

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

Detección y clasificación de patrones globales en
lesiones pigmentadas

Autor: Paloma Caramé Matres

Tutores: Begoña Acha Piñero, Carmen Serrano Gotarredona

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

Sevilla, 2017



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

Detección y clasificación de patrones globales en lesiones pigmentadas

Autor:

Paloma Caramé Matres

Tutores:

Begoña Acha Piñero

Carmen Serrano Gotarredona

Profesoras titulares

Dep. de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2017

Trabajo Fin de Grado: Detección y clasificación de patrones globales en lesiones pigmentadas

Autor: Paloma Caramé Matres

Tutores: Begoña Acha Piñero
Carmen Serrano Gotarredona

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

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2017

El Secretario del Tribunal

A mi familia

Agradecimientos

Aún recuerdo el primer día que entré por las puertas de esta escuela, llena de ilusiones y de inquietudes. Poco sabía por entonces de lo rápido que pasa el tiempo, y de todo lo que iba a ocurrir en los próximos años. Echo la vista atrás y me doy cuenta de que no cambiaría ni un solo momento, malo o bueno, de los que he vivido estos años, porque todos han ayudado a estar donde estoy. Puedo decir, hoy por hoy, sin miedo a equivocarme, que esta ha sido la etapa más importante de mi vida, en la que más he crecido, no solo como profesional, sino también como persona. Quiero aprovechar este espacio para agradecer a los verdaderos responsables de que yo hoy pueda escribir estas palabras. Papá, mamá, Jose, muchas gracias por haber estado siempre y en todo momento a mi lado, en todas las decisiones que he tomado, por darme ánimo y aliento cuando más lo necesitaba, y sobre todo por vuestro cariño constante. Luis, gracias por todo, por mejorar todos los buenos momentos que ha habido durante estos años, y también por mejorar los malos, porque no habría podido tener un mejor acompañante en este camino, y por seguir caminando juntos muchos años más. Gracias a todos mis amigos de la carrera, por el sufrimiento y las alegrías que hemos compartido, que nos han llevado a aquella meta que veíamos tan lejana hace solo unos años atrás. Gracias a mis amigos de toda la vida, por escucharme cuando me hacía falta, darme siempre ánimos y acompañarme aún en la etapa en la que aparentemente nuestros caminos se separaban. También debo agradecer el estar hoy aquí a toda la gente que, de una manera u otra, me animó a hacer esta carrera, porque posiblemente sin ellos no estaría hoy aquí.

Por último, me gustaría agradecer a mis tutoras, Carmen y Begoña, por haberme mostrado la belleza de este mundo que es la ingeniería biomédica, por el esfuerzo presente en este trabajo, todos vuestros consejos y vuestra disponibilidad cuando me ha hecho falta, ayudándome a llevar a buen puerto este trabajo. Me habéis inspirado mucho.

Paloma Caramé Matres

Sevilla, 2017

El cáncer de piel es el tipo de cáncer más común, dentro del cual destaca el melanoma como el responsable de más muertes. El número de casos diagnosticados está incrementándose cada año, siendo de vital importancia un diagnóstico temprano que ayude a reducir la tasa de mortalidad.

El presente proyecto pretende adentrarse en la ingeniería biomédica, siendo un paso previo en el camino que trata de dar solución a este problema, mediante el tratamiento digital de imágenes dermatoscópicas. El objetivo principal del trabajo es clasificar una lesión pigmentada dada en tres tipos de patrones globales. Estos tipos de patrones son reticulados, globulares y homogéneos. Para ello se ha seguido el esquema básico que sigue cualquier sistema de diagnóstico asistido por ordenador. Primero ha procedido a buscar el método óptimo de segmentación que nos permita tratar únicamente la zona de interés. Posteriormente se ha realizado la extracción de características de textura siguiendo distintos métodos, y se ha finalizado clasificando las lesiones en tres posibles clases según su patrón global: reticulado, globular y homogéneo. Para esto último se ha utilizado un sistema de *machine learning*. Por último, se han analizado los resultados obtenidos, encontrándose una precisión total de 87.08% y una sensibilidad total del 80.45%.

Abstract

Skin cancer is the most common type of cancer in which melanoma is the leading cause of death. The number of diagnosed cases is increasing each year, and it is of vital importance an early diagnosis to reduce the mortality rate.

The present project intends to be part of biomedical engineering, being a previous step in the way that tries to solve this problem using the digital treatment of dermoscopic images. The main objective is to classify a given pigmented skin lesion into three types of global patterns. These types of patterns are: reticular, globular and homogeneous. It will follow the basic scheme that follows a computer-aided diagnosis system. First, we proceeded to look for the optimal method of segmentation that allowed us to treat only the zone of interest. Subsequently the extraction of texture features was carried out following different methods, and finally we classified the lesion into three possible classes according to their global pattern: reticular, globular and homogeneous, using a machine learning algorithm. To conclude, the results obtained are analyzed where an accuracy of 87.08% and a sensitivity of 80.45% are achieved.

Índice

Agradecimientos	ix
Resumen	xi
Abstract	xiii
Índice	xiv
Índice de Tablas	xv
Índice de Figuras	xvii
1 Introducción	1
1.1 <i>Modelos diagnósticos</i>	3
1.1.1 Primera Fase	3
1.1.2 Segunda Fase	4
1.2 <i>Sistemas de Diagnóstico Asistido por Ordenador (CAD)</i>	7
2 Estado del arte	9
3 Metodología	11
3.1 <i>Segmentación</i>	11
3.1.1 Crecimiento de Regiones	12
3.2 <i>Extracción de características</i>	15
3.2.1 Matriz de co-ocurrencia	17
3.2.2 Característica basada en la Transformada de Fourier	19
3.2.3 Característica basada en detección de red	20
3.3 <i>Selección de características</i>	22
3.4 <i>Clasificación</i>	23
4 Validación	27
4.1 <i>Patrón Globular</i>	30
4.2 <i>Patrón Reticulado</i>	32
4.3 <i>Patrón Homogéneo</i>	33
5 Conclusiones y líneas futuras	39
Referencias	41

ÍNDICE DE TABLAS

Tabla 1–1. Sistema de puntuación del 7-point checklist	5
Tabla 1–2. Sistema de puntuación de la regla ABCD	6
Tabla 1-3. Sistema de clasificación de la regla ABCD según el TDS	6
Tabla 1-4. Características del método de Menzies	7
Tabla 1-5. Sensibilidad y especificidad de los distintos métodos diagnóstico	7
Tabla 2-1. Porcentaje de aciertos para cada espacio de color obtenido en [16]	9
Tabla 2-2. Resultados de clasificación de [19]	10
Tabla 2-3. Resultados de clasificación de [23]	10
Tabla 4-1. Tabla para evaluar el diagnóstico para la clase Reticulada	27
Tabla 4-2. Asignación de características	29
Tabla 4-3. Procedimiento del algoritmo SFS con su error de clasificación	29
Tabla 4-4. Resultados de la clasificación de las imágenes con patrón globular según el <i>Ground Truth</i>	3030
Tabla 4-5. Datos de TP, TN, FP y FN para el patrón globular	30
Tabla 4-6. Resultados de la clasificación de las imágenes con patrón reticulado según el <i>Ground Truth</i>	32
Tabla 4-7. Datos de TP, TN, FP y FN para el patrón reticulado	32
Tabla 4-8. Resultados de la clasificación de las imágenes con patrón homogéneo según el <i>Ground Truth</i>	34
Tabla 4-9. Datos de TP, TN, FP y FN para el patrón homogéneo	34
Tabla 4-10. Sensibilidad, Especificidad, PPV, NPV y precisión para cada clase, y total expresado porcentualmente	36

ÍNDICE DE FIGURAS

Figura 1-1. Microscopía de Epiluminescencia	1
Figura 1-2. Ley de Snell	2
Figura 1-3. Ángulo de Brewster	2
Figura 1-4. Método de diagnóstico en 2 pasos	3
Figura 1-5. Patrones globales	4
Figura 1-6. Metodología de sistemas CAD	8
Figura 3-1. Ejemplo de segmentación	12
Figura 3-2. Proceso de segmentación	13
Figura 3-3. Proceso de segmentación	15
Figura 3-4. Ejemplo de subimagen tamaño 80x80	15
Figura 3-5. Imagen segmentada	16
Figura 3-6. Pérdida de información en zonas cercanas al borde	16
Figura 3-7. Ejemplo de matriz de co-ocurrencia (GLMC)	18
Figura 3-8. Ejemplo de los espectros de la FFT en dos sub-ímagenes	19
Figura 3-9. Diagrama de extracción de densidad	20
Figura 3-10. Diagrama de flujo del algoritmo implementado para Top-hat	21
Figura 3-11. Esquema de método de selección de características	22
Figura 3-12. Margen de un hiperplano de separación	23
Figura 4-1. Imagen con patrón globular clasificada erróneamente	30
Figura 4-2. Imagen con patrón globular clasificada erróneamente	31
Figura 4-3. Imagen con patrón globular clasificada erróneamente	31
Figura 4-4. Imagen con patrón reticulado clasificada erróneamente	32
Figura 4-5. Imagen con patrón reticulado clasificada erróneamente	33
Figura 4-6. Imagen con patrón reticulado clasificada erróneamente	33
Figura 4-7. Imagen con patrón homogéneo clasificada erróneamente	34
Figura 4-8. Imagen con patrón homogéneo clasificada erróneamente	35
Figura 4-9. Imagen con patrón homogéneo clasificada erróneamente	35

1 INTRODUCCIÓN

El cáncer de piel es, hoy en día, el tipo de cáncer más común entre la población caucásica, con tendencia al alza en estas últimas décadas. Su incidencia está aumentando a razón de un 10% por año, lo que se traduce en que, en los próximos 5 años, aumentará un 50%. El melanoma es el tipo de cáncer de piel responsable de más muertes. Según datos de la Asociación Americana del Cáncer, una persona muere en el mundo cada hora a causa del melanoma [1].

Al año se producen entre 2 y 3 millones de casos nuevos de cáncer de piel, de los cuales, aproximadamente un 5%, es decir, unos 130.000, corresponden a melanomas [2]. No se trata, por tanto, del más común, pero sí del que mayor tasa de mortalidad tiene, ya que su capacidad de generar metástasis es muy superior a la de otros tipos de cáncer de piel, siendo el responsable del 80% de las muertes en estos tipos de cáncer. En estos casos, un diagnóstico temprano es de vital importancia, puesto que, detectada a tiempo, la curabilidad de este tipo de lesión es de más del 95%. Además, el riesgo de sufrir metástasis disminuye con la precocidad del diagnóstico. [3]

Esta necesidad de detectar a tiempo las lesiones, unida a la dificultad que existe para diferenciar un melanoma de una lesión benigna, ha impulsado el desarrollo de tecnologías cuyo objetivo es mejorar la sensibilidad y rapidez del diagnóstico clínico, facilitando la labor del médico y reduciendo a su vez las molestias causadas al paciente. La dermatoscopia, también llamada microscopía de epiluminescencia (*Epiluminescence Microscopy*, ELM), es una técnica no invasiva que usa el aumento óptico para visualizar características morfológicas de la piel que no son detectables a simple vista.

La incursión de la dermatoscopia en la práctica clínica de la dermatología ha puesto de manifiesto una dimensión desconocida hasta el momento, el aspecto morfológico de las lesiones pigmentadas (*Pigmented Skin Lesion*, PSL). Esta nueva dimensión es la que ayuda a diferenciar melanomas de otro tipo de lesiones, ya sean melanocíticas o no melanocíticas. Gracias a la tecnología digital, también es posible observar la evolución de una lesión, ayudando a detectar las PSL benignas sin necesidad de realizar una biopsia. Por estos motivos, la práctica de la dermatoscopia se ha hecho más y más popular, ya no sólo entre los dermatólogos, sino entre oncólogos, cirujanos, pediatras y un gran número de especialistas más.

El diagnóstico clínico sin este tipo de ayudas, es decir, a simple vista, tiene una precisión de un 60% [4]. La dermatoscopia tiene el potencial de mejorar notablemente esa precisión diagnóstica, y de aumentar la sensibilidad de un 10% a un 27% en la detección temprana de melanomas [5].

Se trata de un método sencillo, rápido y barato que consiste en observar la lesión en cuestión con un dermatoscopio: una lupa de 10 a 40 aumentos con una fuente de iluminación (polarizada o no polarizada). Permite ver las PSL sin ser obstruidas por la reflexión a la que estamos sometidos cuando observamos a simple vista.




Figura 1-1. Microscopía de Epiluminescencia

Debido a los fenómenos de la refracción y la reflexión, la visión directa de la piel no penetra en la epidermis, puesto que el índice de refracción del aire es de 1, mientras que el de la epidermis es de 1.55. Para solucionar esto hay dos métodos principales que pueden emplear los dispositivos:

- Una **luz convencional** junto con la aplicación de un fluido, generalmente aceite, de inmersión sobre la piel. El cristal del dermatoscopio tiene un índice de 1.52, muy similar al de la epidermis. En este método es necesario poner en contacto directamente la lente con la superficie cutánea. Generalmente sirve para visualizar mejor estructuras superficiales de las lesiones. Su principal desventaja es que comprime la vasculatura debido a la presión ejercida al tener que poner en contacto el aparato directamente sobre la piel, y, por tanto, los vasos no se observan en su forma ni tamaño real. Son más económicos.

