

Trabajo de Fin de Grado

Grado en Ingeniería de las Tecnologías de
Telecomunicación

Análisis de imágenes dermatoscópicas para la
detección de velo azul blanquecino

Autor: Francisco Javier Rodríguez Fernández

Tutoras: Begoña Acha Piñero y Carmen Serrano Gotarredona

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

Sevilla, 2017



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

Análisis de imágenes dermatoscópicas para la detección de velo azul blanquecino

Autor:

Francisco Javier Rodríguez Fernández

Tutoras:

Begoña Acha Piñero

(Profesora titular)

Carmen Serrano Gotarredona

(Profesora titular)

Dep. de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2017

Trabajo de Fin de Grado: Análisis de imágenes dermatoscópicas para la detección de velo azul blanquecino

Autor: Francisco Javier Rodríguez Fernández

Tutoras: Begoña Acha Piñero y 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

*Los hombres construimos demasiados muros
y no suficientes puentes.*

Isaac Newton

Agradecimientos

Es difícil resumir tantos agradecimientos para tantas personas en tan poco espacio.

En primer lugar quiero agradecer a mi madre toda la constancia que ha tenido desde que era pequeño en que estudiara y no me rindiera. Desde que comencé los estudios ella ha sido la que me ha ayudado cuando era un enano, y también siguió en ello en el instituto, para proseguir en bachillerato. Cuando entré en la carrera me apoyó desde el primer momento y me animó a continuar a pesar de los primeros sufridos años y en gran parte estoy aquí gracias a ella. Te quiero mamá.

Quiero agradecer a mi padre el estar también ahí cuando más lo necesitaba. Cuando he estado en alguna situación que me superaba y tenía la mente cerrada siempre he tenido su apoyo, y por supuesto, como es él, siempre ayudándome a “quitarle hierro al asunto”. En eso siempre ha tenido razón. Te quiero papá.

Como no, agradecer también a mis hermanos pequeños el estar ahí en situaciones más complicadas, aunque sean muy pesados y muchas veces no me dejen estudiar, son irremplazables. Os quiero.

Dar las gracias en especial a mi novia, María de los Ángeles, que ha sido también partícipe de mis dudas y ansiedades durante los estudios desde que la conocí. Ha compartido conmigo varios años de la carrera y es un pilar fundamental para haber llegado hasta este momento, ¡al tuyo le queda poco!. Ha sido mi impulso para comenzar y terminar con buen pie este trabajo, y sobre todo ha sido, es y será mi apoyo personal. Te amo nena.

Dar gracias también a las personas y amigos que han estado ahí cuando necesitaba un consejo, desahogarme, o simplemente despejarme. Aquí quiero destacar a dos personas que también he conocido gracias a los estudios, hemos pasado horas y horas estudiando y sin estudiar. Sin ellos no habría conocido a los mejores compañeros de carrera. Ignacio e Ismael, gracias por todo.

Y por supuesto, dar las gracias a mis tutoras, sin las cuales no podría haber aprendido tanto y haber conseguido terminar el trabajo, y también a todos los profesores que me han enseñado hasta llegar aquí.

La Ingeniería me ha dado mucho.

Gracias a todos por ayudarme a finalizar esta etapa de mi vida.

Francisco Javier Rodríguez Fernández

Sevilla, 2017

Resumen

En el presente trabajo el objetivo final es conseguir realizar un clasificador que implemente la detección de una característica para el diagnóstico de los melanomas, el “Blue-Whitish Veil”, o velo azul blanquecino.

Para ello vamos a clasificar imágenes dermatoscópicas de diversas lesiones, melanocíticas y no melanocíticas, intentando encontrar un método que resulte eficiente a la hora de prevenir la mencionada enfermedad. El método que vamos a usar será un clasificador de máquina de soporte vectorial (SVM) para el aprendizaje y clasificación del algoritmo.

En el capítulo 1 realizaremos una breve introducción a los melanomas desde el punto de vista biológico y médico, y abordaremos la manera de clasificarlo y el estado del arte de estudios centrados en este mismo propósito. En el capítulo 2 nos centraremos en el desarrollo del algoritmo o método en sí, paso por paso. En el capítulo 3 reflejaremos los resultados obtenidos con los diferentes métodos usados y sus comparaciones. Finalmente, en el capítulo 4, comentaremos las conclusiones obtenidas a raíz de los resultados, las valoraciones, limitaciones y recomendaciones de cara a nuevos estudios.

Abstract

In the present work, the final objective is to achieve a classifier that implements the detection of a characteristic for the diagnosis of melanomas, the "Blue-Whitish Veil".

For this, we will classify dermatoscopic images of various lesions, melanocytic and non-melanocytic, trying to find a method that is efficient in preventing the mentioned disease. The method that we will use will be a support vector machine (SVM) classifier for the learning and classification of the algorithm.

In Chapter 1 we will make a brief introduction to the melanomas from the biological and medical point of view, and we will approach the way of classifying it and the state of the art of studies centered on this same purpose. In Chapter 2 we will focus on the development of the algorithm or method itself, step by step. In Chapter 3 we will reflect the results obtained with the different methods used and their comparisons. Finally, in Chapter 4, we will comment on the conclusions obtained from the results, assessments, limitations and recommendations for new studies

Índice

Agradecimientos	ix
Resumen	xi
Abstract.....	xiii
Índice	xiv
Índice de Tablas.....	xvii
Índice de Figuras	xix
Notación.....	xxi
1 Introducción.....	1
1.1 <i>Introducción a los melanomas</i>	1
1.2 <i>Estadísticas</i>	3
1.3 <i>Clasificación desde el punto de vista clínico</i>	3
1.3.1 <i>Dermatoscopia</i>	3
1.3.2 <i>Clasificación y diagnóstico</i>	4
1.3.2.1 <i>Características clínicas que suelen estar presentes en melanomas</i>	4
1.3.2.2 <i>Métodos diagnósticos</i>	5
1.3.2.3 <i>Comparación de los métodos y otros estudios</i>	9
1.4 <i>Estado del Arte</i>	10
1.4.1.1 <i>Estado del arte de clasificadores</i>	10
1.4.1.2 <i>Estado del arte en la clasificación del “Blue-Whitish Veil”</i>	11
1.5 <i>Motivación</i>	12
2 Metodología	13
2.1 <i>Clasificación a nivel local</i>	13
2.1.1 <i>Espacios de color</i>	13
2.1.2 <i>Entrenamiento</i>	16
2.1.2.1 <i>Preprocesado</i>	16
2.1.2.2 <i>Segmentación</i>	17
2.1.2.3 <i>Transformación a distintos espacios de color</i>	19
2.1.2.4 <i>Extracción de bloques</i>	20
2.1.2.5 <i>Extracción de características</i>	20
2.1.2.6 <i>Definición del vector de características</i>	21
2.1.2.7 <i>SVM</i>	21
2.1.3 <i>Prueba</i>	23
2.1.3.1 <i>Cálculo de la probabilidad de error</i>	24
2.1.4 <i>Selección de características</i>	24
2.1.5 <i>Cálculo de la sensibilidad y especificidad</i>	25
2.2 <i>Clasificación a nivel global</i>	25
2.2.1 <i>Clasificación con distribución de probabilidad</i>	26
2.2.1.1 <i>Entrenamiento</i>	26

2.2.1.2	Prueba	29
2.2.2	Clasificación global de la imagen según la clasificación local de los bloques	30
3	Resultados	31
3.1	Resultados en la clasificación local	31
3.1.1	Resultados en la selección de características	31
3.1.2	Resultados de la clasificación local	33
3.2	Resultados en la clasificación global	34
3.2.1	Resultados en la clasificación global con distribución de probabilidad	34
3.2.1.1	Comparación con [31]	34
3.2.2	Resultados en la clasificación global según la clasificación local de los bloques	35
3.2.2.1	Comparación con [31]	35
3.2.2.2	Resultado modificando el número de bloques a 5	36
4	Conclusiones	37
	Referencias	40
	Glosario	45

ÍNDICE DE TABLAS

Tabla 1–1. Comparación de los distintos métodos según el CNMD [14]	10
Tabla 3–1. Resultados en el segundo paso de selección de características	31
Tabla 3–2. Resultados en el tercer paso de selección de características	32
Tabla 3–3. Resultados en el cuarto paso de selección de características	32
Tabla 3–4. Resultados en la clasificación local	33
Tabla 3–5. Resultados de la primera clasificación global	34
Tabla 3–6. Comparación de la primera clasificación global con [31]	34
Tabla 3–7. Resultados de la segunda clasificación global	35
Tabla 3–8. Comparación de la segunda clasificación global con [31]	35
Tabla 3–9. Resultado de la segunda clasificación global modificando el número de bloques	36

ÍNDICE DE FIGURAS

Figura 1-1. Representación de las capas de la piel y los melanocitos[3]	2
Figura 1-2. Ejemplo de funcionamiento de la reflexión y la refracción [10]	4
Figura 1-3. Melanoma con puntos y glóbulos irregulares (flechas) y retículo pigmentado (puntas) [13]	5
Figura 1-4. Procedimiento diagnóstico de 2 etapas en dermatoscopia [15]	6
Figura 2-1. Representación del espacio de color RGB [33]	14
Figura 2-2. Representación del espacio de color HSV [35]	14
Figura 2-3. Representación del espacio de color YUV [36]	15
Figura 2-4. Representación en Matlab de una función gaussiana de dos dimensiones	16
Figura 2-5. Imagen de un ejemplo de Kernel Gaussiano con tamaño 5x5 y $\sigma = 1$ [37]	16
Figura 2-6. Plano R suavizado frente a plano R sin suavizado.	17
Figura 2-7. Máscara de la región segmentada, sin quitar bordes ni superponer la lesión segmentada	18
Figura 2-8. Segmentación con la lesión incluida y sin eliminar los bordes	18
Figura 2-9. Segmentación final con bordes eliminados	19
Figura 2-10. Caso linealmente separable [39]	21
Figura 2-11. Caso no linealmente separable [39]	22
Figura 2-12. Idea del uso de un <i>kernel</i> para la transformación de los datos [39]	22
Figura 2-13. Ejemplo del histograma de probabilidades para una imagen de entrenamiento global	28
Figura 2-14. Ejemplo de 6 de las 10 imágenes usadas para la prueba en global	29

NOTACIÓN

\sin	Función seno
θ_i	Ángulo respecto a la normal del medio i
n	Índice de refracción
\mathfrak{R}^N	Dimensión N
P	Probabilidad de que ocurra el suceso
OR	Odds ratio
VP	Verdaderos positivos
VN	Verdaderos negativos
FP	Falsos positivos
FN	Falsos negativos
$=$	Exactamente igual
\approx	Aproximadamente igual
σ_B^2	Varianza entre clases del método de Otsu
$\omega_{1,2}$	Sumatorio de probabilidad de ocurrencia para todos los niveles de gris de la clase en Otsu
$\mu_{1,2}$	Media de cada clase en Otsu

1 INTRODUCCIÓN

En este primer capítulo introductorio vamos a dejar fijadas las bases sobre las que se asienta el trabajo explicando los motivos que han servido a llevarlo a cabo. Debido a la cercana relación con la medicina y con el objetivo de tener mayor conocimiento sobre el tema que se está tratando, he considerado necesaria la inclusión de una breve introducción desde el punto de vista médico. Lo voy a dividir en cuatro puntos:

1. Introducción a los melanomas.
2. Estadísticas
3. Clasificación desde el punto de vista clínico.
4. Estado del arte.

1.1 Introducción a los melanomas

Vamos a empezar por una breve introducción desde el punto de vista médico [1].

La célula es la unidad básica funcional de la vida, descrita así por biólogos desde la década de los 40 del siglo XIX. No hay una forma de vida más pequeña que la célula, es la unidad estructural y la composición más básica de cualquier ser vivo.

La célula tiene unas características que la definen. Todas las células tienen esta serie de características comunes y es que en su interior, en el núcleo, se encuentra el código genético, más conocido como ácido desoxirribonucleico (ADN). Esto es lo que determina qué es o en que tipo de ser vivo se va a convertir en un futuro. En el citoplasma celular se encuentran una serie de orgánulos que son regulados por el ADN, pero que sin éstos tampoco existiría vida, ya que se encargan de realizar la respiración celular.

En el caso del ser humano, al ser un ser pluricelular, estamos formados por más de una célula. Debido a que no sólo existe una célula, nuestro código genético realiza el proceso de diferenciación celular. Este proceso será importante en el cáncer y más tarde se verá por qué. Es en el estado embrionario cuando se comienza a realizar este proceso y las células madres mediante señales químicas a través del código genético, son elegidas para el tipo de células que serán en un futuro.

La reproducción celular bajo un control, es decir, limitada, es otra característica fundamental de la célula. Es el propio código genético el que establece en una célula si ésta debe madurar o bien es demasiado vieja y debe morir. En el núcleo de la célula se encuentra el gen p53 que es el encargado de revisar el código genético y si encuentra algún fallo por mutación es el que inicia la apoptosis celular (suicidio celular programado).

El interés que conlleva lo anterior es que en el cáncer, hay dos características fundamentales. La primera, que las células se reproducen sin control y a una mayor velocidad de lo normal. La segunda, que existe muy poca diferenciación celular, debido al proceso de indiferenciación.

Existen grandes grupos de células que forman tejidos. Uno de ellos, el epitelial, es el más importante y abundante en el cuerpo junto con el tejido conjuntivo. Su función es hacer de soporte mecánico para las partes que están en contacto con el mundo exterior (piel, tracto digestivo, tracto respiratorio y forma parte de casi todos los órganos). El tejido epitelial tiene como base el tejido conjuntivo, ya que le sirve de soporte y de riego sanguíneo.

En la piel se encuentran tres capas:

- La más externa, epidermis, que es tejido epitelial formado por queratinocitos.
- La intermedia, dermis, es un tejido conjuntivo.

- La inferior, hipodermis, es tejido adiposo.

En la epidermis hay una capa, la capa basal, situada en la base de ésta, y es donde se encuentran las células madre que se convertirán en queratinocitos (tipo de célula epitelial que está en la epidermis). En la capa basal se pueden encontrar los melanocitos, anejos (orgánulos o glándulas) encargados de producir y liberar melanina a los queratinocitos. La melanina es responsable de la coloración de la piel y de ciertos órganos como por ejemplo el ojo. En función de la etnia se sintetiza más o menos melanina. Las personas de tez clara aumentan su nivel de síntesis de melanina cuando se exponen a los rayos ultravioletas.

Los rayos ultravioleta son considerados una agresión en cantidad elevada, ya que en su justa medida son necesarios para la absorción de vitamina D. La función del melanocito es proteger al cuerpo de que no entre más de lo necesario, inyectando más melanina a los queratinocitos y que la capa más externa sea más oscura protegiendo y absorbiendo para que no traspase más de esa radiación al interior del cuerpo y se quede en la parte más externa, la epidermis.

Esta radiación lo que provoca es una mutación en el ADN y aquí radica el inicio del melanoma, tipo de cáncer en el que nos vamos a centrar y que comienza su mutación en el melanocito anteriormente comentado. Por tanto se pueden considerar dos ámbitos que influyen en el desarrollo del melanoma en el cual nos vamos a centrar, ámbitos hereditarios y ámbitos externos.

De ellos influye mayoritariamente el factor externo, que son las radiaciones solares, en concreto las de tipo B (UVB) y las de tipo A (UVA) [2].

