



UNIVERSIDAD DE DEUSTO

ALGORITMO DE DETECCIÓN Y CARACTERIZACIÓN DE PATRONES DERMATOSCÓPICOS PRESENTES EN EL MELANOMA

Tesis doctoral presentada por JOSE LUIS GARCÍA ARROYO
dentro del Programa de Doctorado en Ingeniería Informática y Telecomunicación
Dirigida por la Dra. BEGOÑA GARCÍA ZAPIRAIN

Bilbao, mayo de 2017



UNIVERSIDAD DE DEUSTO

ALGORITMO DE DETECCIÓN Y CARACTERIZACIÓN DE PATRONES DERMATOSCÓPICOS PRESENTES EN EL MELANOMA

Tesis doctoral presentada por JOSE LUIS GARCÍA ARROYO
dentro del Programa de Doctorado en Ingeniería Informática y Telecomunicación
Dirigida por la Dra. BEGOÑA GARCÍA ZAPIRAIN

El doctorando

El director

Bilbao, mayo de 2017

*Dedicado a Jose Luis y Mila, mis queridos aitas, y a Urko, mi
precioso chiquitín.*

Resumen

El melanoma es la forma más peligrosa de cáncer de piel, representando aproximadamente el 1,5 % del total de casos de cáncer a nivel mundial. En la lucha contra el melanoma es fundamental la detección precoz, en caso de ser detectado a tiempo la tasa de mortalidad es del 2 %, subiendo al 83 % cuando ya ha alcanzado el estado invasivo. La dermatoscopia es una técnica de imagen no invasiva –en estos momentos la prueba de referencia o *gold standard*– para la detección precoz de melanoma, permitiendo al experto dermatólogo realizar una valoración de acuerdo a los algoritmos médicos existentes. Actualmente, la automatización de esta tarea es un problema vigente a nivel científico, tanto el problema principal –el diagnóstico– como los subproblemas que lo componen –la segmentación de la lesión y el reconocimiento de los diferentes indicadores, entre ellos los patrones dermatoscópicos–.

En la presente investigación se ha diseñado y desarrollado una familia de algoritmos de procesamiento digital de imagen para las tareas de la segmentación de la lesión y la detección y caracterización de diferentes indicadores, centrándose especialmente en el reconocimiento de los patrones dermatoscópicos. Estos algoritmos son contribuciones científicas y han sido integrados en una herramienta software de ayuda al diagnóstico basado en el algoritmo médico “Regla del ABCD”, siendo las contribuciones más relevantes realizadas el algoritmo de reconocimiento del patrón reticular, el algoritmo de segmentación y la propia herramienta software.

En este documento se explica de manera detallada la principal contribución, el algoritmo de reconocimiento del patrón reticular, un método

innovador de reconocimiento de patrones basado en la clasificación difusa de los pixels. El método ha sido testeado contra una base de datos de 875 imágenes –por mucho, la más grande en el estado del arte en el reconocimiento del patrón reticular– extraída de un Atlas de Dermatoscopia público, alcanzando muy buenos resultados, una AUC de 0,912, una exactitud del 88 %, una sensibilidad del 90,71 % y una especificidad del 83,44 %. La principal aportación de este método es el propio diseño del algoritmo, muy innovador, que puede ser utilizado además en otros problemas de reconocimiento de patrones de naturaleza similar. Otras aportaciones del método son la no necesidad de realizar un preprocesado previo, la gran capacidad de discriminación entre este patrón y otros patrones dermatoscópicos y, finalmente, el establecimiento de un nuevo enfoque metodológico para trabajos de este tipo.

Esta investigación supone un avance a nivel científico en el campo de la diagnosis automatizada de melanoma a partir de imágenes dermatoscópicas.

Laburpena

Melanoma larruazaleko minbizirik arriskutsuena da. Mundu osoan agertzen diren minbizien artean, melanomaren intzidentzia %1,5koa da. Haren kontra jokatzeko, detekzio goiztiarra funtzezkoa da: garaiz diagnostikatuta, hilkortasun-tasa %2koa da, baina, egoera inbaditzailerera helduta, tasa %83ra igotzen da. Dermatoskopia melanoma garaiz detektatzeko irudi-teknika bat da, inbaditzen ez duena, eta momentu honetan erreferentziazkoa edo *gold standard*. Dermatologoek irudi horiekin egiten dituzte haien balorazioak, gaur egungo algoritmoez baliatuz. Prozezu horien automatizazioa indarreko arazo zientifikoa da, bai arazorik nagusia –diagnostikoa bera–, bai hori zehazteko dauden arazo sekundarioak –lesioaren segmentazioa eta adierazle bakoitzaren azterketa, euren artean patroi dermatoskopikoak–.

