

# Trabajo Fin de Grado

Grado en Ingeniería de Tecnologías de Telecomunicación  
Intensificación de Sonido e Imagen

## Algoritmo automático para la detección de melanoma basado en características de color y textura

Autora: María del Mar Velasco Montero

Tutoras: Irene Fondón García

María Auxiliadora Sarmiento Vega

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

Sevilla, 2014





Trabajo Fin de Grado  
Grado en Ingeniería de Tecnologías de Telecomunicación

# **Algoritmo automático para la detección de melanoma basado en características de color y textura**

Autora:

María del Mar Velasco Montero

Tutoras:

Irene Fondón García

Profesora Contratada Doctora

María Auxiliadora Sarmiento Vega

Profesora Ayudante Doctora

Dep. de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2014

Trabajo Fin de Grado: Algoritmo automático para la detección de melanoma basado en características de color y textura

Autora: María del Mar Velasco Montero  
Tutoras: Irene Fondón García  
María Auxiliadora Sarmiento Vega

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

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2014

El Secretario del Tribunal

## CONTENIDO

---

<b>1. INTRODUCCIÓN</b>	<b>7</b>
<b>2. PRINCIPIOS BÁSICOS SOBRE COLOR Y TEXTURA</b>	<b>8</b>
COLOR	8
TEXTURA	9
<b>ALGORITMOS DEL ESTADO DEL ARTE</b>	<b>10</b>
<b>3. DESCRIPCIÓN DEL ALGORITMO DE SEGMENTACIÓN</b>	<b>11</b>
PRE-PROCESADO	12
EXTRACCIÓN DE LOS VECTORES TEXTURA	12
ANÁLISIS DE COMPONENTES PRINCIPALES (PCA)	13
ALGORITMO DE CLUSTERING INICIAL	14
MODELO DE AGRUPAMIENTO DE MEZCLA FINITA	14
CLASIFICACIÓN DE LOS PÍXELES EN LAS DISTRIBUCIONES TEXTURALES	15
MÉTRICA DE LAS DIFERENCIAS DE TEXTURA	15
DIVISIÓN DE LA IMAGEN EN MÚLTIPLES REGIONES	17
IMAGEN DIFERENCIA DE TEXTURA REGIONAL	18
ASIGNACIÓN DE LA CLASE LESIÓN/PIEL A LOS PÍXELES	18
REFINADO DE LA IMAGEN SEGMENTADA	19
RESUMEN	19
<b>4. RESULTADOS</b>	<b>22</b>
<b>5. CONCLUSIONES</b>	<b>58</b>
LÍNEAS FUTURAS	58
<b>6. REFERENCIAS</b>	<b>59</b>

## ÍNDICE DE ILUSTRACIONES Y TABLAS

---

<b>ILUSTRACIÓN 1. FASES DE UN SISTEMA DE AYUDA AL DIAGNÓSTICO BASADO EN PROCESAMIENTO DE IMÁGENES</b>	<b>7</b>
<b>ILUSTRACIÓN 2. MODELO RGB EN FORMA DE CUBO</b>	<b>8</b>
<b>ILUSTRACIÓN 3. CONO REPRESENTACIÓN DEL ESPACIO DE COLOR HSV</b>	<b>9</b>
<b>ILUSTRACIÓN 4. DIAGRAMA DE CROMATICIDAD CIE XYZ</b>	<b>9</b>
<b>ILUSTRACIÓN 5. EJEMPLO DE TEXTURA EN FORMA DE PATRÓN PRESENTE EN LA PERIFERIA DE LA LESIÓN</b>	<b>10</b>
<b>ILUSTRACIÓN 6. IMAGEN ORIGINAL (IZQUIERDA) Y SU VERSIÓN CORREGIDA EN ILUMINACIÓN (DERECHA)</b>	<b>12</b>
<b>ILUSTRACIÓN 7. REPRESENTACIÓN DE LA TEXTURA DE UNA VECINDAD 5X5 CENTRADA EN EL PÍXEL <math>x</math></b>	<b>13</b>
<b>ILUSTRACIÓN 8. EJEMPLO DE CLASIFICACIÓN DE CADA PÍXEL EN UNA DE LAS 10 DISTRIBUCIONES TEXTURALES</b>	<b>15</b>
<b>ILUSTRACIÓN 9. EJEMPLO DE IMAGEN DE DIFERENCIAS TEXTURALES</b>	<b>16</b>
<b>ILUSTRACIÓN 10. IMAGEN SEGMENTADA CON VARIAS REGIONES NO CONTIGUAS</b>	<b>19</b>
<b>ILUSTRACIÓN 11. ETAPAS DEL ALGORITMO IMPLEMENTADO</b>	<b>20</b>
<b>ILUSTRACIÓN 12. DIAGRAMA DEL ALGORITMO DESGLOSADO POR BLOQUES</b>	<b>21</b>
<b>TABLA 1. VARIABLES EMPLEADAS ENTRE LOS DISTINTOS BLOQUES DEL ALGORITMO</b>	<b>21</b>
<b>TABLA 2. CLASIFICACIÓN DE LOS PÍXELES SEGÚN LA VERDAD DE REFERENCIA</b>	<b>22</b>

# 1. INTRODUCCIÓN

---

La motivación de este trabajo es conseguir un sistema que, de manera automática, realice la segmentación de lesiones de piel tomadas con una cámara digital, con el fin de la detección de melanomas. Para ello, se ha desarrollado un algoritmo de segmentación de imágenes como paso inicial de un futuro sistema de ayuda al diagnóstico (*Computer-Aided Diagnosis, CAD*) basado en técnicas de procesamiento de imagen.

El cáncer más común es el de piel y, en concreto, el melanoma es el cáncer con mayor índice de mortalidad de entre todos los cánceres de piel. La tasa de melanoma está en continuo aumento, afectando sobre todo a personas blancas no hispánicas. Las cifras de incidencias estimadas por la Sociedad Americana Contra el Cáncer para el año 2014 sólo en EEUU se elevan a 76100 nuevos diagnósticos y 9710 muertes por melanoma (siendo la tasa de impacto mayor en hombres que en mujeres) (1). La detección precoz de esta lesión de piel aumenta las probabilidades de curación, por lo que cobra gran importancia una alternativa de bajo coste que evite la evaluación de cada paciente por parte de los dermatólogos. Dicha alternativa puede ser un sistema automático que, partiendo de imágenes de lesiones de piel obtenidas con una cámara digital estándar, valore el riesgo de melanoma.

En los últimos años se han desarrollado algoritmos muy diversos con el fin de lograr la segmentación automática de lesiones de piel. Muchos de ellos emplean imágenes tomadas con un dermatoscopio digital, técnica no invasiva de imagen de piel también conocida como microscopía epiluminescente. Ésta consiste en un microscopio que además del aumento óptico, utiliza iluminación con aceite de inmersión o luz polarizada, evitando reflexiones de la luz en contacto con la piel. De esta manera, se consigue hacer visible estructuras bajo la superficie de la piel, que no son discernibles a simple vista, facilitando el diagnóstico (2).

Sin embargo, distintos estudios (3) (4) demuestran la utilidad de las imágenes dermatoscópicas en el diagnóstico de melanoma, pero sólo para dermatólogos expertos, con suficiente experiencia para un uso provechoso del dermatoscopio. En caso contrario, este dispositivo puede incluso disminuir la precisión del diagnóstico. Esta es la causa del interés en algoritmos automáticos de detección de melanoma a partir de fotografías tomadas con una cámara digital, evitándose así la dependencia de un dermatólogo formado en el uso del equipo.

Dada una imagen de lesión de piel que se desea evaluar, se deben dar algunos pasos previos a la clasificación de la misma como benigna o maligna. En primer lugar, se puede aplicar algún tipo de pre-procesado que lleve a una mejor calidad de la imagen o a un mejor contraste de la zona. Tras este paso, se ejecuta el algoritmo de segmentación que encuentra los bordes de la lesión, separando la piel sana de la zona lesionada. Una vez se ha identificado el contorno que delimita el posible cáncer de piel, se extraen características de la lesión. Son estas características las que permiten la clasificación.



ILUSTRACIÓN 1. FASES DE UN SISTEMA DE AYUDA AL DIAGNÓSTICO BASADO EN PROCESAMIENTO DE IMÁGENES

Una segmentación precisa es un paso crucial en el diagnóstico por imagen, ya que las características que permitirán la clasificación de la lesión se basan en la información que ofrece el área seleccionada.

En el campo del cáncer de piel, un conjunto de características muy usado para la clasificación es el conocido como ABCD, que diagnostica a partir de la Asimetría, irregularidad del Borde, Color y Diámetro (5). Estos rasgos son muy dependientes de la exactitud de la localización del borde. De ahí la importancia de un algoritmo de segmentación que ofrezca resultados similares a los obtenidos por un experto que segmentase manualmente la imagen.

## 2. PRINCIPIOS BÁSICOS SOBRE COLOR Y TEXTURA

---

Existe una gran variedad de técnicas de procesado de imágenes que logran dividir una imagen en zonas homogéneas respecto a alguna propiedad deseada. Dicha característica que define la segmentación suele ser el color o la textura.

Las imágenes capturadas con una cámara digital se obtienen de forma que la respuesta del sensor a la luz recibida en cada punto se almacena como un valor que indica el nivel de intensidad en dicho punto. Como resultado, se almacena una matriz bidimensional de niveles de gris.

### COLOR

---

Se sabe que el espectro de color puede ser representado a partir de tres componentes base. Para imágenes en color, se tienen varios canales en escala de gris representando cada uno de ellos un valor o color básico. El color de cada píxel es el resultado de la combinación lineal de los valores de cada uno de los canales. Por lo tanto, la imagen a color está representada por tres planos 2D y cada píxel contiene tres valores de intensidad, uno por canal.

Dependiendo de cuál sea la base a partir de la cual es posible conseguir una gama de colores mediante combinaciones lineales, se tienen distintas representaciones de color, conocidas como espacios de color. A continuación se recogen algunos de los principales espacios de color usados en la representación de imágenes digitales (6).

El espacio de color más utilizado es el RGB. Basado en los tres tipos de receptores de color que tiene el ojo humano, cada plano de color representa un color primario: rojo (*Red*, R), verde (*Green*, G) y azul (*Blue*, B). Es posible modelar este espacio de color como un cubo cuyos ejes son los colores primarios y cada punto es un posible color representable

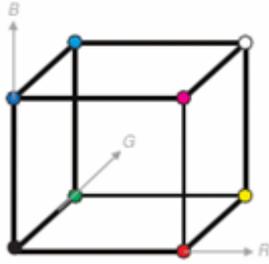


ILUSTRACIÓN 2. MODELO RGB EN FORMA DE CUBO

combinando los primarios. El origen del cubo representa el color negro (ausencia de color) y el vértice opuesto sería el blanco (máxima intensidad de cada color). La Comisión Electrotécnica Internacional (IEC) estandarizó el espacio RGB para sistemas de visualización (imágenes web, editores de imagen) dando lugar a las especificaciones recogidas en el espacio sRGB, usado por Microsoft Windows.

Una vía más cercana a la percepción humana es la representación del color mediante el espacio HSV, donde los tres parámetros básicos son el tono (*Hue*, H), la saturación (*Saturation*, S) y el valor (*Value*, V). El tono indica la longitud de onda dominante, la saturación hace referencia a la pureza (ausencia de blanco) del color y el valor es el brillo. Se puede representar este espacio como un cono cuyo ángulo está relacionado con el tono, el radio con la saturación y la altura con el valor.

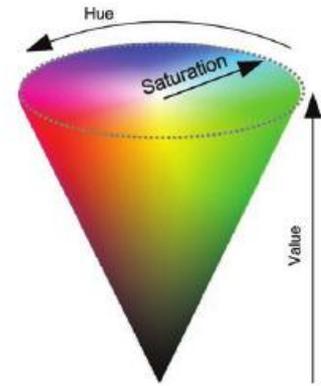


ILUSTRACIÓN 3. CONO REPRESENTACIÓN DEL ESPACIO DE COLOR HSV

La Comisión Internacional del Color (CIE) definió en 1931 un conjunto de primarios XYZ que son abstracciones matemáticas, no pudiendo ser identificados con luces visibles. Uno de ellos se corresponde con el valor de la luminancia o brillo. Mediante una proyección del espacio de color en un plano bidimensional donde las componentes X,Y y Z están normalizadas entre la

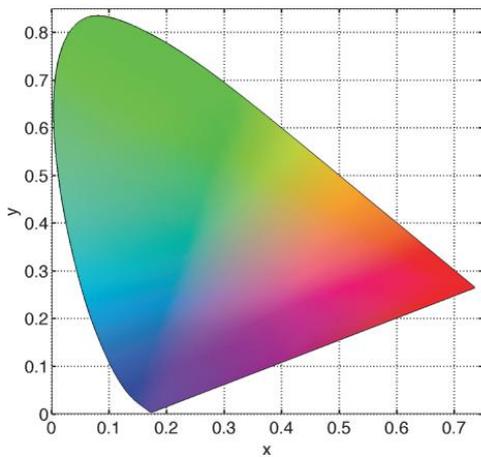


ILUSTRACIÓN 4. DIAGRAMA DE CROMATICIDAD CIE XYZ

suma  $X + Y + Z$ , se puede obtener el llamado diagrama de cromaticidad. En éste todas las combinaciones de colores que se pueden obtener como mezcla de tres colores base quedan dentro del triángulo definido por dichas coordenadas base (7) (8).

Mediante transformaciones matemáticas del espacio XYZ se llega a los sistemas CIE  $L^*a^*b^*$  y CIE  $L^*u^*v^*$  de 1976, que tratan de ser uniformes. Es decir, las diferencias de color percibidas por el ojo humano son proporcionales a las distancias en el diagrama de cromaticidad. El sistema CIE  $L^*u^*v^*$  ha sido muy utilizado en la industria televisiva y de visualización, mientras que la industria de impresión ha optado por CIE  $L^*a^*b^*$ .

## TEXTURA

Por textura se entiende la repetición de un patrón cuyos elementos primitivos o *textels* (*texture elements*) se organizan siguiendo una estructura determinada. El análisis por textura intenta aprovechar los rasgos texturales como fineza, rugosidad, granulación, suavidad, aleatoriedad, etc. presentes en la imagen. Se debe tener en cuenta que un punto no presenta textura, sino que es la región en la que se encuentra la que puede tener características texturales. Aunque la gama de métodos que analizan la textura es muy

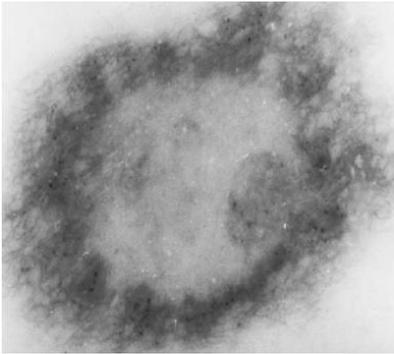


ILUSTRACIÓN 5. EJEMPLO DE TEXTURA EN FORMA DE PATRÓN PRESENTE EN LA PERIFERIA DE LA LESIÓN

amplia (9), a grosso modo pueden clasificarse en métodos estructurales y estadísticos (10) (11) (12).

Los métodos estructurales tratan de encontrar las primitivas que definen la textura y su organización espacial, estudiándolas de forma directa por sus características tales como la forma o el tamaño.

Por su parte, los métodos estadísticos definen la textura según estadísticos extraídos del nivel de gris local de una vecindad. Las distintas texturas pueden ser diferenciadas mediante la comparación de estos estadísticos. Los métodos estadísticos pueden ser clasificados, a su vez, en métodos de primer orden o de orden superior (12).

Si se obtienen medidas estadísticas de la vecindad de píxeles individuales se tienen métodos de primer orden. Estos caracterizan la textura extrayendo información del histograma (número de ocurrencias de cada nivel de gris) a través del cálculo de momentos de distinto orden, obteniéndose la media, varianza, suavidad, curtosis, sesgo, asimetría.

Los métodos de segundo orden utilizan la distribución en la imagen de parejas de píxeles mediante matrices de coocurrencia (histogramas en dos dimensiones). Algunos estadísticos que se pueden obtener son la energía, el contraste, la entropía o la homogeneidad.

## ALGORITMOS DEL ESTADO DEL ARTE

---

En el panorama actual, coexisten algoritmos de segmentación automática de lesiones de piel que necesitan imágenes tomadas con un dermatoscopio, mientras que otros admiten imágenes adquiridas de forma más sencilla con una cámara digital.

Muchos algoritmos incluyen un pre-procesado de la imagen como paso previo fundamental, buscando mejorar el proceso de segmentación mediante técnicas de corrección de iluminación, realce del contraste, cambio de espacio de color, eliminación de artefactos tales como vasos sanguíneos o pelo, etc.

Son muchos los trabajos realizados en el campo de la segmentación de lesiones de piel. Los métodos de segmentación encontrados en la literatura aplican las siguientes técnicas (2):

- Umbralización del histograma: mediante el cálculo del histograma de la imagen se establece uno o varios umbrales que separen los objetos del fondo.
- *Clustering* o agrupación: mediante distintos algoritmos automáticos se consigue la separación de regiones que presentan homogeneidad.
- Algoritmos basados en bordes: se encuentra el borde entre regiones mediante distintas técnicas: contornos activos, operadores de bordes, operadores morfológicos.
- Algoritmos basados en región: llevando a cabo la fusión o escisión de regiones se agrupan los píxeles que comparten características.
- Algoritmos basados en modelos: acuden al modelado de la imagen como campos aleatorios cuyos parámetros son optimizados.

- *Soft-computing*: la clasificación de cada píxel es determinada mediante técnicas computacionales capaces de manejar información imprecisa, como redes neuronales o lógica difusa.

Los algoritmos que se basan en el color de cada píxel para clasificarlo como perteneciente a una determinada región suelen utilizar la información de un único canal (más simple computacionalmente), de tres canales o bien de una transformación de los distintos canales del espacio de color considerado.

Schmid (13) recurre a la matemática morfológica sobre la componente de luminancia, mientras que Celebi et al. (14) aplican métodos de fusión de regiones y Gómez et al. (15) desarrollan un algoritmo de *clustering*.

La umbralización usando imágenes en escala de grises o en un único canal es un método que se repite por los distintos autores. Cavalcanti et al. en (16) realizan una serie de pasos de segmentación, empezando por la umbralización, y siguiendo con contornos activos y operaciones morfológicas.

La mayoría de los algoritmos de segmentación sólo utilizan características de color. Sin embargo, estas características pueden no ser suficientes si los bordes no están totalmente definidos por las variaciones de color, resultando de gran utilidad la información textural debido a la diferencia de textura entre la piel sana y la zona de la lesión.