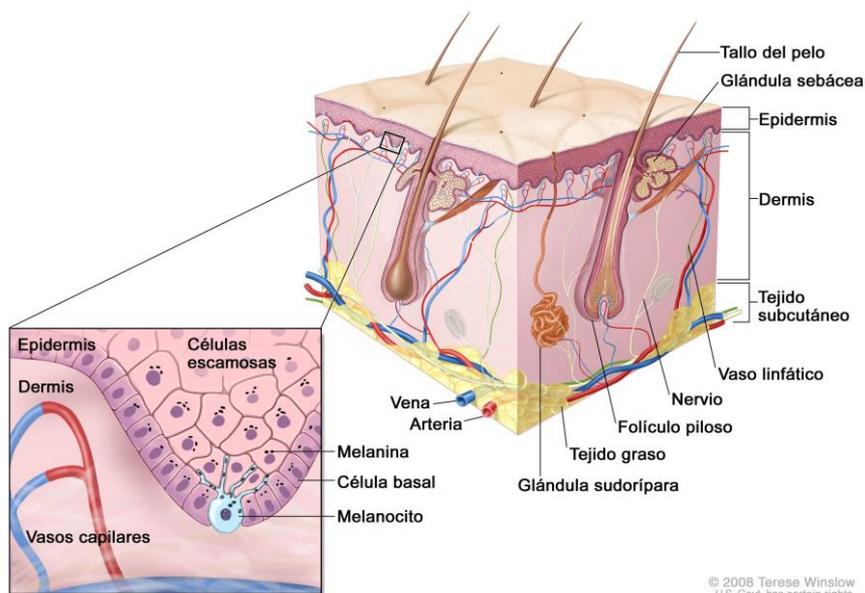


Figura 1-1. Representación de las capas de la piel y los melanocitos.

Los estadios en los que se pueden encontrar son los siguientes [4]:

- Estadio 0 o melanoma *in situ* : El melanoma se encuentra en la epidermis y no ha tocado vasos sanguíneos.
- Estadio I : El melanoma se encuentra en la epidermis o el inicio de la dermis, pero sin dañar ganglios. El grosor es menor a 1 o 2 mm.
- Estadio II : El cáncer afecta a la dermis pero no a ganglios. Grosor entre 2 y 4 mm.
- Estadio III : Que sea mayor de 4 mm, que haya afectados ganglios o tejidos bajo la piel, o que haya tumores alrededor del principal.
- Estadio IV : Afecta a ganglios alejados y órganos.

1.2 Estadísticas

Como bien es sabido, el cáncer forma parte del conjunto de enfermedades más mortíferas actualmente. En España el cáncer es la causa más frecuente de muerte en hombres, y la segunda causa más frecuente de muerte en el caso de mujeres [5]. A nivel mundial se establece entre una de las primeras causas de fallecimientos, en 2012 causó 8'2 millones y se estima que anualmente los casos aumentarán de 14 a 22 millones en las próximas dos décadas. [6].

El tipo de cáncer en el que nos vamos a centrar es el melanoma. En España el melanoma maligno de piel fue causante en 2014 de 599 fallecimientos en hombres y de 460 en mujeres y de ellos, 130 fueron de pacientes menores a los 50 años considerando ambos sexos [7].

En el campo de la incidencia del melanoma se ha demostrado en varias investigaciones que influyen varios factores como son la edad, el sexo y la etnia entre otros [8]. En este campo, el estudio de Wu et al. indica que en general hay más incidencia de melanomas cutáneos en personas de piel blanca seguidas de las hispanas o latinas y después las personas de piel negra, pero en este último grupo hay más índice de diagnóstico en un estado más avanzado que los otros grupos y por tanto un peor pronóstico. En el caso de distinción por sexo también muestra que en personas blancas los índices son mayores para hombres que para mujeres, y un dato interesante que también refleja el estudio es que la edad es un factor que influye en el desarrollo de un melanoma pero afecta de manera equitativa a todos los grupos raciales por igual.

Según la AECC en función de la etapa en la que se encuentre el melanoma cutáneo existen unos porcentajes de prevalencia u otros. La prevalencia a 5 años para estadio 0 es de 97%, para estadio I de 90-95%, para estadio II 45-85%, para estadio III del 45% y para estadio IV de 10% [4].

1.3 Clasificación desde el punto de vista clínico

1.3.1 Dermatoscopia

La clasificación desde el punto de vista clínico se ayuda de una herramienta esencial hoy en día para esta tarea, sin la cual sería mucho más difícil o incluso imposible realizarla, la dermatoscopia.

La dermatoscopia es una técnica no invasiva cuyo fin es poder realizar un diagnóstico sin necesidad de tener que realizar una biopsia de la lesión y poder tener un grado mayor de precisión sobre ésta.

El principal instrumento usado en la dermatoscopia es el dermatoscopio. El dermatoscopio lo que pretende es poder observar características de la lesión que a simple vista no se pueden ver, ya que éstas nos pueden servir para determinar la malignidad o benignidad de esa lesión concreta. El uso del dermatoscopio puede ser de manera directa, para que el experto observe en vivo la lesión y pueda buscar las características que lo relacionen con lesiones malignas o benignas, o se puede usar mediante un acoplamiento a una cámara normal, para así registrar las imágenes de las lesiones que puedan resultar de interés.

El principio sobre el que se asienta el funcionamiento del dermatoscopio es el de poder dejar pasar la luz hasta la capa inferior a la epidermis, la dermis superficial. Es decir, se logra que el estrato córneo se torne traslúcido y de esa forma disminuye la reflexión de los haces de luz; ello permite la visualización detallada de las estructuras que se localizan tanto en la epidermis como en la unión dermoepidérmica y la dermis superficial [9]. Un ejemplo de la reflexión y refracción se puede observar en la figura 1-2.

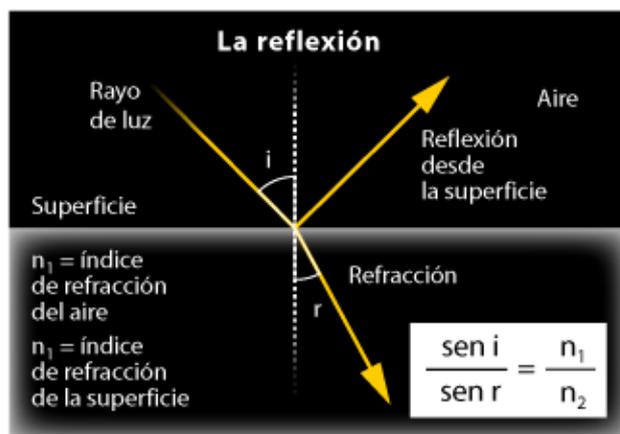


Figura 1-2. Ejemplo de funcionamiento de la reflexión y la refracción.

La visión directa de la piel no penetra en la epidermis ya que existen distintos índices de refracción entre el aire (el medio) y la superficie de la piel (la epidermis en sí) que son 1 y 1'55 respectivamente. El hecho de poder observar más allá de la epidermis viene dado por varios factores :

- El primero de ellos es que el cristal o el conjunto de lentes que conforman el dermatoscopio consiguen un índice de refracción de 1'52, esto es, según la Ley de Snell :

$$\frac{n_1}{n_2} = \frac{\sin \theta_2}{\sin \theta_1}$$

Siendo 1 el cristal y 2 la epidermis, el cociente de los senos es aproximadamente 1, con esto podemos concluir que el ángulo incidente será casi igual al ángulo refractado, eliminando en un gran porcentaje la reflexión.

- El segundo de los factores es que se usa o un interfaz líquido entre el dermatoscopio y la epidermis, o bien luz polarizada desde el dermatoscopio para evitar las reflexiones en el contacto directo con la epidermis.
- El tercer y último factor es que además el propio dermatoscopio incluye una serie de aumentos, desde x10 hasta x40, para poder observar con mayor detalle las características de la lesión.

Se trata de una herramienta muy útil que nos brinda la oportunidad de ver de otra manera distinta las imágenes que hasta entonces no era posible. Gracias a la dermatoscopia se ha gestado un cambio en el tratamiento de las lesiones melanocíticas disminuyendo en gran medida el número de extirpaciones innecesarias como bien refleja Argenziano et al. que debido a la dermatoscopia demuestran que existe un 42% menos de biopsias en este tipo de lesiones [11].

1.3.2 Clasificación y diagnóstico

1.3.2.1 Características clínicas que suelen estar presentes en melanomas

En el ámbito clínico se pueden destacar varias características o criterios que suelen tener los melanomas cutáneos malignos. Entre ellos están [12]:

- Retículo o red pigmentada atípica : Red negra, grisácea o marrón con orificios irregulares y líneas gruesas, sus colores no son homogéneos.
- Glóbulos o puntos irregulares : Son estructuras circulares u ovaladas de color negro, marrón o gris y con una distribución irregular.

- Patrón multicomponente : Cuando existen 3 o más estructuras características de melanoma.
- Pseudópodos y líneas radiales : Ambos se encuentran en la periferia de la lesión, la primera tiene forma bulbosa o digitiforme y la segunda son líneas en patrón radial.
- Velo azul-blanquecino : Es un área de color azul junto con un velo blanquecino, es irregular, desestructurada y en general está en una zona más elevada de la lesión.
- Estructura de regresión : Zona despigmentada con un aspecto blanquecino y/o gránulos con colores azul-grisáceos.
- Estructuras vasculares : Vasos sanguíneos claramente perceptibles y definidos, con un aparición irregular sobre la lesión y/o zonas enrojecidas en las estructuras de regresión.

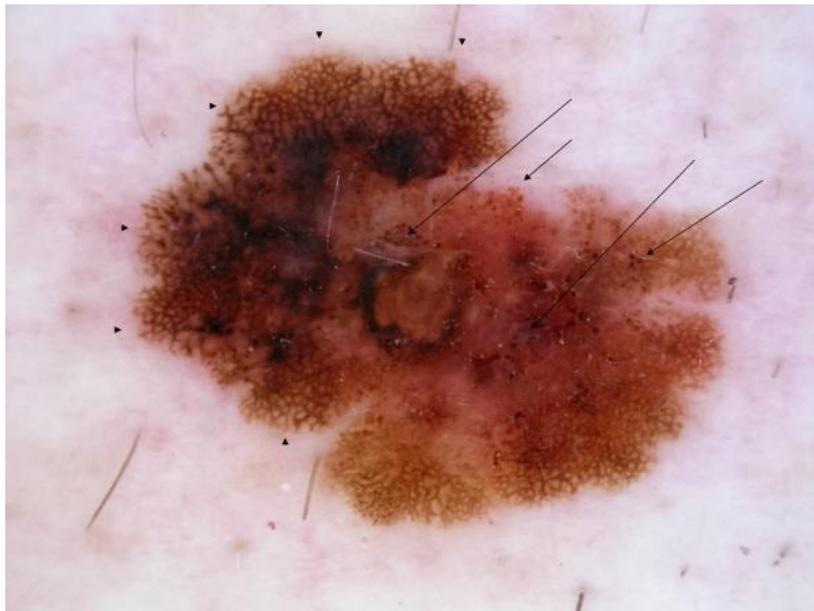


Figura 1-3. Melanoma con puntos y glóbulos irregulares (flechas) y retículo pigmentado (puntas)

1.3.2.2 Métodos diagnósticos

Gracias a la dermatoscopia y la posibilidad de ver características que a simple vista serían impensables, se han desarrollado también distintos métodos que permiten la distinción y clasificación de los distintos tipos de lesiones pigmentadas. Los que se usan para el diagnóstico son: Análisis de Patrones, Regla ABCDE, Método de Menzies y Lista de los 7 puntos entre otros, pero estos son los más relevantes.

La acción a realizar frente a una lesión pigmentada se divide en dos fases, cuyo rendimiento real junto con el de los algoritmos fue verdaderamente evaluado en la Reunión del Consenso vía Internet, “Consensus Net Meeting on Dermoscopy” (CNMD) en el año 2000 [14].

En la primera fase se comprueba si la lesión es melanocítica o no, buscando criterios de los comentados anteriormente que relacionen la lesión con que sea melanocítica y también criterios que sean de lesiones no melanocíticas que en ausencia de ellos nos hagan pensar en que sea melanocítica [14].

En la segunda fase se comprueba si la lesión melanocítica es benigna o maligna reconociendo una serie de parámetros y patrones. Para ello se puede usar análisis de patrones (un método cualitativo) o Regla de ABCD, Método de Menzies y Lista de los 7 puntos de Argenziano (métodos semicuantitativos). Hay más, pero estos últimos son los que más repercusión han tenido y los más usados en diferentes campos [15]. El método de Análisis de patrones se usa más por personas expertas ya que se tienen que distinguir los patrones a simple vista.

En los demás métodos lo que se intentan es crear facilidades para médicos generales y usuarios no expertos y poder diagnosticar de manera más simple y efectiva.

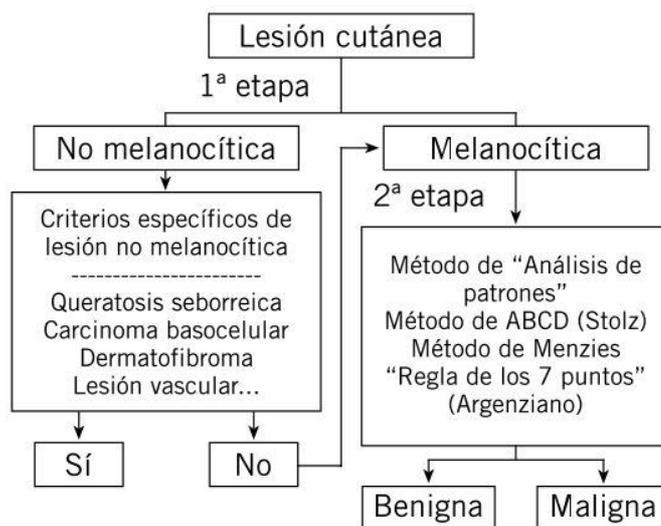


Figura 1-4. Procedimiento diagnóstico de 2 etapas en dermatoscopia

Cada método tiene su especificidad y su sensibilidad. En el caso de la sensibilidad refleja el porcentaje de veces que el algoritmo ha decidido que era enfermo y era correcto, teniendo en cuenta los verdaderos positivos (VP) y los falsos negativos (FN), es decir, enfermos que no los ha detectado bien el algoritmo. En el caso de la especificidad lo que transmite al fin y al cabo es la proporción de no enfermos que no ha diagnosticado el algoritmo y tiene en cuenta los verdaderos negativos (VN) y los falsos positivos (FP). En última instancia para un buen algoritmo nos interesa tener ambos porcentajes altos.

Para la representación de datos en estos tipos de estudios se usan los llamados “odds ratio” en inglés (OR), los cuales indican la proporción o cantidad de veces que un suceso ocurra frente a que ese mismo suceso no ocurra. Matemáticamente, se expresa como la probabilidad de que un evento ocurra dividido entre la probabilidad de que un elemento no ocurra [16].

$$OR = \frac{P}{1 - P}$$

Los métodos para el diagnóstico son:

- Análisis de patrones :

El análisis de patrones permite abordar bastantes características del melanoma, pero tiene una serie de condiciones. Como señala Zaballos, P. et al (2004) :

“El análisis de patrones es el método con el que se obtienen mejores resultados pues permite un abordaje más completo de las lesiones pigmentadas [...]. Existen unas “reglas” importantes que deben considerarse al utilizar este método: a) la presencia de un criterio es más importante que su ausencia [...] b) un solo criterio no es suficiente para hacer el diagnóstico de melanoma; c) algunos criterios son más importantes que otros [...] d) la ausencia de criterios

definidos que permitan un diagnóstico por dermatoscopia deben sugerir la posibilidad de que la lesión pueda corresponder a un melanoma ” (p.5) [15].

En este método se distingue entre las características o patrones globales y los locales.

En el caso de los globales se refiere al patrón más predominante en la lesión, y pueden ser [14] :

- Patrón reticulado
- Patrón globular
- Patrón en estallido de estrellas
- Patrón homogéneo
- Patrón paralelo
- Patrón multicomponente
- Patrón empedrado
- Patrón inespecífico

En el caso de las características locales son [14]:

- Red pigmentada
- Puntos/glóbulos
- Rayas
- Velo azul-blanquecino
- Estructuras de regresión
- Hipopigmentación
- Manchas
- Estructuras vasculares

Hay una serie de parámetros dentro de estos que sugieren malignidad, estos son :

Retículo pigmentado atípico o prominente, puntos y glóbulos irregulares, proyecciones irregulares, velo azul-gris o azul-blanquecino, áreas desestructuradas, estructuras de regresión y estructuras vasculares relacionadas con malignidad (vasos irregulares, glóbulos rojo-azulados y vasos dentro de estructuras de regresión) [15].

Según la evaluación de este método en el CNMD, dentro de las características globales, se le asignó al patrón multicomponente el mayor OR, 4'3, seguido del patrón no específico, 1'4. En las características locales el mayor fue de la red pigmentada atípica con un OR de 9, seguido de las rayas irregulares, 5'8, estableciéndose el “Blue-Whitish Veil” con un OR de 2'9 [14].