Ikerkuntza honetan, irudi digitalak prozesatzeko algoritmo sorta bat diseinatu egin da. Sorta honen bidez, lesioak segmentatu eta adierazle ezberdinak detektatu eta karakterizatu egiten dira, batez ere patroi dermatoskopikoak. Algoritmo hauek ekarpen zientifikoak dira, eta “ABCD erregela” delako algoritmoan oinarritutako diagnosi-laguntzarako software prototipo batean integratu egin dira. Ekarpeng nagusiak hauek dira: segmentazio-algoritmoa, sare patroiak aztertzeko algoritmoa eta diagnosi-laguntzarako software prototipoa.

Txosten honetan ekarpen nagusia zehazten da: sare patroiak detektatzea. Patroiak detektatzeko metodo berritzailea da, pixelen sailkapen difusioan datzana. Metodoa 875 irudiko datu-basearekin testatu egin da –sare patroiaren datu-baserik handiena– atlas dermatoskopiko publiko batetik aterata. Lortutako emaitzak bikainak dira: 0,912ko AUC,

%88ko zehaztasuna, %90,71ko sentsibilitatea eta %83,44ko espezifikotasuna. Metodo berritzaile honen ekarpen nagusia algoritmoaren diseinua da, zeren algoritmoa antzeko izaera duten patroiak detektatzeko erabil daiteke. Algoritmoaren beste ezaugarrien artean aipa daiteke: ez duela aurre prozesamendurik behar, patroiak ezberdintzeko gaitasun handia duela eta, azkenik, era honetako arazoei aurre egiteko ikuspegi metodologiko berria.

Ikerkuntza hau ekarpen zientifiko handia da melanoma diagnosi automatikoaren eremuan, irudi dermatoskopikoetatik abiatuta.

Abstract

Melanoma is the most dangerous form of skin cancer, accounting for approximately 1.5% of all cancers worldwide. In the fight against melanoma early detection is essential; if detected early, the mortality rate is 2%, rising to 83% when it has already reached the invasive state. Dermoscopy is a non-invasive imaging technique –at this time the gold standard– for the early detection of melanoma, allowing the expert dermatologist to perform an assessment according to existing medical algorithms. Currently, the automation of this task is a scientific problem, both the main problem –the diagnosis– and the subproblems that compose it –the segmentation of the lesion and the recognition of different indicators, including dermoscopic patterns–.

In the present research, a family of digital image processing algorithms has been designed and developed for the tasks of lesion segmentation and the detection and characterization of different indicators, focusing especially on the recognition of dermoscopic patterns. These algorithms are scientific contributions and have been integrated into a software prototype for the diagnosis based on the “ABCD Rule” medical algorithm, being the most important contributions the segmentation algorithm, the reticular pattern recognition algorithm and the software prototype itself.

This paper presents in detail the main contribution, the reticular pattern recognition algorithm, an innovative pattern recognition method based on fuzzy classification of pixels. The method has been tested against a database of 875 images –by far the largest in the state of the art in the recognition of the reticular pattern– extracted from a Public Dermoscopy Atlas, achieving excellent results, an AUC of 0.912, an accuracy

of 88%, a sensitivity of 90.71% and a specificity of 83.44%. The main contribution of this method is the very design of the algorithm, highly innovative, that can be used in addition to other problems of recognition of patterns of similar nature. Other contributions of the method are the absence of need to perform a preprocessing, the great capacity of discrimination between this pattern and other dermatoscopic patterns and, finally, the establishment of a new methodological approach for works of this type.

This research represents a scientific advance in the field of automated diagnosis of melanoma from dermoscopic images.

Agradecimientos

Un trabajo de investigación tan extenso como el que se presenta aquí no hubiera sido posible sin la ayuda de muchas personas e instituciones. En este apartado quiero mostrar mi agradecimiento a todas ellas.

En primer lugar, quiero agradecer a Begoña, mi directora de tesis, que en su día me diera la oportunidad de trabajar en investigación en el grupo Deustotech-Life. Su dirección y ayuda han posibilitado que esta investigación haya sido llevada a cabo.