Los métodos que hacen uso de la información textural de cada región, extraen rasgos y medidas de la textura de distintas partes de la imagen y realizan una comparación.

Autores como Stoecker et al. (10) han aplicado algoritmos de detección de bordes basados en textura en imágenes de piel. En concreto, estos autores eligen tres métodos estadísticos de análisis de textura para desarrollar su trabajo: métodos basados en matriz de coocurrencia, estadísticos de la diferencia del nivel de gris, y modelos paramétricos de textura.

Otros autores han aplicado distintos algoritmos de segmentación basados en textura. La información de textura se ha extraído de forma muy diversa, aplicándose modelos de campos aleatorios Markov (17) o filtros Gabor (18).

Con el objetivo de realizar la segmentación de lesiones de piel, sería deseable combinar la información que ofrece tanto el color como la textura, ya que ambas propiedades se presentan diferentes en la piel normal y la zona lesionada. Ésta es la idea llevada a cabo por autores como Pan Ng y Chi-Man Pun (19) o Dhawan A. P. y Sim A. (20), entre otros.

### 3. DESCRIPCIÓN DEL ALGORITMO DE SEGMENTACIÓN

---

El algoritmo que se ha implementado se basa fundamentalmente en el llamado algoritmo de segmentación de lesión por diferencia de textura o TDLS (*Texture Distinctiveness Lesion Segmentation*) desarrollado por Glaister J., Wong A. y Clausi D. A. en (21). En líneas muy generales consiste en la obtención de las texturas presentes en la imagen, el cálculo de una medida diferencia de una textura con el resto, y la clasificación de regiones de la imagen como piel normal o piel lesionada basándose en dicha medida.

## PRE-PROCESADO

Se parte de una imagen digital estándar de un posible melanoma. Las variaciones de la iluminación pueden dar lugar a zonas de la imagen con sombras o brillos, que podrían identificarse incorrectamente como parte de la lesión en el algoritmo de segmentación. De acuerdo con (22), y con objeto de corregir dichas variaciones de iluminación, se aplica un filtro homomórfico como paso de pre-procesado antes de la segmentación. Cada píxel de la imagen puede ser visto como el producto de una componente de iluminación y una componente de reflectancia. El filtro homomórfico aprovecha la escasa variación espacial de la componente de iluminación de la imagen (baja frecuencia de la transformada de Fourier) frente a la mayor variación de la componente reflectancia (alta frecuencia). Un filtrado en el dominio de la frecuencia que afecte de modo desigual a bajas y altas frecuencias permite controlar la iluminación como se desee, mejorando la apariencia de la imagen (23).

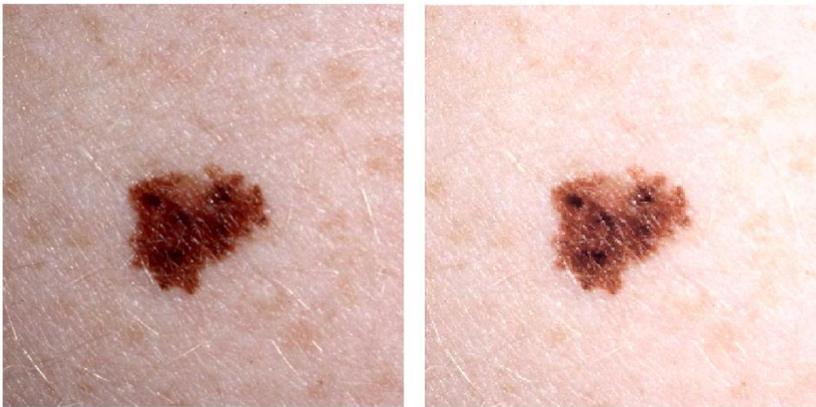


ILUSTRACIÓN 6. IMAGEN ORIGINAL (IZQUIERDA) Y SU VERSIÓN CORREGIDA EN ILUMINACIÓN (DERECHA)

Una vez corregida la imagen, se convierte al espacio de color XYZ, ya que según el estudio presentado por Terrillon et al. (24), en el que se comparan diferentes espacios de color, el XYZ es eficiente en la segmentación de zonas de piel de caras humanas y, por tanto, de otras zonas de piel.

## EXTRACCIÓN DE LOS VECTORES TEXTURA

A continuación, se buscan distribuciones de textura que representen piel y lesión. Para ello, se emplea un modelo estadístico de textura en el que se extrae de cada píxel de la imagen un vector que representa la textura de la vecindad centrada en dicho píxel. Se opta por un modelo de textura basada en la vecindad detallado por Scharfenberger et al. en (25) que es adecuado para representar texturas locales.

La representación de textura es dispersa y radialmente ordenada. Sea  $I(x)$  un canal de color de la imagen, la representación textural de la vecindad centrada en el píxel  $x$  en el mencionado canal es:

$$h_{canal}(x) = \begin{bmatrix} I(x) \text{ ordenación}_\uparrow(I(x_{1,j})) & \text{ordenación}_\uparrow(I(x_{2,j})) \\ \dots & \text{ordenación}_\uparrow(I(x_{n,j})) \end{bmatrix} \quad [1]$$

donde  $x_{i,j}$  es el conjunto de píxeles que forman la capa radial  $i$  sobre el píxel  $x$ . Es decir, es el vector formado por el valor del píxel  $x$  en el canal de color considerado, seguido de la ordenación ascendente de los píxeles de sus capas radiales, empezando por la más cercana.

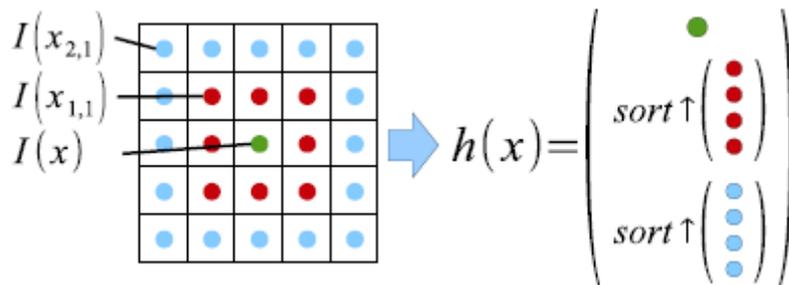


ILUSTRACIÓN 7. REPRESENTACIÓN DE LA TEXTURA DE UNA VECINDAD 5X5 CENTRADA EN EL PÍXEL  $x$

La representación textural de la vecindad teniendo en cuenta los tres canales de color es el vector formado por la concatenación de los vectores textura  $h_{canal}(x)$  obtenidos de cada canal.

$$h(x) = [h_{canal1}(x) \ h_{canal2}(x) \ h_{canal3}(x)] \quad [2]$$

Se ha elegido una vecindad cuadrada 5x5 siguiendo los resultados experimentales obtenidos por Scharfenberger et al. (25). Por lo tanto, para cada píxel de la imagen se tiene un vector textura  $h(x)$  formado por 75 elementos.

Con objeto de extraer el vector textura de los píxeles pertenecientes a la periferia de la imagen, se emplea una imagen similar a la original (pero de mayor tamaño) en la que los bordes son extendidos. Se copia el valor de los píxeles de los bordes, primero los horizontales y después los verticales, formándose una imagen de la que es posible extraer tantos vectores textura como píxeles tiene la imagen original.

## ANÁLISIS DE COMPONENTES PRINCIPALES (PCA)

---

Dada la cantidad y la dimensión de los vectores textura obtenidos, en este paso se reduce el número de componentes de los mismos con el fin de mejorar la eficiencia del algoritmo.

Siguiendo de nuevo el trabajo (25), se realiza un Análisis de Componentes Principales (PCA) que retenga únicamente el número de componentes principales de los vectores textura que representan el 95% de la varianza de todos los vectores textura.

La técnica PCA expresa los datos cuyas dimensiones se desean reducir en términos de sus principales autovectores. Para ello, tras extraer la media a cada vector textura  $h(x)$ , se calculan los autovectores de su matriz de covarianza. Aquellos autovectores con mayores autovalores representan los componentes principales de los datos, esto es, los que contienen más información. Si éstos se agrupan formando las filas de una matriz de transformación y ésta se multiplica a cada vector textura sin media, se está realizando una transformación en la que los nuevos vectores textura  $t(x)$  quedan expresados en términos de los autovectores elegidos y su dimensión se ve reducida (26).

$$h(x) \xrightarrow{PCA} t(x) \quad [3]$$

El número de autovectores principales que suman el 95% de la varianza de todos los autovectores es elegido para formar la matriz de transformación, de modo que determina la dimensión de los nuevos datos.

---

### ALGORITMO DE CLUSTERING INICIAL

---

Para encontrar un conjunto de  $K$  distribuciones Gaussianas que representen las distintas texturas presentes en la imagen, se aplicará un modelo de mezcla finita. La inicialización es importante ya que de ésta depende la robustez y el tiempo de convergencia del modelo. Mediante un algoritmo de agrupamiento o *clustering* se obtendrán los parámetros que inicialicen el modelo.

El algoritmo de *clustering* elegido, denominado *k-means*, trata de encontrar  $K$  grupos de vectores textura o *clusters* de acuerdo a las distancias entre ellos. Se eligen aleatoriamente los centroides o vectores media de los *clusters* y se asigna cada vector textura al *cluster* cuyo centroide está más cerca. Iterativamente, se recalculan los centroides y, consecuentemente, la asignación de cada vector textura a un *cluster* hasta encontrar las agrupaciones que minimizan la suma de las distancias Euclídeas de cada vector textura al centroide de su *cluster*. Por tanto, la función de optimización es la siguiente:

$$\hat{C} = \arg \min_C \sum_{k=1}^K \sum_{t_i \in C_k} \|t_i - \mu_{C_k}\|^2 \quad [4]$$

con  $t_i$  los vectores textura y  $\mu_{C_k}$  centroide del *cluster*  $C_k$

El número  $K$  de *clusters* y, por tanto, de distribuciones Gaussianas que se ha elegido es 10, siguiendo las indicaciones de (21) para un mejor modelado de texturas de piel y lesión.

---

### MODELO DE AGRUPAMIENTO DE MEZCLA FINITA

---

Como se ha mencionado anteriormente, se considera que todos los *clusters* de vectores textura siguen una distribución Gaussiana y se busca la mezcla de  $K$  distribuciones que los modele mediante un segundo algoritmo de *clustering*.

Los parámetros utilizados para la inicialización del algoritmo de mezcla son extraídos de los *clusters* resultados del algoritmo *k-means*, mediante el cálculo de la media  $\mu_{C_k}$ , matriz de covarianza  $\Sigma_{C_k}$  y probabilidad  $\alpha_{C_k}$  de cada *cluster*.

El algoritmo empleado es el conocido como Maximización de la Esperanza o EM. Se trata de un algoritmo iterativo que trata de encontrar los parámetros  $\theta_k$  (media  $\mu_k$ , matriz de covarianza  $\Sigma_k$  y probabilidad  $\alpha_k$ ) óptimos de cada distribución Gaussiana de la mezcla, es decir el estimador de máxima verosimilitud (*maximum likelihood, ML*) logarítmica de los parámetros del modelo. Para ello, se maximiza la siguiente función:

$$\hat{\theta}_{ML} = \arg \max_{\theta} \left( \sum_{i=1}^n \sum_{k=1}^K \log(\alpha_k P(t_i | \mu_k, \Sigma_k)) \right) \quad [5]$$

con  $P(t_i|\mu_k, \Sigma_k)$  la probabilidad del vector textura  $i$  dados los parámetros de la distribución  $k$ .

Mediante la repetición de dos pasos se produce una secuencia de estimadores  $\hat{\theta}$  hasta converger (27):

- Paso E (Esperanza): calcula la esperanza de la verosimilitud logarítmica de los vectores textura condicionada al estimador actual.
- Paso M (Maximización): actualiza los parámetros  $\theta$  para que maximicen la esperanza anterior.

## CLASIFICACIÓN DE LOS PÍXELES EN LAS DISTRIBUCIONES TEXTURALES

---

Al finalizar el algoritmo EM, se tienen  $K$  distribuciones Gaussianas, con sus parámetros definidos, representando las distintas texturas presentes en la imagen. Cada vector textura  $t_i$  es asignado a aquella distribución que maximiza la probabilidad a posteriori  $P(T_j|t_i)$ , es decir, la probabilidad de la distribución  $T_j$  dado el vector textura  $t_i$ . Como cada vector textura pertenece a un píxel de la imagen, es posible asociar cada píxel a una distribución, dando lugar a un mapa de distribuciones de textura.

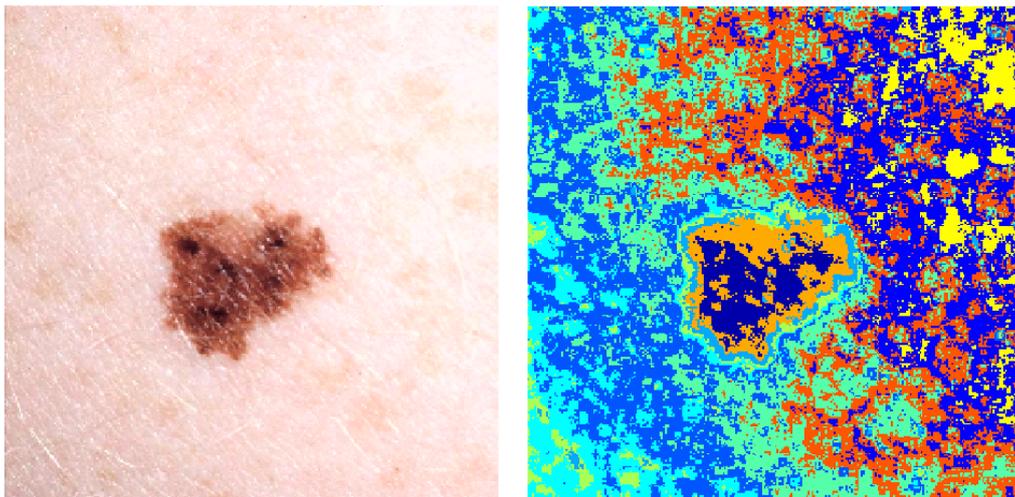


ILUSTRACIÓN 8. EJEMPLO DE CLASIFICACIÓN DE CADA PÍXEL EN UNA DE LAS 10 DISTRIBUCIONES TEXTURALES

En la ilustración 8 se puede observar cómo la zona lesionada de piel tiene unos patrones texturales distintos al resto de piel. Como se han elegido  $K = 10$  distribuciones Gaussianas que caracterizan las diferentes texturas, cada una de ellas se ha representado con un color diferente. En la zona de la lesión existen colores que no se encuentran en su exterior.

## MÉTRICA DE LAS DIFERENCIAS DE TEXTURA

---

Dado que se tienen 10 distribuciones texturales e interesa clasificar los píxeles de la imagen únicamente en dos clases, piel normal o piel de lesión, se debe identificar la clase de cada distribución.

Para tal fin, se procede al cálculo de una medida  $D_j$  que represente la diferencia entre una distribución textural y el resto. En el caso de piel sana, este valor será bajo, en contraste con las zonas de lesión, donde la textura es distinta al resto, dando un valor de diferencia elevado.

En primer lugar, se determina la similitud entre parejas de texturas, mediante el cálculo de la probabilidad  $l_{j,k}$  de que la media de la distribución  $j$  sea una realización de la media de la distribución  $k$ .

$$l_{j,k} = \frac{1}{\sqrt{(2\pi)^n |\Sigma_j|}} e^{(-\frac{1}{2}(\mu_j - \mu_k)^T \Sigma_j^{-1} (\mu_j - \mu_k))} \quad [6]$$

donde  $n$  es el número de dimensiones de los vectores textura una vez reducidos.

Como  $l_{j,k} \neq l_{k,j}$  se define la similitud media entre las distribuciones  $j$  y  $k$  como:

$$L_{j,k} = \frac{l_{j,k} + l_{k,j}}{2} \quad [7]$$

Estas medidas de parecido entre pares de distribuciones texturales son normalizadas entre 0 y 1.

Tal como se ha explicado antes, el interés radica en la diferencia entre texturas más que en el parecido, por lo que la diferencia media entre las distribuciones  $j$  y  $k$  es calculada de la forma:

$$d_{j,k} = 1 - L_{j,k} \quad [8]$$

cuyo valor también pertenece al rango  $[0,1]$ .

Por último, para encontrar la diferencia entre la distribución de textura  $j$  y el resto de distribuciones, se define la siguiente medida:

$$D_j = \sum_{k=1}^K d_{j,k} P(T_k | I) \quad j = 1 \dots K \quad [9]$$

con  $P(T_k | I)$  la probabilidad de que un píxel de la imagen  $I$  sea asociado a la distribución textural  $T_k$ .

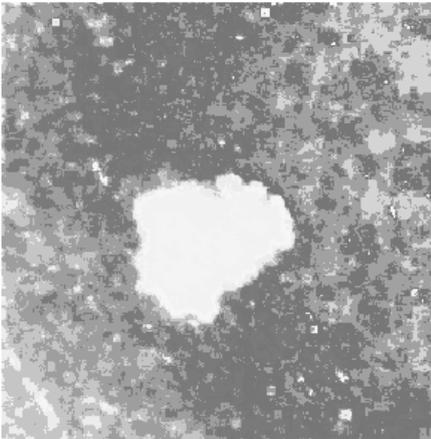


ILUSTRACIÓN 9. EJEMPLO DE IMAGEN DE DIFERENCIAS TEXTURALES

Se puede construir una imagen en la que cada píxel está representado por el valor diferencia textural de su distribución asignada.

Aunque los píxeles de zonas lesionadas de piel presentan una métrica de diferencia de textura elevada, a menudo zonas de piel normal también contienen patrones texturales, viéndose reflejado en píxeles con diferencias de textura también altas. Por ello, es necesario en el algoritmo TDLS un paso que clasifique los píxeles en lesión o piel sana.

## DIVISIÓN DE LA IMAGEN EN MÚLTIPLES REGIONES

La primera técnica de procesamiento de la imagen llevada a cabo para realizar la clasificación de los píxeles es una sobre-segmentación, que incrementará la robustez frente al ruido del algoritmo de segmentación. La imagen es dividida en un gran número de regiones, y posteriormente se determinará la clase (lesión/piel sana) de cada una de ellas.