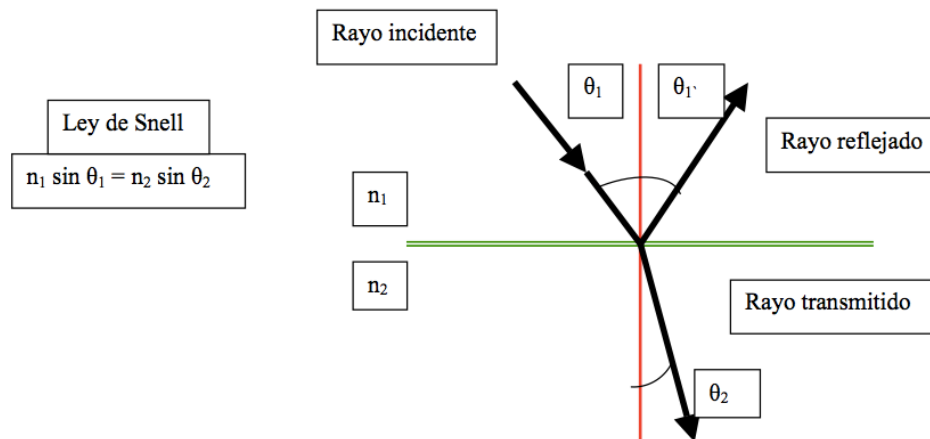


Figura 1-2. Ley de Snell

- Una **luz polarizada**. No requiere líquidos de inmersión ni es necesario poner en contacto el aparato con la piel, por lo que no ejercen presión, lo que los hace ideales para identificar estructuras más profundas, como vasos sanguíneos y colágeno. Al incidir con un haz linealmente polarizado en la dirección paralela al plano de incidencia, el haz reflejado se anula en el ángulo de Brewster, produciéndose una transmisión total del haz entre ambos medios. Permiten visualizar mejor lesiones vasculares. Tienen un coste más elevado.




Figura 1-3. Ángulo de Brewster

1.1 Modelos diagnósticos

Una vez obtenida la imagen dermatoscópica de la lesión, para poder detectar el melanoma, es necesario clasificarla. Es muy común usar el método de diagnóstico en dos etapas: el primer paso consiste en la distinción entre lesión melanocítica y no melanocítica, mientras que el segundo clasifica una lesión melanocítica en benigna o melanoma. En el Consensus Net Meeting on Dermoscopy (CNMD), éste fue el procedimiento establecido para analizar las PSL [6].

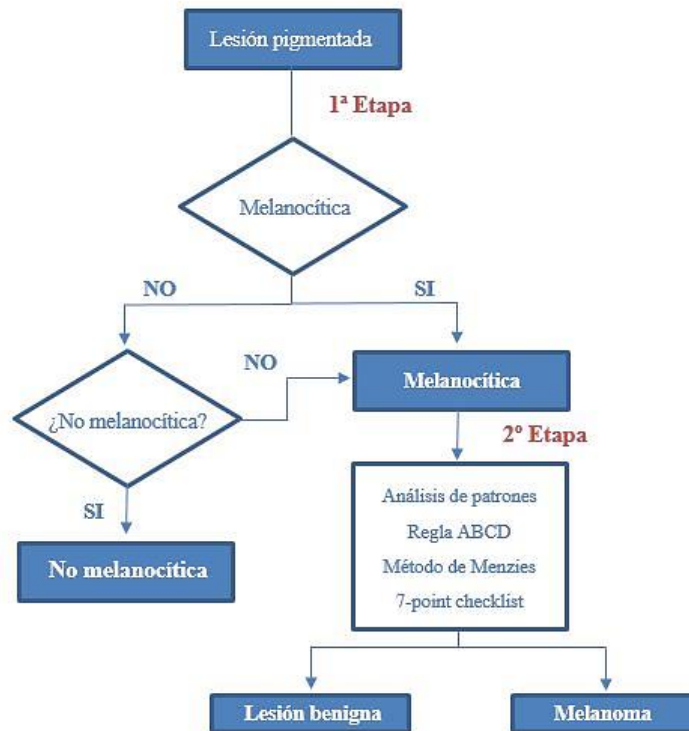


Figura 1-4. Método de diagnóstico en 2 pasos

1.1.1 Primera Fase

La primera fase del procedimiento, tiene como fin catalogar la PSL como melanocítica o no melanocítica. Como podemos ver en la figura 1-4, para ello primero se evalúa en la lesión la presencia de características propias de lesiones melanocíticas, catalogando así este tipo de lesiones. En caso de no encontrar ningún criterio, se pasa a evaluar la presencia de características propias de lesiones no melanocíticas. Si alguna está presente, la lesión queda catalogada como no melanocítica, y en caso contrario, para evitar infradiagnósticos, la lesión se etiqueta como melanocítica.

El método más seguido en la literatura para el análisis y clasificación de imágenes dermatoscópicas es el análisis de patrones [7], escrito por Perhambberger en 1987 y actualizada por el CNMD en el 2003 [6]. Consiste en identificar una serie de patrones presentes en las PSL, que pueden ser globales o locales. Los globales son los que se encuentran recubriendo la mayor parte de la lesión y permiten una clasificación preliminar más rápida, por lo que son los que nos ayudan en esta primera etapa, quedando los locales para la segunda.

Los principales patrones globales son:

- **Patrón reticulado:** Es la característica global más común de lesiones melanocíticas, y está caracterizada por la presencia predominante de red pigmentada en la lesión. La red pigmentada aparece en forma de líneas, delgadas y marrones, que forman una cuadrícula sobre un fondo más homogéneo. [8]

- **Patrón globular:** Caracterizado por la presencia de numerosas estructuras redondeadas u ovaladas con tamaño variado cuya pigmentación puede ir del marrón al gris o incluso al negro. [8]
- **Patrón empedrado:** Es bastante similar al anterior, pero los glóbulos que lo componen son bastante más grandes y están distribuidos de forma muy cercana. Su forma recuerda a la de empedrados o los mosaicos, y de ahí el nombre. [8]
- **Patrón homogéneo:** Estas lesiones se caracterizan por tener una pigmentación difusa en la que destaca la ausencia de características locales distintivas. [8]
- **Patrón estallido de estrellas:** En este caso la lesión se encuentra recubierta por estrías dispuestas de forma radial. [8]
- **Patrón paralelo:** Se encuentra exclusivamente en las palmas de las manos y planta de los pies. Se caracteriza porque la pigmentación sigue los surcos o las crestas de los dibujos formados por los pliegues cutáneos de dichas partes del cuerpo. [8]
- **Patrón lacunar:** Caracterizado por la presencia de numerosas estructuras de varios tamaños, redondeadas u ovaladas de bordes poco definidos llamados lagos rojos y cuya característica más destacada es su coloración rojiza, azul púrpura o negra.
- **Patrón multicomponente:** Este patrón se presenta cuando en una misma lesión hay combinación de tres o más de las características mencionadas anteriormente. [8]
- **Patrón inespecífico:** Este es el patrón asignado cuando el aspecto dermatoscópico no encaja en ninguno de los anteriores. [8]




Figura 1-5. Patrones globales (a) Reticulado; (b) Globular; (c) Empedrado; (d) Homogéneo; (e) Estallido de estrellas; (f) Paralelo; (g) Lacunar; (h) Multicomponente; (i) Inespecífico

1.1.2 Segunda Fase

Como podemos apreciar en la figura 1-4, para la segunda fase, existe un conjunto de diferentes técnicas, validadas por el CNMD que, a partir de la imagen dermatoscópica clasificada como melanocítica, son capaces de clasificar las PSL en dos categorías: lesiones melanocíticas benignas y melanoma; tarea que, como ya adelantamos, era bastante complicada antes de la llegada de la dermatoscopia. Entre estas técnicas vamos a destacar aquellas que se han ido abriendo paso y son cada vez más aceptadas por médicos profesionales, convirtiéndose en algunos de los métodos más mencionados y empleados en este campo:

1.1.2.1 Análisis de patrones [7]

Es el método diagnóstico más completo y con el que se obtienen mejores resultados [6], probablemente debido a que es el método que refleja mejor cómo trabaja el cerebro humano al clasificar imágenes morfológicas. Está basado en el juicio cualitativo, llevado a cabo por un experto, de varios criterios ELM que pueden ser globales o locales. Para la clasificación correspondiente a esta fase, nos centraremos en los patrones locales, que son aquellas características dermatoscópicas que se presentan en una región concreta de la lesión. Estas características son: red pigmentada, puntos y glóbulos, streaks, velo azul-blanquecino, estructuras de regresión, pigmentación, hipopigmentación y estructuras vasculares, que se encuentran definidas completamente en [8].

Estos patrones pueden presentarse con naturaleza regular o irregular, denotando así que una lesión es benigna o melanoma respectivamente. En el CNMD se determinó que los patrones locales que mostraban más correlación con melanomas eran la red pigmentada atípica, streaks irregulares y las estructuras de regresión.

Cabe destacar también que la presencia predominante de algunos de estos patrones puede determinar patrones globales [6].

1.1.2.2 7-point checklist de Argenziano [9]

Es un método de diagnóstico semicuantitativo. Aunque se trata de una técnica diferente, puesto que como ya hemos dicho, el análisis de patrones está basado en un juicio cualitativo, desde el punto de vista médico, puede considerarse una simplificación del análisis de patrones, en la que, de todos los criterios que en este último se definen, se toman únicamente 7 de ellos y se dividen en dos tipos, mayores y menores, cada uno con una puntuación distinta, según su relevancia en las lesiones malignas. La siguiente tabla presenta las características y la puntuación asignada a cada una de ellas:

Criterio	Características	Puntuación
Mayor	Patrón reticulado Atípico Velo azul-blanquecino Patrón Vascular Atípico	2
Menor	Líneas irregulares Pigmentación irregular Puntos irregulares Áreas de regresión	1

Tabla 1-1. Puntuación 7-point checklist

La imagen dermatoscópica es analizada, y se evalúa la presencia de los criterios mencionados en la tabla 1-1. Si finalmente la puntuación obtenida es superior a 3, la lesión es clasificada como melanoma.

1.1.2.3 Regla ABCD de Stolz [10]

Es uno de los métodos más conocidos y aplicados para el estudio de las lesiones melanocíticas. Su nombre hace referencia a las cuatro características que son evaluadas (Asimetría, Borde, Color y Diferencias estructurales – o diámetro en versiones más simplificadas –). A partir de la observación de dichas características se asigna a la lesión una puntuación semi-cuantitativa que permite determinar con bastante precisión si se trata de un melanoma o una lesión benigna.

Concretamente, la puntuación de cada característica se realiza atendiendo a las siguientes consideraciones:

- **Asimetría:** Se valora teniendo en cuenta su color y estructura. Se colocan dos ejes perpendiculares de tal forma que se minimice la asimetría. Si los ejes son completamente simétricos, la puntuación es 0. Si hay asimetría respecto de un único eje, la puntuación es 1. Si existe asimetría respecto de los dos ejes, la puntuación es 2.
- **Borde:** Se divide el borde de la lesión en 8 segmentos, y se añade un punto por cada segmento en el que se observe un cambio brusco.
- **Color:** Es simplemente la suma de los diferentes colores presentes en la lesión.
- **Diferencias estructurales:** Se suma un punto por cada patrón estructural encontrado en la PSL. Las posibilidades son: red pigmentada, glóbulos, áreas homogéneas, manchas y streaks.

Posteriormente, cada puntuación individual es multiplicada por un factor que varía según de qué característica provenga (tabla 1-2), y finalmente, se suman todas las puntuaciones parciales obteniendo el índice dermatoscópico total (*Total Dermoscopic Score*, TDS), y clasificamos la lesión en tres clases según el mismo. Esto se puede observar en la tabla 1-3.

La siguiente tabla describe el sistema de puntuación empleado por esta regla:

Criterio	Rango de puntuación	Factor	Puntuación máxima/mínima
Asimetría	0 - 2	1.3	0.0 - 2.6
Borde	0 - 8	0.1	0.0 - 0.8
Color	1 - 9	0.5	0.5 - 3.0
Diferencias estructurales	1 - 5	0.5	0.5 - 2.5

Tabla 1-2. Sistema de puntuación de la regla ABCD

$$TDS = A \cdot 1.3 + B \cdot 0.1 + C \cdot 0.5 + D \cdot 0.5$$

Benigna	Sospechosa	Maligna
< 4.75	4.8 - 5.45	> 5.45

Tabla 1-3. Sistema de clasificación de la regla ABCD según el TDS

1.1.2.4 Método de Menzies [11]

Es un método sencillo que valora 11 criterios o características dermatoscópicas, divididas en 9 positivas y 2 negativas. Las positivas son características del melanoma, mientras que las negativas definen la lesión como benigna. Para que una lesión sea diagnosticada como melanoma no debe tener ninguna característica negativa y tener, al menos, 1 positiva. En la tabla 1-4 mostramos estas características.

Características positivas	Características negativas
Velo azul-blancuecino Múltiples glóbulos marrones Pseudópodos Distribución radial Zonas sin pigmento Glóbulos negros en la periferia Colores múltiples Puntos de color azul/gris Patrón reticulado	Patrones simétricos Color uniforme

Tabla 1-4. Características del método de Menzies

La tabla 1-5 muestra los resultados de sensibilidad y especificidad obtenido para cada método aquí explicado, así como para la clasificación que tiene lugar en la primera fase [6].