En segundo lugar, me gustaría agradecer también el apoyo de la Universidad de Deusto –en concreto de la Fundación Deusto (Deustotech)– que apostó por mi tesis doctoral desde un primer momento y cuyo respaldo ha sido fundamental.

En tercer lugar, mi agradecimiento hacia mis compañeros de Deustotech Life, donde he tenido la oportunidad de trabajar en un grupo fantástico, tanto a nivel profesional como personal. Han sido muchos y ha sido un placer trabajar con todos ellos; especial relación he tenido con Fernando Jorge, María Viqueira, Nuria Aresti, Gonzalo Eguiluz, Álvaro Muro, Alain Sánchez, Zelai Sáenz de Urturi, Ibón Oleagordia y John O’Toole. También quiero dar las gracias a Javier Vicente e Iñigo Fernández por la orientación que me dieron al inicio de la investigación.

En cuarto lugar, quisiera agradecer también el haber tenido la oportunidad de trabajar con el equipo de investigación Fonetiker, especialmente con Rosa Miren Pagola, Alex Iríbar e Itziar Túrrez. Aún siendo un grupo pequeño, han sido para mí un ejemplo de buen hacer. Quiero destacar especialmente a Rosa Miren, personas como ella son las que han dado a la Universidad de Deusto el prestigio que tiene.

En quinto lugar, me gustaría también mostrar mi agradecimiento a Jose Luis Díaz y Jesús Gardeazabal, médicos dermatólogos de IMQ, que contribuyeron a esta investigación con su gran conocimiento de la materia a nivel médico. Además, quiero hacerlo extensivo al resto de las personas e instituciones presentes en el proyecto de investigación Melanotic, que ha apoyado la realización de esta investigación, en el que participaron la Universidad de Deusto junto con las empresas IMQ, Maser y GAIA y que fue financiado por el Gobierno Vasco (Gaitek).

En sexto lugar, quiero tener también un recuerdo para todos mis amigos, que siempre han sido importantes en mi vida. Sergio Sagarminaga, Pablo Elordui, Marcos Bustinza, Ricardo Sánchez, Jorge Gorria, David Gallo, Asier Mintiaga, Raúl Pérez, Diego Morlán, Donovan Cisneros, Borja Jauregi, Luis Miguel Arroyo, Álvaro Zorrilla, Joseba Molina (QEPD), Jose Carlos Ortiz, Iñaki García, Santos García, Carlos Crespo, Iñigo Fernández, Juan Carlos Hernández y todos los demás.

Finalmente, un agradecimiento muy especial para mi familia. Para los que no están, mis abuelos Jesús, Avelina, Félix y Teresa y mi primita Mertxe. Para mis tíos y primos. Para mis queridas hermanas Elena e Itziar, mis cuñados David y Álex y mis simpáticos y guapísimos sobrinitos Inés, Alicia y Sendoa. Finalmente, quiero sobre todo mostrar mi enorme agradecimiento a mis bondadosos aítas, Jose Luis y Mila, que siempre me han ayudado y apoyado, a quienes quiero dedicar este trabajo, que en parte también es suyo. Ellos han sido siempre un ejemplo y un orgullo para mí y nunca podré devolverles todo el amor que me han dado. Espero poder hacerlo siguiendo su ejemplo. Y por supuesto a mi queridísimo Urko, mi precioso chiquitín, que espero sobre todo que sea muy feliz y que pueda realizar las metas y sueños que se proponga. Bondad, alegría, talento y ganas de aprender tiene a raudales.

Eskerrik asko,

Jose Luis

Mayo 2017

Índice general

| | |
|---|---------------|
| Índice general | xi |
| Índice de figuras | xxi |
| Índice de tablas | xxxvii |
| 1 Introducción | 1 |
| 1.1 Motivación | 1 |
| 1.2 Hipótesis | 6 |
| 1.3 Objetivos | 6 |
| 1.4 Metodología | 7 |
| 1.4.1 Equipo de trabajo | 9 |
| 1.5 Estructuración del documento | 9 |
| 2 Estado del arte | 13 |
| 2.1 Estado del arte a nivel médico | 14 |
| 2.1.1 Conceptos médicos. Melanoma. Magnitud del problema en cifras | 14 |
| 2.1.1.1 La piel humana | 14 |
| 2.1.1.2 Lesiones de piel | 16 |
| 2.1.1.3 Melanoma | 22 |
| 2.1.1.4 Magnitud del problema en cifras | 25 |
| 2.1.2 Técnicas para la detección de melanoma | 26 |
| 2.1.2.1 Imagen Macroscópica | 27 |
| 2.1.2.2 Fotografía de Cuerpo Entero | 27 |