Mediante un algoritmo estadístico de fusión de regiones o SRM (*Statistical Region Merging*) se consiguen distinguir las múltiples regiones. La técnica implementada, basada en el algoritmo propuesto por Nock y Nielsen (28) pero aplicada sobre imágenes en el espacio de color XYZ, asume que inicialmente cada píxel es una región distinta y, de forma iterativa, las regiones van creciendo mediante la unión de aquellas con propiedades homogéneas. Para cada pareja de píxeles adyacentes  $(p, p')$ , se decide si sus regiones  $(R, R')$  son unidas en una sola mediante la realización de un test estadístico de fusión, que está basado en la intensidad de los píxeles. Por lo tanto, en este paso del algoritmo se tienen en cuenta las características de color.

El algoritmo está definido por dos componentes esenciales: el orden en que se comparan las regiones, y el predicado de fusión (test), que determina si dos regiones son unidas en una sola.

En este caso, el predicado  $\mathcal{P}(R, R')$  está diseñado para que se combinen regiones con propiedades homogéneas, de forma que: i) dentro de una región óptima (o estadística) los píxeles compartan la misma esperanza para cada canal de color, y ii) las esperanzas de regiones adyacentes varían al menos en un canal de color. El predicado calcula la diferencia entre las dos regiones de la intensidad media de cada canal de color. El resultado del test será positivo en caso de que esta diferencia no supere un determinado valor  $b(R, R')$  que depende del número de píxeles de las regiones y un parámetro relacionado con el número de regiones de la segmentación final.

$$\mathcal{P}(R, R') = \begin{cases} \text{"positivo"} & \text{si } |\overline{R}_a - \overline{R}'_a| \leq b(R, R') \quad \forall a \in \{X, Y, Z\} \\ \text{"negativo"} & \text{en caso contrario} \end{cases} \quad [10]$$

con  $\overline{R}_a$  la intensidad media de la región  $R$  en el canal de color  $a$ .

Como el orden en que se someten las parejas de píxeles al test influye en el resultado de la segmentación, cada pareja de píxeles es ordenada según la función  $f(p, p')$ , de manera que las parejas de píxeles con menores gradientes locales (más parecidas) serán las primeras en someterse al test.

$$f(p, p') = \max_{a \in \{X, Y, Z\}} |p_a - p'_a| \quad [11]$$

donde  $p_a$  y  $p'_a$  son los valores de los píxeles en el canal  $a$ .

En una vecindad de tamaño 4 (los píxeles se conectan con sus vecinos en horizontal y vertical) se tiene un conjunto de parejas de píxeles cuyas regiones se someterán al test, para determinar si fusionarlas o no. El algoritmo SRM empieza con la ordenación de dicho conjunto de pares de píxeles según la evaluación de la función  $f(p, p')$  de manera ascendente. Se sigue este orden para someter al test cada pareja de píxeles cuyas regiones sean distintas, evaluando el predicado y fusionando sus regiones si el resultado es positivo.

---

## IMAGEN DIFERENCIA DE TEXTURA REGIONAL

---

Como resultado del algoritmo SRM se tiene un mapa de múltiples regiones que esperan su clasificación en piel normal o piel lesionada. Dicha clasificación estará basada en una nueva medida de diferencia de textura, en este caso regional.  $D_R$  representa la medida de diferencia de textura media a lo largo de la región  $R$ .

$$D_R = \sum_{j=1}^K D_j P(T_j|R) \quad R = 1 \dots n^{\circ} \text{ de regiones} \quad [12]$$

donde  $P(T_j|R)$  indica la probabilidad de que un píxel de la región  $R$  sea asociado a la distribución textural  $T_j$ .

Es en este cálculo donde se combina la información procedente de las distintas texturas presentes en la imagen (en la variable  $D_j$ ) con la información de color (que determina las regiones).

Una vez cada píxel es asociado al valor diferencia textural regional de la región a la que pertenece, se construye una nueva imagen de diferencias texturales regionales que determinará la clasificación de los píxeles y, por tanto, la segmentación.

---

## ASIGNACIÓN DE LA CLASE LESIÓN/PIEL A LOS PÍXELES

---

El siguiente paso es la búsqueda de un umbral  $u$  tal que los píxeles con un valor diferencia textural regional superior al mismo queden clasificados como lesión. La imagen segmentada  $imseg$  será binaria con los píxeles identificados como lesión en blanco (píxeles con valor de intensidad 1) y el resto correspondiente a piel sana en negro (intensidad 0).

$$imseg(R) = \begin{cases} 1 & \text{si } D_R \geq u \text{ (zona lesionada)} \\ 0 & \text{en otro caso (piel normal)} \end{cases} \quad [13]$$

donde  $imseg(R)$  hace referencia al valor en la imagen segmentada de los píxeles de cada región  $R$ .

El umbral elegido es el conocido como umbral de Otsu, que divide el histograma en dos clases  $C_1$  y  $C_2$ , minimizando la varianza de la métrica diferencia de textura para cada clase.

$$u = \arg \min_u \left( \sigma_{C_1(u)}^2 P(T|C_1(u)) + \sigma_{C_2(u)}^2 P(T|C_2(u)) \right) \quad [14]$$

con  $\sigma_{C_i(u)}^2$  varianza de los píxeles de la clase  $i$  y  $P(T|C_i(u))$  probabilidad de que un píxel diferencia de textura pertenezca a la clase  $i$ , para el umbral  $u$ .

Si, tras hallar una medida de la efectividad de esta umbralización, se obtiene que el umbral es poco efectivo, se manifiesta en el resultado de la segmentación con zonas de piel identificadas como lesión, lo que indica que el umbral encontrado es demasiado bajo. En este caso, se combina la información del umbral de Otsu con otro tipo de umbral, cuyo valor se ha comprobado experimentalmente que es más alto del deseado, interpretando que zonas de lesión pertenecen a la clase de piel sana. Se tiene, por tanto, un umbral, que pondera ambos, adecuado para la clasificación de los píxeles. Este segundo umbral calcula el histograma de la imagen diferencias de texturas regionales y realiza una búsqueda del mínimo entre dos picos significativos, que representan lesión y piel sana.

---

## REFINADO DE LA IMAGEN SEGMENTADA

---

La segmentación ofrece una imagen binaria en la que aparecen distintas zonas no contiguas identificadas como lesión. De cara a la extracción de características tras la segmentación conviene reducir estas zonas a una única región para ser analizada. Se eliminan todas las pequeñas regiones clasificadas como lesión excepto la región con mayor área, que realmente corresponde a la lesión.



ILUSTRACIÓN 10. IMAGEN SEGMENTADA CON VARIAS REGIONES NO CONTIGUAS

Con objeto de suavizar los bordes, se aplica un operador morfológico que en imágenes binarias realiza la dilatación de objetos blancos sobre un fondo negro, seguida de una erosión de los mismos. Este proceso, conocido como cierre, da lugar al relleno de pequeños huecos, entrantes delgados en el contorno de la región de la lesión, al mismo tiempo que suaviza los bordes, viéndose incrementada el área de la región. Se emplea una máscara o elemento estructura que define el tamaño y la forma de la dilatación y erosión. La máscara recorre la imagen entera y sustituye el píxel donde está centrada por el valor máximo (dilatación) o mínimo (erosión) de la vecindad que ocupa la máscara. En este caso, se emplea una estructura circular de radio 5 píxeles.

Si la región seleccionada como lesión presenta huecos, son rellenados para obtener una imagen binaria en la que la lesión sólo presenta bordes exteriores.

Por último, se realiza un conteo de los píxeles del borde de la imagen clasificados como lesión o como piel normal. Si la mayoría de los píxeles del borde de la imagen han sido identificados como lesión, se invierte la imagen binaria, asumiendo que se ha fotografiado la lesión de manera que se encuentre más bien centrada en la imagen, sin tocar los bordes.

---

## RESUMEN

---

A modo de resumen, el algoritmo TDLS implementado presenta esencialmente cuatro etapas: un pre-procesado para corregir las posibles variaciones de iluminación, una búsqueda de medidas diferencias texturales basada en las distintas distribuciones de textura presentes en la imagen, una clasificación de múltiples regiones en clase lesión o clase piel sana, y un post-procesado o refinado.



ILUSTRACIÓN 11. ETAPAS DEL ALGORITMO IMPLEMENTADO

En el siguiente diagrama se muestra la secuencia de los principales bloques que conforman el algoritmo y las variables empleadas como entrada y salida de los mismos:

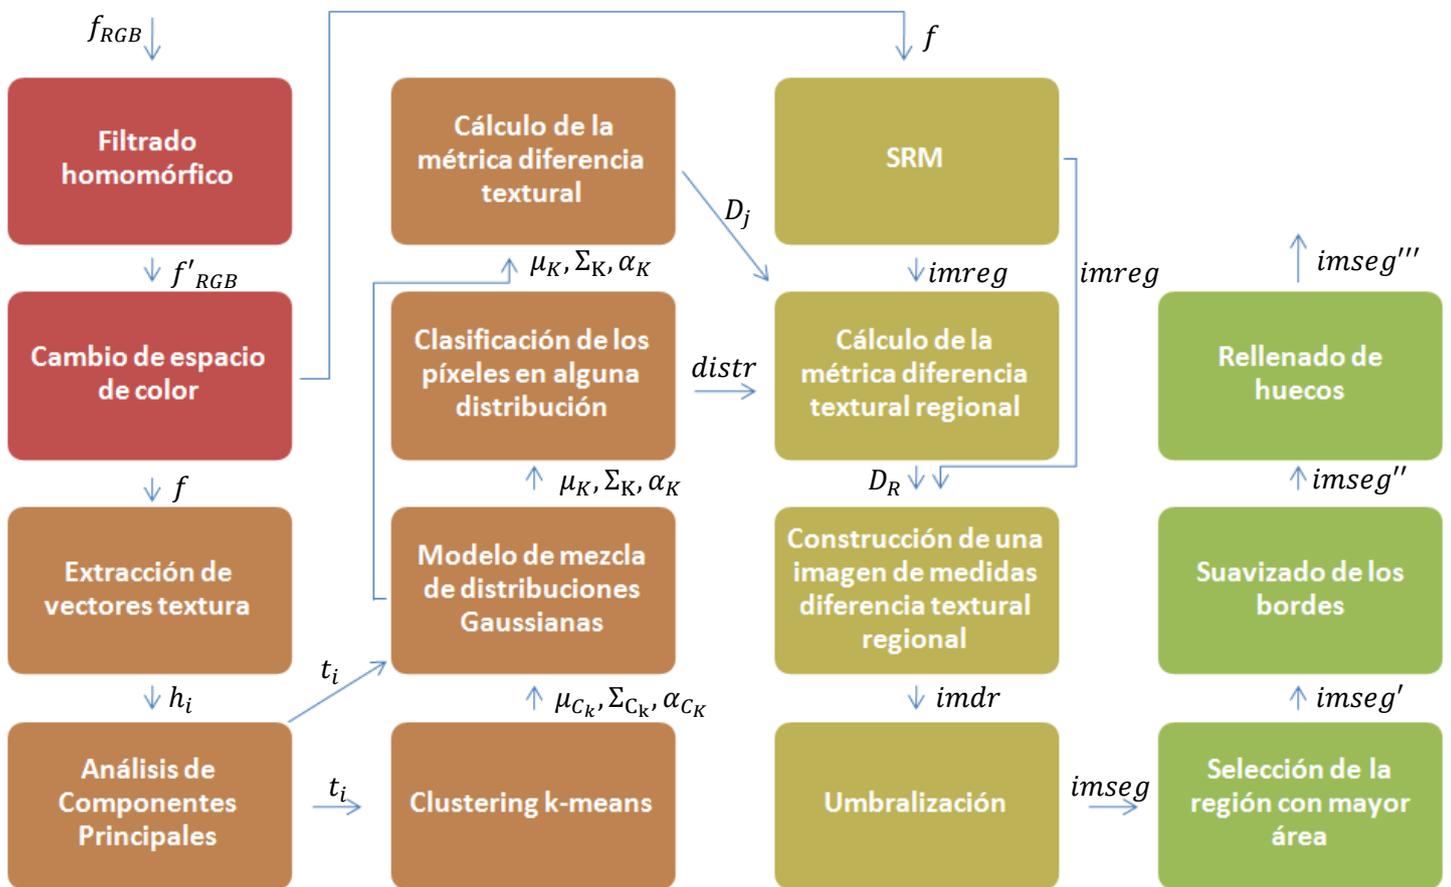


ILUSTRACIÓN 12. DIAGRAMA DEL ALGORITMO DESGLOSADO POR BLOQUES

Variable	Significado	Necesidad
$f_{RGB}$	Imagen de entrada	Filtrado homomórfico
$f'_{RGB}$	Imagen corregida en iluminación	Cambio de espacio de color
$f$	Imagen en el espacio XYZ	Extracción de la información textural y segmentación de múltiples regiones
$h_i$	Vectores textura	Reducción de las dimensiones: PCA
$t_i$	Vectores textura reducidos	Objetos del clustering k-means y modelo de mezcla de distribuciones Gaussianas
$\mu_{C_k}, \Sigma_{C_k}, \alpha_{C_k}$	Media, matriz de covarianza y probabilidad de los clusters	Inicialización del algoritmo EM para obtener el modelo de mezcla de Gaussianas
$\mu_K, \Sigma_K, \alpha_K$	Media, matriz de covarianza y probabilidad de las distribuciones texturales	Clasificación de los píxeles según su probabilidad a posteriori $P(T_j t_i)$ y cálculo de la similitud entre texturas $l_{j,k}$ y la métrica $D_j$
$distr$	Clasificación de cada píxel en una distribución textural	Cálculo de la métrica $D_R$ según la probabilidad $P(T_j R)$ (probabilidad de que un píxel de la región R sea asociado a la distribución textural $T_j$ )
$D_j$	Medida diferencia textural de cada distribución	Cálculo de la métrica $D_R$ , que promedia la medida $D_j$ en cada región
$imreg$	Mapa de regiones resultado del algoritmo SRM con la región de cada píxel	Cálculo de la métrica $D_R$ para cada región y construcción de la imagen en la que cada región toma el valor de su

		medida $D_R$
<b><i>imdr</i></b>	Imagen con los valores de las medidas $D_R$ de cada región	Imagen a umbralizar
<b><i>imseg</i></b>	Imagen segmentada con varias regiones clasificadas como lesión	Refinado: selección de la región de lesión más grande, suavizado de los bordes y rellenado de huecos
<b><i>imseg'</i>, <i>imseg''</i></b>	Distintas fases por las que pasa la imagen segmentada durante el refinado	Refinado
<b><i>imseg'''</i></b>	Imagen segmentada final	

TABLA 1. VARIABLES EMPLEADAS ENTRE LOS DISTINTOS BLOQUES DEL ALGORITMO

## 4. RESULTADOS

El algoritmo ha sido implementado en MATLAB, empleando imágenes de lesión de piel obtenidas del catálogo de imágenes *DermQuest* (29). Para evaluar los resultados obtenidos de un modo objetivo, éstos son comparados con imágenes segmentadas manualmente, que representan la segmentación correcta (verdad de referencia), mediante el cálculo de parámetros de fiabilidad.

La métrica utilizada realiza un conteo de los píxeles que han sido clasificados como lesión o piel normal de forma correcta y errónea, según la imágenes de verdad. La siguiente tabla recoge las definiciones necesarias para determinar las medidas de confianza (2).

PÍXEL EN LA IMAGEN VERDAD DE REFERENCIA	PÍXEL EN LA IMAGEN SALIDA DEL ALGORITMO	
	Lesión	Piel normal
Lesión	Verdadero positivo o TP ( <i>True Positive</i> )	Falso negativo o FN ( <i>False Negative</i> )
Piel normal	Falso positivo o FP ( <i>False Positive</i> )	Verdadero negativo o TN ( <i>True Negative</i> )

TABLA 2. CLASIFICACIÓN DE LOS PÍXELES SEGÚN LA VERDAD DE REFERENCIA

Píxeles “positivos” son aquellos identificados por el algoritmo como lesión y “negativos” los correspondientes a la clase piel normal. Un resultado “verdadero” significa que la clasificación es correcta, coincidiendo la clase del píxel identificada en la imagen de referencia con la indicada por el algoritmo automático.

Teniendo esto en cuenta, se hallan las medidas de Sensibilidad, Especificidad y Precisión:

$$Sensibilidad = \frac{TP}{TP + FN} \quad [15]$$

$$Especificidad = \frac{TN}{TN + FP} \quad [16]$$

$$Precisión = \frac{TP + TN}{TP + FN + TN + FP} \quad [17]$$

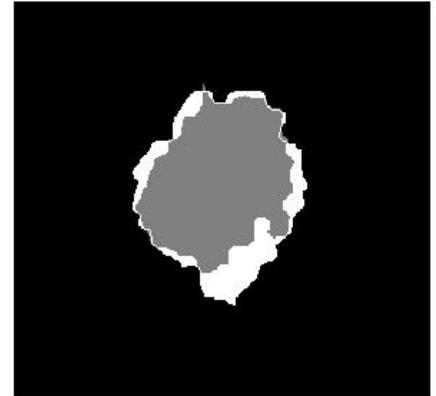
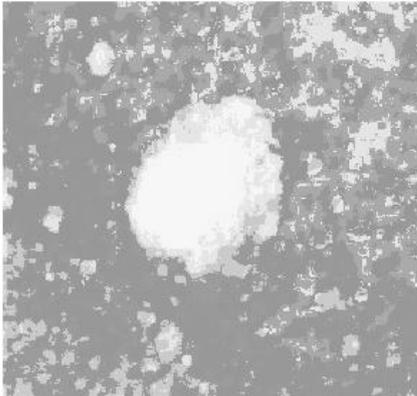
La Sensibilidad y Especificidad son medidas indicadoras de los píxeles de la imagen de referencia de la zona de lesión o piel normal, respectivamente, que han sido bien clasificados. Si la Sensibilidad toma como valor la unidad, todos los píxeles de la lesión han sido clasificados como tales, y se tiene un área segmentada automáticamente que contiene por completo a la verdad de referencia. En el caso de que la Especificidad sea la medida que valga 1, significa que la totalidad de los píxeles que pertenecen a la piel normal según la referencia han sido bien clasificados. Esto ocurre cuando la zona segmentada obtenida mediante el algoritmo está totalmente contenida en la zona delimitada por la segmentación referencia. Por otra parte, la Precisión es el porcentaje total de píxeles de la imagen clasificados de forma correcta.