Método	Sensibilidad (%)	Especificidad (%)
Primera Etapa	95.2	90.5
Análisis de patrones	83.7	83.4
7-point checklist	83.6	71.5
Regla ABCD	82.6	70
Método de Menzies	85.7	71.1

Tabla 1-5. Sensibilidad y Especificidad de los sistemas diagnósticos [6]

1.2 Sistemas de Diagnóstico Asistido por Ordenador (CAD)

Debido a los probados beneficios de la aplicación de imágenes digitales a la dermatología [6] [12], se han ido aplicando los sistemas de diagnóstico asistido por ordenador (*Computer Aided Diagnosis*, CAD) a este campo. Son tecnologías interdisciplinarias bastante novedosas que combinan la inteligencia artificial, el procesado digital de imágenes y algún tipo de especialidad médica, la dermatología en el caso que nos ocupa. Su objetivo es servir de apoyo a especialistas médicos a la hora de diagnosticar la lesión interpretando contenido multimedia. La idea, por tanto, no es la de dar un diagnóstico completo, sino de ayudar al médico a conseguir un diagnóstico óptimo.

Las imágenes médicas contienen gran cantidad de información que los especialistas deben evaluar y analizar en poco tiempo. Los sistemas CAD procesan la información contenida en esas imágenes resaltando aquello que sea relevante, como posibles lesiones melanocíticas o incluso lesiones sospechosas de ser melanoma en el caso que estamos considerando. La ventaja es que a estas tecnologías no se les escapa información menor que sí se escapa a la visión humana, por lo que el doctor es capaz de interpretar toda la información visible sin pasar nada por alto.

Dada una imagen dermatoscópica como entrada, estos sistemas siguen diversos pasos mediante programas y algoritmos, con el fin de clasificar la lesión. Podemos verlos en la figura 1-6. En primer lugar, la imagen es sometida a un pre-procesamiento con el fin de mejorar la imagen eliminando imperfecciones como el ruido, aumentando el contraste o la nitidez para tenerla preparada para el procesamiento posterior. Puede que la imagen no necesite ningún ajuste, por lo que este primer paso es opcional. Después se ejecuta el algoritmo de segmentación, que encuentra los bordes de la lesión, separando así la piel sana de la zona lesionada. Una vez hecho esto se extraen las características que se crean necesarias (texturas, formas, tamaños, color, etc.) y se clasifica conforme a ellas.

En 2009 Maglogianis and Doukas [13] presentaron una visión global de los sistemas CAD, describiendo cómo extraer las características mediante el procesado digital de imagen, así como técnicas para la clasificación de las PSL. En el documento redactado por Celebi et al [14] en 2011, *Advances in skin cancer image analysis*, se resume el progreso conseguido en este campo, incluyendo trabajos de sistemas de imágenes multispectrales, mejora de imágenes y detección del borde de la lesión con la consiguiente extracción de características. Aún más reciente es el trabajo de Korotkov y García [15], que consiste en una crítica bastante extensa de los sistemas CAD enfocados a lesiones pigmentadas microscópicas (dermoscópicas) y macroscópicas (clínicas).



Figura 1-6. Metodología de sistemas CAD

Para usar correctamente un sistema CAD, es importante comprender sus limitaciones puesto que, como con cualquier herramienta, se corre el riesgo de error por mal uso. En concreto queremos destacar que los sistemas CAD no tienen garantía de solución. Que el procedimiento funcione a la perfección no debe garantizar el diagnóstico. Lo único que garantiza es una imagen con zonas relevantes o sospechosas de ese diagnóstico que el especialista debe comprobar y confirmar. Es el profesional el último responsable de la interpretación de estas imágenes. No es objetivo ni competencia de esta tecnología proveer un diagnóstico específico.

2 ESTADO DEL ARTE

El presente trabajo consiste en el diseño de un sistema CAD que clasifique una lesión dada en tres tipos de patrones globales (reticulado, globular y homogéneo). A continuación, veremos brevemente los estudios que han tenido lugar en este campo.

En cuanto a métodos para detección y clasificación de patrones globales, pocos son los que encontramos en la literatura [16] [17] [18] [19].

Entre los estudios llevados a cabo en este campo destaca el de Serrano y Acha [16] en el que propusieron un método novedoso de clasificación automática de cinco tipos de patrones globales (reticular, globular, empedrado, homogéneo y paralelo), basado en el campo aleatorio de Markov (*Markov Random Field*, MRF) extendido a imágenes a color. Primero se modela cada plano como un modelo finito simétrico condicional (*finite symmetric conditional model*, FSCM) y después se supuso que las características seguían una distribución normal multivariante, con diferente media y covarianza según de qué patrón global se tratase. Para clasificar siguieron la regla *maximum a-posteriori* (MAP), que dio lugar a *maximum likelihood* (ML) al ser los patrones equiprobables. Se compararon los resultados obtenidos para distintos espacios de color. Los resultados los podemos observar en la tabla 2-1.

Espacio de color	Aciertos (%)
RGB	80
YIQ	80
HSV	81
L*a*b*	86

Tabla 2-1. Porcentaje de aciertos para cada espacio de color obtenido en [16]

Desde que Serrano y Acha desarrollaron este método, diferentes estudios han seguido sus pasos, como por ejemplo Gola et al. [17], quienes presentaron un método que, junto con la regla ABCD, trataron de detectar tres patrones globales (reticulado, globular y azul homogéneo) para los que usaron tanto detección de bordes y matemáticas morfológicas, como análisis en el espacio de color RGB. El método fue probado con una base de datos de unas 20 imágenes por patrón, consiguiendo una precisión media de un 85%.

En [20] y [21], Tanaka et al. también presentaron una clasificación de un determinado patrón en tres categorías (reticulado, globular y homogéneo) mediante un análisis de texturas. La lesión fue dividida en pequeñas regiones y se calcularon 110 características de textura en cada una de ellas, y 35 fueron las seleccionadas para clasificar. Como resultado se obtuvo un 94% de aciertos.

Sadeghi et al. [18] detectaron y clasificaron cinco tipos de patrones globales (reticular, globular, empedrado, homogéneo y paralelo). Lo hicieron mediante técnicas de análisis de texturas basadas en aproximaciones estadísticas, y la clasificación de una imagen se hacía mapeando y comparándola con la distribución de los modelos aprendidos durante el proceso. El índice de clasificación correcta fue de 86.6% en este caso.

En [22] Saez et al. estudiaron la clasificación de patrones globales. En este estudio se suponía que la distribución de características seguía modelos distintos a lo largo de la lesión: Gaussiano, Gaussiano mixto y otro basado en el modelo bolsa de palabras. Como resultado obtuvieron que el modelo que mayor precisión

alcanzaba era el gaussiano mixto (78.44%).

En su estudio, Abbas et al. [19] extrajeron características tanto de color como de textura para clasificar una lesión en su patrón global correspondiente. Las características se introdujeron en un clasificador muticlass AdaBoost de manera que pudiesen asignar uno de los 7 tipos de patrones globales a la lesión en cuestión (reticulado, globular, empedrado, homogéneo, paralelo, estallido de estrellas y multicomponente). En la tabla 2-2 podemos ver los resultados obtenidos en este estudio.

Patrón	Sensibilidad (%)	Especificidad (%)
Reticulado	87.11	97.96
Globular	86.25	97.21
Empedrado	87.76	93.23
Homogéneo	90.47	95.10
Paralelo	85.25	89.50
Estallido de estrellas	89.62	90.14
Multicomponente	98.50	93.11

Tabla 2-2. Resultados de clasificación de [19]

Iyatomi et al. [23] se centraron únicamente en la detección melanomas acrales lentiginosos, localizados en palmas de manos y suealas de pies, para lo que desarrollaron tres detectores de patrones para las estructuras dermatoscópicas de cresta paralela, surco paralelo y patrón fibrilar. Extrajeron 428 características de cada imagen. Las características eran tanto de color, como de simetría y textura, además de otras relacionadas con el borde de la lesión. Luego, usando el Análisis por Componentes Principales (PCA), esas 428 características se convirtieron en 198 componentes principales (PCs) sin pérdida de información. De esos 198 PCs se seleccionaron los 10 más discriminantes, y se usaron cuatro clasificadores lineales para clasificar en 4 categorías distintas: melanoma, y 3 derivaciones del patrón paralelo. Los resultados obtenidos se muestran en la tabla 2-3.

Clase	Sensibilidad (%)	Especificidad (%)
Melanoma	100	95.9
Cresta paralela	93.1	97.7
Surco paralelo	90.4	85.9
Fibrilar	88	77.9

Tabla 2-3. Resultados de clasificación de [23]

En [24], Piazza et al. tras la evaluación de todos estos patrones en diferentes lesiones, concluyeron que los patrones más frecuentes eran el reticulado (39.0%), seguido del homogéneo (23.9%) y del globular (16.4%).

3 METODOLOGÍA

The development of artificially intelligent aids to tasks such as diagnosis taught us more about our intelligence than it did to replace it.

- Duane Steward-

En los apartados anteriores hemos hablado de la necesidad de disponer de métodos de diagnóstico eficientes que permitan detectar las lesiones malignas antes de que se extiendan, detallando los distintos algoritmos empleados en la actualidad por los dermatólogos.

También hemos visto la escasez de métodos disponibles a la hora de analizar y clasificar patrones globales.

En base a esto, se ha optado por desarrollar un Software de análisis de imagen que desempeñe las siguientes funciones: segmentar las lesiones, analizar su contenido en busca de características relevantes, seleccionar las características con mayor poder discriminatorio y clasificar las lesiones en tres posibles grupos (reticuladas, globulares y homogéneas) según el patrón global que tengan.

Se ha escogido Matlab como lenguaje de programación debido a la gran cantidad de funciones y utilidades que proporciona a la hora de procesar imágenes, además de tener las capacidades adecuadas para representar visualmente la información de las imágenes analizadas. Se ha utilizado la versión Matlab 2015a.

Iremos desglosando los pasos que sigue un sistema CAD, tal y como vimos en la figura 1-6, explicando cómo hemos afrontado cada uno de ellos.

3.1 Segmentación

En el campo del procesamiento de imágenes y la visión artificial, el concepto segmentación engloba el conjunto de técnicas y procesos que hacen posible dividir la imagen en los elementos que la forman. El nivel al que se realiza dicha subdivisión depende de la aplicación concreta, es decir, la segmentación terminará cuando se hayan localizado y separado todos los elementos de interés para el caso concreto. En nuestro caso, hay un único elemento de interés, la lesión, por lo que aplicaremos el algoritmo de segmentación para aislarla del resto de la imagen.

En la práctica, la segmentación se puede ver como un etiquetado, en el que a cada píxel se le asigna una etiqueta que indica a qué objeto pertenece. En nuestro caso un píxel tiene dos posibles etiquetas: lesión o piel sana.

Los algoritmos típicos de segmentación generalmente se dividen en dos tipos: basados en propiedades de discontinuidad y basados en propiedades de similitud. Dentro de la primera categoría se encuentran los algoritmos que intentan dividir la imagen basándose en los cambios bruscos en el nivel de gris, mientras que dentro de la segunda categoría los algoritmos están basados en técnicas que intentan agrupar píxeles con características similares, como la umbralización y el crecimiento de regiones.

De estos grupos, elegimos un algoritmo basado en similitud, puesto que, en muchas de nuestras imágenes, existen cambios bruscos de pigmentación dentro de la propia lesión, por lo que un algoritmo que divida en función de cambios en el nivel de gris no nos es de utilidad, como podemos ver en el ejemplo de la figura 3-1.




Figura 3-1. Ejemplo de segmentación de (a) imagen original con (b) máscara de sobel (c) crecimiento de regiones

Dentro del grupo de algoritmos basados en propiedades de similitud, hemos escogido una segmentación orientada a regiones, puesto que los métodos basados en píxeles como la umbralización, permiten de forma rápida etiquetar las zonas de la imagen, pero no garantizan que las regiones sean conexas, obligando generalmente a utilizar operaciones morfológicas. Sin embargo, la segmentación orientada a regiones no sólo tiene en cuenta el nivel de intensidad de un píxel concreto, sino también su información espacial.

Los métodos orientados a regiones tienen dos modos principales de trabajo: crecimiento de regiones y división y fusión de regiones, también conocida como árbol múltiple. Como en nuestro caso conocemos la posición de los objetos a segmentar, hemos escogido el método de crecimiento de regiones, puesto que la elección de las semillas, o puntos generadores, es más sencilla e intuitiva.

3.1.1 Crecimiento de Regiones

Este método es un algoritmo de segmentación semi-automático, lo que significa que el usuario debe dar una entrada que oriente de alguna manera el proceso.

Básicamente el método consiste en que, a partir de cada semilla, se crecen regiones añadiendo píxeles a dicha semilla entre aquellos vecinos que tengan propiedades similares.

Los parámetros a fijar en el crecimiento de regiones son:

- **Píxeles semilla:** son los píxeles a partir de los cuales crece la región. Hay varias maneras de establecerlos. En nuestro caso el programa nos muestra la imagen, y nos pide un recorte de la zona que queremos segmentar, es decir, de la lesión. A partir de ese recorte, la función obtiene los píxeles semilla.

Queremos resaltar que, puesto que, para obtener las semillas y para todo el proceso de crecimiento de regiones en sí, hay que trabajar con distancias, pasamos tanto la imagen original como el recorte, al espacio de color $L^*a^*b^*$, que se trata de un espacio de color uniforme. Esto quiere decir que las diferencias de color percibidas por el ojo humano son proporcionales a las distancias entre dichos colores.

