iluminación de la imagen;

\mathcal{M}_{bin} , máscara binaria inicial; σ_1 , σ_2 , desviaciones estándar de las funciones

Gaussianas 1 y 2 respectivamente; k_s , tamaño del núcleo; \mathcal{T} , un umbral para

binarizar; m_{k_s} , máximo tamaño de núcleo; p , margen de pixeles.

Result: $refinedObj$ una lista de pixeles conectados

```
1  $\mathcal{W}_{lum} \leftarrow$  obtener una ventana alrededor de  $Obj$  desde  $\mathcal{I}_{lum}$  con un margen  $p$  ;
2  $\mathcal{W}_{bin} \leftarrow$  obtener una ventana alrededor de  $Obj$  desde  $\mathcal{M}_{bin}$  con un margen  $p$  ;
3  $\mathcal{W}_{acm} \leftarrow \mathcal{W}_{bin}$  ;
4 while  $k_s \leq m_{k_s}$  do
5    $\mathcal{W}_{con} \leftarrow$  aplicar una convolución a  $\mathcal{W}_{lum}$  con un núcleo DoG y parámetros  $\sigma_1$ ,
    $\sigma_2$  y  $k_s$  ;
6    $\mathcal{W}_{tmp} \leftarrow$  binarizar  $\mathcal{W}_{con}$  con el umbral  $\mathcal{T}$  ;
7    $\mathcal{W}_{acm} \leftarrow \mathcal{W}_{acm} + \mathcal{W}_{tmp}$  ;
8    $k_s \leftarrow k_s + 2$  ;
9 end
10  $refinedObj \leftarrow$  obtener el objeto refinado desde  $\mathcal{W}_{acm}$  ;
```

Algoritmo 3: Refinamiento de objetos

5. Pruebas y resultados

El propósito de este estudio es contrastar el método propuesto y el método DullRazor en términos de precisión, exhaustividad y medida F_1 ; a continuación se describe el experimento, sus métricas y los resultados obtenidos.

5.1 Datos de prueba

Se utilizaron imágenes dermatoscópicas de la base de datos PH² para llevar a cabo el experimento. Esta contiene 200 imágenes dermatoscópicas con resolución de 768×560 píxeles que se obtuvieron mediante el sistema analizador Tuebinger Mole a una magnificación de 20x (Mendonça et al, 2013).

Como algunas imágenes de la base de datos PH² no contienen objetos no deseados, se seleccionaron manualmente aquellas con vellos o vasos capilares; de las 167 imágenes seleccionadas, se eligieron 50 imágenes para las pruebas.

Para eliminar los ruidos introducidos por factores externos (v.g., líneas causadas por la cámara), se recortaron cinco píxeles en cada uno de los bordes (superior, derecho, inferior e izquierdo) de la imagen, quedando con una resolución final de 758×550 . Las máscaras base se obtuvieron manualmente: por cada imagen, se creó una máscara binaria marcando con 1's los píxeles que conforman los objetos no deseados (vellos y vasos capilares) y con 0's los píxeles del resto de objetos (piel y fondo).

5.2 Detalles de configuración para la obtención de máscaras con el método DullRazor

Las máscaras binarias del método DullRazor se generaron con la aplicación en versión Windows provista por Lee et al (1997). Se llevó a cabo el siguiente procedimiento para obtener la máscara binaria: 1) Configurar la ruta fuente de la imagen y la ruta destino, 2) Desmarcar la opción “Postop Smoothing”, 3) Marcar la opción “Produce Hair Mask” y configurar la ruta destino de la máscara, y 4) Iniciar el proceso.

5.3 Métricas

Se compararon las máscaras generadas desde el método DullRazor y desde el método propuesto con las máscaras base para calcular la precisión (p), la exhaustividad (r) y la medida F (F_1), donde p , r y $F_1 \in [0, 1]$. Para las tres métricas cero representa el peor valor y uno el mejor. Cada pixel blanco de la máscara de ambos métodos fue comparado con el pixel de la misma posición de la máscara base. La precisión se calculó dividiendo el número de pixeles coincidentes (m_p) por la cantidad de pixeles blancos en la máscara generada por el método (t_p).

$$p = \frac{m_p}{t_p} \quad (5.1)$$

La exhaustividad se calculó dividiendo el número de pixeles coincidentes por la cantidad de pixeles blancos en la máscara base (g_t).