ÍNDICE GENERAL

| | | |
|----------|---|----|
| 2.1.2.3 | Dermatoscopia | 27 |
| 2.1.2.4 | Imagen Multiespectral | 28 |
| 2.1.2.5 | Microscopía Confocal de Reflectancia (MCR) | 28 |
| 2.1.2.6 | Ultrasonido de Alta Resolución | 29 |
| 2.1.2.7 | Tomografía de Coherencia Óptica (TCO) | 29 |
| 2.1.2.8 | Imágenes de Resonancia Magnética (IRM) y Tomografía por Emisión de Positrones fusionada con Tomografía Computerizada (TEP/TC) | 29 |
| 2.1.2.9 | Conclusiones | 30 |
| 2.1.3 | Dermatoscopia | 30 |
| 2.1.3.1 | Adquisición de imágenes. | 30 |
| 2.1.3.2 | Diagnóstico a partir de imágenes dermatoscópicas | 32 |
| 2.1.3.3 | Patrones o estructuras dermatoscópicas | 32 |
| 2.1.3.4 | “Método de las 2 Etapas” | 33 |
| 2.1.3.5 | “Análisis de Patrones” | 33 |
| 2.1.3.6 | “Regla del ABCD” | 35 |
| 2.1.3.7 | “Método de Menzies” | 36 |
| 2.1.3.8 | “Lista de los 7 puntos” | 36 |
| 2.1.3.9 | Descripción detallada de los patrones o estructuras dermatoscópicas | 37 |
| 2.1.3.10 | Estandarización de la dermatoscopia | 41 |
| 2.1.3.11 | Importancia de un diagnóstico automatizado. CADs existentes en el mercado actualmente. Limitaciones | 42 |
| 2.1.4 | Conclusiones. Justificación de la necesidad desde el punto de vista médico | 42 |
| 2.2 | Estado del arte a nivel tecnológico | 43 |
| 2.2.1 | Contextualización de la presente investigación en el estado del arte | 43 |
| 2.2.1.1 | Ciclo de vida de un CAD para la detección de melanoma | 43 |
| 2.2.1.2 | Enfoques de un CAD para la detección de melanoma | 44 |
| 2.2.1.3 | Objetivo y alcance de la presente investigación | 45 |

| | | |
|----------|---|-----------|
| 2.2.2 | Estado del arte de la detección y caracterización de los patrones dermatoscópicos | 46 |
| 2.2.2.1 | Objetivos de los trabajos | 47 |
| 2.2.2.2 | Relaciones con otros trabajos | 52 |
| 2.2.3 | Estado del arte de la detección y caracterización del patrón reticular | 56 |
| 2.2.3.1 | Descripción de los métodos más relevantes de reconocimiento del patrón reticular | 56 |
| 2.2.3.2 | Técnicas utilizadas en los métodos de reconocimiento del patrón reticular | 73 |
| 2.2.3.3 | Comparación de resultados obtenidos en los métodos de reconocimiento del patrón reticular | 81 |
| 2.2.4 | Software para el desarrollo de los algoritmos de procesamiento digital de imagen | 87 |
| 2.2.4.1 | Características | 87 |
| 2.2.4.2 | CVIPtools | 88 |
| 2.2.4.3 | OpenCV | 88 |
| 2.2.4.4 | PIL (Python Imaging Library)/Pillow | 89 |
| 2.2.4.5 | Matlab | 89 |
| 2.2.4.6 | Java Advanced Imaging (JAI) | 90 |
| 2.2.4.7 | ImageJ | 90 |
| 2.2.5 | Conclusiones. Justificación de la necesidad desde el punto de vista tecnológico | 91 |
| 3 | Base de datos | 93 |
| 3.1 | Características que debe cumplir la base de datos | 93 |
| 3.2 | Fuentes utilizadas en su construcción | 94 |
| 3.3 | Diseño de la base de datos | 94 |
| 3.4 | Consideraciones sobre el etiquetado | 96 |
| 4 | Diseño del Sistema | 97 |
| 4.1 | Especificación | 97 |
| 4.1.1 | Nuevo enfoque metodológico, una aportación de la presente tesis | 97 |