Una vez tenemos hecho esto, el primer paso que hay que dar es definir el color de referencia, como el color medio de los píxeles que hay en el recorte. Puesto que estamos trabajando con imágenes a color, la referencia ($\bar{L}\bar{a}\bar{b}$) tendrá tres componentes, una por cada plano (\bar{L} , \bar{a} , \bar{b}):

$$\bar{L}\bar{a}\bar{b} = [\bar{L} \ \bar{a} \ \bar{b}] \quad (3-1)$$

$$\bar{X} = \frac{\sum X_{rec}}{N} \quad (3-2)$$

Donde la X representa L, a o b, y N es el número total de píxeles en el recorte.

Una vez que tenemos el color de referencia, el siguiente paso es calcular la imagen de distancias, D . Es una imagen en escala de grises en la que cada píxel representa la distancia Euclídea entre el color de referencia, $(\bar{L}\bar{a}\bar{b})$, y el color del píxel en la imagen original $(L\bar{a}\bar{b})$. El cálculo de esta distancia también tendrá que hacerse para cada uno de los tres planos de color.

Este cálculo, para un píxel dado $p(n,m)$, es como se muestra en la siguiente ecuación:

$$D(n, m) = \sqrt{(L(n, m) - \bar{L})^2 + (a(n, m) - \bar{a})^2 + (b(n, m) - \bar{b})^2} \quad (3-3)$$

Por último, ya podemos calcular las semillas como aquellos píxeles de la imagen de distancia cuyo valor sea menor que cierto umbral (T). Es decir, las semillas son aquellos píxeles cuya distancia al color de referencia (color medio del recorte) sea menor que el umbral, T . Este umbral se calculó mediante el procedimiento de ensayo error, y se lo pasamos a la función como parámetro de entrada.

Puesto que hay imágenes que tienen tonalidades similares a las de la lesión en zonas de no interés (como pelos o sombras), se ha optado por incluir la condición de que las semillas deben estar contenidas en el recorte hecho, de manera que no haya regiones apartadas de la lesión, como ocurre por ejemplo en la figura 3-2. En la figura 3-3 tenemos el resultado de la segmentación para esa misma imagen al introducir la condición.




Figura 3-2. Proceso de segmentación (a) imagen original (b) semillas (c) segmentación

En la figura 3-2 podemos ver cómo hay puntos blancos, que son las semillas, en zonas que no corresponden a lesión, por lo que la segmentación, como también se puede comprobar, es errónea.

- **Condición de inclusión:** Una vez tenemos las semillas, ya podemos hacer el crecimiento de regiones a partir de ellas. En nuestro caso, buscamos tener únicamente dos regiones: R_0 , cuyos píxeles están a 0, para el fondo y R_1 , cuyos píxeles están a 1, para la lesión. Pero inicialmente partimos de tantas regiones como semillas tengamos. Durante todo el proceso debe cumplirse que:
 - $\bigcup_i R_i = R$. Donde R_i es una región conectada, con $i = 1, 2, \dots, n$. R representa la imagen completa.
 - $R_i \cap R_j = \emptyset$. Las regiones deben ser disjuntas. Por eso mismo los distintos conjuntos son particiones de R .
 - $P(R_i) = CIERTO$; $P(R_i \cup R_j) = FALSO$. Todos los píxeles de una región deben cumplir cierta propiedad. En nuestro caso, P es que el color, Lab , de cada píxel, (x, y) de R_i , debe distar del color medio del recorte, \overline{Lab} , menos que un parámetro llamado tolerancia, τ . Las regiones adyacentes deben ser diferentes respecto de la propiedad $P(\cdot)$. Esto se conoce como regla de homogeneidad.

$$\tau = \alpha \cdot T \quad (3-4)$$

Donde α es un parámetro predefinido que pasamos a la función. La elección de α se hizo mediante el procedimiento de ensayo error.

Inicialmente, todos los píxeles menos las semillas pertenecen a R_0 . A partir de las semillas se van incorporando nuevos píxeles a las regiones utilizando un algoritmo que detecta, en cada etapa k y para cada región $R_i(k)$, los píxeles aún no clasificados (pertenecientes a R_0) adyacentes que pertenecen a dicha región. Los píxeles se incluyen en la región $R_i(k)$ deben cumplir:

- Estar espacialmente conectados a ella. Esto garantiza la conectividad de la región.
- El píxel, (x, y) , detectado de esa forma debe cumplir la regla de homogeneidad. Es decir, que la nueva región, $R_i(k) \cup p(n, m)$, cumpla que $P(R_i(k) \cup p(n, m)) = CIERTO$. En ese caso la región se amplía añadiendo dicho píxel.

En nuestro caso, al tener más de una semilla por región, hemos tenido que ampliar el algoritmo de crecimiento de regiones, desarrollando uno de **crecimiento y fusión**. Teniendo en cuenta que las regiones a unir son adyacentes y cumplen todas la misma propiedad $P(\cdot)$, hemos incorporado en el propio algoritmo la función de unir las regiones $R_i, \forall i \neq 0$. Para ello, lo único que hemos hecho es que, al crecer las regiones se miren los píxeles vecinos indistintamente de si están ya clasificados en otra región o no. Es decir, si mi región es R_j , miramos los píxeles adyacentes, $p(n, m) \in R_i, i \neq j$.

No es necesario añadir ninguna condición de parada. El propio algoritmo se detiene cuando no queda en el vecindario de la región ya crecida ningún píxel que cumpla la condición $P(\cdot)$. Como se puede deducir, los criterios de similitud son locales. Esto unido al haber solucionado el problema de semillas fuera de la región de interés, como se explicó anteriormente, da como resultado una segmentación más ajustada y fiel, sobre todo para aquellas imágenes donde, en la piel sana, hay zonas de tonalidades similares a las de la lesión. Podemos ver esto en la imagen 3-3.

El resultado del proceso de segmentación es una máscara binaria, donde a 1 tenemos los píxeles pertenecientes a la región, y a 0 los que son piel sana. Para una mejor interpretación visual, tanto en la figura 3-2 como en la figura 3-3 mostramos como imagen final de segmentación únicamente el borde detectado. Esto lo hemos conseguido restando a la máscara su versión erosionada, con lo que obtenemos el borde; ese borde lo negamos y superponemos plano a plano con la imagen original en RGB.




Figura 3-3. Proceso de segmentación (a) imagen original (b) semillas (c) segmentación

Podemos apreciar que el resultado no es totalmente perfecto, pero tengamos en cuenta que este es un caso bastante extremo, donde hay dificultades como la del vello corporal, y sí que es bastante ajustado y funcional para el procesado que viene a continuación.

3.2 Extracción de características

Una vez segmentada la lesión, es necesario extraer características de la misma respecto a las cuales se clasificará.

Para este paso la imagen segmentada, ya en escala de grises, es subdividida en pequeñas subimágenes cuadradas de 80x80. Puesto que, en muchos casos, la mayoría de la imagen está a 0 (es piel sana), hemos tenido que introducir pequeñas correcciones para evitar que se extrajesen características que no fuesen fiables al provenir de una subimagen donde la totalidad, o prácticamente la totalidad, del recorte fuese negro, como es el caso de la figura 3-4. Esto ahorra coste computacional y mejora la clasificación posterior.



Figura 3-4. Ejemplo de subimagen tamaño 80x80

En primer lugar, obtenemos el BoundingBox de la lesión y recortamos conforme a él la imagen segmentada, figura 3-5. El Bounfing Box es el rectángulo que delimita un objeto. De esta manera, nos ahorramos que se extraigan y procesen características del resto de la imagen, que en algunos casos puede llegar a ser hasta el

80% de la misma. Esto ahorra muchísimo coste computacional. También arregla un problema de cara a la clasificación, puesto que las características extraídas de esos recortes no serían representativas de la clase a la que pertenecen las lesiones correspondientes, pero esto lo veremos en el siguiente capítulo.




Figura 3-5. Imagen segmentada (a) original (b) recortada con Bounding Box

Con esto el problema se ve reducido, pero aún así vemos que siguen quedando muchas zonas negras. Esto se hace más patente cuanto más asimétrica sea la PSL en cuestión. No obstante, al no ser cuadrada la lesión, no nos podemos quedar con subimágenes que contengan única y exclusivamente zonas de lesión, puesto que perderíamos mucha información de estructuras que se encuentren muy cercanas al borde (característico de la red pigmentada y de los glóbulos), figura 3-6. Por tanto, habiendo reducido ya gran parte del costo computacional, hacemos recortes de la imagen completa de la figura 3-5 (b), procediendo sólo al cálculo de características si el número de píxeles pertenecientes a la lesión en el recorte es igual o superior a $5/6$ de los píxeles totales. Es decir, si el recorte tiene en total 6400 píxeles, únicamente se tendrán en cuenta aquellos recortes en los que el número de píxeles pertenecientes a la lesión sea igual o superior a 5333. En caso contrario, el recorte se desecha y no se tiene en cuenta para ningún tipo de cálculo ni clasificación. Este número se ha obtenido mediante el procedimiento de ensayo-error.




Figura 3-6. Pérdida de información en zonas cercanas al borde

También queremos destacar que los recortes se han llevado a cabo solapando los mismos. Por el procedimiento de ensayo-error se ha tomado un avance de un recorte a otro de 30 píxeles. Con esto conseguimos no saltarnos ni cortar ninguna estructura, analizando la mitad de un glóbulo o una red en un recorte y la otra mitad en otro, con lo que quedarían los resultados falseados.

Una vez hecho esto, pasamos a la extracción. En nuestro caso hemos extraído un total de 6 características. De ellas, 4 son derivadas de la matriz de co-ocurrencia, 1 de ellas está basada en la transformada de Fourier, y otra está basada en un procedimiento de detección de red pigmentada.

Todas ellas son características relacionadas con la textura, que es muy importante en la clasificación de regiones de interés de una imagen. Cuando los humanos observamos una imagen, estamos procesando básicamente dos tipos de información: el color y la textura, es decir, la relación que tienen entre sí los distintos niveles de gris de la imagen: si describen algún patrón, o si el aspecto es liso, granuloso, etc. Está relacionada, por tanto, con la distribución espacial de los niveles de gris.

A la hora de extraer características de textura se pueden emplear varios modelos: estadísticos, estructurales o espectrales. El algoritmo empleado para extraer las características de la matriz de co-ocurrencia sigue un modelo estadístico, mientras que el usado para extraer la basada en la Transformada de Fourier sigue uno espectral; y en el caso de la característica basada en la detección de red pigmentada, se emplea una combinación del estructural y el espectral.

3.2.1 Matriz de co-ocurrencia

En 1973, Haralick et al. [25] publicaron un trabajo que ha tenido un gran impacto en el campo del análisis de imagen, porque permite cuantificar características texturales presentes en una imagen. Al método lo llamaron *Gray Level Co-Occurrence Matrix*, (GLCM). La premisa es que el resultado de la clasificación de un píxel puede variar cuando se analiza aisladamente o cuando se consideran también a sus vecinos. Hoy en día se trata del método más común para analizar texturas.

La matriz de co-ocurrencia es una matriz de frecuencias con la que un nivel de gris, i , aparece en una relación espacial específica con otro nivel de gris, j , en una ventana pequeña. Es un modo de análisis de textura basado en estadísticos de 2º orden porque considera parejas de píxeles vecinos, separados una distancia, d , y formando un determinado ángulo entre ellos. Revela, por tanto, propiedades sobre la distribución espacial de los niveles de intensidad en la textura de la imagen.

El ejemplo de la figura 3-7 representa la formación de la GLCM para una imagen con 8 posibles niveles de intensidad, cuando la distancia empleada es 1 y el ángulo 0º. En nuestro caso, hemos empleado una distancia de 2 y un ángulo de 45º, obtenidos mediante el procedimiento de ensayo error. Queremos destacar que las entradas de la matriz de dicho ejemplo son el número de ocurrencias para cada pareja de valores, mientras que, en las ecuaciones 3-5, 3-6, 3-7 y 3-8, denotamos con $P_{i,j}$ la frecuencia de ocurrencia para cada pareja de valores, que se obtiene normalizando el número de ocurrencias.

Las características extraídas fueron:

- **Contraste:** devuelve una medida de la cantidad de variaciones locales en los niveles de gris de la imagen. Cuanto mayor es la variación de niveles de gris, mayor es el contraste.

$$Con = \sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2 \quad (3-5)$$

El rango de esta característica va de 0 al cuadrado del tamaño de la matriz, GLMC. Si el contraste es 0, los niveles de gris son constantes a lo largo de la imagen, por lo que una imagen homogénea tendrá un valor bajo, mientras que imágenes con grandes variaciones de intensidad en píxeles cercanos tendrán un contraste alto.

- **Correlación:** devuelve una medida de la dependencia lineal de los niveles de gris de una imagen.

$$Cor = \sum_{i,j=0}^{N-1} P_{i,j} \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i \sigma_j)}} \quad (3-6)$$

Donde μ_i y μ_j son la media de los niveles de gris en la ventana. A su vez, σ_i y σ_j representan la desviación típica de los niveles de gris en la ventana. Estos valores coinciden si la matriz es simétrica.

El rango de la correlación va de -1 a 1. Una imagen perfectamente correlada tendrá de valor 1 o -1, según la correlación sea positiva o negativa. Si la correlación es 0, no existe dependencia lineal entre los niveles de gris.