A continuación se muestran los resultados que se han obtenido a partir de 70 imágenes de lesiones de piel. Para cada posible melanoma, se representa en primer lugar una imagen en la que cada píxel está representado por su diferencia textural regional. Cuanto mayor es esta medida, más brillante aparece el píxel. La segunda imagen es la fotografía de entrada al algoritmo, en la cual se ha delimitado en blanco el borde de la lesión según el resultado de la segmentación automática. Por último se compara el resultado obtenido (máscara gris) con la segmentación de referencia (máscara blanca), útil para determinar los parámetros de confianza.

---

#### IMAGEN 1

---



*Sensibilidad* = 0.7508

*Especificidad* = 0.9992

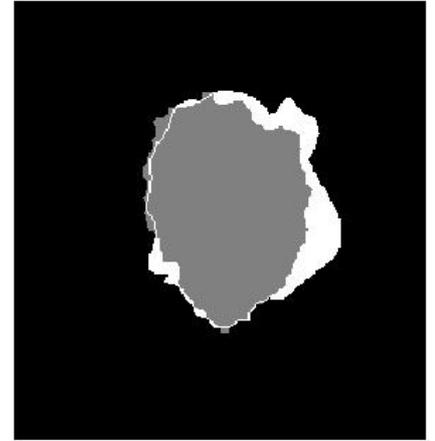
*Precisión* = 0.9616

La imagen referencia y la salida del algoritmo ofrecen un resultado muy parecido, como se observa en la comparativa de máscaras.

---

## IMAGEN 2

---



*Sensibilidad* = 0.8002

*Especificidad* = 0.9949

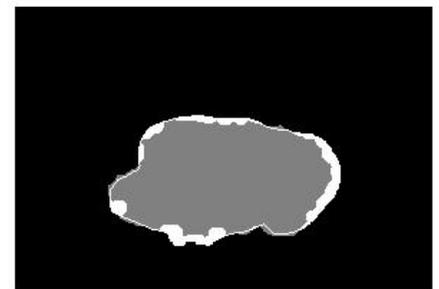
*Precisión* = 0.9583

Aunque el área de la verdad de referencia es algo superior al de la segmentación obtenida, la delimitación de la lesión de piel se aproxima bastante a la esperada, quedando reflejado en la cercanía de los bordes de ambas máscaras.

---

## IMAGEN 3

---



*Sensibilidad* = 0.8724

*Especificidad* = 0.9968

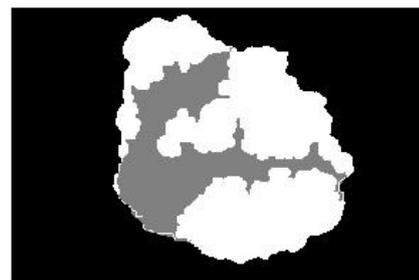
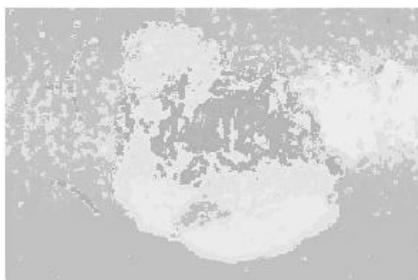
*Precisión* = 0.9733

En este caso se obtienen muy buenos resultados como manifiestan las medidas de confianza y la comparativa de máscaras.

---

#### IMAGEN 4

---



*Sensibilidad* = 0.8726

*Especificidad* = 0.9968

*Precisión* = 0.9733

Las condiciones de luz en las que se ha tomado la fotografía han condicionado el resultado del algoritmo, mostrándose en la identificación de los píxeles saturados de la lesión como piel sana.

---

#### IMAGEN 5

---



*Sensibilidad* = 0.9670

*Especificidad* = 0.9657

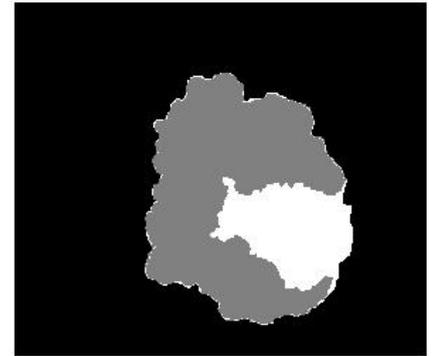
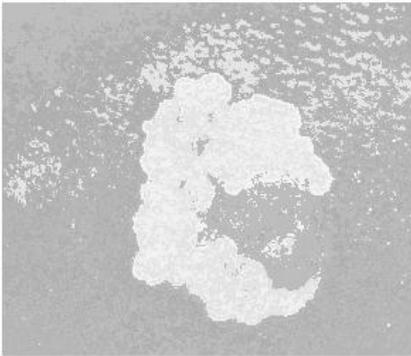
*Precisión* = 0.9661

Los resultados en esta fotografía son bastantes acertados, consiguiéndose una segmentación muy próxima a la referencia.

---

### IMAGEN 6

---



*Sensibilidad* = 0.7318

*Especificidad* = 0.9966

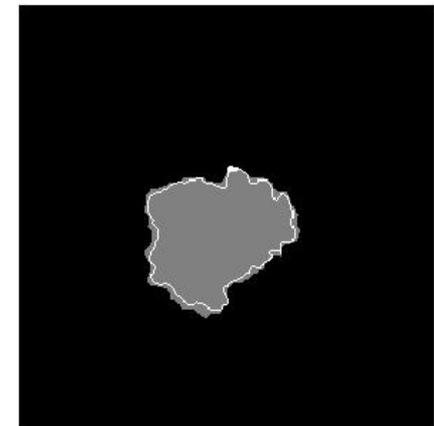
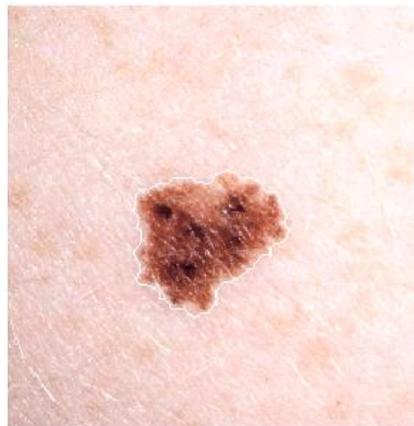
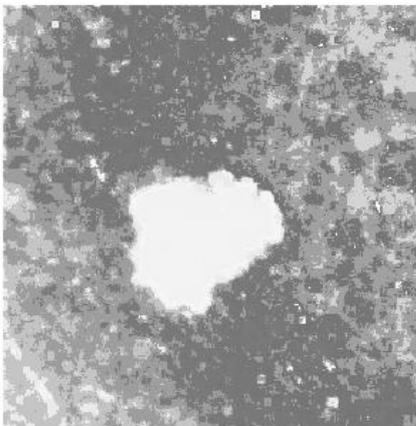
*Precisión* = 0.9261

La delimitación de los bordes de la lesión es casi perfecta en la mayoría del perímetro. Sólo se diferencia de la segmentación de referencia en la zona de lesión que tiene una textura muy similar a la de la piel, donde el algoritmo ha interpretado la zona como piel sana.

---

### IMAGEN 7

---



*Sensibilidad* = 0.9936

*Especificidad* = 0.9910

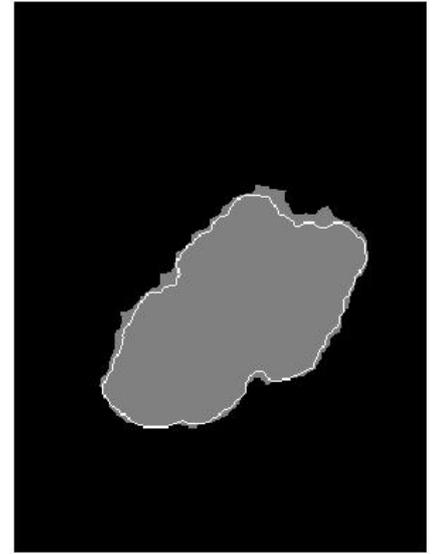
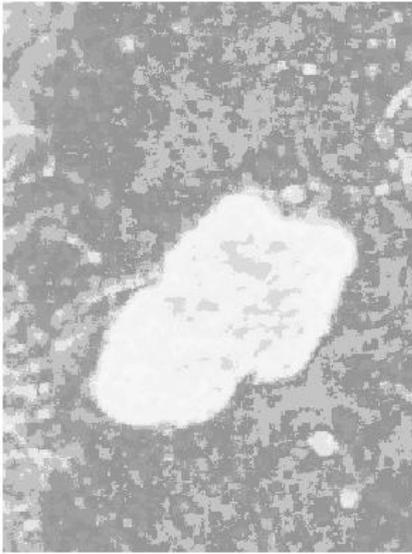
*Precisión* = 0.9912

Tanto los parámetros de fiabilidad como la máscara obtenida indican la bondad del resultado del algoritmo en esta imagen, proporcionando una segmentación casi perfecta.

---

### IMAGEN 8

---



*Sensibilidad* = 0.9980

*Especificidad* = 0.9835

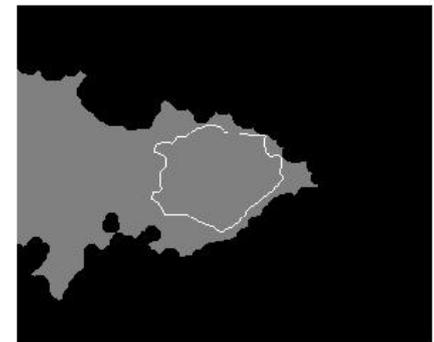
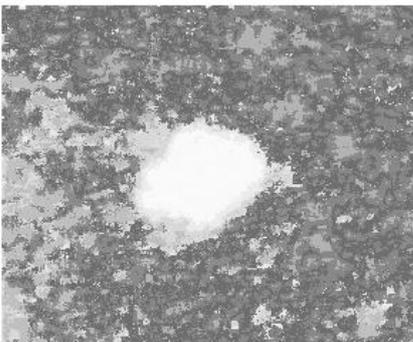
*Precisión* = 0.9858

Los resultados se ajustan bastante a la segmentación referencia, dando unas medidas de fiabilidad que superan el 98%.

---

### IMAGEN 9

---



*Sensibilidad* = 1.000

*Especificidad* = 0.7998

*Precisión* = 0.8135

En esta imagen no se consigue una segmentación adecuada por la consideración de piel adyacente a la lesión como parte de la misma.

---

### IMAGEN 10

---



*Sensibilidad = 0*

*Especificidad = 0.9689*

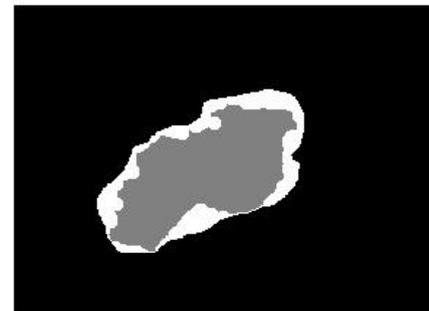
*Precisión = 0.8869*

Como muestra la Sensibilidad, el resultado es erróneo. Esto es debido a las diversas texturas presentes en la zona de piel alrededor de la lesión, que complican la búsqueda de la misma.

---

### IMAGEN 11

---



*Sensibilidad = 0.6945*

*Especificidad = 1*

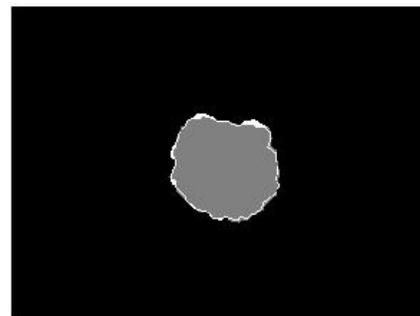
*Precisión = 0.9500*

Aunque de área menor que la lesión segmentada manualmente debido a la poca nitidez de los bordes en la imagen y el parecido de la textura de los mismos con la piel normal exterior, la forma del contorno es parecida a la de la referencia.

---

### IMAGEN 12

---



*Sensibilidad* = 0.9613

*Especificidad* = 0.9981

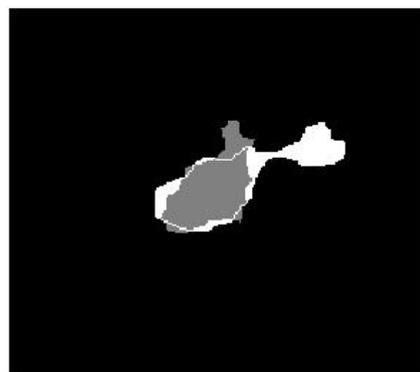
*Precisión* = 0.9955

Aquí se muestra otro caso de acierto en los resultados. La distinta textura presente en la lesión con respecto a la piel queda recogida fielmente en la imagen diferencias de texturas regionales.

---

### IMAGEN 13

---



*Sensibilidad* = 0.5833

*Especificidad* = 0.9934

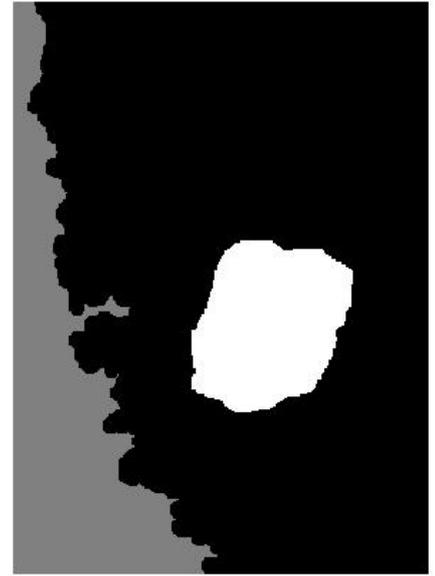
*Precisión* = 0.9726

A pesar de la dificultad inicial que añade la variedad de texturas presentes en la piel alrededor de la lesión, los resultados se aproximan en gran parte a la verdad de referencia.

---

IMAGEN 14

---



*Sensibilidad = 0*

*Especificidad = 0.8037*

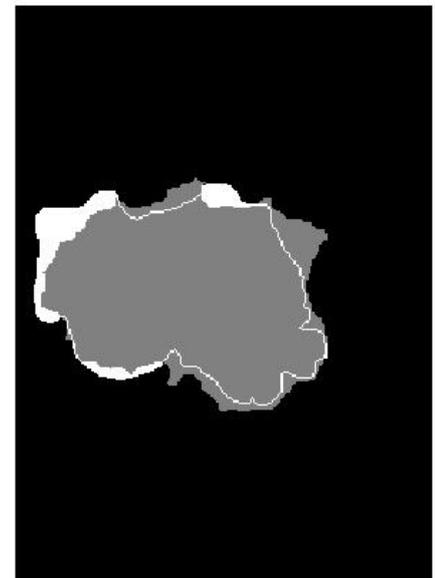
*Precisión = 0.7333*

Los patrones texturales de la piel normal y las condiciones de iluminación han condicionado de nuevo los resultados, considerándose la zona menos iluminada de la fotografía como lesión.

---

IMAGEN 15

---



*Sensibilidad = 0.8957*

*Especificidad = 0.9738*

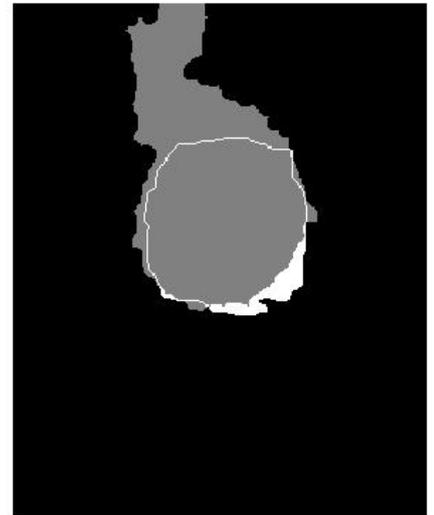
*Precisión = 0.9592*

Los resultados son bastante buenos como muestran los parámetros de confianza.

---

IMAGEN 16

---



*Sensibilidad = 0.9162*

*Especificidad = 0.9291*

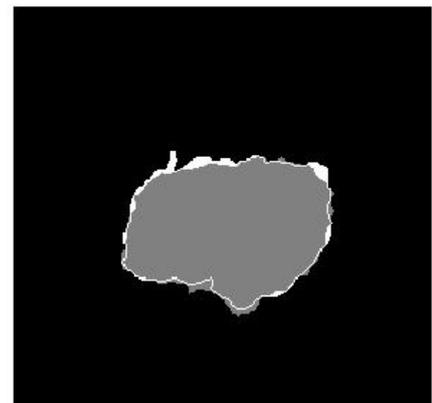
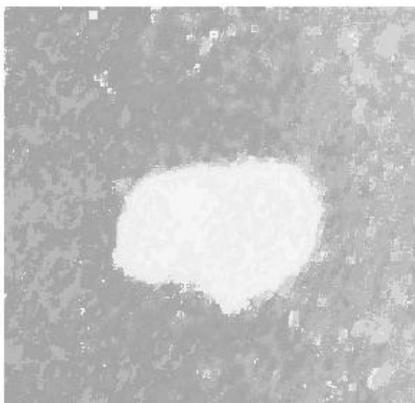
*Precisión = 0.9277*

Gran parte de la lesión ha sido identificada, pero se ha marcado además una zona de piel cuya diferencia textural regional es elevada, aunque inferior a la presente en la lesión. Un umbral superior mejoraría la segmentación en este caso concreto.

---

IMAGEN 17

---



*Sensibilidad = 0.9474*

*Especificidad = 0.9952*

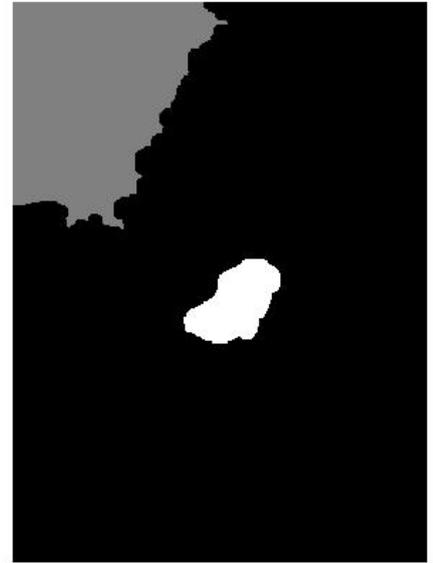
*Precisión = 0.9882*

En esta fotografía se consiguen resultados muy buenos como se puede ver en los parámetros de fiabilidad y en las tres imágenes anteriores.