- Método ABCD de Stolz :

El método de ABCD de Stolz consiste en tener en cuenta varios aspectos de la lesión y puntuarlos según una serie de coeficientes. Los aspectos a tener en cuenta para el cálculo de la puntuación son:

Asimetría (A), cese o corte abrupto en el borde del patrón pigmentado (B), colores distintos (C) y diferentes estructuras (D) [17].

- Asimetría : Se evalúa dividiendo la imagen en dos ejes perpendiculares centrándolos

de forma que se obtenga la menor simetría posible. Si hay simetría en los dos ejes la puntuación que se le asigna es 0, si hay asimetría en un eje, 1, y si hay asimetría en ambos, 2 (de 0 a 2) [17].

- Bordes : Se evalúan las lesiones dividiendo la imagen en ocho segmentos y se puntúa con un punto cada uno si en ese segmento hay un corte abrupto del patrón pigmentado (de 0 a 8) [17].
- Colores : En función del número de colores que haya presentes en la lesión se tiene en cuenta un punto por cada color presente (de 1 a 6) [17].
- Diferentes estructuras : La evaluación en este caso es como en los anteriores, se consideran una serie de estructuras y a raíz del número de estructuras que tenga la lesión se suma un punto por cada estructura (de 1 a 5) [17].

Al finalizar la revisión de puntuaciones, se realiza un cálculo con una serie de factores por cada aspecto. 1'3 para A, 0'1 para B, 0'5 para C y 0'5 para D. En la puntuación final se establece que el umbral a partir de el cual es una lesión sospechosa es 4'75 si es menor es benigna y si es mayor de 5'45 maligna [17]. Donde finalmente quedaría la fórmula para la puntuación de esta manera:

$$\text{Puntuación} = 1'3 \cdot A + 0'1 \cdot B + 0'5 \cdot C + 0'5 \cdot D$$

Donde la puntuación final posible está en el rango de 1 a 8'9 [17].

Según el estudio de Nachbar, F. et al, la sensibilidad para el melanoma maligno con el método de ABCD es de 92'8% y la especificidad de 91'2% [17].

En el CNMD se asignaron los mayores odds ratio en ABCD para la asimetría de dos ejes, 13'7, seguido del número de colores entre 5 y 6 con OR de 5 [14]. En este método no se define con exactitud el OR del "Blue-Whitish Veil", al encontrarse dentro de la característica de los colores.

- Lista de los 7 puntos de Argenziano :

Este método está basado en el Análisis de patrones. Mediante análisis multivariable se consiguieron calcular los odds ratios para cada criterio.

En función de estos odds ratios se dividieron los criterios en criterios mayores (ratios por encima de 5) y criterios menores (ratios por debajo de 5). Como su propio nombre indica, este método tiene en cuenta 7 criterios o características dermatoscópicas [18] :

- Criterios mayores : Retículo pigmentado atípico, velo azul-gris y patrón vascular atípico [18].
- Criterios menores : Rayas, manchas, glóbulos y puntos irregulares y patrones de regresión [18].

A los criterios mayores se le dan 2 puntos y a los menores 1. Teniendo en cuenta todas las características presentes en la lesión que se estudie, si la puntuación final es mayor de 3 se considera melanoma [18].

Este método, si en total la puntuación ha sido mayor a 3, nos brinda una sensibilidad del 95%, y una especificidad del 75% [18].

Cabe destacar que el criterio al que mayor odds ratio se le asigna, es decir, aquel que más incrementa la probabilidad de diagnóstico de un melanoma es el velo azul-gris o velo azul-blanquecino conocido en inglés como "whitish veil", "milky way", "gray-blue veil" o "blue-whitish veil". En concreto se le asigna un OR de 11'10 lo que traducido a probabilidad es un 91'73 % [18].

Sin embargo, en el CNMD se le asigna un OR mayor a la red pigmentada atípica, 9, y después a las rayas irregulares, 6'1, quedando el "Blue-Whitish Veil" con un OR de 2'9 [14].

- Método de Menzies :

El método de Menzies está basado en el análisis de 11 criterios dermatoscópicos, donde, de estos 11, divide entre criterios negativos y criterios positivos, entendiendo como negativos aquellos que no deben estar presentes para un diagnóstico final como melanoma y positivos como los que, si al menos uno de ellos está presente, el diagnóstico será melanoma [19].

Clasifica como criterios negativos a [15] :

- Simetría presente en los patrones de la lesión (no en la forma de ésta)
- Monocromía o presencia de un solo color

Como criterios positivos [15] :

- Velo azul-blanquecino
- Despigmentación pseudocicatricial (área en el interior de la lesión que es blanquecina y bien definida, su tono debe ser más claro que la piel alrededor de la lesión)
- Múltiples colores (de 5 a 6)
- Retículo pigmentado prominente (lo forman líneas gruesas)
- Pseudópodos
- Proyecciones radiales
- Múltiples puntos marrones
- Glóbulos y puntos negros periféricos
- Múltiples puntos azul-gris

Para llegar a diagnosticar una lesión como melanoma no debe tener ninguno de los negativos, es decir, ni tener patrones simétricos ni tener un solo color y además debe presentar al menos uno de los positivos [15].

En el CNMD en el caso de que sea un patrón asimétrico se le asigna un OR de 43'8 y en el caso de más de un color 18'5, donde se encontraría el "Blue-Whitish Veil" [14].

1.3.2.3 Comparación de los métodos y otros estudios

Algunos estudios de comparaciones entre los métodos muestran diferentes datos interesantes. El estudio de Carli et al, muestra que para observadores no entrenados, en este caso residentes de medicina, el método que de media dió más precisión diagnóstica fue el de análisis de patrones, un 68'7%, seguido del método ABCD (56'1%) y por último la lista de los 7 puntos(53'4%) [20].

En el CNMD se obtuvieron mediante modelos de regresión de ecuaciones de estimación generalizada, la sensibilidad y especificidad de los métodos, dando como resultado [14] :

	Sensibilidad (%)	Especificidad (%)
Análisis de patrones	83'7	83'4
Regla de ABCD	82'6	70
Método de Menzies	85'7	71'1
Lista de los 7 puntos	83'6	71'5

Tabla 1-1. Comparación de los distintos métodos según el CNMD.

Esta introducción a la clasificación era necesaria para entender y establecer el porqué del presente trabajo. En este trabajo nos vamos a centrar en una de las características que anteriormente hemos estado viendo, y que se tiene en cuenta en todos los métodos u análisis por su estrecha relación con la malignidad en el melanoma, el velo azul-blanquecino conocido en inglés como “Blue-Whitish Veil”.

En todos los métodos vistos, el velo azul-blanquecino está considerado entre las características que relacionan a una lesión con ser melanoma. En la regla ABCD como color y en los otros con una puntuación o relación de malignidad altos, por tanto es un patrón a tener muy en cuenta a la hora de realizar un diagnóstico de la lesión.

Algunos estudios como el de Massi, D. et al [21] muestra en sus conclusiones que la presencia del “blue-whitish veil” es altamente indicativa de realizar un diagnóstico final como melanoma maligno con 91% de especificidad y 75% de sensibilidad. En el de Menzies, S. W. , Ingvar, C. y McCarthy, W. H. [22] se muestra que, entre las características que ofrecían una diferencia significativa entre lesiones pigmentadas que no eran melanomas y los verdaderos melanomas se encontraba el “blue-whitish veil” como una de las principales con una especificidad del 95% para el melanoma.

Esto nos muestra la importancia de esta característica en el diagnóstico precoz del melanoma, lo cual es fundamental para asegurar la supervivencia del paciente.

1.4 Estado del Arte

En este subcapítulo vamos a exponer los trabajos anteriores, más relacionados con el presente trabajo, realizados por investigadores y expertos en el campo de la clasificación de imágenes, y en concreto aplicado al “Blue-Whitish Veil”.

1.4.1.1 Estado del arte de clasificadores

Todo se remonta al comienzo del “machine learning” en los años 50, donde se establecen las bases para realizar un clasificador con aprendizaje, en el cual primero se definen la base de muestras o de datos de entrenamiento que se conocen de antemano, más tarde necesitamos saber qué técnica vamos a usar y por último realizar el sistema clasificador. La técnica debe obtener a partir de los datos de entrenamiento un conocimiento útil para

poder realizar una diferenciación entre las clases establecidas.

Cuando se plantea el algoritmo “Nearest Neighbor” en 1951 por Fix, E. y Hodges, J. L. [23] es cuando se desvía el “machine learning” a la rama que nos permitirá el reconocimiento de patrones.

Más tarde, en el estudio de Cover, T. y Hart, P. [24] se incluyen por primera vez datos o resultados analíticos de algunos problemas sobre el algoritmo, como los problemas del tamaño finito de la muestra y del número finito de vecinos cercanos, en este mismo estudio se enuncia que la simple regla del vecino más cercano tiene una probabilidad de error menor a dos veces la probabilidad de error de Bayes. En inglés también se conoce como el algoritmo kNN (“k-Nearest Neighbors”), donde el valor de k representa el número de vecinos que se buscarán en el algoritmo.

El algoritmo de kNN asentó las bases para el posterior desarrollo de muchos algoritmos de clasificación a lo largo de los años

En el campo de la clasificación de imágenes mediante aprendizaje ha habido muchos estudios que han señalado varios algoritmos de aprendizaje, cada uno con sus características e implementación. En concreto el estudio reciente de Zhang et al. [25] desarrolla una comparación entre los algoritmos de clasificación establecidos y otros nuevos teniendo en cuenta los estudios anteriores comparativos e incluyendo una comparación novedosa del tiempo de entrenamiento, dato importante para la implementación real.

Dentro de los algoritmos más populares destacados por su precisión y rendimiento en muchos ámbitos, se encuentran el “Support Vector Machines” (SVM) y el “Random Forest” (RF) [25]. En una segunda categoría se encuadrarían los “nuevos” clasificadores que han sido desarrollados en años recientes, como el “Extreme Learning Machine” (ELM), “Sparse Representation based Classification” (SRC) y “Deep Learning” (DL). En una última categoría se incluirían algoritmos ya establecidos pero más antiguos como C4.5, kNN, “AdaBoost” (AB), “Logistic Regression” (LR) y “Stochastic” que no han tenido tantos ámbitos donde destaquen por su rendimiento como los de la primera categoría [25].

En nuestro caso vamos a centrarnos en el SVM, un algoritmo de clasificación que ha demostrado ser bastante preciso en muchos ámbitos. En el ámbito que a nosotros nos interesa, el dermatológico, según el estudio comparativo de Zhang et al. [25], en el cual usaron 71 bases de datos distintas para comparar 11 algoritmos de clasificación y con un rango entre 0 y 1, SVM en la base de datos de dermatología tuvo una precisión de 1, el mejor de todos los algoritmos. En la comparativa en tiempos de entrenamiento fue el cuarto mejor con un tiempo de 0’0087 seg para el entrenamiento [25].

1.4.1.2 Estado del arte en la clasificación del “Blue-Whitish Veil”

En relación a la detección automática del “Blue-Whitish Veil” ha habido varios estudios.

En el estudio de Celebi et al. (2008) [26] se realizó una detección automática del blue-whitish veil y estructuras que están relacionadas con ésta. En este estudio se realizaron por pasos un primer pre-procesado, la extracción de características de color, la inducción mediante un árbol de decisión, aplicación de las reglas de decisión y por último un post-procesado.

El pre-procesado se realizó primero delimitando los bordes de la lesión por expertos dermatólogos, el siguiente paso fue que para determinar el color de fondo de la piel primero se omitió un equivalente al 10% de la lesión alrededor del borde para evitar confusiones con inflamaciones, etc y con el 20% que rodea al 10% anterior se calculó el color del fondo de la piel como una media. Este 10% y 20% se calcularon con una transformada Euclídea de distancia. Por último se delimitaron de manera manual círculos alrededor de las zonas con “veil” y sin él, para tener los datos de entrenamiento [26].

Para la caracterización de los píxeles se extrajeron 15 características de color y 3 de textura [26].

En la clasificación se usó un clasificador de árbol de decisión dividiendo en dos clases: veil o no veil. En concreto se usó el bien conocido algoritmo C4.5 [26].

Por último en la segunda parte del estudio se desarrolló un clasificador para diferenciar entre melanoma y lesiones benignas basándose en la presencia o ausencia de la característica de “blue-white veil” [26].

Este estudio dio como resultado para toda la base de datos de imágenes (512) sensibilidad del 69’35% y especificidad 89’97% [26].

En el estudio de [27] se basan en el anterior de Celebi et al. para proponer, primero, una mejora en términos de complejidad y costes computacionales frente al anterior, y segundo, un nuevo método alternativo al propuesto por el método anterior. En la primera parte sus resultados de especificidad y sensibilidad fueron muy parecidos al rendimiento del método propuesto por Celebi et al. pero sí encontraron que las características de textura tomadas en cuenta en el anterior estudio no eran relevantes para la detección del blue-whitish veil y también que el algoritmo para clasificación SVM es el que mejor resultado dio pero más coste computacional y complejidad tenía. En la segunda parte se propone un método donde primero se pasa de RGB a CIELAB (L^*a^*b) porque es un modelo de color perceptualmente más uniforme. Para la segmentación de la imagen de color se usó un software denominado EDISON (“**E**dge **D**etection and **I**mage **S**egmentation **S**ystem”) basado en el algoritmo “Mean-shift” (MS). Este último método para las imágenes de entrenamiento dio una sensibilidad de 71% y una especificidad de 97% superando al estudio anterior [27].

En otro estudio, de Arroyo, J. , Zapirain, B. y Zorrilla, A. [28] realizaron un método para detectar automáticamente la característica de “blue-whitish veil” usando técnicas de “machine learning” supervisado en dos fases: primero obtener las condiciones que satisfagan a los píxeles y segundo obtener las características que la imagen de la lesión debería tener. Se aplicó a 887 imágenes y les dio un resultado de 89’06% de detecciones correctas.

En un estudio más reciente de Kropidlowski, K. et al [29] , se buscó la detección del “blue-whitish veil” y se tuvieron en cuenta las características de color para ello. El método propuesto implementa la lista de los 7 puntos para la detección. La precisión del método desarrollado fue de un 78% para la detección del “blue-whitish veil”.

Un estudio muy reciente como el de Jaworek-Korjakowska, J. et al. [30] presenta una aproximación no supervisada a la detección del “blue-whitish veil” pero basándose más en los planos de color. Este estudio en concreto realiza un análisis en el espacio de color HSV. El método se probó en un set de 179 imágenes dermatoscópicas dando como resultado una tasa de error en la detección menor al 15%.

1.5 Motivación

Como ya hemos visto el melanoma es uno de los muchos cánceres mortales actualmente. La rápida aparición, diseminación y posterior agravamiento de la enfermedad es una característica clave que hace del melanoma un cáncer muy mortífero. Aquí radica la decisión tomada para poder realizar un método diagnóstico efectivo y también asequible para su implantación, de forma que se pueda incluir un segundo punto de vista o apoyar de alguna manera, siendo la decisión del especialista siempre la decisión a tomar, a la hora de diagnosticar una lesión. Pretendo con el presente trabajo aportar una ayuda o como mínimo no ser un mero observador ya que puede ayudar a aumentar en gran medida la detección temprana del melanoma y un método implantado para el uso habitual o diario puede conseguir agilizar bastante las diagnósticos de pacientes pudiendo verse más pacientes, evitando así una espera innecesaria con el posterior agravamiento de la enfermedad

2 METODOLOGÍA

Este capítulo se centra en la explicación del algoritmo usado para la realización de la detección.

En el presente trabajo el objetivo es diseñar un método de detección automática del “blue-whitish veil”, característica muy presente en los melanomas y que se la relaciona con ellos. Para la realización de éste método voy a tomar como guía el trabajo hecho por Wadhawan, T., Hu, R. y Zouridakis, G. [31] donde desarrollan un método de clasificación para el “blue-whitish veil”. Aunque lo tomaré como referencia los pasos que siga no serán exactamente los establecidos, más tarde concretaré las diferencias.

El método que vamos a implementar se va a desarrollar en el software de programación Matlab.