- **Energía** (*Angular Second Moment, ASM*): es otra medida de la variación de los niveles de gris en la imagen, pero ejecutada como la suma de los elementos cuadrados en la matriz, GLMC.

$$E = \sum_{i,j=0}^{N-1} P_{i,j}^2 \quad (3-7)$$

El rango de esta característica va de 0 a 1. A mayor ASM, mayor uniformidad. Para una imagen completamente uniforme, constante, la ASM es 1.

- **Homogeneidad** (*Inverse Difference Moment, IDM*): devuelve una medida del parecido de la matriz GLMC respecto de su versión diagonalizada.

$$H = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2} \quad (3-8)$$

El rango de esta característica va de 0 a 1. Para una imagen con una GLMC diagonal, la IDM es 1.




Figura 3-7. Ejemplo de matriz de co-ocurrencia (GLCM)

Recordamos que los valores de la matriz del ejemplo de la figura 3-7 son los $P_{i,j}$ sin normalizar.

3.2.2 Característica basada en la Transformada de Fourier

Para la extracción de la característica derivada de la transformada de Fourier, nos hemos basado en [26].

El algoritmo propuesto para la extracción de esta característica sigue un modelo espectral, que está basado en el análisis de la transformada de Fourier y es útil para la detección de la periodicidad espacial global de la textura. Lo podemos dividir en dos pasos:

- Calcular el espectro de Fourier de la subimagen, aplicando la Transformada Rápida de Fourier en 2-D (2-D FFT), que es un algoritmo que permite calcular computacionalmente y de manera eficiente la Transformada Discreta de Fourier en 2-D (2-D DFT). Se basa en la descomposición fila-columna. A continuación tenemos el par transformado de la DFT:

$$X(k_1, k_2) = \sum_{n_1=0}^{N_1-1} \sum_{n_2=0}^{N_2-1} x(n_1, n_2) e^{-j2\pi k_1 \frac{n_1}{N_1}} e^{-j2\pi k_2 \frac{n_2}{N_2}} \quad (3-9)$$

$$x(n_1, n_2) = \sum_{k_1=0}^{N_1-1} \sum_{k_2=0}^{N_2-1} X(k_1, k_2) e^{j2\pi n_1 \frac{k_1}{N_1}} e^{j2\pi n_2 \frac{k_2}{N_2}} \quad (3-10)$$

El resultado es una matriz de números complejos, a los que calculamos el módulo, $|X(k_i, k_j)|$, e introducimos en otra matriz, M . Para interpretarlos debemos tener en cuenta que, los cambios bruscos en los niveles de intensidad, correspondientes a altas frecuencias, están colocadas en los puntos más alejados del origen del espectro FFT, situado en el centro. Por otro lado, la intensidad media del recorte, correspondiente a frecuencia 0, se encuentra en el origen del espectro. Por tanto, cambios suaves en los niveles de gris, que se corresponden con las bajas frecuencias, se encuentran cerca del origen. Como ejemplo podemos ver la figura 3-8, en la que se muestra el espectro de dos subimágenes de distinto tipo. El correspondiente a un recorte de red pigmentada tiene más contenido espectral.




Figura 3-8. Ejemplos de los espectros de la FFT en dos sub-imágenes: (a) subimagen con red (b) su espectro (c) subimagen sin red (d) su espectro

- Para contabilizar de alguna forma este fenómeno, umbralizamos la matriz M , para tener en cuenta únicamente aquellos puntos que sean mayores que cierto umbral. A estos puntos se les calcula las varianzas a lo largo de los ejes, s_x^2 y s_y^2 . Finalmente se calcula un valor global (S), que será la característica extraída del espectro:

$$S = \sqrt{s_x^2 + s_y^2} \quad (11)$$

3.2.3 Característica basada en detección de red

Para el cálculo de esta característica nos hemos basado en el trabajo de detección de red pigmentada llevada a cabo por Betta et al. [27]. El resultado obtenido es una nube de puntos distribuidos en las discontinuidades que una lesión presente, por lo que la densidad de puntos será mayor para lesiones con muchas discontinuidades (red pigmentada) y nula para lesiones sin discontinuidades bruscas (homogéneas). En el punto medio de una y otra se encuentran las lesiones con patrón globular.

El objetivo es detectar y cuantificar las estructuras presentes en la imagen. Para lograrlo, usamos una combinación de dos técnicas. Como podemos ver en el diagrama de la figura 3-9, el algoritmo se divide en dos ramas, una sigue un método estructural y la otra uno espectral. La entrada común para ambos caminos es una subimagen en escala de grises de tamaño 80x80.

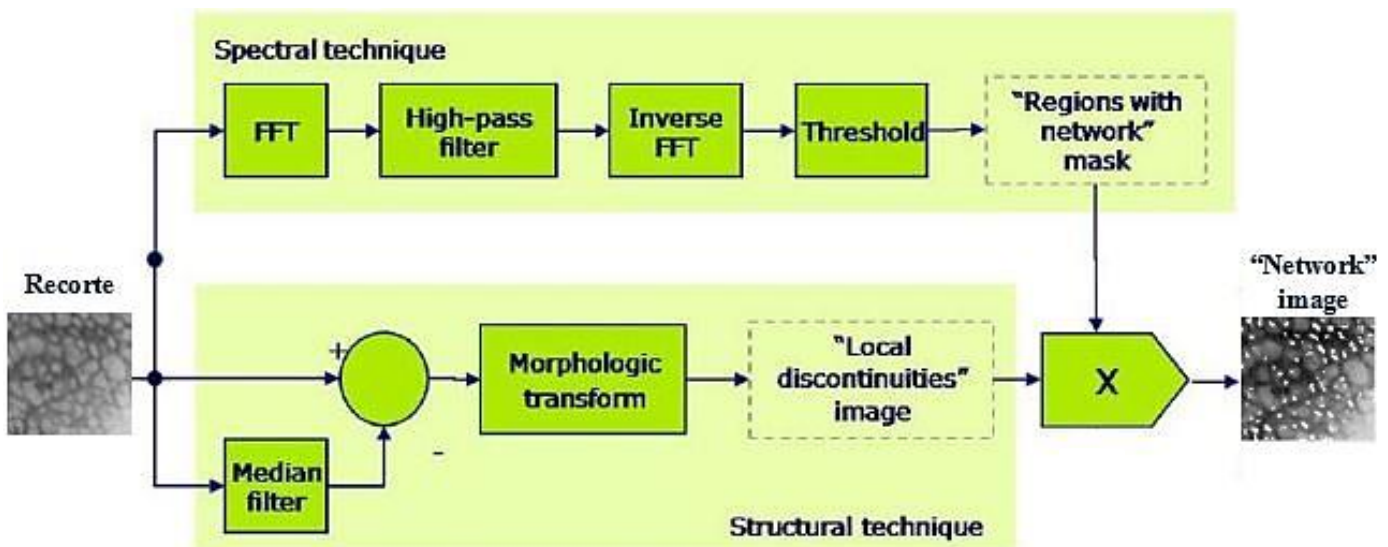


Figura 3-9. Diagrama de extracción de densidad

- **Método espectral:** está basado en el análisis de Fourier de la imagen. Nos sirve, como ya hemos mencionado antes, para determinar el periodo espacial de la textura, permitiendo la identificación únicamente de regiones donde existan discontinuidades.

Lo que se hace es calcular el módulo de la FFT a la imagen, paso que ya hemos explicado anteriormente. Esto nos facilita el filtrado, que se convierte en una simple multiplicación. La FFT sirve como entrada a un filtro paso de alta, eliminando las zonas homogéneas del recorte, colocadas en el centro del espectro, resaltando así las discontinuidades. Para ello hemos usado un filtro ideal. Las frecuencias de corte de dicho filtro se han obtenido buscando un decrecimiento brusco en el espectro.

Tras esto, se deshace la FFT aplicando la transformada inversa, y umbralizamos la imagen. El umbral empleado fue obtenido mediante el procedimiento ensayo-error.

La imagen obtenida tras este paso es una máscara de las regiones con patrón.

- **Metodo estructural:** Este método permite detectar las discontinuidades comparando la imagen monocromática con su versión tras pasar por un filtro de mediana. El filtro de mediana es un filtro de suavizado, por tanto, lo que obtenemos en este paso son los bordes, las altas frecuencias de la imagen (líneas, puntos, etc). Si la imagen es constante, el resultado será una imagen negra.

A la imagen resultante, le aplicamos matemáticas morfológicas. La operación elegida fue un Top-hat, que se suele emplear para resaltar detalles en zonas de poco contraste, como es nuestro caso, puesto que recordemos que aplicamos esta operación al resultado de restar una imagen con su versión suavizada.

El Top-hat, T_w , no es más que la diferencia de la imagen original con ella misma tras hacerle un *opening*. Dada una imagen, f , y un elemento estructura, b :

$$T_w(f) = f - f \circ b \quad (3-12)$$

Donde $f \circ b$ denota la operación del *opening*.

El elemento estructura que usaremos (elemento que define el tamaño y la forma de la vecindad en la que se aplica la operación) es una línea, puesto que el fin es detectar la red pigmentada. En cuanto al ángulo empleado, iremos barriendo cada 10° , aplicando el Top-Hat a la imagen resultante de la iteración anterior. Podemos ver este proceso en la figura 3-10. Para una correcta visualización hemos escalado los valores de la imagen de entrada a $[0 \ 255]$, puesto que eran muy bajos.

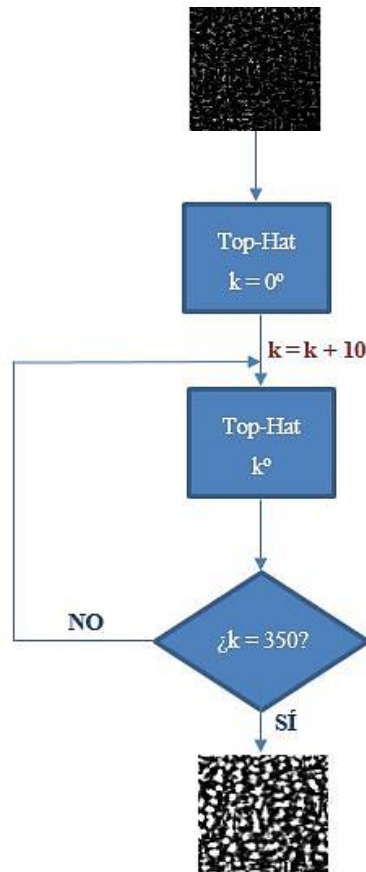


Figura 3-10. Diagrama de flujo del algoritmo implementado para el Top-hat

Una vez tenemos la imagen con discontinuidades locales y la máscara de regiones con patrón, sólo hay que multiplicarlas, para obtener las discontinuidades únicamente en las zonas que tengan algún patrón, obteniendo la imagen de discontinuidades. En la figura 3-11 podemos ver un ejemplo de esta imagen para cada tipo de patrón. Para mejorar la visualización, hemos superpuesto esta imagen con la original.




Figura 3-11. Imagen de discontinuidades en (a) patrón reticulado (b) patrón globular (c) patrón homogéneo

Con esta imagen es fácil ver que hay una clara distinción entre patrones según la densidad de puntos que en ella hay. Por ello extraemos la densidad y la usamos como característica.

$$d = \frac{n}{N} \quad (13)$$

Donde n es el número de puntos distintos de 0 en la imagen de discontinuidades, y N es el número total de puntos, es decir 6400.

3.3 Selección de características

Es importante entender que un mayor número de características no garantiza una mejor clasificación. De hecho, en la mayoría de casos, la empeora. La selección de características es una estrategia que busca seleccionar el sub-conjunto de características óptimo de cara a la clasificación. La premisa central es que el vector de características contiene atributos redundantes, irrelevantes e incluso aleatorios y que, aunque cada característica por separado tenga poder discriminatorio, al introducirse en el conjunto pueden empeorar el resultado final. El propósito de los sistemas de selección de características es:

- Mejorar la clasificación eliminando atributos dañinos.
- Reducir coste computacional eliminando atributos irrelevantes o redundantes.
- Facilitar la interpretación simplificando el modelo.

Las características han de facilitar la clasificación, no empeorarla, y para ello deben tener lo que se conoce como homogeneidad intraclase, que significa que deben estar ligadas a las clases; pero también han de tener capacidad discriminante (dispersión intraclase).

El problema es el siguiente: dado un conjunto de características, $F = \{f_i | i = 1 \dots N\}$, de N elementos, escoger un subconjunto $Y_M \in F$ de tamaño $M \leq N$, que optimice una cierta función criterio $J(Y)$

$$Y_M = \{f_{i_1}, f_{i_2}, \dots, f_{i_M}\} = \arg \max_{M, i_M} J\{f_i | i = 1 \dots N\} \quad (3-14)$$

El procedimiento básico es realizar una búsqueda exhaustiva del mejor subconjunto de $M \leq N$ características en base a una función criterio, examinando todos los posibles conjuntos de M características, lo que significa $\binom{N}{M}$ combinaciones para un valor M fijado. Si se quiere optimizar también M tendremos $2^N - 1$ combinaciones distintas. En general la función criterio trata de medir la capacidad discriminativa del subconjunto de características seleccionado, y es lo realmente influyente en el resultado, por lo que su elección es crucial.

El algoritmo que hemos empleado para seleccionar el subconjunto óptimo dentro de nuestro conjunto de características ha sido el conocido como *Sequential Forward Search*, SFS. Elige el subconjunto de características de la matriz F que mejor predice los datos añadiendo secuencialmente características hasta que no se produzca mejora en la predicción.