---

### IMAGEN 18

---



*Sensibilidad* = 0

*Especificidad* = 0.8560

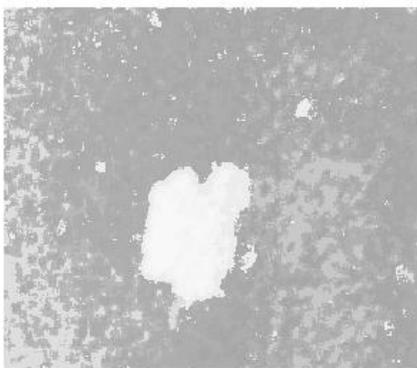
*Precisión* = 0.8375

Aquí se tiene un nuevo ejemplo de segmentación errónea debido a las diferentes condiciones de iluminación en las distintas partes de la fotografía.

---

### IMAGEN 19

---



*Sensibilidad* = 0.9044

*Especificidad* = 0.9951

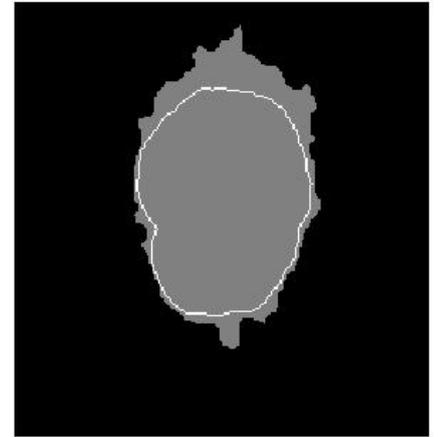
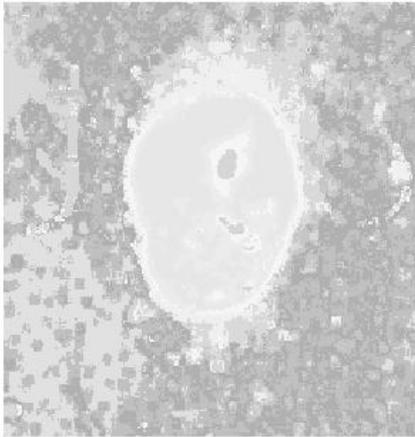
*Precisión* = 0.9877

En este caso se obtiene una segmentación bastante aproximada a la referencia, cumpliéndose el objetivo del algoritmo.

---

## IMAGEN 20

---



*Sensibilidad* = 1

*Especificidad* = 0.9370

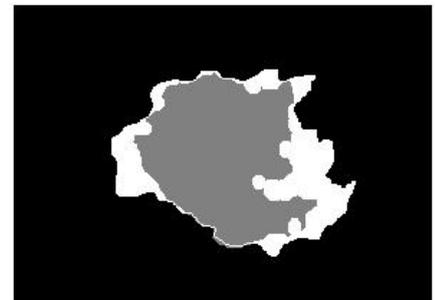
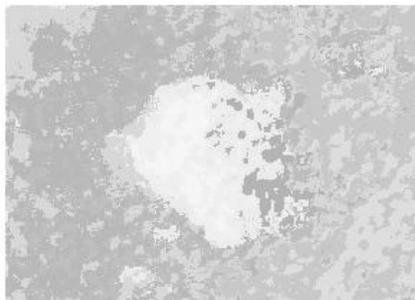
*Precisión* = 0.9479

La zona cercana a la lesión con características de color y textura distintas al resto de piel han llevado al algoritmo a clasificarla como parte de la lesión. Aun así, las medidas indican una correcta delimitación de la lesión.

---

## IMAGEN 21

---



*Sensibilidad* = 0.6651

*Especificidad* = 0.9989

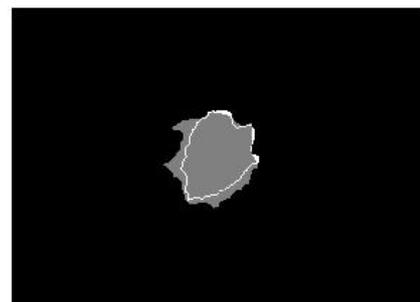
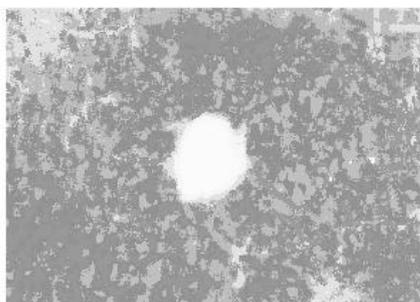
*Precisión* = 0.9196

La irregularidad de los bordes queda recogida en la segmentación realizada. Sin embargo, la escasa nitidez de los mismos en algunas zonas han llevado al algoritmo a disminuir el área considerada.

---

### IMAGEN 22

---



*Sensibilidad* = 0.9680

*Especificidad* = 0.9882

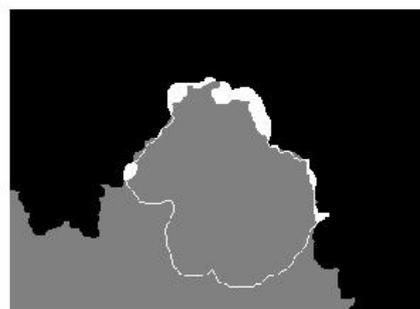
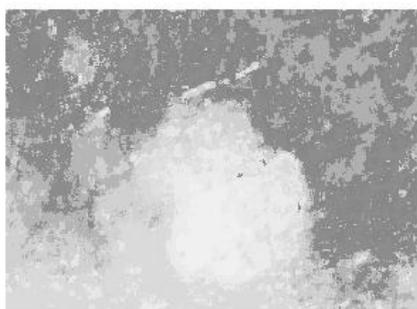
*Precisión* = 0.9874

Aunque de mayor irregularidad y área, la lesión segmentada se acerca bastante a la referencia.

---

### IMAGEN 23

---



*Sensibilidad* = 0.9163

*Especificidad* = 0.7565

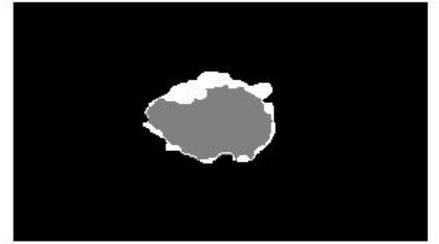
*Precisión* = 0.7901

La sombra en la parte inferior de la imagen ha sido interpretada de manera errónea, condicionando los resultados. Un mejor pre-procesado de la imagen que corrigiese las grandes diferencias de iluminación o bien un mayor control sobre la adquisición de la fotografía corregirían este problema.

---

### IMAGEN 24

---



*Sensibilidad* = 0.7326

*Especificidad* = 0.9996

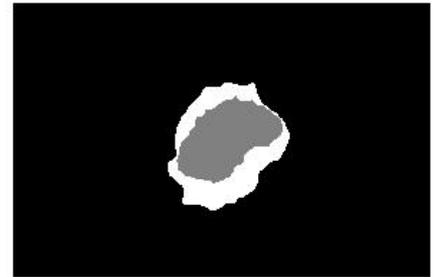
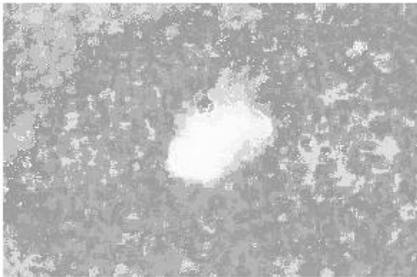
*Precisión* = 0.9761

Aquí se tiene un nuevo ejemplo de segmentación adecuada, donde la coincidencia en gran parte de las máscaras reflejan el buen resultado.

---

### IMAGEN 25

---



*Sensibilidad* = 0.5311

*Especificidad* = 1

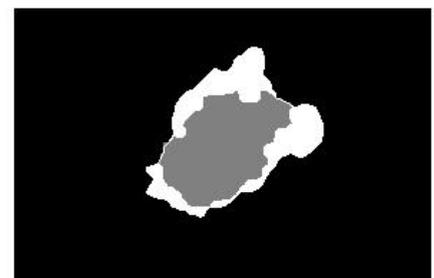
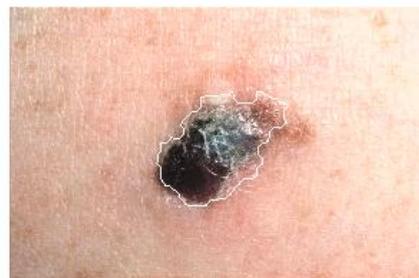
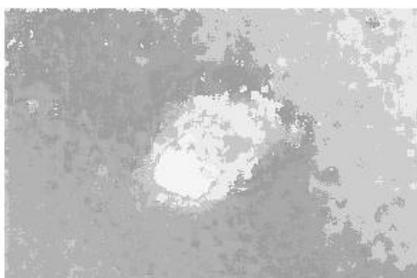
*Precisión* = 0.9567

La información de diferencias de textura ha sido bien interpretada como muestran los buenos resultados obtenidos.

---

### IMAGEN 26

---



*Sensibilidad* = 0.5726

*Especificidad* = 0.9997

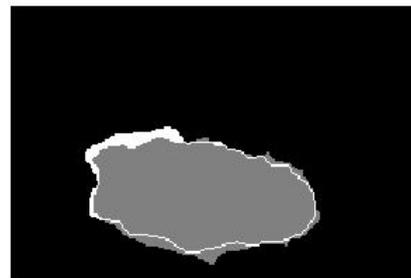
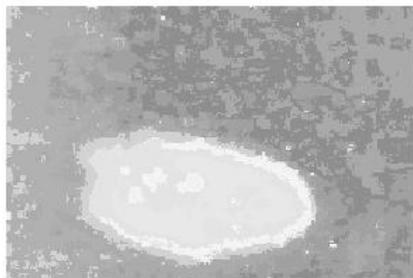
*Precisión* = 0.9384

Aunque de menor área, la segmentación delimita correctamente la zona de la fotografía cuya diferencia de textura es elevada.

---

IMAGEN 27

---



*Sensibilidad* = 0.9270

*Especificidad* = 0.9845

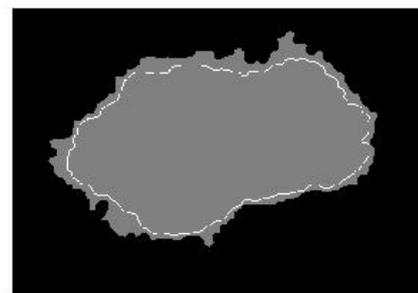
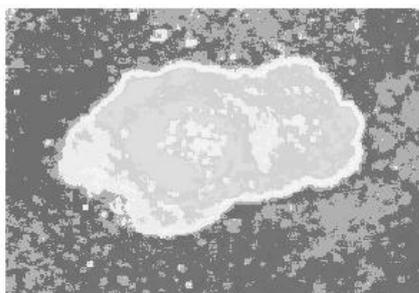
*Precisión* = 0.9740

Tanto la forma del contorno, como el área y la zona delineada se acercan mucho a la referencia, quedando de manifiesto en unas medidas de fiabilidad muy buenas.

---

IMAGEN 28

---



*Sensibilidad* = 1

*Especificidad* = 0.9159

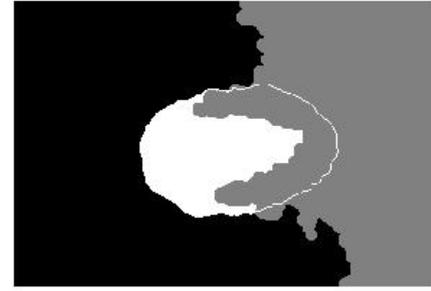
*Precisión* = 0.9417

Aunque se consideren parte de la lesión píxeles de piel cercanos a la misma, la segmentación ha dado buen resultado.

---

### IMAGEN 29

---



*Sensibilidad* = 0.4201

*Especificidad* = 0.6192

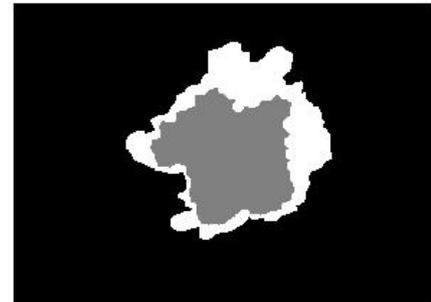
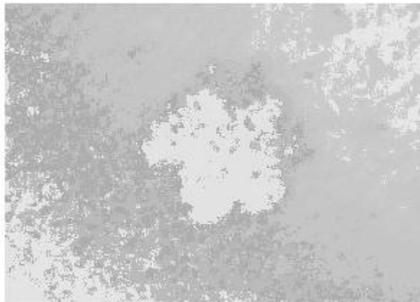
*Precisión* = 0.5858

La gran diferencia de iluminación entre la parte derecha e izquierda de la imagen han proporcionado otro ejemplo de segmentación errónea.

---

### IMAGEN 30

---



*Sensibilidad* = 0.5351

*Especificidad* = 1

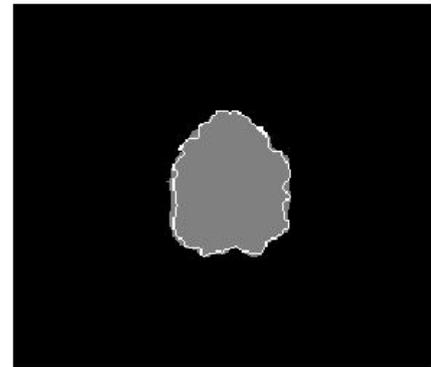
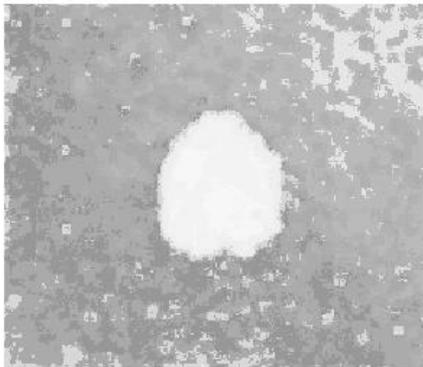
*Precisión* = 0.9112

La Sensibilidad no es muy elevada debido a las diferencias de áreas entre la segmentación automática y la manual. Sin embargo, la Precisión indica que el resultado no es malo, como se puede comprobar comparando las máscaras.

---

### IMAGEN 31

---



*Sensibilidad* = 0.9878

*Especificidad* = 0.9945

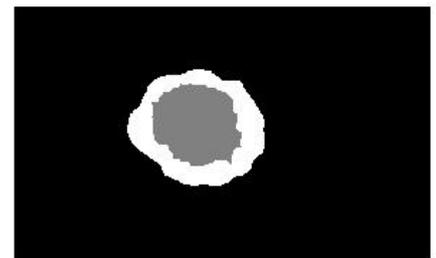
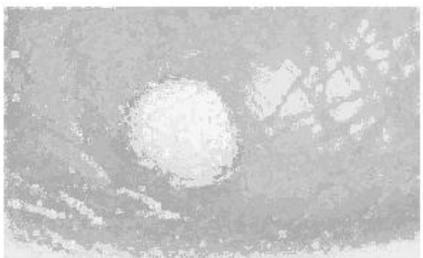
*Precisión* = 0.9939

Las medidas de fiabilidad muestran una correcta segmentación, que queda reflejada en las mínimas diferencias entre las máscaras.

---

### IMAGEN 32

---



*Sensibilidad* = 0.4748

*Especificidad* = 1

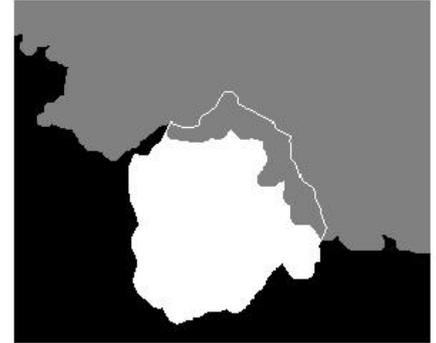
*Precisión* = 0.9411

Los resultados en esta fotografía son buenos, ya que se mantienen las propiedades de simetría y regularidad del contorno de la lesión, aunque el área segmentada sea menor que la referencia.

---

### IMAGEN 33

---



*Sensibilidad* = 0.1879

*Especificidad* = 0.4195

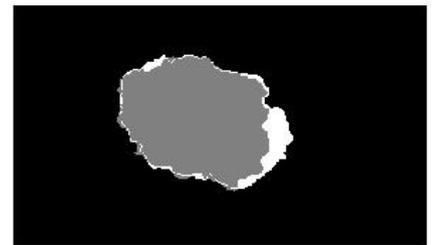
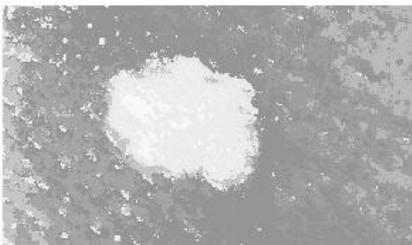
*Precisión* = 0.3684

La similitud entre la lesión y la piel tanto en textura como en color, unida a unas condiciones variables de iluminación a lo largo de la fotografía, dan lugar a una segmentación incorrecta.

---

### IMAGEN 34

---



*Sensibilidad* = 0.8804

*Especificidad* = 0.9958

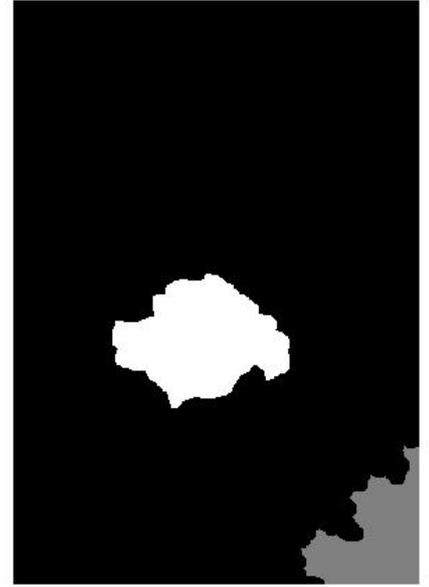
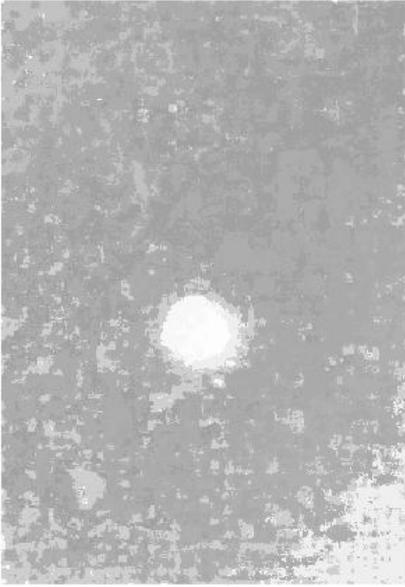
*Precisión* = 0.9766

Este es un nuevo caso de buen resultado por parte del algoritmo implementado.