ÍNDICE GENERAL

| | | |
|---------|--|-----|
| 4.1.2 | Estudio del patrón para su objetivación | 99 |
| 4.1.2.1 | Estudio de la descripción o caracterización del patrón red pigmentada | 99 |
| 4.1.2.2 | Consideraciones sobre el etiquetado de la base de datos y la influencia de la subjetividad sobre el mismo | 102 |
| 4.1.2.3 | Elementos distorsionadores | 103 |
| 4.1.3 | Especificación del sistema | 103 |
| 4.2 | Diseño de alto nivel | 105 |
| 4.2.1 | Motivación de la clasificación difusa o <i>fuzzy</i> de los pixels . | 105 |
| 4.2.2 | Esquema del diseño de alto nivel | 106 |
| 4.2.3 | Procesado previo de la imagen | 108 |
| 4.2.4 | Segmentación de la lesión | 108 |
| 4.3 | Diseño de bajo nivel | 110 |
| 4.3.1 | Módulo 1: Detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad | 110 |
| 4.3.1.1 | Esquema del módulo 1 | 110 |
| 4.3.1.2 | 1.1. Toma de muestras de pixels | 112 |
| 4.3.1.3 | 1.2. Extracción de características de color y textura | 112 |
| 4.3.1.4 | 1.3. Generación del modelo de clasificación difusa y creación de conjuntos difusos | 126 |
| 4.3.1.5 | 1.4. Generación de imágenes de probabilidad . . | 130 |
| 4.3.2 | Módulo 2: Procesamiento y caracterización de las imágenes de probabilidad y diagnosis | 134 |
| 4.3.2.1 | Motivación de las combinaciones de las máscaras extraídas a partir de las imágenes de probabilidad correspondientes a los $\alpha - cortes$ o $\alpha - cuts$ obtenidos a partir de los conjuntos difusos. Parámetros α_{red} , $\alpha_{agujero}$ y $prop$ | 134 |

| | | |
|----------|--|------------|
| 4.3.2.2 | Motivación de la parametrización obtenida a partir de la especificación del sistema. Parámetros <i>numMinAgujeros</i> , <i>distMaxAgujeros</i> y <i>rangMaxTamanyoAgujeros</i> . Valores umbrales <i>thr_minTamanyoAgujero</i> , <i>thr_maxTamanyoAgujero</i> y <i>thr_numMinTotalAgujeros</i> | 142 |
| 4.3.2.3 | Esquema del módulo 2 | 143 |
| 4.3.2.4 | 2.1. Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” | 144 |
| 4.3.2.5 | 2.2. Selección del mejor modelo de clasificación | 161 |
| 4.3.2.6 | 2.3. Diagnósis entre “ausente” y “presente” . . . | 161 |
| 4.4 | Software para el desarrollo de los algoritmos de procesamiento digital de imagen | 161 |
| 4.4.1 | Tecnologías utilizadas | 161 |
| 4.4.2 | <i>Framework</i> software construido | 164 |
| 4.4.2.1 | Algoritmos de alto nivel desarrollados | 164 |
| 4.4.2.2 | Utilidades implementadas | 166 |
| 4.4.2.3 | Librerías externas utilizadas | 166 |
| 5 | Resultados | 169 |
| 5.1 | Resultados parciales: Detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” | 170 |
| 5.1.1 | Resultados numéricos | 170 |
| 5.1.1.1 | FUNDAMENTOS: Clasificadores basados en árbol de decisión | 171 |
| 5.1.1.2 | FUNDAMENTOS: Clasificador Selva Aleatoria o <i>Random Forest</i> | 171 |
| 5.1.1.3 | FUNDAMENTOS: Exactitud, sensibilidad, especificidad y AUC | 173 |
| 5.1.1.4 | FUNDAMENTOS: Validación cruzada | 174 |
| 5.1.2 | Ejemplos gráficos | 176 |