La base de datos de imágenes dermatoscópicas que vamos a usar son 90 imágenes dermatoscópicas [32] compuestas por 60 imágenes de “blue-whitish veil” y 30 imágenes sin “blue”, de estas 30, 10 imágenes son “clark nevus” y 20 “dermal nevus”.

El método de clasificación lo vamos a dividir en dos etapas: clasificación local y clasificación global. Y, a su vez, estas dos etapas en otras dos, a saber: entrenamiento y prueba.

2.1 Clasificación a nivel local

En la clasificación local vamos a establecer la manera en la que vamos a analizar las imágenes y cómo vamos a procesarlas para conseguir segmentar las lesiones.

Vamos a usar características de color para el entrenamiento. En el estudio de referencia se trabaja con los espacios de color RGB, HSV, YUV y $O_1O_2O_3$.

2.1.1 Espacios de color

Los espacios de color que vamos a utilizar son :

- RGB :

Este espacio de color es el más usual, y se basa en la representación por separado del plano R (rojo), el G (verde) y el B (azul). Es una representación aditiva de colores, es decir, la suma de ellos da el color blanco. Cada uno de los planos está en el rango de enteros de 0 a 255, donde (255,255,255) sería blanco, el (122,122,122) gris, el (255,0,0) rojo puro, etc.

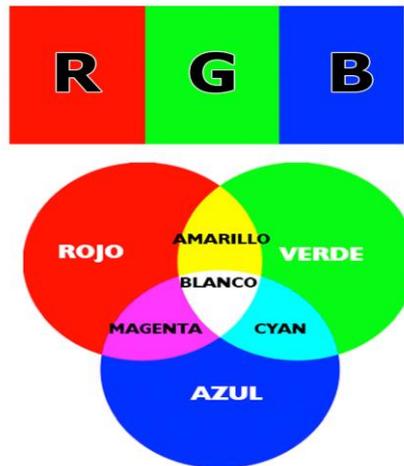


Figura 2-1. Representación del espacio de color RGB.

- HSV :

El espacio de color HSV está compuesto por el “Hue”, “Saturation” y “Value”, es decir, el matiz (o tono), la saturación y el brillo. Este espacio es conocido por ser un espacio que en su representación se acerca bastante a la percepción natural de los colores por el ser humano. El tono marca la longitud de onda predominante, es decir, si se establece como un color u otro. La saturación indica la mezcla con otros colores, es decir, la pureza, muy saturado significa muy puro, un color vivo. El brillo está relacionado con la intensidad o luminosidad del color [34].

Lo cual lo hace bastante interesante para el objetivo que perseguimos, y ya hemos visto que otros estudios también lo han considerado.

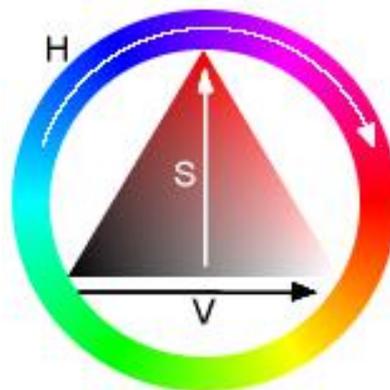


Figura 2-2. Representación del espacio de color HSV.

- YUV :

El espacio de color YUV está compuesto de la componente de luminancia Y (o luma) referida a la información en blanco y negro, y de las componentes de cromaticidad U y V, referidas a información sobre el color y que provienen de una relación con las diferencias R-Y y B-Y respectivamente. En sus comienzos este espacio de color fue diseñado para hacer compatible las por aquel entonces nuevas tecnologías de televisión en color con las antiguas de televisión en blanco y negro. Ya que permite enviar por separado información de blanco y negro (Y) e información de color (U,V). Todo ello siempre

referido de manera analógica, no digital. Mientras que en el sistema PAL se usa la transmisión YUV en el sistema NTSC se usa la YIQ, donde I y Q son equivalente a U y V. Es un espacio donde se acerca bastante su diseño al de la percepción humana, pero sin llegar a tanto como el anterior. En la Figura 2-3 se puede observar los valores para la crominancia, y cambiando la componente Y oscureceríamos o iluminaríamos más el plano.

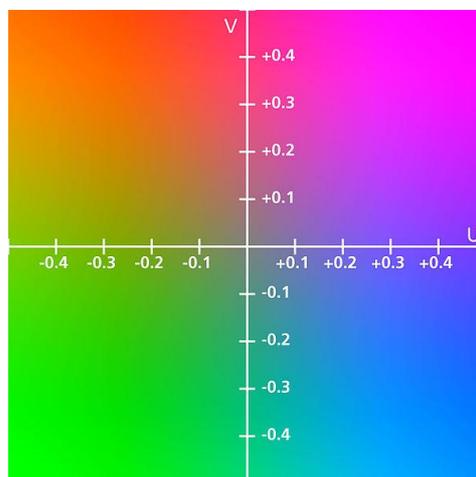


Figura 2-3. Representación del espacio de color YUV.

- O1O2O3 :

Quizás el menos conocido de los espacios de color comentados. Este espacio es conocido como el espacio de color oponente $O_1O_2O_3$. El canal O_1 corresponde con la luminancia. El canal O_2 , que se define como el canal rojo-verde, corresponde analíticamente con la diferencia entre el canal G y el R del espacio RGB ($O_2 = G - R$). El canal O_3 es el canal azul-amarillo, que analíticamente es la diferencia entre el canal azul y el amarillo, donde el amarillo es la suma del R y del G ($O_3 = B - (R + G)$). Es un espacio que generalmente trabaja bien en diferentes entornos.

2.1.2 Entrenamiento

En la parte de entrenamiento, a su vez, hay diferentes pasos a seguir. Antes que nada un preprocesado para preparar la imagen. Primero se realizará una segmentación de la lesión para extraer la lesión y obtener la región de interés (ROI). El segundo será una transformación de la imagen de entrada en RGB a los diferentes espacios de color anteriormente descritos. El tercero será seleccionar de esa ROI una serie de “patches” (bloques) que no se superpongan entre sí, de un determinado tamaño K . El siguiente y cuarto paso será extraer las características de color de esos “patches” a través del cálculo de sus histogramas y concatenarlos todos en una variable. Con estos datos, conseguir calcular los vectores de características F_i . Finalmente introduciremos éstos últimos en una SVM para el entrenamiento.

2.1.2.1 Preprocesado

Para la segmentación hemos realizado primero un preprocesado. Éste ha consistido en aplicarle una máscara o kernel (matriz de coeficientes) gaussiano a la imagen seleccionada, es decir, un suavizado gaussiano.

La máscara o kernel viene definido por la función gaussiana para dos dimensiones :

$$w(i, j) = \frac{1}{2\pi\sigma^2} \cdot e^{-\frac{i^2+j^2}{2\sigma^2}}$$

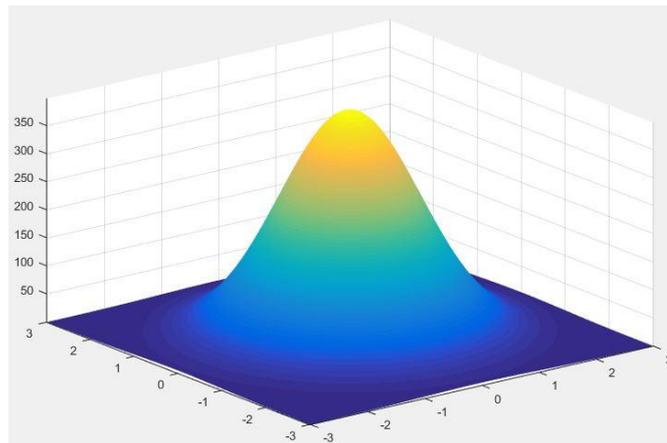


Figura 2-4. Representación en Matlab de una función gaussiana de dos dimensiones.

La aplicación de una máscara consiste en un proceso de convolución. Se inicia píxel a píxel aplicando la máscara gaussiana a cada píxel de la imagen y se hace una convolución con toda la vecindad del píxel principal y el mismo píxel principal y el resultado de esa convolución es el que sustituye el valor del píxel central.

	1	4	7	4	1
	4	16	26	16	4
$\frac{1}{273}$	7	26	41	26	7
	4	16	26	16	4
	1	4	7	4	1

Figura 2-5. Imagen de un ejemplo de Kernel Gaussiano con tamaño 5x5 y $\sigma = 1$.

Hemos elegido el filtro gaussiano porque es un tipo de filtro que mejora los resultados de otros filtros como el de la media o el de la media ponderada, da más peso (en términos de coeficientes) a los píxeles centrales, y menos a los más lejanos. También se puede modificar el grado de suavizado asignando distintos valores a la desviación típica (σ).

Este paso lo hacemos porque en algunas imágenes hay ruido, y al suavizarlas de manera sutil, conseguimos homogeneizar la imagen y que a la hora de segmentar no se segmenten elementos que no pertenecen a la lesión.

La máscara que hemos aplicado nosotros tiene tamaño de 10 y $\sigma = 2$, ya que permite eliminar bien ruido sin emborronar demasiado la imagen.

Mediante el comando “imfilter” aplicamos el filtro gaussiano creado anteriormente a cada plano. El resultado será el plano suavizado.

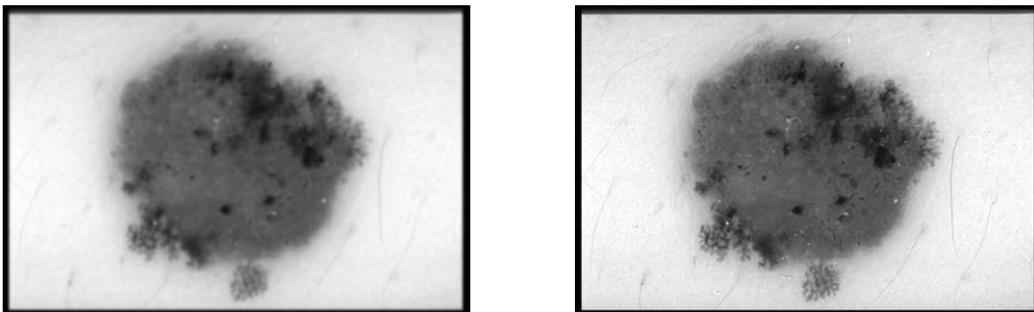


Figura 2-6. Plano R suavizado frente a plano R sin suavizado.

2.1.2.2 Segmentación

Lo primero que hemos realizado es una conversión a tipo de variable “double” (doble precisión en coma flotante) ya que al operar con los planos de color se necesita que estén normalizados y originalmente la imagen está en “uint8” (enteros sin signo de 8 bits). Hemos separado los planos de la imagen original, la cual es leída con “imread” y posteriormente sacamos los campos “R”, “G” y “B”. Para cada uno de los planos realizamos los siguientes pasos :

- 1) Definimos la manera de umbralización mediante Otsu. La umbralización mediante Otsu consiste en dividir en varias clases (en nuestro caso dos) y maximizar la distancia entre las respectivas medias de esas clases para discernir bien entre una u otra (equivalente a maximizar la varianza entre clases), es decir, maximizar :

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

Es decir, es un procedimiento mediante el cual se obtiene un umbral óptimo de acuerdo al criterio mencionado anteriormente. Esto en Matlab lo hemos implementado mediante la combinación de dos comandos:

Primero “graythresh” calcula el umbral óptimo de manera normalizada.

Posteriormente hay que pasar el umbral anterior al comando “im2bw”, que consigue poner en blanco y negro la imagen (segmentarla), usando el umbral obtenido por “graythresh”.

El resultado se invierte para que coincida el blanco con la lesión y el negro con la piel sana. Esto se hace para cada plano por separado, y más tarde se unen todos.

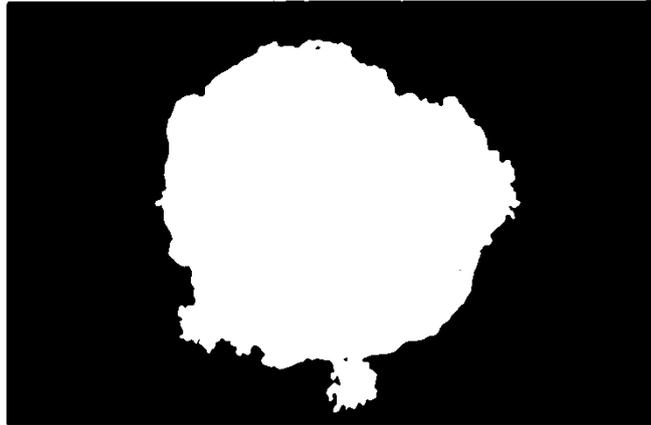


Figura 2-7. Máscara de la región segmentada, sin quitar bordes ni superponer la lesión segmentada.

- 2) El siguiente paso ha sido multiplicar la máscara por el plano que se está estudiando, quedando el resultado en niveles de gris de la siguiente forma :

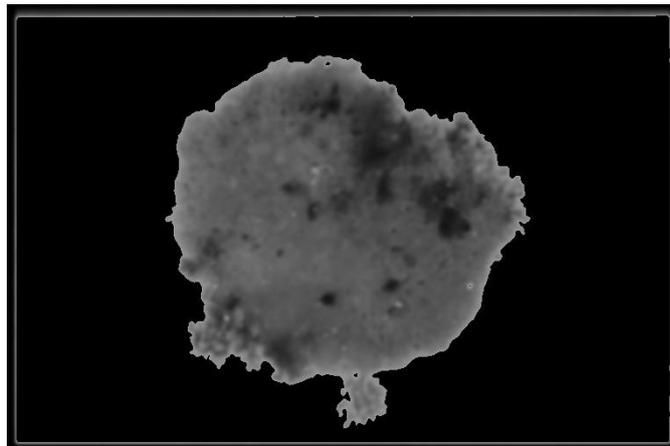


Figura 2-8. Segmentación con la lesión incluida y sin eliminar los bordes.

- 3) Por último para mejorar las imágenes hemos quitado el borde de éstas mediante un bucle “for” e introduciendo a partir de los píxeles con columnas menores de 20 y mayores a 725 y con filas mayores de 490, un cero en los píxeles de la imagen. Con resultado :

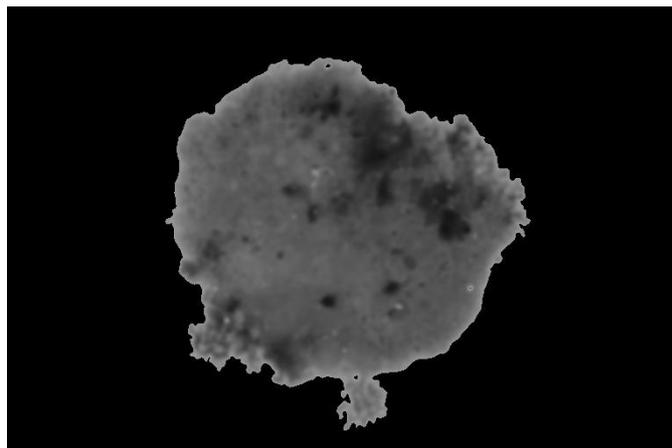


Figura 2-9. Segmentación final con bordes eliminados

- 4) Finalmente se unen todas las máscaras de los planos de color mediante AND para obtener una combinación de resultados.

2.1.2.3 Transformación a distintos espacios de color

El siguiente paso realizado ha sido la conversión a los distintos espacios de color propuestos en el trabajo.

- Para conseguir la conversión al espacio HSV, simplemente hemos usado el comando de Matlab “rgb2hsv”, hemos pasado cada plano de la variable resultante a variables por separado para obtener H, S y V.
- Para la conversión al espacio YUV hemos implementado la operación de relación entre RGB e YUV. Anteriormente teníamos los planos de RGB en “double” para poder operar con ellos. La relación es la siguiente :

$$Y = 0,299 \cdot R + 0,587 \cdot G + 0,114 \cdot B$$

$$U = 0,492 \cdot (B - Y)$$

$$V = 0,877 \cdot (R - Y)$$

- Para pasar a $O_1 O_2 O_3$ hemos realizado un paso similar al anterior teniendo en cuenta la relación existente entre este espacio y el espacio de RGB. Esa relación es :

$$O_1 = \frac{(R - G)}{\sqrt{2}}$$

$$O_2 = \frac{(R + G - 2 \cdot B)}{\sqrt{6}}$$

$$O_3 = \frac{(R + G + B)}{\sqrt{3}}$$

El siguiente paso que hemos realizado es el paso anteriormente comentado de la segmentación pero para todos estos nuevos espacios de color, es decir, para cada plano de cada espacio.