$$r = \frac{m_p}{g_t} \quad (5.2)$$

La medida F tradicional o la media armónica de precisión y exhaustividad, se define como:

$$F_1 = 2 \cdot \frac{p \cdot r}{p + r} \quad (5.3)$$

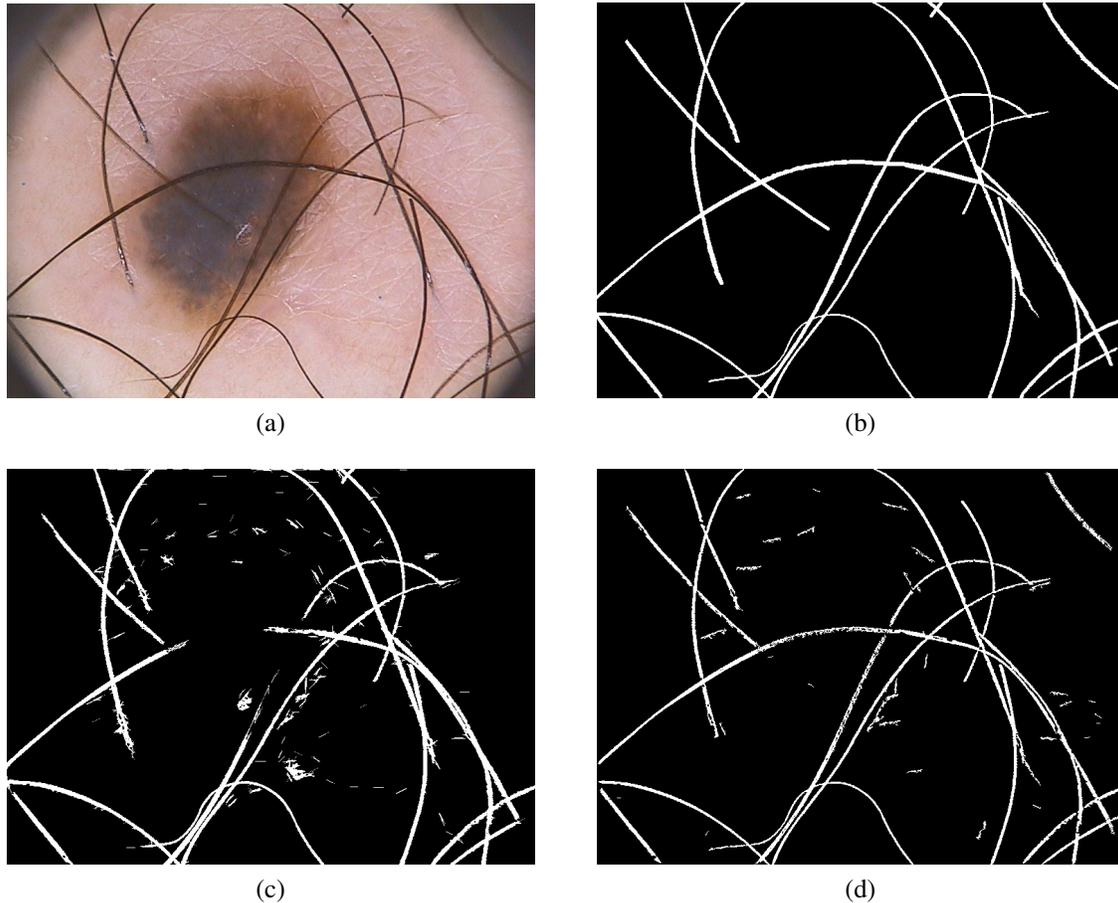


Figura 5.1: Comparación de resultados obtenidos por el método DullRazor y el método propuesto. (a) imagen original, (b) máscara base, (c) resultado de DullRazor, (d) resultado del método propuesto.

La figura 5.1 muestra un ejemplo de la máscara resultante del método DullRazor (c), la máscara resultante del método propuesto (d), la imagen original (a) desde donde se generaron las máscaras, y la máscara base (b); para este caso la máscara binaria del método DullRazor logró una precisión de 0.7023, una exhaustividad de 0.8309 y una medida F_1 de 0.7612, mientras que el método propuesto logró una precisión de 0.9373, una exhaustividad de 0.8372 y una medida F_1 de 0.8844.

5.4 Análisis estadístico

Para comparar los resultados obtenidos del método DullRazor y el método propuesto se aplicó una prueba t-student para muestras pareadas con el software SPSS. Los resultados se describen como (media \pm desviación estándar).