---

### IMAGEN 35

---



*Sensibilidad = 0*

*Especificidad = 0.9591*

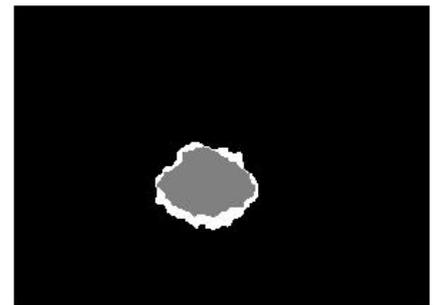
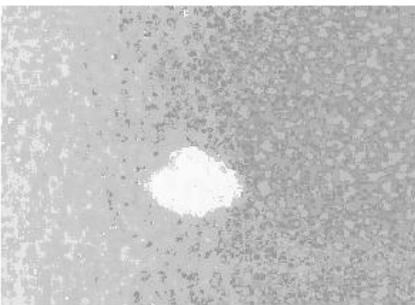
*Precisión = 0.8997*

En esta imagen existe una zona de piel normal que presenta rasgos texturales distintos al resto. El pequeño área de la lesión, en la imagen diferencias de texturas, con respecto al tamaño total de la imagen hacen que esta zona de piel normal se clasifique como lesión al ser mayor.

---

### IMAGEN 36

---



*Sensibilidad = 0.7160*

*Especificidad = 1*

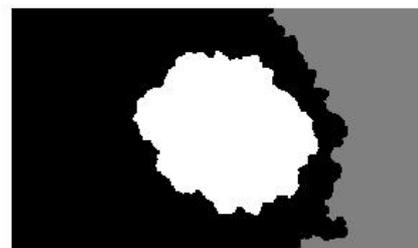
*Precisión = 0.9857*

El algoritmo ha interpretado correctamente la diferente textura de la zona de la lesión, dando lugar a unos resultados muy aceptables.

---

### IMAGEN 37

---



*Sensibilidad = 0*

*Especificidad = 0.6830*

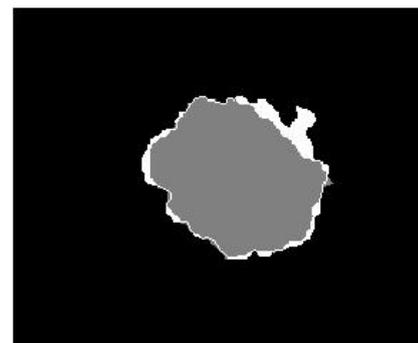
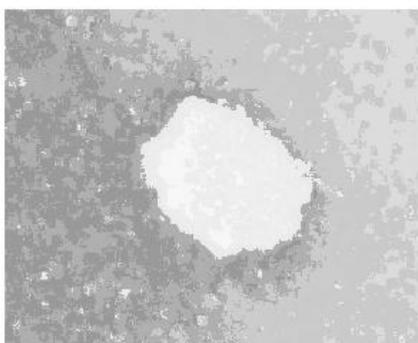
*Precisión = 0.5453*

En este caso concreto, si el umbral fuese mayor, se lograría segmentar de forma correcta la lesión de piel. Una vez más, una mejor corrección de las variaciones de iluminación como paso previo a la segmentación llevarían a una imagen diferencias de texturas adecuada y se evitaría este problema.

---

### IMAGEN 38

---



*Sensibilidad = 0.8807*

*Especificidad = 0.9987*

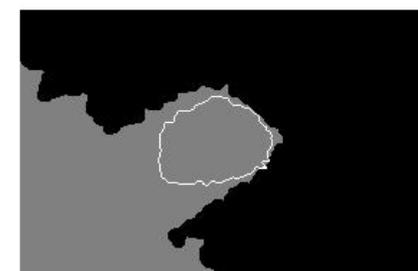
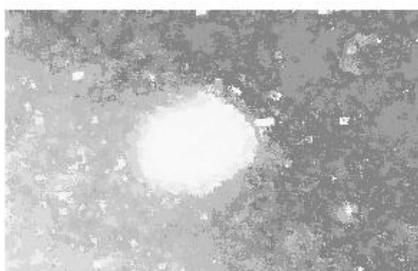
*Precisión = 0.9807*

La delimitación de los bordes de la lesión basada en la imagen diferencias de texturas regionales se ajusta bastante bien a la verdadera segmentación.

---

### IMAGEN 39

---



*Sensibilidad* = 0.9976

*Especificidad* = 0.7185

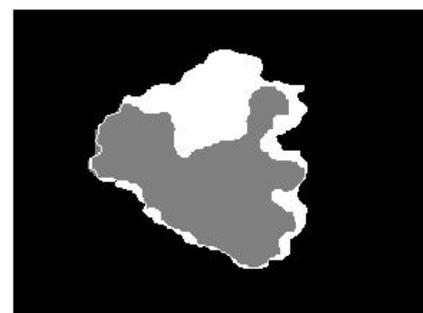
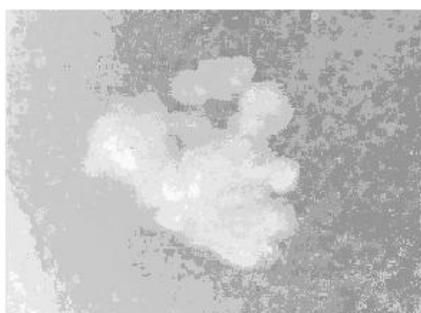
*Precisión* = 0.7380

A pesar de que el algoritmo detecta las diferentes características de la zona lesionada con respecto a la piel sana, un umbral demasiado bajo o una corrección de la iluminación insuficiente reducen la bondad de los resultados.

---

#### IMAGEN 40

---



*Sensibilidad* = 0.0820

*Especificidad* = 0.9987

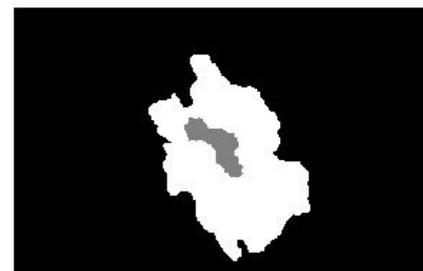
*Precisión* = 0.9079

Al algoritmo implementado se le ha exigido que determine como lesión una sola región contigua de piel. En este caso, existen pequeñas zonas no conectadas que poseen textura y color diferente al de la piel. Este es el motivo por el cual la región delimitada automáticamente no se ajusta perfectamente a la verdad de referencia.

---

#### IMAGEN 41

---



*Sensibilidad* = 0.0820

*Especificidad* = 1

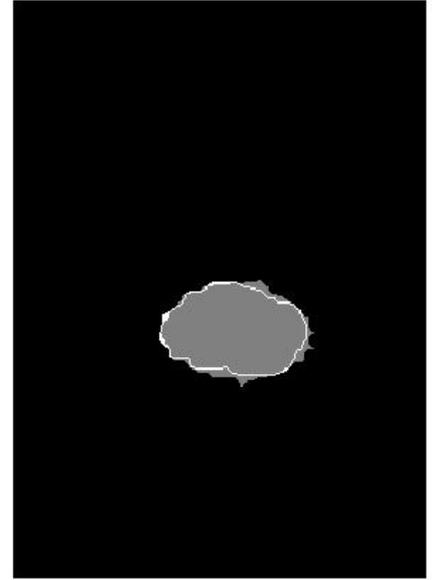
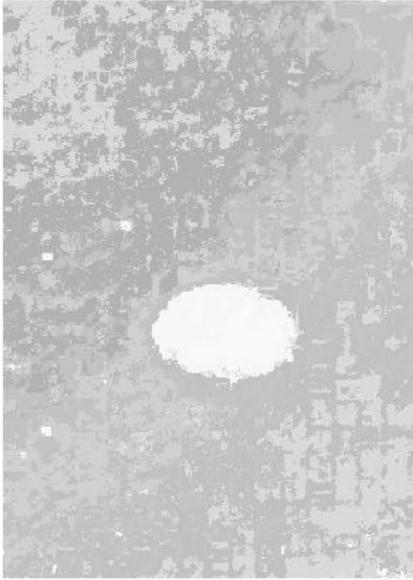
*Precisión* = 0.8489

La dificultad de esta lesión de piel es el poco contraste presente en la imagen, lo que complica la extracción de información de las distintas zonas de la imagen. Un realce de contraste como paso previo facilitaría la segmentación.

---

### IMAGEN 42

---



*Sensibilidad* = 0.9761

*Especificidad* = 0.9956

*Precisión* = 0.9948

En esta imagen se tienen unas medidas de fiabilidad muy buenas, ajustándose la segmentación obtenida a la referencia.

---

### IMAGEN 43

---



*Sensibilidad* = 0.9663

*Especificidad* = 0.9903

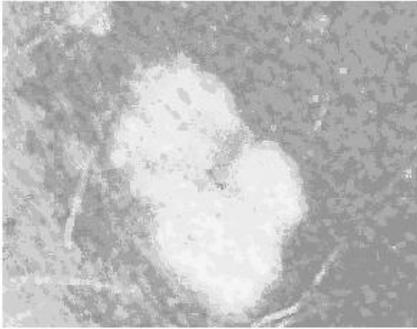
*Precisión* = 0.9863

Aquí se obtienen unos resultados muy aproximados a los óptimos, con medidas de fiabilidad elevadas.

---

### IMAGEN 44

---



*Sensibilidad* = 0.8066

*Especificidad* = 0.9991

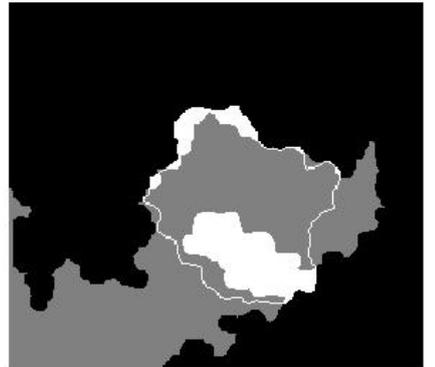
*Precisión* = 0.9507

Nuevamente el algoritmo ha realizado una buena segmentación, como muestran los resultados.

---

### IMAGEN 45

---



*Sensibilidad* = 0.6693

*Especificidad* = 0.7997

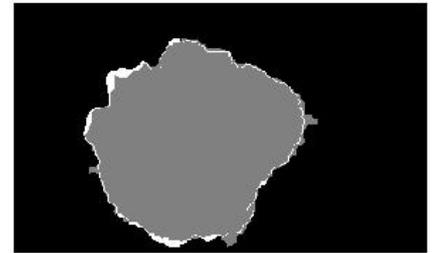
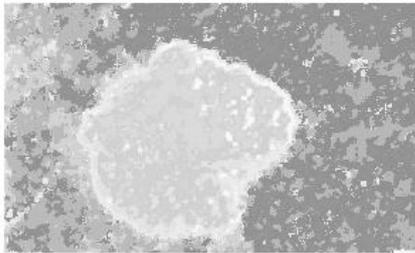
*Precisión* = 0.7780

En esta fotografía aparecen zonas muy expuestas a la luz en contraste con otras zonas poco iluminadas, lo que conlleva un mal resultado.

---

### IMAGEN 46

---



*Sensibilidad* = 0.9698

*Especificidad* = 0.9868

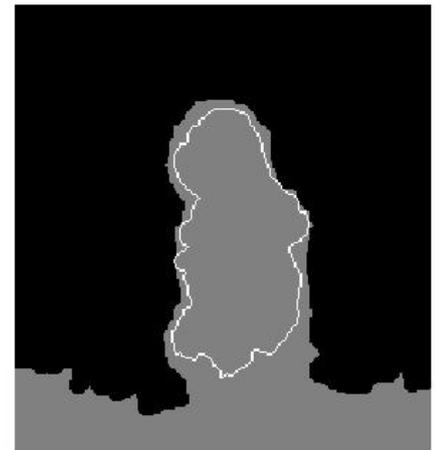
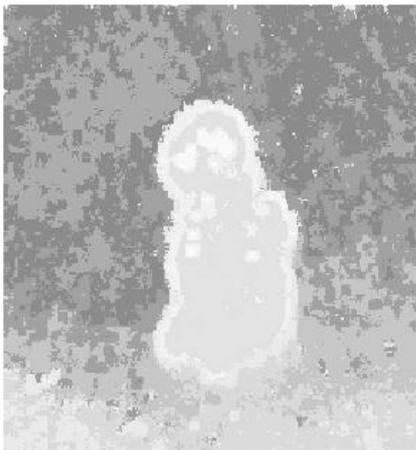
*Precisión* = 0.9817

Los bordes han sido encontrados de forma precisa como reflejan las medidas de confianza con valores por encima del 96%.

---

### IMAGEN 47

---



*Sensibilidad* = 0.9990

*Especificidad* = 0.7835

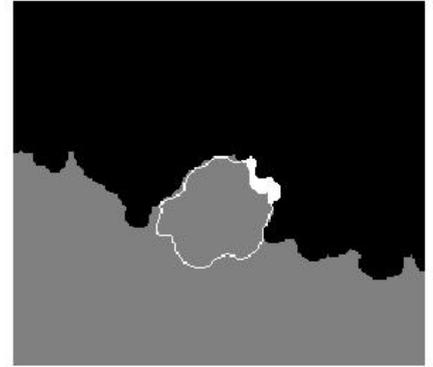
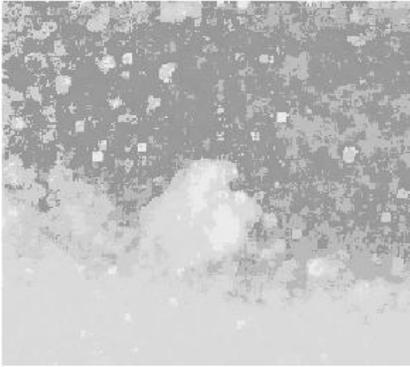
*Precisión* = 0.8136

En este caso no se ha conseguido una delimitación correcta del posible melanoma, interpretándose piel normal como parte de la lesión.

---

### IMAGEN 48

---



*Sensibilidad* = 0.9197

*Especificidad* = 0.6063

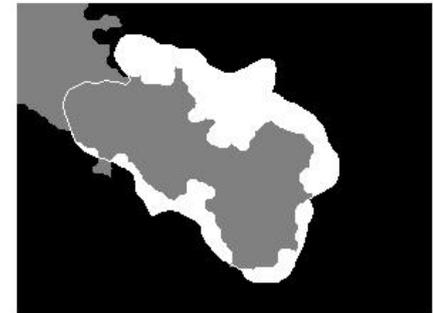
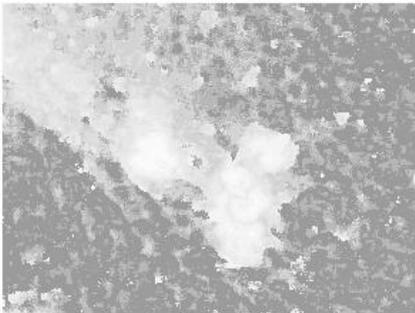
*Precisión* = 0.6259

Al examinar la fotografía se puede ver la dificultad de esta lesión por la presencia de rasgos texturales en la piel normal y las reducidas diferencias de color entre lesión y piel.

---

### IMAGEN 49

---



*Sensibilidad* = 0.5803

*Especificidad* = 0.9012

*Precisión* = 0.8046

Esta lesión de piel se consigue segmentar de forma aproximada. A simple vista se puede observar que la segmentación realizada se ciñe a la separación de zonas de piel con características diferentes al resto.

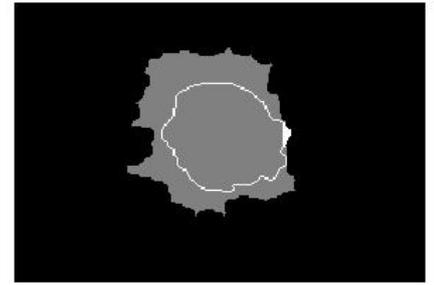
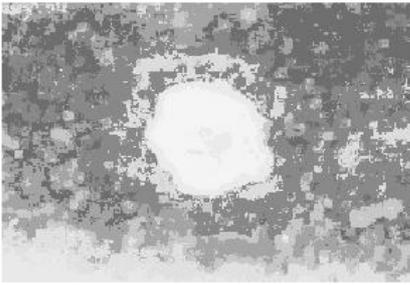
---

---

### IMAGEN 50

---

---



*Sensibilidad* = 0.9895

*Especificidad* = 0.9103

*Precisión* = 0.9174

Aquí el algoritmo une a la verdadera zona de lesión una parte de piel adyacente que aumenta el área de la zona delimitada.

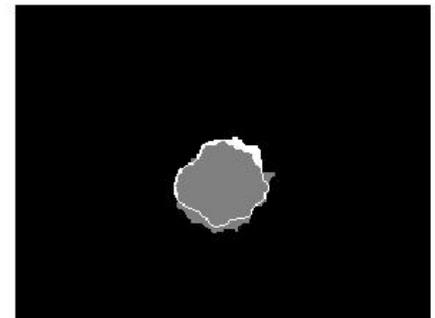
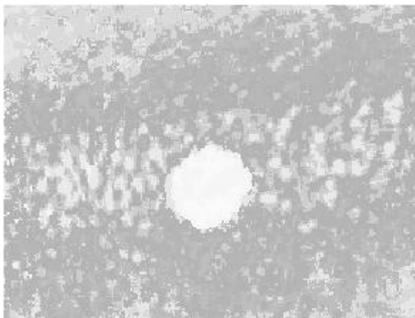
---

---

### IMAGEN 51

---

---



*Sensibilidad* = 0.8916

*Especificidad* = 0.9947

*Precisión* = 0.9901

Aunque existen zonas de piel cuyos píxeles están saturados, el algoritmo ha llevado a cabo una segmentación correcta.