Funciona tal y como vemos en la figura 3-12. Su estrategia de búsqueda es partir de un conjunto de atributos vacío, y, evaluando cada característica con la función criterio, en cada iteración añade al subconjunto la que proporciona al mismo la mayor capacidad discriminante.

La función criterio que hemos empleado es un clasificador, es decir, devuelve la tasa de error obtenida al clasificar los datos con el subconjunto de características proporcionado. Para ello empleamos el mismo clasificador que utilizaremos posteriormente para clasificar nuestras imágenes. Este tipo de funciones nos elimina aquellas características que son perjudiciales o irrelevantes en el conjunto.

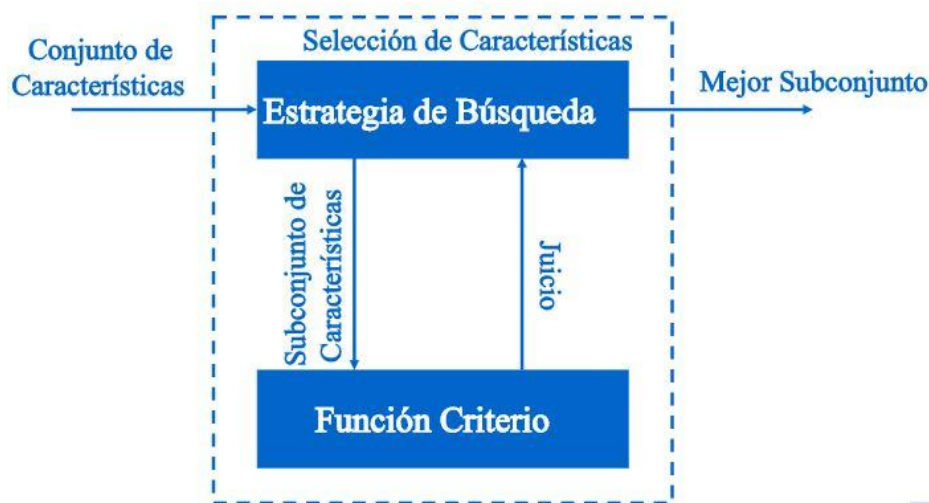


Figura 3-12. Esquema de método de selección de características

3.4 Clasificación

El reconocimiento de patrones es una de las tareas principales consideradas dentro del *machine learning* y está directamente relacionado con asignar etiquetas de pertenencia a una clase de observaciones de algún fenómeno, basándose en el análisis de un conjunto de datos previamente dado.

Teniendo ya el subconjunto óptimo de características, el siguiente, y último paso que damos en nuestro sistema es el de clasificar las lesiones. Para la clasificación hemos empleado un algoritmo de *machine learning* conocido como Máquinas de vectores de soporte (*Support Vector Machine*, SVM). Es un método de clasificación supervisada, cuyo objetivo fundamental es aprender a clasificar a partir de un conjunto de muestras de entrenamiento, cuyas clases conocemos *a priori*. Para ello, la máquina de aprendizaje busca la existencia de algún tipo de dependencia entre los datos de entrada y la salida. Para nosotros, la entrada son los vectores de características de n imágenes, $\{x_i | i = 1 \dots n\} \in X \in R^M$, y la salida la clase a la que pertenecen dichas imagen, $\{y_i | i = 1 \dots n\} \in Y \in R$.

En su formulación básica, SVM corresponde a un clasificador binario lineal. Es decir, que permitiría distinguir únicamente entre dos clases usando como frontera de clasificación una línea recta si estamos en R^2 , o un hiperplano en R^n . Sin embargo, nuestro problema de clasificación es multiclase, por lo que habrá que extender el algoritmo para solucionarlo, tratando el problema como concatenación de varias clasificaciones binarias, en las que $y_i \in \{-1, +1\}$.

El proceso se puede dividir en dos etapas:

- **Aprendizaje** de la máquina a partir de un conjunto de entrenamiento, $Z = \{(x_1, y_1), \dots, (x_n, y_n)\}$. Es posible definir un hiperplano de separación como una función lineal capaz de separar dicho conjunto sin error:

$$D(x) = (w_1 x_1 + \dots + w_M x_M) + b = \langle w, x \rangle + b \quad (3-15)$$

Donde w y b son coeficientes reales.

El hiperplano, además, debe cumplir las siguientes restricciones para todo x_i del conjunto:

$$\begin{cases} \langle w, x_i \rangle + b \geq 0 & \text{si } y_i = +1 \\ \langle w, x_i \rangle + b \leq 0 & \text{si } y_i = -1 \end{cases} \quad (16)$$

También expresado como:

$$y_i D(x_i) \geq 0 \quad i = 1, \dots, n \quad (17)$$

Sin embargo, existen infinitos hiperplanos separables, siempre que cumplan las restricciones anteriores. Por ello, se establece un criterio adicional que permita definir un hiperplano de separación óptimo. Para ello, definimos margen del hiperplano, τ , como la mínima distancia entre dicho hiperplano y el elemento más cercano de cualquier clase. Entonces podremos decir que un hiperplano de separación será óptimo cuando su margen sea máximo. A los elementos que definen el margen se les conoce como *vectores soporte*. Tenemos un ejemplo de esto en la figura 3-13, donde en la imagen (b), podemos ver que los elementos representados con relleno, son los vectores soporte.




Figura 3-13. Margen de un hiperplano de separación: (a) hiperplano no óptimo (b) hiperplano óptimo y vectores soporte

Una propiedad inmediata de la definición de hiperplano óptimo, es que éste es equidistante al elemento más cercano de cada clase.

La distancia de un hiperplano $D(x)$ y un elemento x' , viene dada por:

$$d = \frac{|D(x')|}{\|w\|} \quad (3-18)$$

Haciendo uso de las expresiones (3-17) y (3-18), todos los vectores de entrenamiento cumplirán:

$$\frac{y_i D(x_i)}{\|w\|} \geq \tau \quad (3-19)$$

Por lo que, el problema de encontrar el hiperplano óptimo equivale a encontrar el valor, w , que maximiza el margen. Para limitar el número de soluciones a una sola, se fija que:

$$\tau = \frac{1}{\|w\|} \quad (3-20)$$

Con la consiguiente conclusión de que, aumentar el margen, es equivalente a disminuir la norma de w . La distancia al hiperplano de los vectores soporte siempre es de $\frac{1}{\|w\|}$, y siempre cumplen que $|D(x)| = 1$.

Desde un punto de vista práctico, el hiperplano separador de margen máximo ha demostrado tener una buena capacidad de generalización, evitando en gran medida el problema del sobreajuste, que consiste en sobreentrenar el algoritmo.

- **Clasificación** de muestras cuyas clases desconocemos. La entrada al sistema será una muestra, $x_i \in R^M$, y el sistema proporcionará como salida la clase, $y_i \in R$, a la que pertenecen dichos datos.

Una vez obtenido esto, no olvidemos que estamos extrayendo características y clasificando subimágenes de la imagen original, que es la que nos interesa clasificar según sus patrones globales.

Recordemos que nosotros hacemos todo este proceso para cada subimagen, por lo que, para conseguir clasificar la imagen completa a partir de a clasificación parcial de la misma, y atendiendo a la definición de patrón global hecha en capítulos anteriores, almacenamos los resultados de la clasificación de cada subimagen e imponemos la condición de que se clasifique la imagen en aquella clase a la que más subimágenes pertenezcan.

4 VALIDACION

En este capítulo mostraremos los resultados obtenidos en nuestro estudio. La evaluación de los mismos resulta fundamental en el desarrollo de un sistema de clasificación automática. Para ello usamos un total de 160 imágenes: 70 correspondientes al patrón reticulado, 50 al globular y 40 al homogéneo.

Las imágenes proceden de la base de datos Interactive Atlas of Dermoscopy de Argenziano et al. [8]. Son imágenes en formato “jpg” de dimensiones 768x512 píxeles, con una resolución vertical y horizontal de 72 puntos por pulgada. Este Atlas es usado tanto por expertos como por estudiantes del campo de la dermatoscopia en todo el mundo, donde las opiniones de todos ellos respecto a esta base de datos son siempre positivas.

Tenemos, por tanto, 160 imágenes clasificadas en el Atlas, y tenemos la clasificación de esas mismas imágenes proporcionada por el programa que hemos propuesto. Para una clase dada, la clasificación de una imagen es:

- **Positiva:** Si la imagen es clasificada en dicha clase.
- **Negativa:** Si la imagen NO es clasificada en dicha clase.

Antes de continuar, explicaremos algunos términos que vamos a utilizar:

- **Verdaderos Positivos** (*True Positive*, TP): Se consideran TP aquellas imágenes que, para una clase dada, nuestro método clasificó como positivas, y la clasificación del Atlas era positiva también.
- **Verdaderos Negativos** (*True Negative*, TN): Se consideran TN aquellas imágenes que, para una clase dada, nuestro método clasificó como negativas, y la clasificación del Atlas era negativa también.
- **Falsos Positivos** (*False Positive*, FP): Se consideran FP aquellas imágenes que, para una clase dada, nuestro método clasificó como positivas, y la clasificación del Atlas era negativa.
- **Falsos Negativos** (*False Negative*, FN): Se consideran FN aquellas imágenes que, para una clase dada, nuestro método clasificó como negativas, y la clasificación del Atlas era positiva.

Es evidente que un buen clasificador deberá presentar altas tasas de TP y TN frente a FN y FP.

Se conoce como *Ground Truth* a la información objetiva acerca de los elementos, es decir, a la clasificación real de las imágenes. En nuestro Caso el *Ground Truth* es la clasificación del Atlas.

La tabla 4-1 ilustra estos conceptos para la clasificación en una clase concreta, la reticulada.

		Clasificación del programa		
		Reticulado	Globular	Homogéneo
Ground Truth	Reticulado	TP	FN	FN
	Globular	FP	TN	TN
	Homogéneo	FP	TN	TN

Tabla 4-1. Tabla para evaluar el diagnóstico para la clase Reticulada.

Generalmente, en lugar de estos datos, se calculan ciertos parámetros relacionados con el funcionamiento del programa, que son los siguientes:

- **Sensibilidad:** Porcentaje de imágenes pertenecientes a una clase que se clasificaron correctamente. También se puede ver como la probabilidad de que, para una clase concreta, el programa identifique correctamente una lesión como perteneciente a dicha clase.

$$S = \frac{TP}{TP + FN} \quad (4-1)$$

- **Especificidad:** Porcentaje de imágenes NO pertenecientes a una clase que se clasificaron como NO pertenecientes a dicha clase. También se puede ver como probabilidad de que, para una clase concreta, el programa identifique correctamente a las lesiones que no pertenecen a dicha clase.

$$Spec = \frac{TN}{TN + FP} \quad (4-2)$$

- **Valor Predictivo Positivo** (*Positive Predictive Value*, PPV): Probabilidad de que una lesión pertenezca a una clase, si el programa la ha clasificado como perteneciente a la misma:

$$PPV = \frac{TP}{TP + FP} \quad (4-3)$$

- **Valor Predictivo Negativo** (*Negative Predictive Value*, NPV): Probabilidad de que una lesión NO pertenezca a una clase, si el programa NO la ha clasificado como perteneciente a la misma:

$$NPV = \frac{TN}{TN + FN} \quad (4-4)$$

- **Precisión:** La precisión de un clasificador es el porcentaje global de acierto del mismo. Evidentemente la precisión será del 100% cuando no existan ni FP ni FN.

$$P = \frac{TN + TP}{TN + TP + FN + FP} \quad (4-5)$$

Todos estos resultados hay que darlos para cada clase.

Para la validación de nuestro programa hemos tomado 10 muestras de cada clase para conformar un *training set* (datos de entrenamiento) de 30 imágenes. Nuestro *training set* debe estar compuesto por imágenes del mismo tamaño que las que se clasificarán posteriormente, y, como ya mencionamos en el apartado anterior, nuestro sistema clasifica una lesión a partir de la clasificación parcial de cada subimagen, por lo que las imágenes de entrenamiento serán recortes de 80x80 representativos de cada clase.

Puesto que una lesión puede llegar a tener hasta 1000 subimágenes, y éstas no tienen por qué coincidir con los recortes tomados para el *training set*, no hay problema de corrupción de resultados por clasificar imágenes con las que se entrena, por lo que se simplifica mucho tanto la clasificación como la validación puesto que no es necesario emplear algoritmos de validación cruzada, en los que se hacen grupos de imágenes tratando de que no coincidan las imágenes de entrenamiento con las de clasificación, y rotando dichos grupos para el análisis de los datos completos. Al no ser necesarios estos métodos de validación cruzada, ahorramos coste computacional.

En cuanto a la clasificación, lo primero que queremos destacar es que el algoritmo SFS nos seleccionó un total de dos características como subconjunto óptimo para la clasificación. En la tabla 4-3 tenemos un resumen del proceso llevado a cabo por este algoritmo para llegar finalmente a esa conclusión. En ella recorremos las distintas iteraciones llevadas a cabo por el algoritmo SFS en las que, como explicamos en el apartado 3.3, el algoritmo añade al subconjunto la característica que menor índice de error proporciona al conjunto.

Para facilitar la lectura, en la tabla 4-2 asignamos un número a cada característica. Ese número lo usaremos en la tabla 4-3 para referirnos a las características correspondientes.