5.5 Resultados del experimento

Una diferencia muy significativa se encontró en la precisión entre el método propuesto ($.78 \pm .19$) y el método DullRazor ($.41 \pm .26$); $t(49) = 13.24$, $P < .001$. También la diferencia en exhaustividad entre el método propuesto ($.65 \pm .18$) y el método Dullrazor ($.44 \pm .28$), $t(49) = 8.33$, $P < .001$, fue muy significativa. Finalmente, en la medida F_1 , se encontró una diferencia muy significativa entre el método propuesto ($.69 \pm .17$) y el método DullRazor ($.37 \pm .23$), $t(49) = 15.81$, $P < .001$.

5.6 Conclusiones

Se considera que existe una diferencia estadísticamente significativa cuando es improbable que un resultado haya sido debido al azar. En las pruebas realizadas para contrastar el método DullRazor y el método propuesto se encontraron diferencias significativas en términos de precisión, exhaustividad y medida F_1 . Todos estos favoreciendo al método propuesto. Lo que demuestra que el método propuesto es más eficiente que el método DullRazor.

6. Conclusión y trabajo futuro

En este Capítulo se discute y concluye la tesis y se describe el trabajo futuro.

6.1 Discusión

El pipeline general del Diagnóstico Asistido por Computadora (CAD) de enfermedades de la piel consiste en: i) adquirir imágenes, ii) aplicar filtros, iii) segmentar la lesión, iv) extraer características, y v) clasificar. La aplicación de filtros, tiene como objetivo eliminar ruido y objetos no deseados (v.g., vellos y vasos capilares) que ocultan características relevantes en las imágenes. El resultado de la eliminación de objetos no deseados afecta la eficiencia de los procesos posteriores, especialmente la segmentación. En la actualidad existen métodos que realizan esta tarea. Uno de los más usados es el DullRazor de Lee et al (1997). Este se basa en la operación morfológica de cierre; usa tres kernels, cada uno posibilita la detección de estructuras que están en un rango de ángulos. Este rango no cubre los 360° . Este enfoque lo hace propenso a omitir algunas estructuras. Otro método es el E-shaver de Kiani and Sharafat (2011), que basa la detección en el operador de Prewitt; uno vertical y otro horizontal. Al igual que DullRazor este método omite estructuras que están en ciertos ángulos. Finalmente, el método propuesto por Abbas et al (2011) que se basa en convoluciones usando un kernel de Derivada de Gaussiana, realiza una fase de refinamiento que liga estructuras que probablemente están desconectadas. Esto posibilita la adición de ruidos.

El método propuesto a diferencia de los métodos descritos, es capaz de detectar objetos

Capítulo 6. Conclusión y trabajo futuro

en cualquier ángulo con una convolución, esto debido al kernel de Diferencia de Gaussianas (DoG) que se utiliza. Adicionalmente, para mejorar la definición e identificación de los objetos, se usa una técnica con múltiples convoluciones con kernels DoG de diferentes parámetros que agrega más información a los objetos. El resultado de esta técnica es un objeto re-definido el cual es más fácil de identificar.

6.2 Conclusiones

En esta tesis se presentó un nuevo método para la detección de vellos y vasos capilares basado en convoluciones con el kernel de DoG. Se contrastó el método DullRazor y el método propuesto en términos de precisión, exhaustividad y medida F_1 . Los resultados obtenidos mostraron diferencias muy significativas en las tres métricas, todas favoreciendo al método propuesto. Esto demuestra que la eficiencia del método propuesto es superior a la del DullRazor. Por lo tanto, el método propuesto puede ayudar a mejorar el resultado de los procesos posteriores en la detección de cáncer de piel mediante imágenes dermatoscópicas.

6.3 Trabajo futuro

Se tiene considerado agregar la función de inpainting mediante el método Fast Marching de Telea (2004). También se pretende incluir funcionalidad para la detección de objetos no deseados cuyas tonalidades de pixeles sean más claras que las de los pixeles vecinos que conforman la piel.

Bibliografía

Abbas Q, Celebi ME, García IF (2011) Hair removal methods: a comparative study for dermoscopy images. *Biomedical Signal Processing and Control* 6(4):395–404

Alegre E, Sánchez L, Fernández R, Mostaza J (2003) *Procesamiento digital de imagen: fundamentos y prácticas con matlab*. Universidad de León

American Cancer Society (2018) Key statistics for melanoma skin cancer. <https://www.cancer.org/cancer/melanoma-skin-cancer/about/key-statistics.html>, online; accessed 06-July-2018

Benvenuto-Andrade C, Oseitutu A, Agero AL, Marghoob AA (2005) Cutaneous melanoma: surveillance of patients for recurrence and new primary melanomas. *Dermatologic therapy* 18(6):423–435

Cotton SD (1995) *Colour, colour spaces, and the human visual system*. University of Birmingham, School of Computer Science e-print, 1st May