2.1.2.4 Extracción de bloques

A continuación lo que vamos a hacer será extraer los bloques o “patches” de las segmentaciones de los planos de color.

Para este punto lo primero que se considera es el tamaño de los bloques que vamos a extraer. Para poder discernir junto a la imagen original, ayudándose también de las coordenadas del bloque, donde se encuentra dicho bloque y poder decir si es o no es de “blue-whitish veil” se eligió un tamaño de $K = 40$ (40x40 píxeles), suficientes para ver si es una zona u otra, no demasiado grande para tener un mayor número de muestras y de un tamaño bueno para analizar características representativas.

Sobre la implementación en Matlab:

Para cada plano definimos una variable “bloque” de ceros y de tamaño 40x40 donde guardaremos los píxeles extraídos de ese bloque. También vamos a definir ya unas variables “MH” (Matriz de Histogramas), una para cada plano, donde guardaremos los histogramas concatenados (poner uno detrás del anterior y así sucesivamente) de cada bloque.

Ahora recorreremos la imagen completa mediante un doble “for” de 40 en 40 y vamos comprobando que las cuatro esquinas del posible bloque sean distintas de cero, es decir, estén dentro de la segmentación y por tanto sean parte de la lesión de interés.

Si se cumple que todas son distintas de cero, entonces a cada variable “bloque” de cada plano, le asigno los píxeles respectivos de la segmentación de cada plano.

2.1.2.5 Extracción de características

Para la extracción de características, dentro del mismo bucle anterior, lo que se hizo fue usar el comando “imhist” para calcular el histograma del bloque. Al ser bastantes características (12 planos de color) decidimos establecer para el histograma una división en 10 bins, ya que un número mayor tendría un mayor coste computacional y también una mayor complejidad a la hora de realizar el entrenamiento y la clasificación.

Sobre la implementación en Matlab:

Para obtener el histograma tuvimos que pasar los bloques de “double” a “uint8” previamente habiéndose multiplicado todos los píxeles por 255 (para escalarlos antes de convertirlos y que estén en el rango de 0 a 255).

El resultado dado por “imhist” fue, tanto el número de píxeles en cada intervalo, como los intervalos (“bins”). El dato interesante para nosotros era el número de píxeles en cada intervalo, por lo que el siguiente paso fue concatenar el número de píxeles en cada intervalo con la matriz de histogramas, así, para cada bloque, se irían rellenando las variables de “MH” con los números de píxeles en cada intervalo.

Este paso anterior se hace para cada plano, y finalmente se vuelven a poner a cero las variables de los bloques, para poder rellenarse con el bloque siguiente y así termina el bucle.

2.1.2.6 Definición del vector de características

Para este punto voy a seguir la notación del estudio [31], donde cada 'F' será un vector de características compuesto de una fila y 120 columnas, y el subíndice 'i' corresponderá a cada bloque o "patch".

La obtención del vector de características, o F_i , se realizó usando el bucle anterior para obtener todos los patches de las imágenes. Es decir, una F_1 se compondría de todos los valores del histograma de ese primer bloque para todos los planos de color, una F_2 sería para el segundo bloque y así sucesivamente.

En este punto primero se establecieron los bloques elegidos para el entrenamiento con "blue-whitish veil" y más tarde los "no blue-whitish veil". Como la variable final que tenemos que formar para introducirla en la SVM es una matriz, con columnas las características (intervalos de los espacios de color) y con filas los vectores de características (F_i), al haber 12 planos de color y 10 bins o intervalos por cada uno eso crea una matriz de 120 columnas y por tanto, para que haya un buen entrenamiento es necesario un numero mayor de filas (observaciones). De ahí que se hayan elegido 150 bloques de cada clase (blue y no blue), equivalente a 300 filas, para mejorar el resultado del entrenamiento.

Las variables con los recortes o "patches" de las diferentes clases "blue" y "no blue", se guardaron externamente mediante el comando "save" para poder cargarlas en los archivos futuros sin interferir con otras variables y no tener tantas variables en memoria al mismo tiempo.

2.1.2.7 SVM

Tampoco es nuestro objetivo centrarnos en el interior de los algoritmos de clasificación ni en su desarrollo, pero es conveniente una introducción al algoritmo el cual nos vamos a centrar en el presente trabajo.

Las SVM's o máquinas de soporte vectorial tienen como objetivo final discernir si el elemento introducido es de una clase o de la otra clase (es un clasificador binario). Para ello lo primero que hace es con los elementos de entrada (datos de entrenamiento) traza la distribución de los elementos del mismo tipo, es decir, mapea, a un espacio de una dimensión mayor. Esto lo hace para encontrar un hiperplano óptimo que consiga separar las dos clases maximizando la distancia entre ellas. Para encontrar ese hiperplano con esa distancia óptima (mayor) usa los denominados vectores de soporte, que no son más que algunos datos de entrada, los más representativos para el cálculo de la distancia. Para entenderlo mejor, de acuerdo al caso de \mathcal{R}^2 sería :

Hay dos casos posibles : Conjunto linealmente separable y no linealmente separable [38]

- Conjuntos linealmente separables :

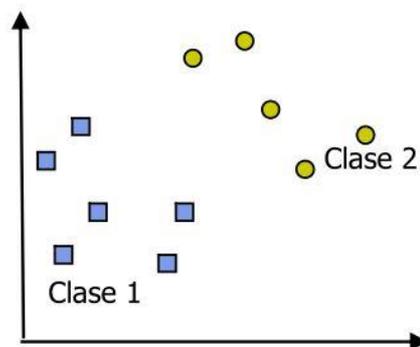


Figura 2-10. Caso linealmente separable.

En el caso de conjunto linealmente separable, como hemos dicho antes, se busca el hiperplano óptimo para separar ambas clases, esto se hace cogiendo los datos de entrada, que cada uno tienen una etiqueta distinta (1 y -1) y en un espacio de características mayor \mathcal{R}^N (se aumenta ‘N’) se distribuyen los elementos del mismo tipo. Se crea un hiperplano, en el caso de \mathcal{R}^2 una recta, que separa ambas clases, y donde se busca que la distancia entre ellas sea la mayor posible usando los vectores de soporte [38].

- Conjuntos no linealmente separables :

En el caso de conjuntos no linealmente separables, como se aprecia en la figura 2-10, no es tan trivial. Al no haber una separación directa entre los distintos elementos hace falta introducir nuevos cambios y variables. Se introduce la variable no negativa $\xi_i \geq 0$ para los ‘i’ elementos, que indica el error al clasificar cada elemento, ya que se considera que no se puede, en este caso, clasificar sin error. Se busca por tanto minimizar estos errores [38].

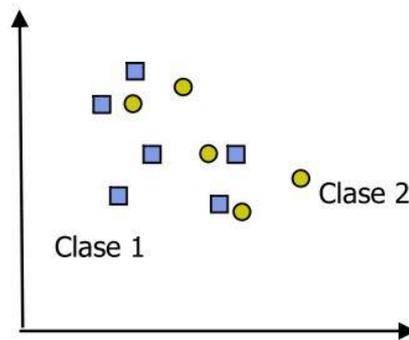


Figura 2-11. Caso no linealmente separable.

Para solucionar este caso también hay un cambio en el procedimiento, y es que se introduce una función kernel para poder separar las clases como si fuera un caso linealmente separable. Esto lo que hace es aplicar una transformación a los datos y consigue separarlos de una manera más sencilla.

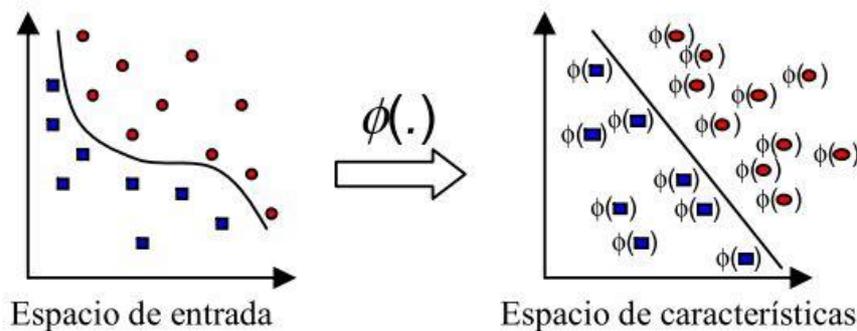


Figura 2-12. Idea del uso de un *kernel* para la transformación de los datos.

Como ya hemos visto, la SVM es un algoritmo de clasificación que tiene como objetivo discernir entre una clase u otra a partir de una serie de datos. En esta parte del entrenamiento lo que queremos hacer es entrenar una SVM a partir de los datos que hemos adquirido con los bloques elegidos (tanto blue como no blue) y a partir de ellos que la SVM aprenda correctamente a separar entre un bloque con “blue” y uno sin “blue”.

Para hacer esto en Matlab hemos seguido varios pasos :

- Primero hemos definido una variable que indique (con conocimiento previo) si es una observación de “blue-whitish veil” o no. La variable es “VectorDecision”, la hemos definido como un vector columna con 300 filas (nº de observaciones). Esta variable tiene los valores 1 (blue) y -1 (no blue). Hemos seleccionado uno por uno los “patches” mejores para el entrenamiento, evitando imperfecciones de las imágenes como pompas, pelos, reflejos, y “patches” mal definidos, y hemos rellenado los 150 primeros con blue y los 150 restantes con no blue.
- El siguiente paso ha sido definir la matriz que introduciremos en la SVM para su entrenamiento, “DatosEntrenamiento” con tamaño 300x120 (300 observaciones y 120 columnas con una característica por columna) y cargar mediante el comando “load” las variables donde teníamos los bloques con blue del archivo anterior (previamente guardadas con el comando “save”). Estas variables las hemos traspuesto para que coincidan las filas con los bloques y las columnas con las características. Hemos creado una matriz donde incluir todas esas variables por orden, “MHBLUE” donde mediante el comando “horzcat” hemos concatenado horizontalmente y hemos creado la matriz de donde cogeremos los bloques que nos hayan resultado interesantes para el entrenamiento y que tengan blue. Ahora mediante un “for” hemos recorrido la matriz y hemos guardado en “DatosEntrenamiento” sólo los bloques que anteriormente habíamos seleccionado como interesantes para el entrenamiento
- A continuación hemos hecho lo mismo exactamente pero con las variables que tenían los bloques de no blue. Hemos definido en este caso la variable como “MH” y mediante “horzcat” hemos concatenado horizontalmente las otras variables. Exactamente igual, hemos recorrido la matriz y hemos ido guardando dentro de “DatosEntrenamiento” los bloques que nos habían parecido buenos para el entrenamiento de la SVM.
- Una vez completados los datos para el entrenamiento, lo siguiente ha sido usar el comando “fitcsvm” para poder entrenar la SVM pasándole como argumentos :
 - a) La variable “DatosEntrenamiento” con todas las observaciones.
 - b) La variable “VectorDecision” con la asignación de cada observación a cada clase.
 - c) El parámetro opcional “PredictorNames”, para nombrar de manera distinta a cada una de las columnas, ya que al tener tantas características, nos interesa mantener un orden.

2.1.3 Prueba

En el apartado de prueba, lo que haremos será coger los datos de entrenamiento que antes hemos seleccionado y también cogeremos el modelo de SVM entrenado en el apartado anterior. Uniremos ambos para conseguir una clasificación para cada bloque de si es “blue” o no lo es.

En el código lo que hemos implementado ha sido :

- Primero, hemos cargado una variable mediante “load” de otro archivo que previamente habíamos guardado con “save”, “MHT” (Matriz de Histogramas Totales) donde en él hemos seleccionado de las imágenes en la carpeta de prueba para la clasificación local, “patches” concretos de blue y no blue, todos los “patches” que podemos obtener de esas determinadas imágenes con objetivo de ser las muestras usadas para la clasificación.
- El siguiente paso ha sido pasar estas variables a “double” y, como hemos sacado una variable “MHT” por cada plano de color, sustituir cada variable por su traspuesta (para que coincida columnas con características y filas con observaciones).
- A continuación hemos creado una variable “MHT” con la concatenación horizontal (mediante “horzcat”) de todas las variables de los planos de color anteriores.
- Por último, con el modelo entrenado en el paso de entrenamiento anterior al que hemos llamado “ModeloSVM”, y con las nuevas muestras a clasificar “MHT”, clasificamos

llamando al comando “predict”. Nos devuelve la variable “Prediccion”, donde por cada observación (fila o “patch”), nos indica mediante la etiqueta (1 o -1) si es “blue” o “no blue” respectivamente.

2.1.3.1 Cálculo de la probabilidad de error

En este apartado simplemente vamos a tener dos elementos. Por un lado las etiquetas reales de cada bloque, que las hemos extraído bloque a bloque observando los 300 bloques, decidiendo si es realmente o no “blue”. Por otra parte tenemos las etiquetas de la predicción hechas por nuestro clasificador entrenado en la fase de prueba. Vamos a comparar ambas y vamos a calcular la probabilidad de error existente.

En término de implementación en Matlab :

Para calcular la probabilidad de error primero hemos definido una variable “TagReal”, donde se incluirán las etiquetas reales de esos “patches”, previamente observados uno a uno para discernir si es o no “blue”.

Más tarde lo que haremos será sumar esta última variable con los patches correspondientes de la predicción dada por la clasificación. Al sumar, como las etiquetas son o 1 o -1, si el resultado es cero querrá decir que ambas etiquetas eran contrarias, en otro caso, querrá decir que son coincidentes.

Esto último en el código lo hemos realizado sumando ambos vectores y denominando a la variable “Error”.

Lo siguiente que hemos hecho ha sido definir una variable “numzeros” e igualarla a cero. Esta variable nos contará el número de etiquetas erróneas que tenemos en estos patches al recorrer la variable “Error”. Hemos seleccionado 300 patches de la carpeta de prueba, definiendo la etiqueta real (“blue” o no) uno a uno, para comprobar la efectividad del método.

Por último calculamos la probabilidad de error dividiendo el número de ceros entre el número de elementos que tenemos (300).

2.1.4 Selección de características

Recordamos que tenemos 120 características (10 por cada plano de color y 12 planos), por tanto, es capital hacer una selección de características y quedarnos con las mejores, ya que si no, sería necesario para un mejor método muchas más observaciones y todo eso incrementaría además el coste computacional del algoritmo y disminuiría su eficiencia.

Para realizar esto, nos hemos basado en la selección de características hacia adelante o SFS. Esta consiste en que se van introduciendo las características una por una y se va viendo si mejora o empeora el modelo.

En el software Matlab se encuentra la instrucción “sequentialfs” para realizar selección de características SFS (“Sequential Forward Selection”), aunque nosotros lo hemos realizado manualmente. En vez de introducir una a una manualmente hemos introducido las 10 características correspondientes a un histograma de un plano de color.

La selección de características la hemos implementado con la siguiente metodología. Hemos realizado varias selecciones, y varios pasos, buscando la menor probabilidad de error. Los pasos han sido :

- 1) Primero hemos introducido las 120 características y hemos calculado la probabilidad de error, dando ésta 0,4. Este paso es simplemente para expresar como dato la eficiencia del modelo con todas las

características. En los siguientes pasos buscaremos optimizar y evitar características que hacen que empeore la clasificación.

- 2) Como segundo paso, hemos incluido de diez en diez, es decir, cada plano de color (plano R : de R_1 hasta R_{10}) y por cada plano introducido hemos calculado la probabilidad de cada plano de color por separado, siendo el plano H el que mejor resultado mostró.
- 3) El tercer y último paso de selección fue introducir las posibles combinaciones del plano H con los demás planos y calcular la probabilidad, así con cada una. La combinación que mejor resultado nos aportó fue la del plano H con el plano B, es decir, HB. Finalmente seguimos iterando intentando encontrar la siguiente combinación posible, pero ninguna ofrecía mejor o igual probabilidad de error, todas la empeoraban, de ahí que eligiéramos finalmente la combinación de 20 características HB.