ÍNDICE GENERAL

| | | |
|----------|--|------------|
| 5.2 | Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo | 183 |
| 5.2.1 | Resultados numéricos. Selección del mejor modelo | 183 |
| 5.2.1.1 | FUNDAMENTOS: Clasificador C4.5 | 190 |
| 5.2.2 | Ejemplos gráficos | 191 |
| 5.2.2.1 | Tarea 1: Generación de las máscaras correspondientes a los $\alpha - cortes$ para cada α_{red} y para cada $\alpha_{agujero}$ e intersección con la máscara de segmentación | 192 |
| 5.2.2.2 | Tarea 2: Selección de los agujeros de tamaño adecuado para cada α_{red} | 198 |
| 5.2.2.3 | Tarea 3: Selección de los agujeros agrupados en alguna subred para cada α_{red} | 200 |
| 5.2.2.4 | Tarea 4: Selección de los agujeros que pertenecen a la red pigmentada para cada $(\alpha_{red}, \alpha_{agujero})$ | 202 |
| 5.3 | Resultados finales: Reconocimiento del patrón red pigmentada o reticular | 215 |
| 5.3.1 | Análisis del comportamiento del método frente a las imágenes de la base de datos | 215 |
| 5.3.2 | Comparación entre el método propuesto y los métodos más relevantes del estado del arte | 220 |
| 6 | Conclusiones | 223 |
| 6.1 | Cumplimiento de objetivos | 223 |
| 6.2 | Contribuciones | 225 |
| 6.2.1 | Reconocimiento del patrón reticular | 226 |
| 6.2.1.1 | Diseño innovador del algoritmo | 227 |
| 6.2.1.2 | No necesidad de realizar un preprocesado previo | 229 |
| 6.2.1.3 | Robusto frente a la no segmentación de la lesión | 229 |
| 6.2.1.4 | Gran capacidad de discriminación entre este patrón y otros patrones dermatoscópicos | 229 |
| 6.2.1.5 | Gran fiabilidad del método | 230 |

| | | |
|---------|---|-----|
| 6.2.1.6 | Establecimiento de un nuevo enfoque metodológico para trabajos de este tipo | 230 |
| 6.2.1.7 | Puede ser utilizado en otros problemas de reconocimiento de patrones de naturaleza similar . . . | 231 |
| 6.2.2 | Estudio del estado del arte relativo a los métodos para la detección automatizada de melanoma, especialmente exhaustivo en las áreas en las que se ha centrado la investigación | 231 |
| 6.2.3 | Creación de base de datos de imágenes dermatoscópicas | 231 |
| 6.2.4 | <i>Framework</i> software para el desarrollo de algoritmos de procesamiento digital de imagen | 232 |
| 6.2.5 | Segmentación de la lesión | 232 |
| 6.2.6 | Reconocimiento del patrón globular | 233 |
| 6.2.7 | Reconocimiento del patrón puntos | 233 |
| 6.2.8 | Reconocimiento del patrón ramificaciones lineales/pseudópodos | 233 |
| 6.2.9 | Reconocimiento del patrón velo azul-blanquecino | 234 |
| 6.2.10 | Reconocimiento del patrón homogéneo | 234 |
| 6.2.11 | Reconocimiento del patrón homogéneo azulado | 234 |
| 6.2.12 | Reconocimiento del patrón manchas de pigmento | 235 |
| 6.2.13 | Reconocimiento del patrón hipopigmentación | 235 |
| 6.2.14 | Reconocimiento de los indicadores asimetría, bordes y color correspondientes al algoritmo médico “Regla del ABCD” | 235 |
| 6.2.15 | Prototipo software para el diagnóstico de melanoma | 236 |
| 6.3 | Impacto científico | 236 |
| 6.3.1 | Artículos y capítulos de libros | 237 |
| 6.3.1.1 | Artículo: “Detection of pigment network in dermoscopy images using supervised machine learning and structural analysis” | 237 |
| 6.3.1.2 | Capítulo de libro: “Automated detection of melanoma in dermoscopic images” | 237 |