Feit NE, Dusza SW, Marghoob AA (2004) Melanomas detected with the aid of total cutaneous photography. *British Journal of Dermatology* 150(4):706–714

Ford A, Roberts A (1998) *Colour space conversions*. Westminster University, London 1998:1–31

Fornaciali M, Avila S, Carvalho M, Valle E (2014) Statistical learning approach for ro-

BIBLIOGRAFÍA

- bust melanoma screening. In: Graphics, Patterns and Images (SIBGRAPI), 2014 27th SIBGRAPI Conference on, IEEE, pp 319–326
- Kiani K, Sharafat AR (2011) E-shaver: An improved dullrazor® for digitally removing dark and light-colored hairs in dermoscopic images. *Computers in biology and medicine* 41(3):139–145
- Lee T, Ng V, Gallagher R, Coldman A, McLean D (1997) Dullrazor®: A software approach to hair removal from images. *Computers in biology and medicine* 27(6):533–543
- Mendonça T, Ferreira PM, Marques JS, Marcal AR, Rozeira J (2013) Ph 2-a dermoscopic image database for research and benchmarking. In: Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE, IEEE, pp 5437–5440
- Palus H (1998) Colour spaces, chapter 4. Chapman and Hall, p 67
- Piccolo D, Ferrari A, Peris K, Daidone R, Ruggeri B, Chimenti S (2002) Dermoscopic diagnosis by a trained clinician vs. a clinician with minimal dermoscopy training vs. computer-aided diagnosis of 341 pigmented skin lesions: a comparative study. *British Journal of Dermatology* 147(3):481–486
- Proakis JG, Manolakis DG, nica (trad) Santalla del R; o V, Luis J (2007) Tratamiento digital de señales. Pearson Educación
- Rayner JE, Laino AM, Nufer KL, Adams L, Raphael AP, Menzies SW, Soyer HP (2018) Clinical perspective of 3d total body photography for early detection and screening of melanoma. *Frontiers in medicine* 5
- Richter AN, Khoshgoftaar TM (2017) Predicting sentinel node status in melanoma from a

BIBLIOGRAFÍA

- real-world ehr dataset. In: 2017 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), IEEE, pp 1872–1878
- Telea A (2004) An image inpainting technique based on the fast marching method. *Journal of graphics tools* 9(1):23–34
- Tkalcic M, Tasic JF (2003) Colour spaces: perceptual, historical and applicational background, vol 1. IEEE
- UNAM DGCS (2018) Cáncer de piel, el segundo más frecuente en México, advierte investigador de la unam. http://www.dgcs.unam.mx/boletin/bdboletin/2017_237.html, URL http://www.dgcs.unam.mx/boletin/bdboletin/2017_237.html, online; accessed 06-July-2018
- Vestergaard M, Macaskill P, Holt P, Menzies S (2008) Dermoscopy compared with naked eye examination for the diagnosis of primary melanoma: a meta-analysis of studies performed in a clinical setting. *British Journal of Dermatology* 159(3):669–676
- Weinstock MA (2006) Cutaneous melanoma: public health approach to early detection. *Dermatologic therapy* 19(1):26–31
- Wighton P, Lee TK, Lui H, McLean DI, Atkins MS (2011) Generalizing common tasks in automated skin lesion diagnosis. *IEEE Transactions on Information Technology in Biomedicine* 15(4):622–629
- Wikipedia (2018) Morfología matemática. https://es.wikipedia.org/wiki/Morfología_matemática, online; accessed 10-September-2018
- Wurm EM, Soyer HP (2010) Scanning for melanoma. *Australian Prescriber* 33(5):150–5
- Xiang Z, Joy G (1994) Color image quantization by agglomerative clustering. *IEEE Computer Graphics and Applications* (3):44–48

Glosario

Apertura es la operación morfológica que consiste en aplicar a una imagen binaria o en escala de grises una operación de Erosión y al resultado aplicarle una operación de Dilatación. 22

Cierre es la operación morfológica que consiste en aplicar a una imagen binaria o en escala de grises una operación de Dilatación y al resultado aplicarle una operación de Erosión. 23

convolución es el cálculo que se realiza sobre una imagen con un núcleo para desenfocar, realzar, detectar bordes y más. 9

Dermatoscopia es una técnica no invasiva de diagnóstico en dermatología, que mediante un instrumento óptico, llamado dermatoscopio, permite examinar mejor las lesiones por debajo de la superficie cutánea amplificando in-vivo la imagen sospechosa una vez eliminados los fenómenos de refracción y reflexión de la luz sobre la piel. 1