En conclusión, el paso que finalmente nos desveló la mejor combinación de características fue el tercero, ya que se consigue una mayor optimización al tener una probabilidad de error baja y también por tener solamente 20 características, una disminución considerable teniendo en cuenta las 120 iniciales.

2.1.5 Cálculo de la sensibilidad y especificidad

Como bien hemos comentado en el capítulo de introducción del presente trabajo, los datos de sensibilidad y de especificidad son fundamentales para determinar el rendimiento de este tipo de algoritmos.

Para el cálculo de estos parámetros en nuestro método, hemos realizado varios pasos.

Hemos definido las variables de sensibilidad y especificidad. Hemos definido una variable por cada elemento que interviene en el cálculo de éstas, es decir, “VP” (verdaderos positivos), “FN” (falsos negativos), “VN” (verdaderos negativos) y “FP” (falsos positivos). Hemos recorrido ambos vectores simultáneamente “TagReal” y “Prediccion”, comparando los valores. Si ambos son 1 incrementamos la variable “VP”, si ambos son -1 aumentamos “VN”, si la verdadera es 1 y la predicción -1 aumentamos “FN” y si la verdadera es -1 y la predicción 1 incrementamos “FP”.

Por último aplicamos la definición de sensibilidad y especificidad :

$$Sensibilidad = \frac{VP}{VP + FN}$$

$$Especificidad = \frac{VN}{VN + FP}$$

2.2 Clasificación a nivel global

En esta otra parte del método, lo que vamos a clasificar es la imagen completa, no por “patches” o bloques como la clasificación anterior. Es decir, al final dirá si una imagen tiene “blue-whithish” o no, pero no bloque a bloque. Se usan dos aproximaciones, basadas en :

- Crear una distribución de probabilidad a partir de los resultados del local
- Ver las marcas de color de los vecinos.

2.2.1 Clasificación con distribución de probabilidad

En este tipo de clasificación, lo que vamos a usar es la probabilidad, y también los histogramas de esas probabilidades para conseguir clasificar las imágenes como “blue” o no.

2.2.1.1 Entrenamiento

Para el entrenamiento en la clasificación global hacemos los mismos pasos que hemos realizado en el entrenamiento de la clasificación local, pero incluimos los siguientes puntos.

2.2.1.1.1 Cálculo de la probabilidad de patch

En este nuevo apartado lo que hacemos es calcular la probabilidad de cada bloque de pertenecer o no a un bloque con “blue”. Para eso nos ayudamos del modelo realizado en la clasificación local, ya que es a nivel de “patch”. Usando el modelo de la clasificación local, obtenemos la probabilidad de cada “patch” para cada imagen de entrenamiento global.

Esta probabilidad se calcula en nuestro algoritmo de la siguiente forma :

Definimos una matriz de imágenes “MHG” (**M**atriz de **H**istogramas **G**lobales), en la cual lo que tendremos es el resultado de haber recorrido la imagen de entrenamiento y haber sacado todos sus “patches”, concatenados horizontalmente de manera que se corresponda las filas a “patches” u observaciones y las columnas a las características. Esto es como en la metodología de la clasificación local.

El siguiente paso es cargar el modelo hecho anteriormente (“ModeloSVM”) para la clasificación local, es decir, el modelo que habíamos creado para clasificar en local, donde previamente lo habíamos guardado con el comando “save” lo cargamos ahora con “load”.

Para la obtención de la probabilidad posterior, o lo que es lo mismo, la probabilidad en clasificación de cada “patch”, hemos hecho uso del comando de Matlab “fitSVMPosterior” pasándole como argumento de entrada nuestro “ModeloSVM”. Este comando te permite entrenar un modelo donde te da la posibilidad de obtener (con “predict”) la probabilidad de clasificación tanto de que sea verdadero (“blue”) como de que sea falso (“no blue”). El uso de este comando nos devuelve un modelo, que hemos llamado “ScoreSVMModel”.

Este último modelo devuelto lo introducimos en “predict”, junto con las veinte características que conseguimos aislar con un buen resultado en la clasificación local. El resultado devuelto es doble, primero la predicción con las etiquetas predichas, y segundo una matriz con filas igual al número de “patches” y columnas, la primera con la probabilidad de pertenecer a la clase negativa (no “blue”) y la segunda con probabilidad de pertenecer a la clase positiva (“blue”).

Por último nos quedamos con la segunda columna y denominamos al vector “ProbBlue”. Con lo que en esta variable tendremos guardados los valores, en términos de probabilidad, de pertenencia a la clase “blue” de todos los “patches” analizados en la lesión.

2.2.1.1.2 Construcción de un histograma global para la imagen

El objetivo en este apartado es crear un histograma a partir de las probabilidades calculadas en el apartado anterior. Con esto se consigue un histograma donde los valores son las probabilidades.

Para la implementación en Matlab :

Para la construcción de un histograma global hemos hecho uso de la función de Matlab “histogram”.

A esta función le hemos pasado como primer parámetro el vector “ProbBlue”, y como segundo parámetro el número de “bins” o intervalos que queremos que lo divida, hemos puesto en este último 10, ya que se consigue buena apreciación con pocos recursos.

2.2.1.1.3 Construir el histograma de probabilidad para todas las imágenes del ‘training set’

En este apartado vamos a recorrer nuestra carpeta de entrenamiento, donde hemos escogido 10 imágenes sin “blue” y otras 10 con “blue”. Para cada imagen vamos a calcular el recuento de todos los patches que se encuentran entre unas determinadas probabilidades. Con lo que finalmente tendremos el número de “patches” en cada intervalo del histograma, es decir, en cada región en función de la probabilidad, la cantidad de “patches” que tienen esas probabilidades. Al fin y al cabo es agrupar los patches con esas mismas probabilidades en un histograma.

Para conseguir el objetivo de este punto, hemos primero definido una carpeta con 10 imágenes de “blue” y otras 10 imágenes de no “blue” para realizar el entrenamiento.

Para las imágenes de ‘training’, nos interesaban incluir imágenes que en su conjunto fueran claramente de una clase u otra. Debido a que en la clasificación global nos fijamos en histogramas de imágenes en vez de en “patches” concretos, las imágenes también debían tener un histograma claramente definible como “blue” o no “blue”, por lo que la selección de imágenes aptas para el entrenamiento se hizo más compleja.

La implementación en Matlab ha sido la siguiente :

Hemos incluido en el código una bandera denominada “imagen”, que hace referencia al número de imagen de la carpeta de entrenamiento que corresponda en ese momento, y vamos incrementándola en cada iteración. Esta bandera nos vale para, según la imagen correspondiente, calcular el valor analítico de su histograma para poder incluirlo en la SVM, ya que de por sí, el histograma devuelto por el comando “histogram”, permite acceder a datos individuales (probabilidades) pero no al conjunto que nos interesa (“patches” en cada intervalo).

Para calcular esto hemos implementado en Matlab lo siguiente. Primero vemos el número de imagen (comprobando la bandera “imagen”), después hemos definido una variable “HistogramaImagen”, una por cada imagen, que serán las características que introduciremos a la SVM. Esta variable no será más que el recuento de “patches” en cada intervalo. Hemos creado un bucle “for” y en él recorreremos hasta la longitud de todos los datos individuales devueltos por “histogram” (length(Hist.Data)). Conforme vamos recorriendo, vamos comprobando si se encuentra el dato en un intervalo u otro, uno por uno, es decir, si está entre 0 y 0.1, o entre , 0.1 y 0.2 y así sucesivamente. Y vamos incrementando la variable “HistogramaImagen” en cada columna en función del intervalo que se trate.

Finalmente, lo que tendremos será una variable de una fila y 10 columnas, donde en cada columna estará el recuento de “patches” en cada intervalo del histograma correspondiente.

Una vez que tenemos una variable como ésta por cada imagen, es decir, el recuento de “patches” por cada imagen, tenemos el objetivo de este apartado, un histograma de probabilidad (G_i), donde ‘i’ hace referencia a cada imagen.

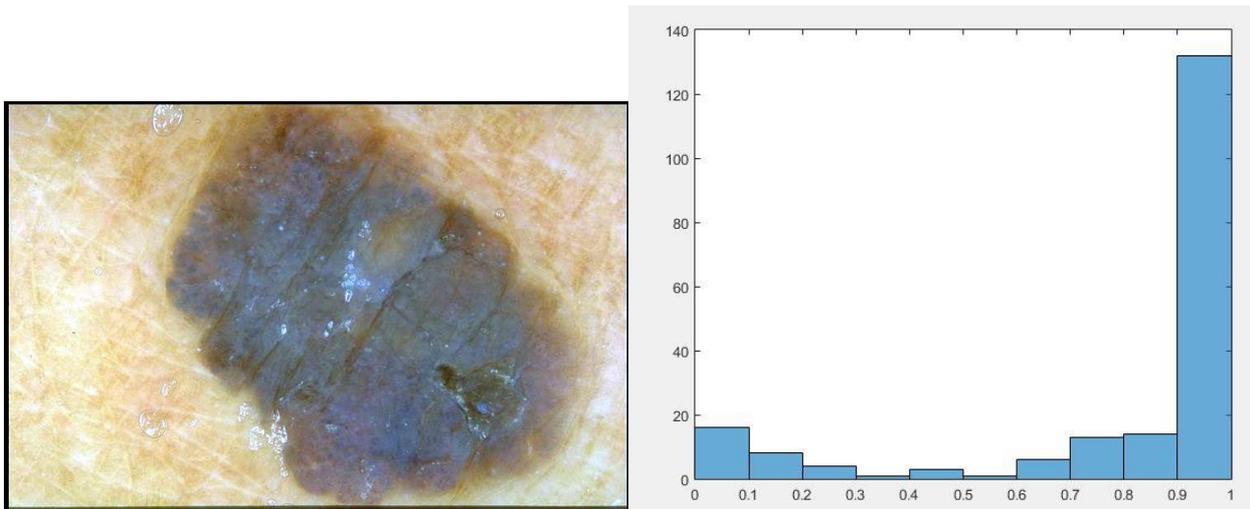


Figura 2-13. Ejemplo del histograma de probabilidades para una imagen de entrenamiento global.

Como se puede observar en la imagen queda reflejado con bastante claridad, en este caso, si se compone de “blue-whitish” o no, solamente viendo la cantidad de “patches” con muy alta probabilidad (unos 135 aproximadamente) frente a los demás con menos probabilidades de serlo. En otras imágenes con menos extensión de “blue” o más pequeñas, puede no ser tan evidente.

2.2.1.1.4 Entrenamiento de la SVM con los histogramas de probabilidades como características

En este punto lo que se realiza es el entrenamiento del clasificador SVM con todos los histogramas de probabilidades de las imágenes de entrenamiento. Aparte de estos histogramas, para el entrenamiento también usaremos las etiquetas reales de cada imagen, sabiendo cuáles de ellas son de “blue” y cuáles no.

El objetivo aquí es conseguir terminar el entrenamiento obteniendo el hiperplano devuelto por la SVM, para aplicarlo en el siguiente punto y poder tener el modelo final entrenado.

En este apartado, en términos de implementación, hemos realizado lo siguiente :

Lo primero que hemos hecho ha sido definir un vector columna, el cual nos servirá de referencia para entrenar, denominado “VectorDecisionGlobal”, donde hemos incluido las etiquetas de las imágenes de entrenamiento (-1 para imágenes sin “blue” y 1 para imágenes con “blue”).

El siguiente paso ha sido usar el comando “vertcat” (concatenación vertical), para poder crear una única variable de datos que pasarle a la SVM. Esta variable de datos la hemos llamado “Gi”. “Gi” está formada por 20 filas (una por imagen) y por 10 columnas (una por característica introducida o intervalo de histograma), que ha sido formada concatenando verticalmente las variables “HistogramaImagen” de cada una de las imágenes.

Para entrenar el modelo hemos usado el comando “fitsvm”, al cual le hemos introducido una primera variable de datos (“Gi”) y una segunda de referencia “VectorDecisionGlobal”.

El modelo devuelto y entrenado lo hemos denominado “ModeloSVMGlobal”, y lo hemos guardado en un archivo .mat con “save”.

2.2.1.2 Prueba

El objetivo ahora es poder clasificar imágenes según el modelo entrenado con anterioridad para poder discernir en función de los histogramas de probabilidad si una imagen en su conjunto es o no (o en qué porcentaje) “blue”.

Para empezar, vamos a comentar la base de datos de “test”. Hemos definido una base de datos para la prueba compuesto por 10 imágenes de “blue” y otras 10 imágenes de no “blue”, ambas distintas de las imágenes de entrenamiento. La base de datos no la hemos podido definir más extensa, debido a varios factores en relación a las imágenes no “blue” :

- De las imágenes sin “blue” solamente tenemos 30.
- 10 las hemos usado para el entrenamiento, y por tanto no valen para la clasificación.
- De las 20 restantes, hemos seleccionado las 10 más destacables o que podrían ser más comprometedoras, ya que tienen algunas características que pueden resultarles más complejas al modelo a la hora de clasificar y el resultado será más real. De las otras 10 había imágenes que el método no ha conseguido segmentar de una manera eficiente por no ser muy definidas, y otras que al ser prácticamente marrones se hubiesen clasificado sin ninguna dificultad, por tanto esas 10 las hemos descartado.
- Con la prueba se pretende tener una visión global, y por ello he querido que fueran el mismo número de imágenes de “blue”, que de no “blue”.

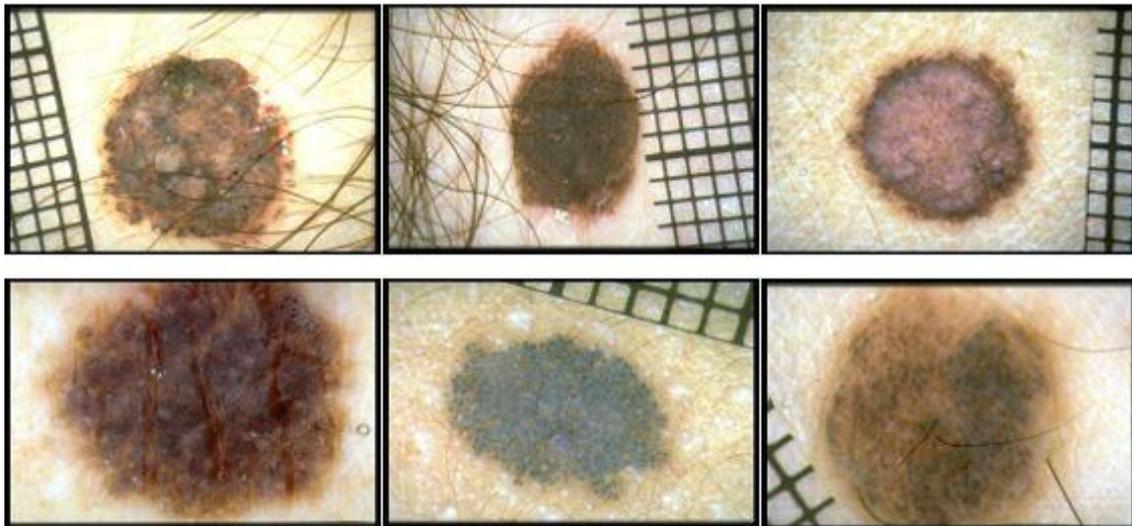


Figura 2-14. Ejemplo de 6 de las 10 imágenes usadas para la prueba en global.

En la figura están algunas imágenes usadas para la prueba del método de clasificación global, como puede verse, son imágenes que tienen algunos tonos en la lesión o características que pueden entrar en conflicto con la clasificación del “blue-whitish veil”, lo hemos hecho así para que realmente sean más representativos los resultados.

En torno a la implementación en Matlab, en este punto se realizan muchos pasos anteriores, ya que hay que volver a segmentar, sacar los histogramas de los “patches”, determinar sus probabilidades y realizar un histograma de probabilidades idénticamente a los realizados en pasos anteriores, por lo que obviaré el comentario de implementación, ya que es prácticamente reciclar el código del entrenamiento.

A la hora de clasificar, simplemente hemos ido introduciendo para cada imagen el vector de características de

histogramas junto con el modelo global entrenado en el punto anterior. Con la predicción iremos observando a qué imágenes le asigna “blue” y a cuáles no. Por último se calculará el error, la sensibilidad y la especificidad, conociendo previamente que imágenes son “blue” o no.