Característica	Número asignado
Densidad	1
Contraste	2
Correlación	3
Energía	4
Homogeneidad	5
S	6

Tabla 4-2. Asignación de características.

Característica nueva	Subconjunto	Error de clasificación
1	1	0.299
4	1,4	0.195
3	1,4,3	0.289
5	1,4,3,5	0.289
6	1,4,3,5,6	0.300
2	1,4,3,5,6,2	0.667

Tabla 4-3. Procedimiento del algoritmo SFS con su error de clasificación.

Como podemos ver en la tabla 4-3, el subconjunto con mayor capacidad discriminante es el formado por las características 1 y 4. A continuación, pasaremos a exponer detalladamente los resultados de clasificación obtenidos para cada clase con este subconjunto.

En cada apartado expondremos resultados de clasificación, así como una tabla con los TP, TN, FP, FN. También expondremos algunos ejemplos de Falsos Negativos, para tratar de analizar por qué falló el algoritmo.

4.1 Patrón Globular

En este apartado estudiaremos la clasificación de las imágenes catalogadas como globulares en el *Ground Truth*. Una a una van pasando por el programa, dando lugar a una clasificación u otra. Los resultados obtenidos se muestran en la tabla 4-4:

PATRÓN GLOBULARES		
Reticuladas	Globulares	Homogéneas
6	38	6

Tabla 4-4. Resultados de la clasificación de las imágenes con patrón globular según el *Ground Truth*.

En la tabla 4-5 podemos ver un resumen de la clasificación de este patrón, en la que mostramos TP, TN, FP y FN.

DATOS PARA EL PATRÓN GLOBULAR			
TP	TN	FP	FN
38	96	14	12

Tabla 4-5. Datos de TP, TN, FP y FN para el patrón globular.

A continuación, expondremos algunos casos de imágenes clasificadas erróneamente, y analizaremos brevemente cada caso:




Figura 4-1. Imagen con patrón globular clasificada erróneamente (a) original y (b) segmentación de la misma.

En la figura 4-1, podemos ver que los glóbulos se encuentran muy próximos, provocando una textura muy similar a la del patrón reticulado, que ha sido la clase asignada por el programa a esta imagen finalmente.

Lo primero a comprobar cuando se clasifica mal una imagen es la segmentación, puesto que es posible que no estemos analizando la lesión completa, subanálisis, o, por el contrario, estemos analizando zonas de piel sana, sobrealálisis. En este caso, la segmentación es correcta.

Algo a destacar es el tamaño de la lesión, muy reducido como podemos comprobar, lo que hace que el número de bloques o subimágenes que se extraen y procesan de la misma sea bajo, 11. Esto quiere decir, que los bloques en los que aparece el borde de la lesión, donde las medidas están algo distorsionadas, en relación con los bloques donde aparece únicamente lesión, es elevado, lo que distorsiona la clasificación, ya que no hay a

penas subimágenes de lesión pura que compensen las subimágenes parciales, en las que no sólo hay lesión. Otro ejemplo de esto lo podemos ver en la figura 4-2.




Figura 4-2. Imagen con patrón globular clasificada erróneamente (a) original y (b) segmentación de la misma.




Figura 4-3. Imagen con patrón globular clasificada erróneamente (a) original y (b) segmentación de la misma.

El caso de la lesión de la figura 4-3 es bien distinto. En primer lugar, cabe destacar que nos encontramos en un caso de sobresegmentación. Si nos fijamos, veremos que la pigmentación del borde de la lesión y la de la piel sana es muy parecida. Puesto que para que el programa sea lo más automatizado posible, los parámetros que establecemos son generalizados y válidos para el mayor número de imágenes posible. No obstante, las zonas analizadas pertenecientes a piel sana son muy pocas en comparación a las pertenecientes a la lesión.

Lo siguiente que llama la atención son unas zonas de brillo, que el ojo humano es capaz de interpretar correctamente, pero para un programa, que trata todos los píxeles de información como niveles de gris distintos, es complicado de enseñar. Estas zonas, posiblemente procedentes del aceite de inmersión necesario para obtener la imagen dermatoscópica, comprometen la clasificación, puesto que se puede entender como cambios en el nivel de gris muy bruscos y próximos, que no corresponden al patrón globular al que pertenece la lesión.

Otra cosa a destacar es que los glóbulos son bastante grandes, por lo que difícilmente entrarán completos en una subimagen 80x80, lo que hace casi imposible que se reconozca el patrón globular.

4.2 Patrón Reticulado

Como mencionamos anteriormente, disponemos de 70 imágenes catalogadas como lesiones con patrón reticulado. Estas imágenes, como en el caso anterior, son leídas y clasificadas por el programa, obteniendo los resultados de la tabla 4-6.

PATRÓN RETICULADO		
Reticuladas	Globulares	Homogéneas
58	10	2

Tabla 4-6. Resultados de la clasificación de las imágenes con patrón reticulado según el *Ground Truth*.

En la tabla 4-7 podemos ver un resumen de la clasificación de este patrón, en la que mostramos TP, TN, FP y FN.

DATOS PARA EL PATRÓN RETICULADO			
TP	TN	FP	FN
58	82	8	12

Tabla 4-7. Datos de TP, TN, FP y FN para el patrón reticulado.

Mostramos a continuación algunos ejemplos de imágenes clasificadas erróneamente:




Figura 4-4. Imagen con patrón reticulado clasificada erróneamente (a) original y (b) segmentación de la misma.

En el caso de la figura 4-4, podemos ver que la imagen en sí, y particularmente el retículo de la misma, está un poco difuso, por lo que podría no analizarse correctamente. Podríamos arreglar este problema preprocesando la imagen para darle más nitidez, pero puesto que nuestro objetivo es conseguir un programa general y automático, que no dependa de cada caso concreto, sino que se ajuste lo mejor posible a las necesidades generales, desechamos esa opción. Podemos encontrar un caso similar en la figura 4-5.

Además, llama la atención que aparecen glóbulos en la parte inferior de la lesión, lo que puede inducir a error a nuestro programa.




Figura 4-5. Imagen con patrón reticulado clasificada erróneamente (a) original y (b) segmentación de la misma.

En la figura 4-5 podemos ver también una red poco definida. Como dijimos anteriormente un filtrado paso alto es una posible solución, pero ésta se desecha para ganar en autonomía del algoritmo.




Figura 4-6. Imagen con patrón reticulado clasificada erróneamente (a) original y (b) segmentación de la misma.

En el caso de la figura 4-6, podemos ver que hay algo de sobresegmentación, lo cual es bastante entendible si nos fijamos en que la lesión tiene estructuras de regresión. Aún así, la sobresegmentación es mínima, y no debería comprometer el resultado final.

Lo que sí puede comprometer el resultado son las zonas de regresión que hay presentes en la imagen, puesto que se tratan de zonas homogéneas, o en algún caso, como en las que envuelven a los vellos, con forma redondeada, recordando a un glóbulo.

Como vemos, la parte del retículo queda bastante estrecha en la mayoría de la imagen, recorriendo el borde, lo que podría hacer que en los recortes no hubiese zonas prominentes de red, lo que conllevaría una mala clasificación.

4.3 Patrón Homogéneo

En este apartado estudiaremos la clasificación de las imágenes catalogadas como homogéneas en el *Ground Truth*. Disponemos de 40 imágenes que son leídas y clasificadas por el programa, obteniendo los resultados de la tabla 4-8.

PATRÓN HOMOGÉNEO		
Reticuladas	Globulares	Homogéneas
2	5	33

Tabla 4-8. Resultados de la clasificación de las imágenes con patrón homogéneo según el *Ground Truth*.

En la tabla 4-9 podemos ver un resumen de la clasificación de este patrón, en la que mostramos TP, TN, FP y FN.

DATOS PARA EL PATRÓN HOMOGÉNEO			
TP	TN	FP	FN
33	111	9	7

Tabla 4-9. Datos de TP, TN, FP y FN para el patrón homogéneo.

Queremos ilustrar algunas de los FN obtenidos:




Figura 4-7. Imagen con patrón homogéneo clasificada erróneamente (a) original y (b) segmentación de la misma.

El caso más curioso nos lo encontramos en la figura 4-7. Podemos ver cambios de pigmentación en esta imagen, lo cual compromete bastante la clasificación de la misma, puesto que no se trata de una pigmentación homogénea y firme, como podríamos pensar, por toda la lesión.

Además, podemos observar ciertas estructuras circulares de color más claro distribuidas a lo largo de la zona con pigmentación oscura, lo cual también compromete la clasificación, puesto que nosotros analizamos texturas basándonos en los cambios en los niveles de gris, que es la información de la que disponemos.

También cabe destacar el tamaño de la misma, teniendo únicamente 12 subimágenes, por lo que la mayoría, por no decir la totalidad, corresponden a subimágenes donde se ve el borde y/o los cambios de pigmentación que hay en la lesión.




Figura 4-8. Imagen con patrón homogéneo clasificada erróneamente (a) original y (b) segmentación de la misma.

En la figura 4-8, podemos ver una sobresegmentación que sí podría comprometer la clasificación. Está producida por una línea fina pegada a la lesión, de pigmentación prácticamente idéntica a algunas zonas de la misma, por lo que es inevitable que haya una pequeña fuga. Puesto que únicamente tenemos en cuenta bloques que contengan más de 83% de píxeles pertenecientes a la lesión (no negros), esto no debe afectar demasiado.

Observando detenidamente la lesión, podemos encontrar glóbulos y pequeñas estructuras vasculares en la misma, así como cambios de pigmentación, aunque bastante leves. Esto hace que el programa no interprete la textura como homogénea, con el consiguiente fallo de clasificación.




Figura 4-9. Imagen con patrón homogéneo clasificada erróneamente (a) original y (b) segmentación de la misma.

El caso de la figura 4-9. es otro caso de cambios de pigmentación en la lesión, por lo que el programa podría detectarlo como una discontinuidad, y, por tanto, no homogéneo.

Además, hay estructuras propias de la piel que distorsionan nuestra medida, como pequeños puntos de tonos más claros. Sería posible arreglarlo haciendo un suavizado, pero una vez más, optamos por no hacerlo para ganar en autonomía del programa.

Una vez analizados los casos más significativos que presentan problemas a nuestro clasificador, procedemos a mostrar los resultados de los índices antes explicados: Sensibilidad, Especificidad, PPV, NPV y precisión. Ambos deben darse para cada clase. Presentaremos también la media aritmética de todos estos valores, como un resultado global para el clasificador. Esto se muestra en la tabla 4-10. Para su cálculo nos hemos apoyado en los datos presentados en las tablas 4-5, 4-7 y 4-9.

	RETICULADO	GLOBULAR	HOMOGENEO	TOTAL
Sensibilidad (%)	82.86	76	82.5	80.45
Especificidad (%)	91.11	87.27	92.5	90.29
PPV (%)	87.9	73.1	78.57	79.86
NPV (%)	87.23	88.9	94.1	90.08
Precisión (%)	87.5	83.75	90	87.08

Tabla 4-10. Sensibilidad, Especificidad, PPV, NPV y precisión para cada clase, y total expresado porcentualmente.

De los datos anteriores podría deducirse que nuestro algoritmo funciona mejor cuando se le presentan patrones homogéneos y reticulados.

Si nos paramos a pensar, en el caso del patrón homogéneo puede deberse a que estas imágenes no presentan grandes cambios en la intensidad, que es básicamente lo que buscamos, lo que las hace “fácilmente” identificables, a excepción de los casos expuestos en este capítulo (figuras 4-7, 4-8 y 4-9). Esto se puede deducir mirando la tabla 4-9, donde vemos el reducido número de FP (9 de 120 posibles) y FN (7 de 40 posibles, cuyos casos más significativos ya se explicaron), o visto de otra manera, podemos fijarnos en el elevado número de TN que presenta (111 de 120 posibles). Estos datos, a nivel práctico, se traducen en la tabla 4-10, donde vemos que este patrón presenta gran especificidad, que a su vez guarda gran relación con el NPV. Es decir, presenta altas tasas de que una lesión no sea homogénea si el programa no la ha clasificado como tal. También presenta una precisión relativamente alta, lo que indica un buen índice de aciertos, y una sensibilidad y PPV aceptables, lo que supone que las probabilidades de que se clasifique correctamente el patrón homogéneo también lo son.

El patrón reticulado, sin embargo, es el caso opuesto, los cambios de intensidad son tantos y tan bruscos que no hay prácticamente opción a confusión. Esto se puede ver en la tabla 4-7, que como hemos visto anteriormente, se resume en la tabla 4-10, donde podemos ver una elevada especificidad, lo que significa que el programa funciona muy bien no detectando patrón donde no hay. También tiene buenos índices de PPV, NPV y precisión, es decir, que la tasa de aciertos es buena, funciona muy bien para detectar el patrón reticulado en lesiones que lo tienen. La sensibilidad es aceptable, y como podemos comprobar, mejora la del dermatólogo sin ayuda de estas técnicas [4]. Cabe destacar que ningún marcador baja del 80%.

De todo esto se deduce que el patrón globular queda a medio camino entre el reticulado y el homogéneo, de ahí que sea el que menores porcentajes ha mostrado. Se trata de un patrón con cambios de intensidad, pero más suaves que en el reticulado, llegando a parecerse bastante al homogéneo si los cambios son lo suficientemente difusos o los glóbulos lo suficientemente grandes. Puede confundirse con cualquiera de los patrones, como podemos ver en la tabla 4-3, es el que mayor FP presenta (14 sobre 110), o en las tablas 4-4 y 4-6, donde vemos que es el patrón al que más han derivado las clasificaciones erróneas. Esto se traduce, según la tabla 4-8., en que presenta la especificidad y PPV con porcentaje más bajo, aunque sigue siendo aceptable y, sobre todo, sirviendo de ayuda a los profesionales, ya sean especialistas o no. A su vez, podemos también ver que los otros tres índices, especificidad, NPV y precisión, son buenos, llegando casi al orden de los 90%.