ÍNDICE GENERAL

| | | |
|---------|---|-----|
| 6.3.1.3 | Capítulo de libro: “Comparison of image processing techniques for reticular pattern recognition in melanoma detection” | 238 |
| 6.3.1.4 | Artículo: “Hypopigmentation pattern recognition in dermoscopy images for melanoma detection” | 238 |
| 6.3.1.5 | Artículo: “Recognition of pigment network pattern in dermoscopy images based on fuzzy classification of pixels” | 239 |
| 6.3.1.6 | Artículo: “Segmentation of skin lesions based on fuzzy classification of pixels and histogram thresholding” | 239 |
| 6.3.2 | Congresos | 240 |
| 6.3.2.1 | “Blue-white veil and dark-red patch of pigment pattern recognition in dermoscopic images using machine-learning techniques” | 240 |
| 6.3.2.2 | “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” | 240 |
| 6.3.3 | Patentes y registros software | 241 |
| 6.3.3.1 | Herramienta software “MELANOPAS” | 241 |
| 6.3.4 | Otros méritos de investigación | 241 |
| 6.3.4.1 | Artículo del periódico Cinco Días | 241 |
| 6.3.4.2 | Primer Premio en el Certamen de Trabajos Estudiantiles del CIITI 2014 | 241 |
| 6.3.4.3 | Áccesit (Segundo Premio) en la XI Edición del Premio UD-GRUPO SANTANDER de Investigación (Convocatoria 2015) | 242 |
| 6.3.4.4 | Reto del ISIC 2016 para la segmentación de la lesión en una imagen dermatoscópica | 242 |
| 6.3.4.5 | Reto del ISIC 2017 para la segmentación de la lesión en una imagen dermatoscópica | 243 |
| 6.3.5 | Impacto científico no directamente relacionado con la presente investigación | 243 |

ÍNDICE GENERAL

| | | |
|--|---|------------|
| 6.3.5.1 | Artículos y capítulos de libros relacionados . . . | 244 |
| 6.3.5.2 | Congresos | 244 |
| 6.3.5.3 | Patentes y registros software | 245 |
| 6.4 | Líneas futuras | 246 |
| Bibliografía | | 249 |
| A MELANOPAS: un prototipo para el diagnóstico de melanoma | | 277 |
| A.1 | Introducción | 277 |
| A.2 | Arquitectura | 278 |
| A.3 | Herramienta software para el diagnóstico automatizado | 278 |
| A.3.1 | Preprocesado | 279 |
| A.3.2 | Segmentación | 279 |
| A.3.3 | Detección y caracterización de indicadores | 279 |
| A.3.3.1 | A: Asimetría | 279 |
| A.3.3.2 | B: Bordes | 279 |
| A.3.3.3 | C: Color | 281 |
| A.3.3.4 | D: Estructuras Dermatoscópicas | 281 |
| A.3.4 | Diagnosis | 282 |

Índice de figuras

| | | |
|-----|---|----|
| 1.1 | Dos imágenes dermatoscópicas de ejemplo, la primera corresponde a un nevo displásico –lesión benigna– y la segunda corresponde a un melanoma. Fuente en [ASP ⁺ 00]. | 3 |
| 1.2 | Ejemplos de patrones o estructuras dermatoscópicas. Fuente en [MPA09]. | 4 |
| 2.1 | a) Capas que forman la piel humana, fuente en [US 15]. b) Capas que forman la epidermis, fuente en [Ana15]. | 15 |
| 2.2 | Lesiones de la piel más relevantes, clasificadas por los criterios benignas/malignas y no melanocíticas/melanocíticas. | 17 |
| 2.3 | Ejemplos de lesiones de piel. a) Queratosis seborreica. b) Lesión vascular. c) Dermatofibroma. d) Lentigo. e) Nevo azul. f) Nevo de Spitz. g) Nevo melanocítico atípico. h) Carcinoma basocelular. Fuente en [ASP ⁺ 00]. | 21 |
| 2.4 | Niveles de Clark. Fuente en [Ter14] | 24 |
| 2.5 | a) Dispositivo de captura de imágenes de cuerpo entero Canfield VECTRA, fuente en [Can16]. b) Dermatoscopio MoleMax HD, fuente en [Der16]. c) Dermatoscopio multiespectral Melafind, fuente en [MEL15]. d) Dispositivo de captura de imágenes de microscopía confocal de reflectancia VivaScope, fuente en [MAV16]. . . | 31 |
| 2.6 | Método de las 2 Etapas. | 34 |