La implementación de este apartado en Matlab ha sido la siguiente :

Hemos cargado con “load” el modelo entrenado en el punto anterior. A continuación hemos introducido el modelo anterior en “fitSVMPosterior” lo hemos introducido en el comando “predict” como primer parámetro, y como segundo hemos metido la variable “Hi”. Como valores devueltos sacamos tanto la predicción de la imagen “PrediccionGlobal”, como la probabilidad de que esa imagen sea o no “blue”, “ProbGlobal”. De esa “ProbGlobal” nos quedamos con la segunda columna (la que tiene la probabilidad de que sea “blue”), ésta será la probabilidad de que la imagen tenga “blue-whitish veil”.

En el bucle donde recorreremos la base de datos de prueba, hemos definido una variable “imagen” para saber a cuál de las imágenes de la base de datos corresponde. Hemos definido también otra, “PrediccionTEST”, como vector columna, con una fila para cada imagen que servirá para determinar las predicciones de las 20 imágenes.

El planteamiento a seguir es el siguiente. El bucle va pasando por las imágenes de la base de datos de prueba, la variable imagen indica que imagen es, en función de la imagen que sea se coloca en una fila u otra de la variable “PrediccionTEST” la salida de la predicción de la SVM, “PrediccionGlobal”.

Para el error hacemos lo mismo que en local, sumamos las etiquetas reales y las predecidas. En la variable resultado buscamos los ceros (“fallos”) y los dividimos entre el número de elementos para calcular la probabilidad de error.

Para la sensibilidad vamos recorriendo los vectores de predicción y los de etiquetas reales y vamos comparando para ver si coinciden en que es “blue”(VP), que ha predicho que era y no era (FP), que ha predicho que no era y era (FN) y que ha predicho que no era y no era (VN).

Todo ello lo incluimos en las fórmulas anteriormente descritas de la sensibilidad y la especificidad y calculamos sus valores.

2.2.2 Clasificación global de la imagen según la clasificación local de los bloques

Según marca el estudio [31] ,en esta clasificación no haremos uso de la SVM, ya que simplemente nos fijaremos en los patches de la imagen y en su probabilidad, si uno o más de los patches está marcado como “blue”, entonces marcaremos a esa imagen como blue sin importar lo demás. Si no hay ninguno marcado como “blue”, no se marcará la imagen como “blue”.

Aparte del método original, hemos realizado una modificación para cinco bloques, no sólo uno, ya que con cinco es más representativo el resultado final. En el siguiente capítulo veremos los resultados.

En este apartado he obviado la implementación en Matlab por ser demasiado básica.

3 RESULTADOS

En este capítulo vamos a mostrar los resultados obtenidos tanto en la clasificación local como en la global, así como las respectivas comparaciones respecto al artículo original [31] por el cual nos hemos guiado para realizar el presente trabajo.

3.1 Resultados en la clasificación local

En la clasificación local hemos realizado varios pasos para el análisis de características en modelos distintos de entrenamiento buscando la máxima optimalidad en ellos.

3.1.1 Resultados en la selección de características

- Como primer paso probamos la clasificación introduciendo las 120 características, es decir, desde R_1 hasta $O_{3_{10}}$ (120 características), nos dió una probabilidad de error de 0,4. Debido a que la probabilidad se puede mejorar y principalmente, que el número de características empleado es muy elevado, seguimos el procedimiento para encontrar las características óptimas.
- En el segundo paso hicimos varios análisis a los planos de espacios de color por separado y obtuvimos los siguientes resultados :

ANÁLISIS POR PLANOS	PROBABILIDAD DE ERROR
<i>R</i>	0,3
<i>G</i>	0,37
<i>B</i>	0,31
<i>H</i>	0,2
<i>S</i>	0,26
<i>V</i>	0,5833
<i>Y</i>	0,3833
<i>U</i>	0,3433
<i>V</i>	0,62
<i>O₁</i>	0,4033
<i>O₂</i>	0,2667
<i>O₃</i>	0,5067

Tabla 3-1. Resultados en el segundo paso de selección de características.

Como podemos observar, el mejor resultado es el plano H con una probabilidad de error de 0,2 con 10 características. En nuestros resultados es un plano muy representativo.

- En el tercer paso, hemos incluido a ese plano H, otro plano en el cual no empeore la probabilidad de error anterior. Hemos realizado todas las combinaciones posibles del plano H con los demás planos, y los resultados son los siguientes :

COMBINACIÓN	PROBABILIDAD DE ERROR
HR	0,4967
HG	0,4533
HB	0,16
HS	0,4367
HV	0,4967
HY	0,2067
HU	0,1667
HV*	0,1633
HO ₁	0,1633
HO ₂	0,1667
HO ₃	0,2133

Tabla 3-2. Resultados en el tercer paso de selección de características.

(El símbolo * hace referencia al plano de color V del espacio YUV)

Como puede observarse en los resultados, la combinación con el plano H que mejor resultado dió fue la combinación HB, la cual disminuyó y no empeoró la probabilidad de error conseguida en el plano H. Por tanto, lo que tenemos ahora son 20 características que nos dan una probabilidad de error de 0,16.

- El siguiente paso, como cabía esperar, es comprobar si la combinación de ambos planos anteriores con un plano adicional sigue estando con la misma o mejor probabilidad de error. Hemos seguido haciendo combinaciones, en este caso de 30 características. Éstas han sido :

COMBINACIÓN	PROBABILIDAD DE ERROR
HBR	0,17
HBG	0,2433
HBS	0,5
HBV	0,21
HBY	0,38

HBU	0,1633
HBV*	0,1633
HBO₁	0,19
HBO₂	0,1733
HBO₃	0,3733

Tabla 3-3. Resultados en el cuarto paso de selección de características.

(El símbolo * hace referencia al plano de color V del espacio YUV)

A raíz de los resultados puede observarse que no hay ninguna combinación adicional posible que siga mejorando e incluso iguale la probabilidad de error conseguida. Debido a esto, hemos decidido quedarnos con las 20 características anteriores y una probabilidad de error de 0,16.

Dentro de estas 20 características hemos hecho muchas combinaciones entre las 20 características buscando la combinación más óptima para construir el modelo. Hemos buscado esta combinación atendiendo al método SBS. Con las 20 características, en cada iteración, hemos ido quitando la que daba peor resultado y así sucesivamente. Finalmente ninguna de estas combinaciones ha resultado con menor probabilidad de error que con los dos espacios combinados, por tanto hemos elegido esta opción.

3.1.2 Resultados de la clasificación local

En relación a la clasificación local no tenemos datos de [31] de referencia para comparar con los nuestros, debido a que los resultados de [31] se centran en los resultados de la clasificación global.

En nuestro estudio la clasificación local ha tenido los siguientes resultados :

Probabilidad de error	0,16
Sensibilidad	91,23%
Especificidad	79,57%

Tabla 3-4. Resultados en la clasificación local.

Dentro de los valores estándares para este tipo de clasificaciones y estudios son valores que se encuentran dentro de una buena clasificación, llegando en la sensibilidad hasta el 91%, y en la especificidad un poco menos, un 80%. En cuanto a la probabilidad de error se sitúa en un valor bastante bajo, 0,16, lo cual nos hace indicar que la clasificación local a nivel de “patch” es medianamente buena.

3.2 Resultados en la clasificación global

A continuación vamos a exponer los resultados obtenidos en las dos clasificaciones globales y la comparación con [31].

3.2.1 Resultados en la clasificación global con distribución de probabilidad

En cuanto a la primera clasificación global nuestros resultados fueron los siguientes :

Probabilidad de error	0,3
Sensibilidad	80%
Especificidad	60%

Tabla 3-5. Resultados de la primera clasificación global.

Los resultados nos permiten ver que hemos empeorado en la sensibilidad en lo referente a la clasificación local, ya que hemos disminuido más de 10% entre ambas clasificaciones. En relación a la probabilidad de error también ha empeorado, aumentando en 0,14, aunque todavía está en el 70% de casos bien clasificados. Sin embargo, en términos de especificidad, hemos empeorado bastante, en torno a 20% menos en especificidad con respecto a la clasificación local.

3.2.1.1 Comparación con [31]

En comparación con [31], vamos a mostrar primero una comparación con la primera clasificación global de “blue-whitish veil”. Comparación con la precisión general de la clasificación global del estudio :

	PRESENTE TRABAJO	ESTUDIO ORIGINAL
SENSIBILIDAD	80%	90,59%
ESPECIFICIDAD	60%	65,5%

Tabla 3-6. Comparación de la primera clasificación global con [31].

Con los valores una vez enfrentados se puede visualizar la diferencia respecto al estudio de referencia, en el cual se mejora frente al nuestro la sensibilidad en un 10’59%, siendo más eficaz el original a la hora de reconocer lesiones de “blue”, sin embargo, en el caso de la especificidad, aunque es un valor bastante bajo, se mantiene bastante parecido al [31].

3.2.2 Resultados en la clasificación global según la clasificación local de los bloques

Los resultados obtenidos en la segunda clasificación global fueron los siguientes :

Probabilidad de error	0,3
Sensibilidad	100%
Especificidad	40%

Tabla 3-7. Resultados de la segunda clasificación global.

Conforme a los resultados obtenidos en esta clasificación global, podemos ver que lo primero que destaca, aparte de la sensibilidad muy alta, es que disminuye en gran cantidad el porcentaje de especificidad, debido a que hay lesiones que no son “blue” y que sin embargo pueden que en un “patch” determinado tengan otras características que resulten difíciles de distinguir al clasificador, y ya con que un “patch” sea clasificado como “blue”, la lesión entera es “blue”. Se pierde bastante objetividad y capacidad discriminatoria al limitar la clasificación al primer “patch” considerado “blue”. En el otro aspecto, la sensibilidad es totalmente comprensible que consiga valores muy altos, ya que al primer “patch” que se distinga como “blue” se considera la lesión “blue”, por tanto tiene un índice de acierto altísimo. La probabilidad de error ha empeorado considerablemente respecto a la clasificación local, no tanto respecto a la primera global la cual es exactamente la misma, situándose en el porcentaje del 70% de los casos bien clasificados.

En definitiva, los valores obtenidos no son totalmente representativos porque se consigue un porcentaje altísimo de sensibilidad sacrificando la eficiencia en la especificidad.

3.2.2.1 Comparación con [31]

En comparación con [31], los resultados son estos :

	PRESENTE TRABAJO	ESTUDIO ORIGINAL
SENSIBILIDAD	100%	95,27%
ESPECIFICIDAD	40%	63,9%

Tabla 3-8. Comparación de la segunda clasificación global con [31].

Según los resultados en comparación con [31], podemos observar que en el ámbito de la sensibilidad, se ha aumentado bastante con respecto a la primera clasificación global, un valor casi de 100% de acierto en sensibilidad es posible con este método, en mi caso el 100% es probablemente una unión de que por un lado un simple bloque puede ser clasificado como “blue” por error y por otro lado porque la base de datos de prueba no es muy extensa. Por eso no es un dato representativo en su totalidad, sino más bien orientativo del alto porcentaje que se podría obtener de sensibilidad con este método, basta sólo con ver el resultado de [31], donde con respecto al anterior método se ha mejorado en un 5%.

En relación a la especificidad, nuestros resultados no han sido tan buenos como los del estudio. Tanto en nuestro caso como en el del estudio, en este método, ha disminuido la especificidad. En nuestro caso ha sido un descenso excesivamente grande, un 20%, debido en parte, al conjunto de imágenes no “blue” que hemos establecido en la base de datos, teniendo algunas características parecidas al “blue”, que pueden confundir al clasificador a la hora de establecer una predicción y clasificar como “blue” lo que no es, y como en éste método si existe “blue” en un “patch”, ya la imagen es “blue”, reduce en gran medida la especificidad.

3.2.2.2 Resultado modificando el número de bloques a 5

Para tener unos resultados que representen mejor la clasificación hemos introducido una modificación. En vez de que al tener un único bloque la imagen se considere “blue”, hemos impuesto que sea con 5 bloques. El resultado lo podemos ver en la tabla :

Probabilidad de error	0,35
Sensibilidad	80%
Especificidad	50%

Tabla 3-9. Resultado de la segunda clasificación global modificando el número de bloques.

Podemos ver que la especificidad se ha incrementado un 10%, aunque se acerca más al valor de [31], sigue sin ser un valor aceptable. La sensibilidad, como es lógico, ha disminuido un 20%, estableciéndose en el 80%. La probabilidad de error es la peor en todas las clasificaciones, un 0,35.

4 CONCLUSIONES

Como capítulo final, procederemos a mostrar las conclusiones sobre los resultados, la metodología y las limitaciones encontradas en el presente trabajo.

Como inicio del capítulo, sería conveniente remontarnos a los objetivos del trabajo. En este trabajo hemos planteado como objetivo realizar un clasificador centrado en la característica de “Blue-Whitish Veil”, asociada a lesiones melanocíticas, para la clasificación de éstas y preferiblemente un método eficiente para la implementación y aplicación real.

Al término del presente trabajo, hemos conseguido realizar tres tipos distintos de clasificaciones, a saber :

- Clasificación local basada en características de color mediante “patches”.
- Clasificación global con distribución de probabilidad.
- Clasificación global según la clasificación local de bloques de la lesión.

De estos tipos de clasificaciones que hemos conseguido realizar, no todas tienen el mismo grado de satisfacción.

Comenzando por la clasificación local, podemos afirmar objetivamente (de acuerdo a otros estudios comentados anteriormente) que es un resultado bastante bueno el conseguido, teniendo en cuenta que ambos valores (sensibilidad y especificidad) se encuentran en un buen intervalo del 90% y casi el 80% respectivamente, los cuales son intervalos bastante deseables. La razón de ser de un resultado tan exitoso se ha gestado en la realización de un entrenamiento minucioso con los “patches”, escogiendo sólo y únicamente “patches” completamente “blue” y completamente sin “blue”, esto, unido a un número elevado de “patches” seleccionados para el entrenamiento (300), y, por supuesto, a la selección de características implementada, ha demostrado a la hora de clasificar para las distintas imágenes que se consigue un resultado bastante bueno.

En lo referente a la clasificación global con distribución de probabilidad podemos afirmar que el resultado está situado también en un intervalo bueno teniendo en cuenta el estudio de Wadhawan, T., Hu, R. y Zouridakis, G. [31] en el cual nos hemos basado. Nuestros resultados se acercan bastante a los resultados conseguidos en el estudio, no tanto en sensibilidad como en especificidad (80% y 60% respectivamente), esto demuestra que la eficiencia de nuestro método es garantizada a pesar de no llegar a los niveles de precisión del estudio de referencia. La tasa de acierto tan buena en esta clasificación se debe a una base sólida y con buen rendimiento de clasificación en local, ya que es el sustento de la clasificación en global.

Por último, en la clasificación global según la clasificación local de bloques, no hemos podido conseguir un buen resultado debido a la metodología. A pesar de que en el estudio de referencia da buenos resultados, a nosotros, posiblemente debido en primer lugar a que no teníamos acceso a una base de datos tan extensa y en segundo, a que las imágenes seleccionadas no eran de fácil clasificación teniendo en cuenta que presentaban características que podían causar error de clasificación en el clasificador, no nos ha sido un método efectivo. En sensibilidad demuestra un índice de acierto muy alto tanto en nuestro método como en el del estudio, en cuanto a especificidad, tanto en nuestro método como en el del estudio, disminuye respecto a otros métodos anteriores, aunque en nuestro método desciende bastante, estableciéndose en un 40%. Este dato no nos resulta totalmente significativo, ya que la metodología usada favorece bastante el incremento de la sensibilidad y menoscaba la especificidad. En cuanto a la modificación para asignar a la imagen etiqueta “blue” si había 5 bloques en vez de 1, hemos conseguido aumentar un poco la especificidad (hasta el 50%), bajando a su vez la sensibilidad (al 80%). Sin embargo tampoco conseguimos buenos resultados con este último método.

Las carpetas definidas para el entrenamiento y para la clasificación global pueden haber afectado a la baja especificidad de los métodos globales, ya que en el caso del entrenamiento, de las 10 imágenes, 7 de ellas

contenían zonas de “blue” grandes, y sólo 3 de ellas pequeñas. Esto es un problema a la hora de clasificar.