Dilatación es una de las dos operaciones fundamentales (la otra es la Erosión) en el procesamiento de imágenes morfológico en las que se basan todas las otras operaciones morfológicas. 21

disemina extender o esparcir sin orden y en diferentes direcciones. 1

DoG Diferencia de Gaussianas (del inglés *Difference of Gaussians*). 36

DullRazor es un método para eliminar vellos en imágenes dermatoscópicas. 7

elemento estructurante es una matriz pequeña que se usa para probar una imagen sacando conclusiones sobre cómo esta matriz encaja o no en las formas de la imagen. Este

concepto se utiliza en el filtrado no lineal de imágenes. 7

Erosión es una de las dos operaciones fundamentales (la otra es la Dilatación) en el procesamiento de imágenes morfológico en las que se basan todas las otras operaciones morfológicas. 20

espacio de color es la colección de todos los colores definidos en un modelo de color. 15

estadísticamente significativa es una expresión que se usa cuando es improbable que un resultado haya sido debido al azar. 42

exhaustividad es la fracción de instancias relevantes que han sido recuperadas. 3

ganglio linfático es una estructura en forma de frijol que forma parte del sistema inmunitario. 1

imagen médica es el conjunto de técnicas y procesos usados para crear imágenes del cuerpo humano, o partes de él, con propósitos clínicos (procedimientos médicos que buscan revelar, diagnosticar o examinar enfermedades) o para la ciencia médica (incluyendo el estudio de la anatomía normal y función). 11

imágenes dermatoscópicas son fotografías digitales de una lesión de la piel tomadas con una cámara equipada con una extensión especial de la lente. 4

kernel núcleo en español. 9

lesiones nodulares son lesiones redondeadas, circunscritas, profundas y dependiendo de su localización pueden ser palpables o no. 2

matiz es un componente que indica el color. 17

medida F es la media armónica que combina los valores de la precisión y de la exhaustividad. 40

melanoma es el tipo más peligroso de cáncer de piel. 1

morfología matemática es una teoría y técnica para el análisis y tratamiento de las estructuras geométricas, basada en la teoría de conjuntos, teoría de retículos, topología y funciones aleatorias. 19

máscara binaria es el conjunto de datos que, junto con una operación permiten extraer selectivamente ciertos datos almacenados en otro conjunto. 7

nevo es una proliferación de distintos tipos de células en la piel. 2

núcleo es una matriz pequeña que se utiliza para el desenfoque, enfoque, realce, detección de bordes y más en imágenes. Este concepto se utiliza en el filtrado lineal de imágenes. 36

observador colorimétrico es el conjunto de funciones que mapea colores. 17

Oncodermatología es una amplia subespecialidad dermatológica. Comprende el diagnóstico y el tratamiento de las lesiones cancerosas de la piel. 1

parámetro de umbral es el parámetro que sirve para separar píxeles. En la binarización, el umbral es la frontera que separa los 1's y los 0's. 7

precisión es la fracción de instancias recuperadas que son relevantes. 3

procesamiento de imágenes es un conjunto de técnicas que se aplican a las imágenes digitales con el objetivo de mejorar la calidad o facilitar la búsqueda de información. 11

prognosis es el conocimiento anticipado de algún suceso. 2

prueba T es una prueba de hipótesis de la media de una o dos poblaciones distribuidas normalmente. 42

retículo es una estructura algebraica con dos operaciones binarias, o bien un conjunto parcialmente ordenado con la propiedad fundamental de que toda pareja de elementos tiene un único supremo (o extremo superior) y un único ínfimo (o extremo inferior). 19

Glosario

teledetección es la adquisición de información a pequeña o gran escala de un objeto o fenómeno, ya sea usando instrumentos de grabación o instrumentos de escaneo en tiempo real inalámbricos o que no están en contacto directo con el objeto (como por ejemplo aviones, satélites, astronave, boyas o barcos). 11

tipología es el estudio de los tipos o modelos que se usan para clasificar en diversas ciencias o disciplinas científicas. 19

Transformada de Fourier es una transformación matemática empleada para transformar señales entre el dominio del tiempo (o espacial) y el dominio de la frecuencia. 12

transformada de Radon es una transformación integral que consiste en la integral de una función sobre un conjunto de rectas. 9

vasos capilares son vasos sanguíneos que surgen como pequeñas ramificaciones de las arterias a lo largo de todo el cuerpo y cerca de la superficie de la piel. 3

vellos son el tipo de pelo que recubre la mayor parte del cuerpo en los seres humanos. 3