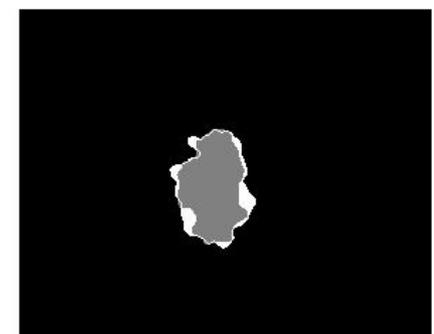
---

---

### IMAGEN 52

---

---



*Sensibilidad* = 0.8034

*Especificidad* = 0.9994

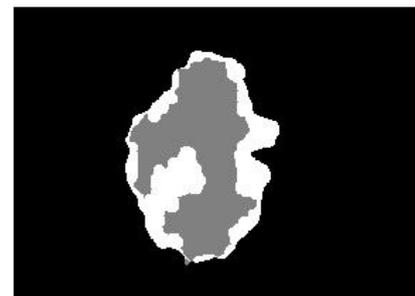
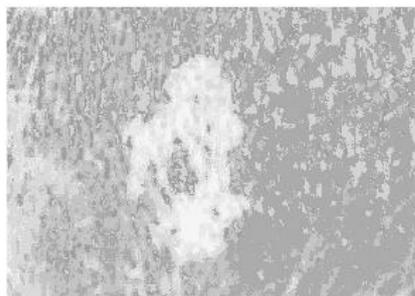
*Precisión* = 0.9900

La Sensibilidad no toma un valor muy alto debido a que el área de la lesión es pequeño respecto a la imagen completa. Sin embargo la Especificidad y Precisión indican que la segmentación es muy buena.

---

### IMAGEN 53

---



*Sensibilidad* = 0.5920

*Especificidad* = 0.9997

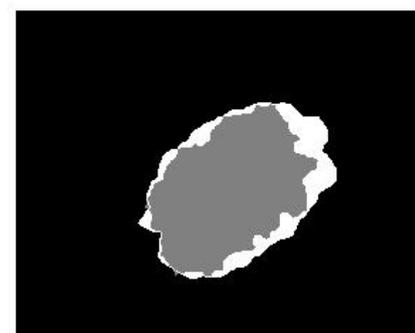
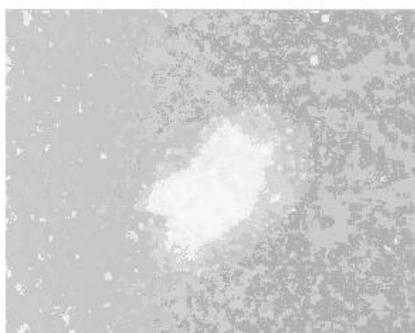
*Precisión* = 0.9250

La información de textura y color de la lesión ha sido identificada correctamente como refleja la imagen de diferencias de texturas. Sin embargo, la forma y el área de la máscara resultado podrían acercarse más a la verdad de referencia.

---

### IMAGEN 54

---



*Sensibilidad* = 0.7652

*Especificidad* = 0.9997

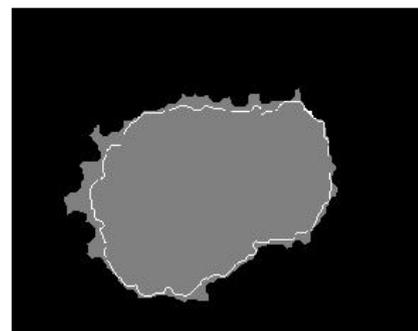
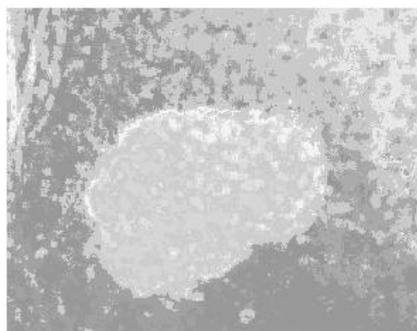
*Precisión* = 0.9592

La comparativa de las máscaras indican que en esta imagen se consiguen buenos resultados.

---

### IMAGEN 55

---



*Sensibilidad* = 0.9985

*Especificidad* = 0.9548

*Precisión* = 0.9661

Aunque de área algo superior a la referencia, la zona segmentada automáticamente se aproxima mucho a la segmentación manual.

---

### IMAGEN 56

---



*Sensibilidad* = 0.8888

*Especificidad* = 0.9970

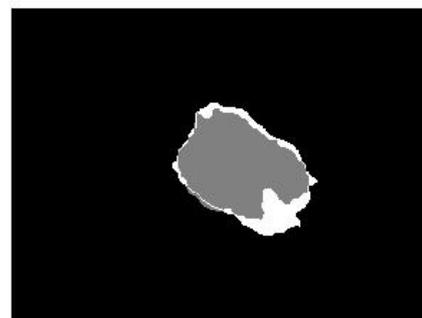
*Precisión* = 0.9868

Aquí se tiene un nuevo ejemplo de eficacia del algoritmo, quedando de manifiesto en la comparación de máscaras y las medidas de fiabilidad.

---

### IMAGEN 57

---



*Sensibilidad = 0.7721*

*Especificidad = 0.9988*

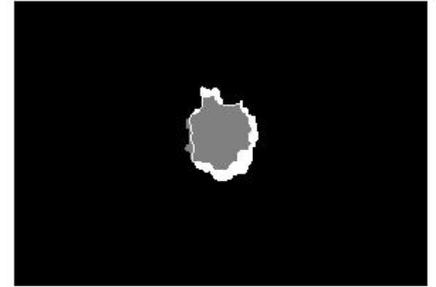
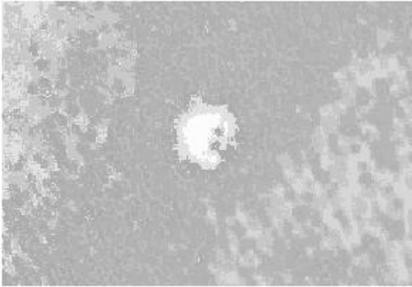
*Precisión = 0.9786*

Si bien la Sensibilidad no es muy elevada como ocurriría en casos anteriores, la Especificidad y Precisión indican que los resultados son buenos.

---

### IMAGEN 58

---



*Sensibilidad = 0.7028*

*Especificidad = 0.9988*

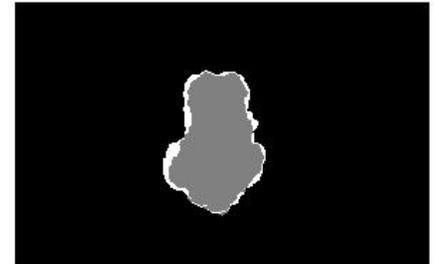
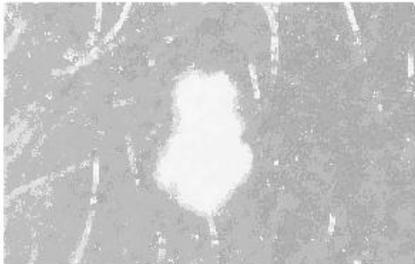
*Precisión = 0.9872*

La prueba del algoritmo con esta fotografía ofrece una segmentación bastante eficaz.

---

### IMAGEN 59

---



*Sensibilidad = 0.8749*

*Especificidad = 0.9996*

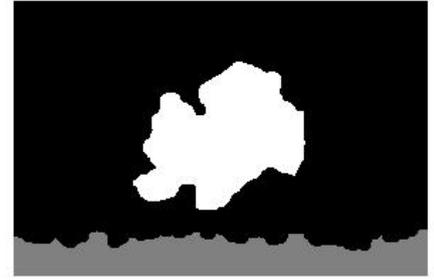
*Precisión = 0.9881*

De nuevo obtenemos una segmentación muy precisa, notándose en la cercanía de los bordes de las dos segmentaciones: la automática y la manual, verdad de referencia.

---

### IMAGEN 60

---



*Sensibilidad* = 0

*Especificidad* = 0.8498

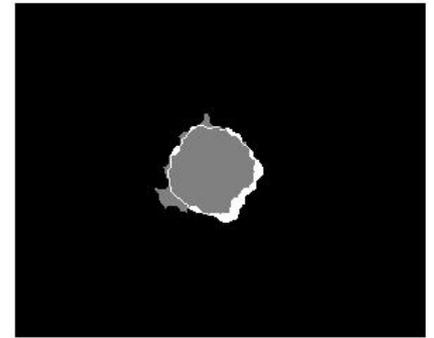
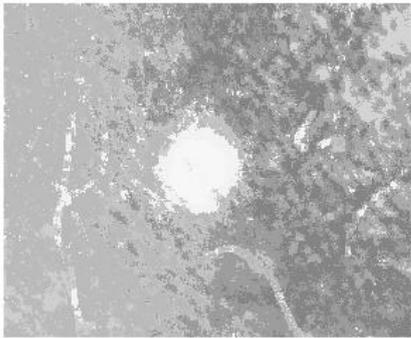
*Precisión* = 0.7302

La imagen diferencias de textura indica la gran variedad de texturas presentes en la imagen y, por tanto, la dificultad para llevar a cabo una correcta segmentación. Una vez más, las variaciones de iluminación excesivas llevan a un resultado erróneo.

---

### IMAGEN 61

---



*Sensibilidad* = 0.8577

*Especificidad* = 0.9955

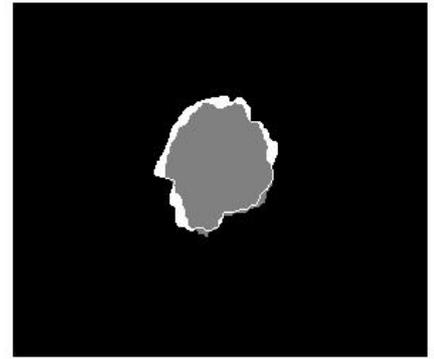
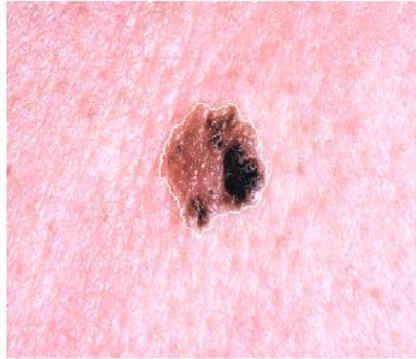
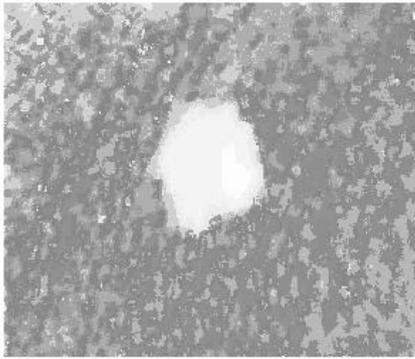
*Precisión* = 0.9889

Las tres imágenes resultado del algoritmo muestran su eficacia para esta fotografía en concreto.

---

### IMAGEN 62

---



*Sensibilidad* = 0.8366

*Especificidad* = 0.9983

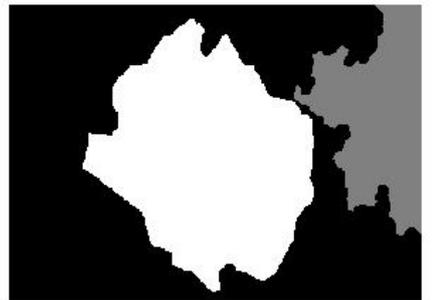
*Precisión* = 0.9857

Aquí se muestra un nuevo caso de buena segmentación, cumpliéndose el objetivo del algoritmo.

---

### IMAGEN 63

---



*Sensibilidad* = 0

*Especificidad* = 0.8034

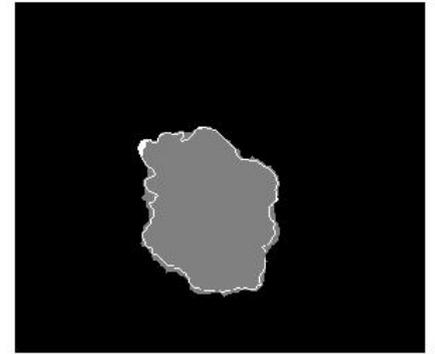
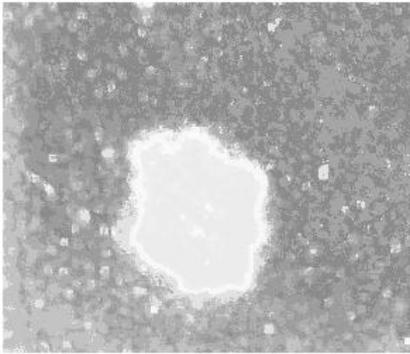
*Precisión* = 0.5497

La fotografía de partida no es adecuada para ejecutar el algoritmo, ya que no tiene gran contraste y presenta zonas iluminadas y otras de sombras. Además la piel normal presenta también patrones texturales.

---

### IMAGEN 64

---



*Sensibilidad* = 0.9902

*Especificidad* = 0.9900

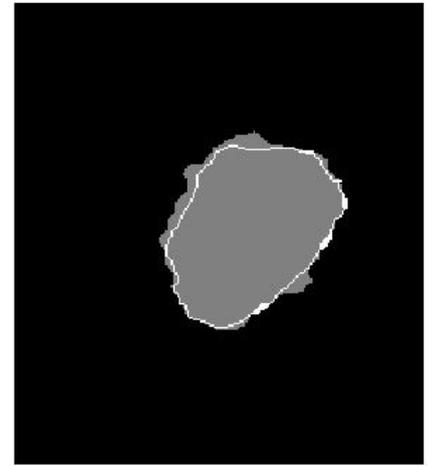
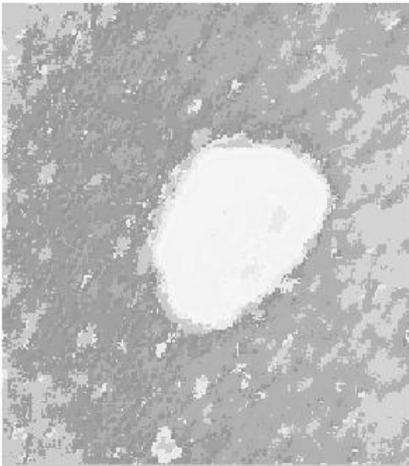
*Precisión* = 0.9900

Los valores del 99% de las medidas de confianza hacen de esta fotografía un ejemplo de precisión y eficacia del algoritmo.

---

### IMAGEN 65

---



*Sensibilidad* = 0.9832

*Especificidad* = 0.9860

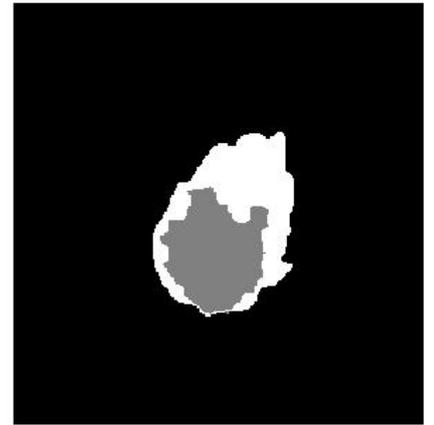
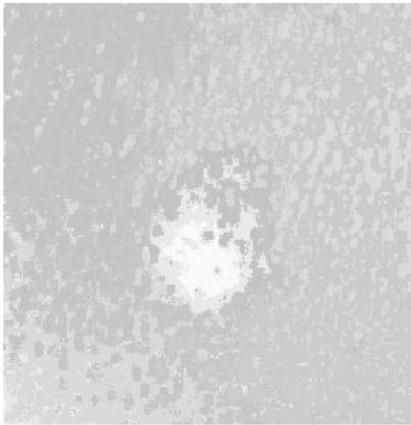
*Precisión* = 0.9856

Como en el caso anterior, con esta imagen el algoritmo consigue muy buenos resultados.

---

### IMAGEN 66

---



*Sensibilidad* = 0.4694

*Especificidad* = 0.9999

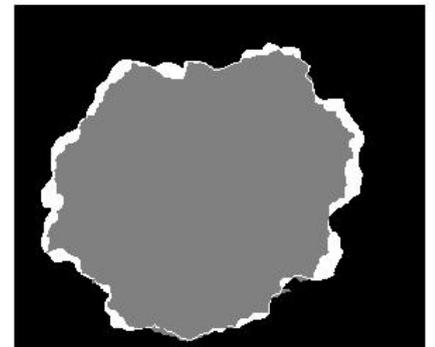
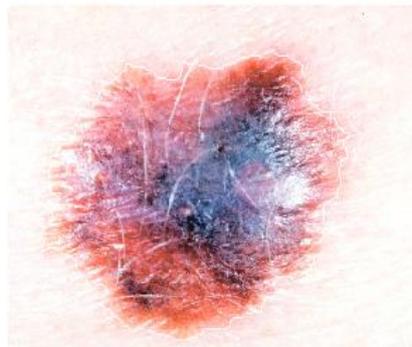
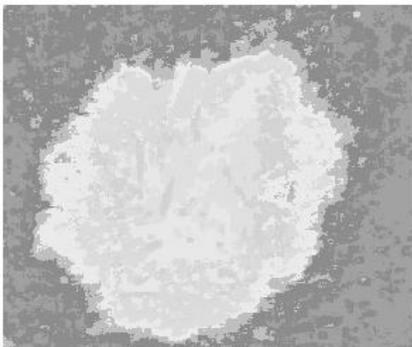
*Precisión* = 0.9417

En esta fotografía el área delimitada es inferior a la que tiene la referencia, mostrándose en un valor bajo de la Sensibilidad.

---

### IMAGEN 67

---



*Sensibilidad* = 0.9060

*Especificidad* = 0.9956

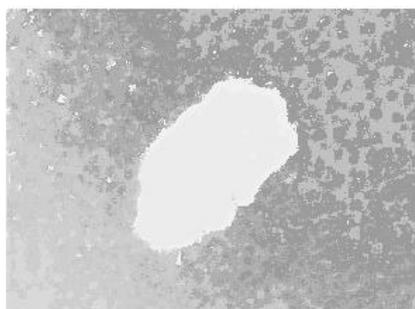
*Precisión* = 0.9519

Las medidas de fiabilidad y las imágenes anteriores muestran un buen funcionamiento del algoritmo.

---

### IMAGEN 68

---



*Sensibilidad* = 0.9720

*Especificidad* = 0.8106

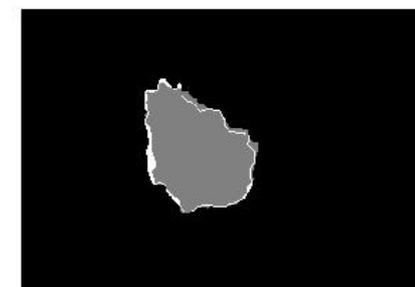
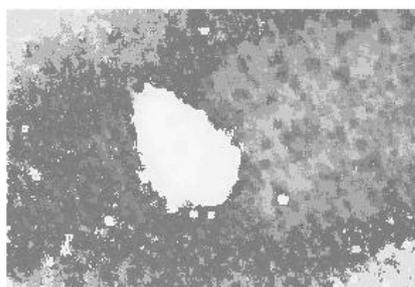
*Precisión* = 0.8338

El problema de esta lesión mal segmentada está en el umbral elegido, que debería ser mayor.