Conviene destacar que pensamos que hemos satisfecho los objetivos en una medida buena, sobre todo en la clasificación local, pudiendo ser interesante una aplicación real basada en nuestro método. En referente a la segunda clasificación global no hemos llegado a determinar tan buenos niveles de precisión como en [31], por tanto, aquí no percibimos tangible lo minucioso y procedimental del método definido. Podría haberse mejorado en especificidad si las imágenes hubiesen sido menos difíciles de clasificar para el clasificador, pero esto no hubiese reflejado una implementación real y hubiese puesto a prueba realmente el resultado conseguido como se ha hecho. Este último resultado no representa la garantía que contiene nuestro método, como bien se refleja en los resultados de los métodos anteriores.

Para finalizar con los resultados, nos centraremos en los resultados obtenidos, en general, en ambas clasificaciones para nuestro método. En la clasificación local se observan unos resultados mejores que en la primera clasificación global, tanto en sensibilidad (91,23% frente a 80%) como en especificidad (79,57% frente a 60%). Esto demuestra que a nivel de “patch” frente a nivel de imagen, según nuestro método, existe un mayor índice de acierto en la primera, y superior en lesiones cancerígenas o anaplásicas, que en lesiones benignas ante casos de proliferación celular.

Enfocando nuestros resultados desde la perspectiva metodológica, decir que consideramos algunos puntos sobre los que se estructura, básicos, para haber obtenido la precisión del método. Como principal, la selección de características, sin la cual no se podría haber desarrollado un método medianamente bueno, porque como principal hándicap de éste método están las 120 características, las cuales hay que reducir para conseguir un método eficiente. Como segundo punto señalamos la precisión a la hora de establecer un entrenamiento como fundamental, donde hemos seleccionado cada bloque con precisión evitando imperfecciones de las imágenes como pompas, pelos y bloques a caballo entre “blue” y no “blue”.

Dentro de la metodología, nos ha resultado interesante el hecho de desviarse hacia otros espacios de color y por tanto explorar la clasificación según otras perspectivas. Cabe destacar y comentar la solución por la que finalmente nos decantamos con mejor precisión, compuesta por el plano H y el plano B. El plano H es un plano de matiz, como bien vimos en el capítulo 2 del presente trabajo, en el cual vimos que representaba la longitud de onda, motivo por el que es tan representativo en nuestro resultado, ya que establece de manera bastante buena la longitud de onda en este caso del azul, con un margen (no es azul puro). En referente al plano B, era de esperar que fuese un plano que diera buenas indicaciones de “blue”, ya que el propio nombre del plano lo refleja. Ambos planos, trabajando juntos, consiguen gran efectividad.

Por tanto, de cara al futuro, vemos importante e interesante la inclusión de nuevos espacios de color en los estudios de clasificación, ya que la mayoría no suelen desviarse mucho de los propuestos generalmente, y el hecho de explorar nuevos espacios puede darnos la posibilidad de encontrar uno que sea muy preciso en cuanto a este tipo de clasificación. Por ejemplo, con espacios como CIE L^*a^*b y CIE XYZ, los cuales son planos orientados para la percepción humana y pueden dar resultados interesantes.

También consideramos importante para estudios futuros, y es algo donde hemos encontrado carencias en otros estudios comentados, la especificidad. Parámetro normalmente no tan cargado de interés en este tipo de estudios como la sensibilidad, la cual casi siempre se encuentra superior a ésta. La especificidad mejora el diagnóstico frente a una lesión que no es “blue”, pero a priori, no se sabe a ciencia cierta si podría ser o no “blue”. El hecho de descartar una lesión que no lo es, es bastante importante a la hora de implementar un algoritmo así de manera real, ya que evitaría el tiempo causado por ambigüedades, descartaría una posible rama de actuación frente a la lesión y podría optimizar bastante el tiempo de reacción frente a una lesión determinada, ya que descolapsaría bastante la espera frente a otras lesiones que sí pueden ser verdaderamente malignas, y el tiempo en el diagnóstico de los melanomas es fundamental.

En cuanto a las limitaciones, pensamos que una importante ha sido no tener una base de datos de imágenes dermatoscópicas más extensa, la cual sin duda habría aportado resultados mucho más representativos, ya que nos habría permitido probar nuestro método con muchas más muestras y realizar un entrenamiento mucho más amplio sobre todo en el caso de clasificación global.

REFERENCIAS

- [1] B. Young and J.W. Heath, *Wheater's Histología Funcional: texto y atlas en color*, 4th. ed. Harcourt, 2000
- [2] Sol y cáncer de piel, Asociación Española Contra el Cáncer, aecc©. Disponible en:
<https://www.aecc.es/SobreElCancer/Prevencion/elsol/Paginas/solycancerdepiel.aspx>
02/08/17 18:06
- [3] Instituto Nacional del Cáncer de EEUU (NCI®). Disponible en:
https://www.cancer.gov/espanol/tipos/piel/paciente/deteccion-piel-pdq#section/_5
17/10/2017, 17:44
- [4] Fases melanoma, Asociación Española Contra el Cáncer, aecc©. Disponible en:
<https://www.aecc.es/SOBREELCANCER/CANCERPORLOCALIZACION/MELANOMA/Paginas/fases.aspx>
23/08/2017 18:39
- [5] Mortalidad, Sociedad Española de Oncología Médica©, 2017. Disponible en:
<http://www.seom.org/en/prensa/el-cancer-en-espanyacom/105941-las-cifras-del-cancer-en-espana-2017?start=3#content>
08/07/17, 17:30
- [6] Datos y cifras sobre el cáncer, Organización Mundial de la Salud, OMS©, 2017. Disponible en:
<http://www.who.int/cancer/about/facts/es/>
09/07/17 18:22
- [7] Instituto Nacional de Estadística, INE©, 2017. Disponible en:
<http://www.ine.es/jaxi/tabla.do?type=pcaxis&path=/t15/p417/a2014/10/&file=01001.px>
22/08/2017 17:57
- [8] X. C. Wu, M. J. Eide, J. King, M. Saraiya, Y. Huang, C. Wiggins, J. S. Barnholtz-Sloan, N. Martin, V. Cokkinides, J. Miller, P. Patel, D. U. Ekwueme, and J. Kim, "Racial and ethnic variations in incidence and survival of cutaneous melanoma in the United States, 1999-2006," *Journal of the American Academy of Dermatology*, vol. 65, no. 5 SUPPL. 1. 2011.
- [9] Carlos Ortega, B. *Dermatoscopia. Utilidad y peculiaridades en piel pigmentada*. México, D. F. : McGRAW-HILL/INTERAMERICANA EDITORES, 2016. ISBN 978-607-15-1362-5

- [10] Cunill, I. R., Cunill, I. R., Gutierrez, A. M., Reina, J. P., Mora, M. J. G. d. M. y. (2007, March 13). page_08. Disponible en :
http://ocwus.us.es/pintura/usos-plasticos-del-color/temario/temas2_IMSWCT/page_08.htm.
16/10/2017 17:25
- [11] Argenziano, G. , Soyer, H. P. , Chimenti, S. , Argenziano, G. , Ruocco, V. *Impact of dermoscopy on the clinical management of pigmented skin lesions*. Clin Dermatol. 2002, vol. 20, no. 3, pp. 200-202
- [12] R. R. Marín and B. C. Ortega, “Criterios dermatoscópicos para el diagnóstico de lesión melanocítica y melanoma cutáneo,” *Dermatología Cosmet. Medica y Quir.*, vol. 12, no. 2, pp. 142–148, 2014.
- [13] Web docente de Dermatología (Dermatoweb), Dr. X Soria y Dr. JM Casanova. Disponible en:
<http://dermatoweb2.udl.es/atlasg.php?idfoto=408981&lletra=m&pag=4&idsubmenu=2552&idapartat=3471&idsubapartat=>
17/10/2017 18:54
- [14] G. Argenziano, H. P. Soyer, S. Chimenti, R. Talamini, R. Corona, F. Sera, M. Binder, L. Cerroni, G. De Rosa, G. Ferrara, R. Hofmann-Wellenhof, M. Landthaler, S. W. Menzies, H. Pehamberger, D. Piccolo, H. S. Rabinovitz, R. Schiffner, S. Staibano, W. Stolz, I. Bartenjev, A. Blum, R. Braun, H. Cabo, P. Carli, V. De Giorgi, M. G. Fleming, J. M. Grichnik, C. M. Grin, A. C. Halpern, R. Johr, B. Katz, R. O. Kenet, H. Kittler, J. Kreusch, J. Malvehy, G. Mazzocchetti, M. Oliviero, F. Özdemir, K. Peris, R. Perotti, A. Perusquia, M. A. Pizzichetta, S. Puig, B. Rao, P. Rubegni, T. Saida, M. Scalvenzi, S. Seidenari, I. Stanganelli, M. Tanaka, K. Westerhoff, I. H. Wolf, O. Braun-Falco, H. Kerl, T. Nishikawa, K. Wolff, and A. W. Kopf, “Dermoscopy of pigmented skin lesions: Results of a consensus meeting via the internet,” *J. Am. Acad. Dermatol.*, vol. 48, no. 5, pp. 679–693, 2003.
- [15] P. Zaballos, C. Carrera, S. Puig, J. Malvehy Departamentos de Dermatología, and P. Zaballos Diego, “Educación Médica Continuada Criterios dermatoscópicos para el diagnóstico del melanoma Dermoscopic Criteria in the Diagnosis of Melanoma,” *Med Cutan Iber Lat Am*, vol. 32, no. 1, pp. 3–17, 2004.
- [16] The Difference Between "Probability" and "Odds", Boston University School of Public Health Content©2016. Disponible en:
http://sphweb.bumc.bu.edu/otlt/mphmodules/bs/bs704_confidence_intervals/BS704_Confidence_Intervals10.html
28/8/2017 13:23
- [17] F. Nachbar, W. Stolz, T. Merkle, A. B. Cognetta, T. Vogt, M. Landthaler, P. Bilek, O. Braun-Falco, and G. Plewig, “The ABCD rule of dermoscopy,” *J. Am. Acad. Dermatol.*, vol. 30, no. 4, pp. 551–559, 1994.
- [18] G. Argenziano, G. Fabbrocini, P. Carli, V. De Giorgio, E. Sammarco, M. Delfino, V. De Giorgi, E. Sammarco, and M. Delfino, “Epiluminescence microscopy for the diagnosis of doubtful melanocytic skin lesions,” *Arch. Dermatol.*, vol. 134, no. 12, pp. 1563–1570, 1998.
- [19] S. W. Menzies, C. Ingvar, K. A. Crotty, and W. H. McCarthy, “Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features,” *Arch. Dermatol.*, vol. 132, no. 10, pp. 1178–82, 1996.

- [20] P. Carli, E. Quercioli, S. Sestini, M. Stante, L. Ricci, G. Brunasso, and V. DE Giorgi, "Pattern analysis, not simplified algorithms, is the most reliable method for teaching dermoscopy for melanoma diagnosis to residents in dermatology," *Br. J. Dermatol.*, vol. 148, no. 5, pp. 981–984, May 2003
- [21] D. Massi, V. De Giorgi, P. Carli, and M. Santucci, "Diagnostic significance of the blue hue in dermoscopy of melanocytic lesions: a dermoscopic-pathologic study," *Am. J. Dermatopathol.*, vol. 23, no. 5, pp. 463–469, 2001
- [22] S. W. Menzies, C. Ingvar, and W. H. McCarthy, "A sensitivity and specificity analysis of the surface microscopy features of invasive melanoma.," *Melanoma research*, vol. 6, no. 1, pp. 55–62, 1996
- [23] E. Fix and J. L. Hodges, "Discriminatory Analysis - Nonparametric discrimination consistency properties," *Usaf Sch. Aviat. Med. Randolph Field, Texas*, no. May, pp. 1–21, 1951.
- [24] T. Cover and P. Hart, "Nearest neighbor pattern classification," *IEEE Trans. Inf. Theory*, vol. 13, no. 1, pp. 21–27, Jan. 1967
- [25] C. Zhang, C. Liu, X. Zhang, and G. Almpanidis, "An up-to-date comparison of state-of-the-art classification algorithms," *Expert Syst. Appl.*, vol. 82, pp. 128–150, 2017
- [26] M. E. Celebi, H. Iyatomi, W. V. Stoecker, R. H. Moss, H. S. Rabinovitz, G. Argenziano, and H. P. Soyer, "Automatic detection of blue-white veil and related structures in dermoscopy images," *Comput. Med. Imaging Graph.*, vol. 32, no. 8, pp. 670–677, 2008.
- [27] D. P. Hibar, S. E. Medland, J. L. Stein, S. Kim, L. Shen, A. J. Saykin, G. I. De Zubicaray, K. L. McMahon, G. W. Montgomery, N. G. Martin, M. J. Wright, S. Djurovic, I. A. Agartz, O. A. Andreassen, and P. M. Thompson, "Medical Image Computing and Computer-Assisted Intervention – MICCAI 2013," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 8150, no. PART 2, pp. 690–697, 2013
- [28] J. L. G. Arroyo, B. G. Zapirain, and A. M. Zorrilla, "Blue-white veil and dark-red patch of pigment pattern recognition in dermoscopic images using machine-learning techniques," in *IEEE International Symposium on Signal Processing and Information Technology, ISSPIT 2011*, 2011, pp. 196–201
- [29] K. Kropidlowski, M. Kociolek, M. Strzelecki, and D. Czubinski, "Blue whitish veil, atypical vascular pattern and regression structures detection in skin lesions images," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2016, vol. 9972 LNCS, pp. 418–428.
- [30] Jaworek-Korjakowska, Joanna & Kłeczek, Paweł & Grzegorzec, Marcin & Shirahama, Kimiaki. (2017). Automatic Detection of Blue-Whitish Veil as the Primary Dermoscopic Feature. LIBRO: *Artificial Intelligence and Soft Computing*, pp 649-657. DOI: 10.1007/978-3-319-59063-9_58. ISBN: 978-3-319-59062-2
- [31] T. Wadhawan, R. Hu, and G. Zouridakis, "Detection of blue-whitish veil in melanoma using color descriptors," *Proc. - IEEE-EMBS Int. Conf. Biomed. Heal. Informatics Glob. Gd. Chall. Heal. Informatics, BHI 2012*, vol. 25, no. Bhi, pp. 503–506, 2012
- [32] G. Argenziano, H.P. Soyer, V. De Giorgi, D. Piccolo, P. Carli, M. Delfino, A. Ferrari, R. Holfmann-Wellenhof, D. Massi, G. Mazzocchetti, M. Scalvenzi y I. H. Wolf, *Dermoscopy an Interactive Atlas*, Ed. EDRA Medical Publishing and New Media, 2000

- [33] Gráfica Digital. Disponible en : <https://mtm162.wordpress.com/tag/rgb/>
17/9/2017 19:25
- [34] Apuntes de la asignatura Televisión. Tema 4: Luces, colores y el sistema visual humano. Curso 2016/2017. Autor: Jose Ramón Cerquides Bueno
- [35] EcuRed. Disponible en: https://www.ecured.cu/Modelo_HSV
17/9/2017 20:42
- [36] Wikimedia Commons. Disponible en : https://commons.wikimedia.org/wiki/File:YUV_UV_plane.jpg
27/9/2017 11:38
- [37] MIPAV Wiki. Disponible en : <https://mipav.cit.nih.gov/pubwiki/index.php/File:GaussianKernel.jpg>
1/10/2017 13:46
- [38] C. Cortes and V. Vapnik, "Support-Vector Networks," *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995.
- [39] G. Betancour, "Las máquinas de soporte vectorial (SVMs)," *Sci. Tech.*, no. 27, pp. 67–72, 2005

GLOSARIO

ADN: Ácido desoxirribonucleico	1,2
UVA: Ultravioleta tipo A	2
UVB: Ultravioleta tipo B	2
AECC: Asociación Española Contra el Cáncer	3
CNMD: Consensus Net Meeting on Dermoscopy	5,7,8,9
SVM: Máquina de Soporte Vectorial (Support Vector Machines)	11,12,16,20,22,23,25,27,29
ROI: Región de Interés (Region Of Interest)	16