Todo esto se resume en la columna del total de la tabla 4-10, en la que se ha hecho la media aritmética de los porcentajes obtenidos para cada clase. Podemos comprobar que prácticamente ningún índice baja del 80%. Cabe destacar que la precisión total del sistema ha sido de en torno a un 87%, lo que supone una tasa bastante baja de error.

5 CONCLUSIONES Y LÍNEAS FUTURAS

El trabajo realizado pretende adentrarse en la ingeniería biomédica y en la capacidad de la misma para ayudar a prevenir enfermedades. En el caso estudiado, el melanoma, se ha desarrollado un programa que en ningún momento pretende proporcionar un diagnóstico completo de la enfermedad, pero sí que pretende ser un paso más en el mismo.

Ha consistido en la realización de un programa de procesamiento de imagen que estime ciertas características de textura y clasifique conforme a ellas en tres de los patrones globales más importantes del Análisis de Patrones [7], que es el método más citado y empleado para la detección de melanomas. Hemos podido estudiar diversos métodos de segmentación, así como emplear distintas técnicas de extracción de características texturales e investigar acerca de métodos de selección de características, clasificación y validación de resultados.

En cuanto a las conclusiones extraídas a lo largo de la realización proyecto, son las siguientes:

- El melanoma es el tipo de cáncer de piel más agresivo, suponiendo el 80% de las muertes de cáncer de piel.
- Es un asunto de importancia, puesto que el número de personas afectadas por esta enfermedad incrementa en torno a un 10% cada año.
- Una detección temprana es de vital importancia, surgiendo para conseguirlo técnicas como la dermatoscopia, que además de ayudar en este aspecto, ha supuesto un descenso considerable del número de intervenciones realizadas en el campo de la dermatología.
- Son pocos los métodos de detección y clasificación de patrones globales que encontramos en la literatura.
- El programa propuesto es un sistema autónomo, puesto que los parámetros empleados son fijos para todas las imágenes, por lo que no presentan dependencia de la imagen de entrada.
- El algoritmo de segmentación empleado consigue segmentar la lesión correctamente incluso en casos adversos, como pueden ser zonas de pigmentación similar que no pertenecen a la lesión.
- El programa propuesto funciona mejor para lesiones de un tamaño superior a 150x150 píxeles, presentando un bajo rendimiento para imágenes con tamaño inferior.
- El programa presenta los mejores resultados para el patrón homogéneo, y los más bajos para el globular. No obstante los índices son buenos en ambos casos.
- El sistema presenta mayor precisión no detectando patrones que no están presentes a detectando los que sí lo están, aunque es bastante acertado en ambas tareas.
- Finalmente, a la vista de los resultados, destacar que el programa cumple con la función para la que fue diseñado: detectar patrones globales con el fin de servir de ayuda en el campo de la medicina.

Como hemos podido ir viendo, el sistema tiene ciertas limitaciones que podrían ser objeto de estudio para investigaciones posteriores, tales como:

- Eliminación efectiva del ruido en las imágenes dermatoscópicas de cara a la segmentación y a la extracción de características, tales como vello o manchas causadas por la interfase líquida utilizada junto al instrumento óptico. Para ello se propone incluir un preprocesado que trabaje con operadores morfológicos o bien el método propuesto por [28] en el que emplean técnicas de umbralización y filtros direccionales.
- Estudio de algún método que consiga aumentar la fiabilidad en la clasificación de lesiones con tamaño reducido, bien eliminando la interferencia que produce el borde o tratando la lesión como un todo evitando así la necesidad de recorrer la imagen por bloques.
- Incluir información de color, no solo de textura, para detectar un caso muy común de lesiones homogéneas que son las lesiones homogéneas con pigmentación azul.
- Aumentar el número de características extraídas con vistas a conseguir alguna que mejore la capacidad diagnóstica del conjunto.
- Sería también interesante profundizar en el estudio de este tipo de patrones para distinguir casos regulares de irregulares.
- También nos plantearíamos la opción de aumentar el número de patrones globales en los que se clasifica para así tener un sistema más imparcial que sea capaz de clasificar cualquier tipo de lesión.

Tras haber conseguido que un programa tenga cierta autonomía a la hora de detectar ciertos tipos de patrones, queremos remarcar que, aunque el pensamiento de que el procesamiento computacional y los sistemas de inteligencia artificial sea un hecho, nunca debemos olvidar que hay un objetivo que cumplir, que es emplear todo ese avance en proporcionar información que mejore los resultados y de algún modo, la calidad de vida, de los pacientes.

Para concluir, queremos destacar la experiencia adquirida durante el desarrollo del trabajo, que nos ha ayudado a afianzar los conocimientos adquiridos a lo largo de la carrera y a adquirir otros nuevos, así como a coger soltura en proyectos de más envergadura y preparándonos, de algún modo, para el mundo laboral.

REFERENCIAS

- [1] «El melanoma es el cáncer de piel menos común pero el que mayor tasa de mortalidad tiene,» *Público*, 13 Junio 2016.
- [2] «Un centenar de casos de melanoma son diagnosticados anualmente en Baleares,» *Europa Press*, 13 Junio 2017.
- [3] Miller AJ, Mihm MC., «Melanoma,» *The New England Journal of Medicine*, vol. 355, pp. 51-65, 2006.
- [4] Pehamberger H, Kittler H, Wolff K, Binder M., «Diagnostic accuracy of dermoscopy,» *The Lancet Oncology*, vol. 3, nº 3, p. 7, 2002.
- [5] M. J., «Systematic review of the diagnostic accuracy of dermatoscopy in detecting malignant melanoma.,» *The Medical Journal of Australia*, 1997.
- [6] Argenziano G, Soyer H.P, Chimenti S, Talamini R, Corona R, Sera F, Binder M, Cerroni L, Kopf A. W., «Dermoscopy of pigmented skin lesions: results of a consensus meeting via the internet.,» *J. Am. Acad. Dermatol.*, vol. 48, nº 5, pp. 680-693, 2003.
- [7] Pehamberger H, Steiner A, Wolff K., «in vivo epiluminescence microscopy of pigmented skin lesions. I. Pattern analysis of pigmented skin lesions.,» *American Academy of Dermatology*, vol. 17, nº 4, pp. 571-583, 1987.
- [8] Soyer, H.P., Argenziano, G., Chimenti, S., Menzies, S., Pehamberger, H., Rabinovitz, H., *Dermoscopy of pigmented skin lesions. An atlas based on the Consensus Net Meeting on Dermoscopy 2000*, Milan: Edra Medical Publishing and New Media, 2001.
- [9] Argenziano, G., Fabbrocini, G., Carli, P., De Giorgi, V., Sammarco, E., Delfino, M., «Epiluminescence microscopy for the diagnosis of doubtful melanocytic skin lesions. Comparison of the ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis,» *Arch. Dermatol.*, Vols. %1 de %2134:1563-70, 1998.
- [10] Stolz W, Riemann A, Cognetta AB, Pillet L, Abmayr W, Hoelzel D., «ABCD rule of dermatoscopy: a new practical method for early recognition of malignant melanoma,» *Eur J Dermatol*, Vols. %1 de %24:521-7, 1994.
- [11] Menzies, S.W., Ingvar, C., Crotty, K.A., McCarthy, WH., «Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features,» *Arch. Dermatol.* , Vols. %1 de %2132: 1178-82, 1996.
- [12] Stoecker, W.V., Moss, R.H., «Editorial: digital imaging in dermatology,» *Comput. Med. Imaging Graph*, vol. 16, nº 3, pp. 145-150, 1992.
- [13] Maglogiannis, I., Doukas, C.N., «Overview of advanced computer vision systems for skin lesions

- characterization,» *IEEE Trans. Inf. Technol. Biomed*, vol. 13, n° 5, pp. 721-733, 2009.
- [14] Celebi, M.E., Stoecker, W.V., Moss, R.H., «Advances in skin cancer image analysis,» *Comput. Med. Imaging Graph*, vol. 35, n° 2, pp. 83-166, 2011.
- [15] Korotkov, K., Garcia, R., «Computerized analysis of pigmented skin lesions: a review,» *Artif. Intel. Med.*, vol. 56, n° 2, pp. 69-90, 2012.
- [16] Serrano, C., Acha, B., «Pattern analysis of dermoscopic images based on Markov random fields,» *Pattern Recognit*, vol. 42, pp. 1052-1057, 2009.
- [17] Isasi Gola, A., Garcia Zapiain, B., Mendez Zorrilla, A., «Melanomas non-invasive diagnosis application based on the ABCD rule and pattern recognition image processing algorithms,» *Comput. Biol. Med.*, vol. 41, pp. 742-755, 2011.
- [18] Sadeghi, M., Lee, T.K., McLean, D., Lui, H., Atkins, M.S., «Global pattern analysis and classification of dermoscopic images using textons,» *Biomedical Optics and Medical Imaging*, 2012.
- [19] Abbas, Q., Celebi, M.E., Serrano, C., Garcia, I.F., Ma, G., «Pattern classification of dermoscopy images: a perceptually uniform model,» *Pattern Recognit*, vol. 46, pp. 86-97, 2013.
- [20] Tanaka, T., Torii, S., Kabuta, I., Shimizu, K., Tanaka, M., Oka, H., «Pattern classification of nevus with texture analysis,» *Annual International Conference of the IEEE Engineering in Medicine and Biology—Proceedings 26 II*, pp. 1459-1462, 2004.
- [21] Tanaka, T., Torii, S., Kabuta, I., Shimizu, K., Tanaka, M., «Pattern classification of nevus with texture analysis,» *IEEE Trans. Electr. Electron. Eng.*, vol. 3, n° 1, pp. 143-150, 2008.
- [22] Sáez, A., Serrano, C., Acha, B., «Model-Based Classification Methods of Global Patterns in Dermoscopic Images,» *IEEE Trans. Med. Imaging*, vol. 33, n° 5, pp. 1137-1147, 2014.
- [23] Iyatomi, H., Oka, H., Celebi, M.E., Ogawa, K., Argenziano, G., Soyer, H.P., Koga, H., Saida, T., Ohara, K., Tanaka, M., «Computer-based classification of dermoscopy images of melanocytic lesions on acral volar skin,» *J. Invest. Dermatol.*, vol. 128, n° 8, pp. 2049-2054, 2008.
- [24] Piazza, C.D., Marcassi, A.P., Seize, M.P., Yamada, S., Maciel, M.G., Cestari, S.C.P., «Dermoscopic patterns of melanocytic nevi in children and adolescents: A cross-sectional study,» *Anais Brasileiros de Dermatologia*, vol. 92, n° 3, pp. 340-344, 2017.
- [25] Haralick, R.M., Shanmugan, K., and Dinstein, I., «Textural features for image classification,» *IEEE Transaction on System, Man and Cybernetics.*, Vols. %1 de %2SMC-3, n° 6, pp. 610-621, 1973.
- [26] Betta, G., Di Leo, G., Fabbrocini, G., Paolillo, A., Scalvenzi, M., «Automated Application of the “7-point checklist” Diagnosis Method for Skin Lesions: Estimation of Chromatic and Shape Parameters,» de *Technology Conference*, Ottawa, 2005.
- [27] Betta, G., Di Leo, G., Fabbrocini, G., Paolillo, A., Sommella, P., «Dermoscopic image-analysis system: estimation of atypical pigment network and atypical vascular pattern,» de *MEMEA 06: Proceedings of the IEEE International Workshop on Medical Measurement and Applications*, 2006.
- [28] K. L. Y. a. L. X. Eltayef, Artist, *Detection of Pigment Networks in Dermoscopy Images*. [Art]. Computer Science Department, Brunel University London, Uxbridge, UB8 3PH, UK, 2017.

- [29] Autor, «Este es el ejemplo de una cita,» *Tesis Doctoral*, vol. 2, nº 13, 2012.
- [30] O. Autor, «Otra cita distinta,» *revista*, p. 12, 2001.
- [31] Perhamberger, sfdafda, fdsfda: fdsafd, fdsafd.
- [32] S. A. W. K. Perhamberger H, in vivo epiluminescence microscopy of pigmented skin lesions. I. Pattern analysis of pigmented skin lesions., *J Am Acad Dermatol*. 1987;17:571-83..
- [33] Xia, Y., Feng, D., Zhao, R., «Adaptive segmentation of textured images by using the coupled Markov random field model,» *IEEE Trans. Image Proces*, vol. 11, pp. 3559-3566, 2006.
- [34] Nachbar, F., Stolz, W., Merkle, T., Cagnetta, A.B., Vogt, T., Landthaler, M., «The ABCD rule of dermatoscopy: high prospective value in the diagnosis of doubtful melanocytic skin lesions,» *J Am Acad Dermatol*, vol. 30, pp. 9-551, 1994.
- [35] Di Leo, G., Fabbrocini, F., Paolillo, A., Sommella, P., «Automatic Diagnosis of Melanoma: a Software System based on the 7-Point,» de *Proceedings of the 43rd Hawaii International Conference on System Sciences*, Hawaii, 2010.