---

### IMAGEN 69

---



*Sensibilidad* = 0.9373

*Especificidad* = 0.9963

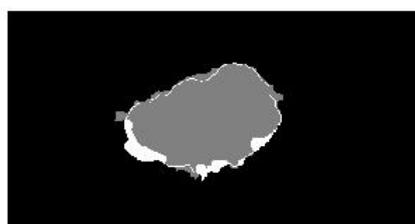
*Precisión* = 0.9913

Comparando la verdad de referencia con la segmentación salida del algoritmo, se puede comprobar el buen resultado en esta fotografía.

---

### IMAGEN 70

---



*Sensibilidad* = 0.8967

*Especificidad* = 0.9911

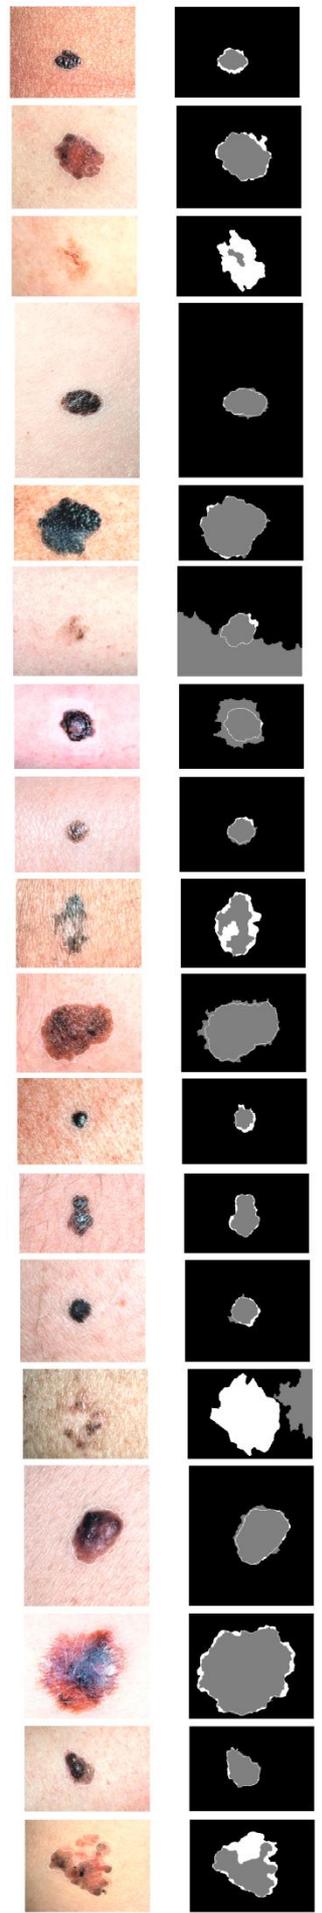
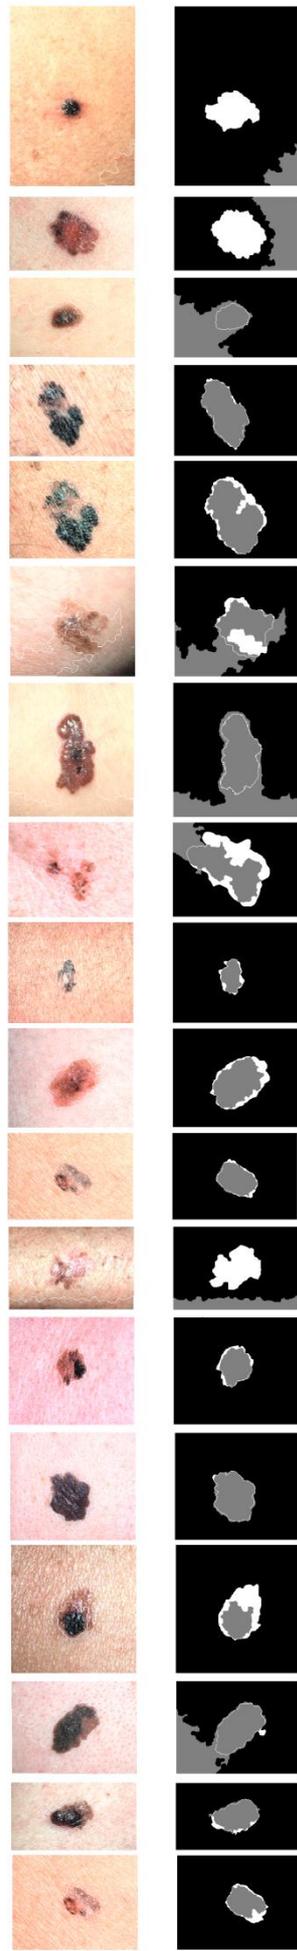
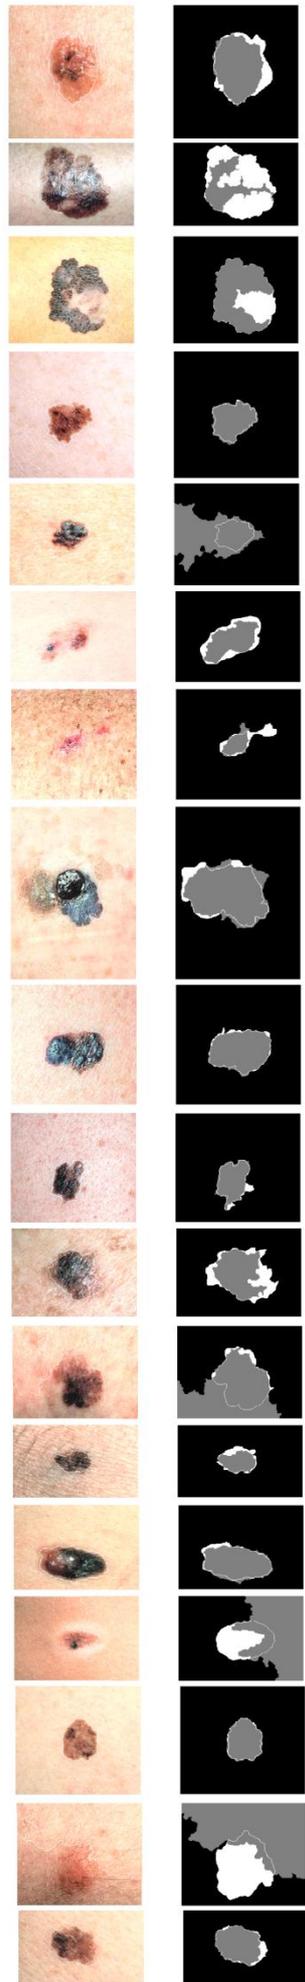
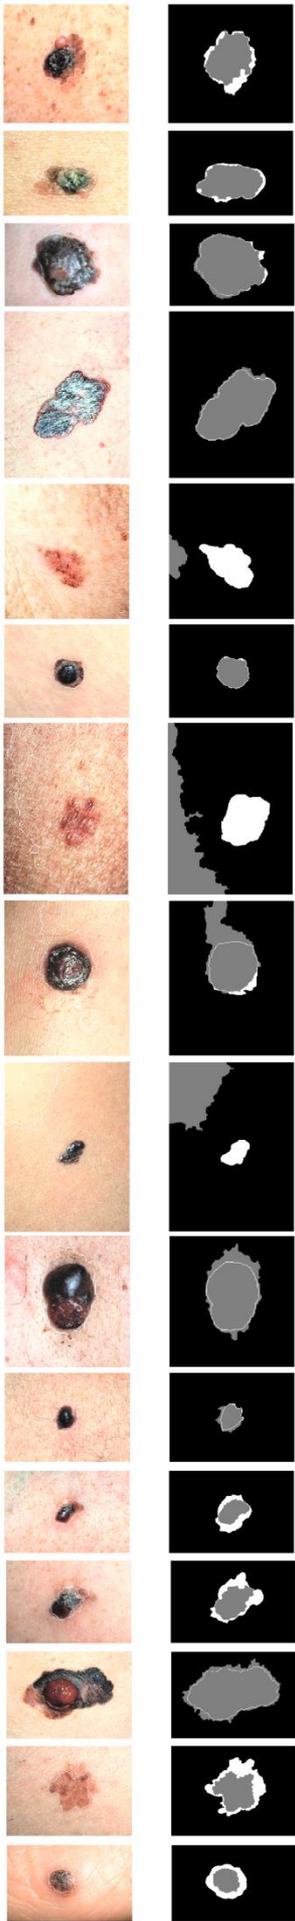
*Precisión* = 0.9786

Este es otro ejemplo de eficacia del método empleado para llevar a cabo la segmentación de la lesión de piel.

A la vista de los resultados, se demuestra el correcto funcionamiento del algoritmo. Cabe destacar que las imágenes objeto de las pruebas experimentales no han sido adquiridas expresamente para aplicarles el algoritmo, lo que, en algunos casos, dificulta la segmentación. Si se toman las fotografías de manera controlada, evitando zonas de reflejos, píxeles saturados o sombras, los resultados mejorarían considerablemente. También sería deseable que aparezca la lesión alejada de los bordes de la imagen para una correcta segmentación. Por tanto, muchos casos expuestos de segmentación errónea no se deben a un fallo del algoritmo, sino al pre-procesado de la imagen, que no es objeto de este trabajo.

Se debe tener en cuenta que uno de los objetivos del algoritmo es su funcionamiento autónomo, por lo que la determinación del umbral es la misma para todas las imágenes. Es por ello que no es el óptimo para algunas imágenes concretas. Otra causa de error que se repite en las pruebas realizadas es la presencia de patrones texturales en la piel sana además de la lesión, condicionando los resultados.

En las siguientes imágenes se recogen los resultados obtenidos de las 70 fotografías de forma reducida y compacta.



---

## 5. CONCLUSIONES

---

El objetivo establecido antes de la realización de este trabajo era el desarrollo de un sistema autónomo capaz de segmentar imágenes de lesiones de piel tomadas con una cámara de fotografía digital, que estuviese basado en la información del color y textura.

Una vez implementado el algoritmo y realizadas las pruebas pertinentes, se comprueba que el algoritmo cumple con la finalidad del mismo:

- Es un sistema autónomo, pues los parámetros empleados son fijos para todas las imágenes, sin ninguna dependencia respecto a la imagen de entrada.
- Consigue segmentar la lesión de piel presente en las imágenes, dando unos resultados bastante precisos según las medidas de fiabilidad.
- Funciona con imágenes obtenidas de forma simple, con una cámara digital estándar, lo que facilita el proceso de adquisición de la imagen evitando la necesidad de un dermatoscopio.
- Captura las distintas texturas presentes en la imagen mediante un modelo textural estadístico que ordena los niveles de gris de la vecindad de cada píxel.
- Tiene en cuenta la información de color en una sobre-segmentación inicial que separa la imagen en múltiples regiones de color homogéneo para, posteriormente, ser clasificadas en lesión o piel normal.

Por todo ello, se han alcanzado los objetivos propuestos inicialmente, quedando demostrado con los resultados obtenidos experimentalmente.

---

## LÍNEAS FUTURAS

---

Con la mirada puesta en posibles mejoras que desemboquen a un algoritmo más rápido o eficaz, se proponen distintas modificaciones del algoritmo que podrían ser objeto de futuras pruebas.

En primer lugar, dados los resultados obtenidos, sería conveniente aplicar un pre-procesado que consiga mejores resultados en la corrección de las variaciones de iluminación, causa de segmentación errónea en varios casos. Para poder aplicar el algoritmo a imágenes de piel en la que aparezca vello, se podrían emplear operadores morfológicos que lo eliminen previamente.

También se podría sustituir el algoritmo de sobre-segmentación inicial SRM por otro que también esté basado en las características de color de la imagen. La ventaja de este cambio sería reducir el tiempo de la segmentación, ya que el algoritmo SRM es una de las fases del TDLS que más tarda en ejecutarse.

Otro posible cambio podría estar determinado por el empleo de un modelo de mezcla de distribuciones texturales distinto al utilizado. En lugar de suponer que cada conjunto de píxeles que representan la misma textura en la imagen sigue una distribución Gaussiana, se pueden asumir distintos tipos de distribuciones.

Por último, se podrían realizar pruebas modificando el espacio de color de la imagen. El algoritmo desarrollado emplea imágenes en el espacio de color XYZ porque, según el estudio comparativo de Terrillon et al. (24), este espacio de color da buenos resultados para la segmentación de zonas de piel. Sin embargo, sería interesante comprobar los resultados obtenidos con distintos espacios de color.

## 6. REFERENCIAS

---

1. **Society, American Cancer.** Melanoma Skin Cancer. [En línea] 2014. [Citado el: 23 de Mayo de 2014.] <http://www.cancer.org/cancer/skincancer-melanoma/index>.
2. *Lesion border detection in dermoscopy images.* **Celebi, M Emre, y otros.** s.l. : Computerized Medical Imaging and Graphics, 2009, Vol. 33, págs. 148-153.
3. *Epiluminescence microscopy of small pigmented skin lesions: Short-term formal training improves the diagnostic performance of dermatologists.* **Binder, Michael, y otros.** Vienna, Austria : Journal of the American Academy of Dermatology, 1997, Vol. 36, págs. 197-202.
4. *Diagnostic accuracy of dermoscopy.* **Kittler, H., y otros.** s.l. : The Lancet Oncology, 2002, Vol. 3, págs. 159-165.
5. *Characterization of Skin Lesions.* **Madhankumar, K. y Kumar, P.** Salem, Tamilnadu : IEEE, 2012. 978-1-4673-1037-6.
6. **Solomon, Chris y Breckon, Toby.** *Fundamentals of digital image processing: a practical approach with examples in Matlab.* Hoboken, N.J. : Wiley-Blackwell, 2011.
7. **Stone, Maureen.** *Field Guide to Digital Color.* Natick, MA, USA : CRC Press, 2003.
8. **Westland, Stephen, Ripamonti, Caterina y Cheung, Vien.** *Computational Colour Science Using MATLAB, 2nd Edition.* Chichester, U.K. : John Wiley & Sons, 2012.
9. *Texture Analysis and Synthesis: A Review of Recent Advances.* **Manian, Vidya y Vásquez, Ramón.** Mayagüez, Puerto Rico : Visual Information Processing XII, 2003, Vol. 5108, págs. 242-250.
10. *Texture in skin images: comparison of three methods to determine smoothness.* **Stoecker, William V., Chiang, Chang-Sung y Moss, Randy H.** s.l. : Computerized Medical Imaging and Graphics, 1992, Vol. 16, págs. 179-190.
11. *Detection of pigment network in dermoscopy images using texture analysis.* **Anantha, Murali, Moss, Randy H. y Stoecker, William V.** Columbia : Computerized Medical Imaging and Graphics, 2004, Vol. 28, págs. 225-234.
12. *Procesamiento Digital de textura: Técnicas utilizadas en aplicaciones actuales de CBIR.* Lima : Revista de investigación de sistemas e informática, 2010, Vol. 7. 1816-3823.
13. *Lesion detection in dermatoscopic images using anisotropic diffusion and morphological flooding.* **Schmid, P.** Kobe : s.n., 1999. International Conference on Image Processing. Vol. 3. 0-7803-5467-2.
14. *Border detection in dermoscopy images using statistical region merging.* **Celebi, M. E., y otros.** s.l. : Skin Research and Technology, 2008, Vol. 14, págs. 347-353.
15. *Independent Histogram Pursuit for Segmentation of Skin Lesions.* **Gomez, D. D., y otros.** s.l. : IEEE Transactions on Biomedical Engineering, 2008, Vol. 55, págs. 157-161. 0018-9294.

16. *A coarse-to-fine approach for segmenting melanocytic skin lesions in standard camera images.* **Cavalcanti, P. G. y Scharcanski, J.** s.l. : Computer methods and programs in biomedicine, 2013, Vol. 112, págs. 684-693.
17. *Pattern analysis of dermoscopic images based on Markov random fields.* **Serrano, C. y Acha, B.** s.l. : Pattern recognition, 2009, Vol. 42, págs. 1052-1057.
18. *Texture segmentation of dermoscopy images using Gabor filters and g-means clustering.* **Hwang, S. y Celebi, M. E.** 2010. International Conference on Image Processing, Computer Vision, and Pattern Recognition (IPCV 2010). 882886.
19. *Skin Color Segmentation by Texture Feature Extraction and K-mean Clustering.* **Pan, Ng y Chi-Man, Pun.** Bali : IEEE, 2011. Third International Conference on Computational Intelligence, Communication Systems and Networks (CICSyN) .
20. *Segmentation of images of skin lesions using color and texture information of surface pigmentation.* **Dhawan, Atam P. y Sim, Anne.** s.l. : Computerized Medical Imaging and Graphics, 1992, Vol. 16, págs. 163-177.
21. *Segmentation of skin lesions from digital images using joint statistical texture distinctiveness.* **Glaister, Jeffrey, Wong, Alexander y Clausi, David A.** s.l. : IEEE Transactions on Biomedical Engineering, 2014, Vol. 61. 0018-9294.
22. *A perceptually oriented method for contrast enhancement and segmentation of dermoscopy images.* **Abbas, Qaisar, y otros.** s.l. : Skin Research and Technology, 2013, Vol. 19, págs. 490-497.
23. *Face recognition under large illumination variations using homomorphic filtering in spatial domain.* **Shahamat, Hossein y Pouyan, Ali A.** s.l. : Journal of Visual Communication and Image Representation, 2014, Vol. 25, págs. 970-977.
24. *Comparative performance of different skin chrominance models and chrominance spaces for the automatic detection of human faces in color images.* **Terrillon, J. C., y otros.** 2000. Fourth IEEE International Conference on Automatic Face and Gesture Recognition. págs. 54-61.
25. *Statistical Textural Distinctiveness for Salient Region Detection in Natural Images.* **Scharfenberger, C., y otros.** Portland, OR : IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2013. págs. 979 - 986. 1063-6919.
26. **Smith, Lindsay I.** Department of Computer Science. University of Otago. [En línea] 2014. [Citado el: 29 de Mayo de 2014.] [http://www.cs.otago.ac.nz/cosc453/student\\_tutorials/principal\\_components.pdf](http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf).
27. *Unsupervised Learning of Finite Mixture Models.* **Figueiredo, M.A.T. y Jain, A.K.** s.l. : IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, Vol. 24, págs. 381-396.
28. *Statistical Region Merging.* **Nock, Richard y Nielsen, Frank.** s.l. : IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, Vol. 26, págs. 1452-1458.
29. DermQuest. [En línea] 2014. [Citado el: 21 de Mayo de 2014.] <https://www.dermquest.com/image-library/>.