ÍNDICE DE FIGURAS

| | | |
|------|--|-----|
| 2.7 | Ejemplos de patrones dermatoscópicos. a) Retículo pigmentado. b) Glóbulos. c) Proyecciones. d) Velo azul-blanquecino. e) Hipopigmentación. f) Estructuras de regresión. g) Vascular. h) Paralelo. Fuente en [ASP ⁺ 00]. | 39 |
| 2.8 | Ciclo de vida de un sistema automatizado de detección de melanoma | 44 |
| 2.9 | Visión de alto nivel del método de Di Leo et al. 2008. Reimpreso con permisos de [DLPS08]. | 60 |
| 2.10 | Esquema del método propuesto por Sadeghi et al. 2011. Reimpreso con permisos de [SRLA11]. | 63 |
| 2.11 | Visión de alto nivel del método propuesto por Sadeghi et al. 2010. Reimpreso con permisos de [SRW ⁺ 10]. | 64 |
| 2.12 | Visión de alto nivel del método propuesto por Barata et al. 2012. Reimpreso con permisos de [BMR12b]. | 67 |
| 2.13 | Visión de alto nivel del método propuesto por García-Arroyo y García-Zapirain 2014. Reimpreso con permisos de [GAGZ14]. . . | 71 |
| 4.1 | Nuevo enfoque metodológico para la realización de un sistema de reconocimiento de un patrón dermatoscópico, en el que se introduce la especificación del sistema, que permite su posterior parametrización, como tarea obligatoria antes de su diseño y desarrollo dentro del ciclo de vida de construcción del sistema. | 98 |
| 4.2 | Dos ejemplos claros de presencia del patrón red pigmentada (con la categoría de “presente”). | 100 |
| 4.3 | Dos ejemplos claros de no presencia del patrón red pigmentada (con la categoría de “ausente”). | 101 |
| 4.4 | Cuatro ejemplos de imágenes categorizadas con patrón red pigmentada (categorizadas como “presente”) en las que la estructura tiene bajo contraste y la red es muy tenue, además en la última de ellas hay muy pocos agujeros. | 101 |
| 4.5 | Dos ejemplos de “imágenes frontera”, una “presente” y la otra “ausente”, en las cuales el etiquetado es muy discutible. | 102 |

| | | |
|------|--|-----|
| 4.6 | Dos ejemplos de imágenes en las cuales la presencia de pelos dificulta el reconocimiento del patrón red pigmentada, una “presente” y la otra “ausente”. | 103 |
| 4.7 | Cuatro ejemplos de imágenes en las cuales la presencia de aceite dificulta el reconocimiento del patrón red pigmentada, dos “presente” y la otras dos “ausente”. | 104 |
| 4.8 | Diagrama de alto nivel del sistema. | 107 |
| 4.9 | Máscaras de segmentación correspondientes a 4 imágenes de ejemplo. | 109 |
| 4.10 | Fases del módulo 1 de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad. | 111 |
| 4.11 | Tareas correspondientes a la fase 1.2 de extracción de características de los pixels. | 113 |
| 4.12 | El Modelo de color RGB se puede describir utilizando un cubo, en el que los tres ejes de coordenadas son R, G y B. En este caso se utilizan valores entre 0 y 255. En las dos primeras se puede ver las direcciones ascendentes y descendentes de las tres dimensiones, en la tercera un ejemplo para el valor RGB (83,150,60). Fuente en [Wik15]. | 114 |
| 4.13 | El Modelo de color HSV se puede describir como un cono, correspondiendo el ángulo a la H, el radio a la S y la altura a la V. Fuente en [Wik05]. | 116 |
| 4.14 | Campana de Gauss 2D. Fuente en [Wik06]. | 120 |
| 4.15 | A nivel gráfico, diferencia entre un conjunto nítido (<i>crisp</i>) y un conjunto difuso (<i>fuzzy</i>). Fuente en [Wik09]. | 129 |
| 4.16 | Ejemplo del proceso de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} | 131 |

ÍNDICE DE FIGURAS

- 4.17 Sigue con el ejemplo de la Fig. anterior –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} 132
- 4.18 Sigue con el ejemplo de las dos Figs. anteriores –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Esta imagen de color es la imagen $I_{red.agujero.otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul. 133
- 4.19 Ejemplo del proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad, en una imagen con red pigmentada. La primera imagen es la original I . Las tres siguientes son las imágenes de probabilidad (imágenes de gris) I_{red} , $I_{agujero}$ e I_{otro} . La quinta es la imagen de color $I_{red.agujero.otro}$ 137
- 4.20 Ejemplo de las máscaras extraídas de las imágenes de probabilidad I_{red} e $I_{agujero}$ de la Fig. 4.19 correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para α_{red} y $\alpha_{agujero}$ e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,3}$; 2: $BW_{agujero}^{0,3}$; 3: $BW_{red}^{0,4}$; 4: $BW_{agujero}^{0,4}$; 5: $BW_{red}^{0,5}$; 6: $BW_{agujero}^{0,5}$ 138
- 4.21 Ejemplo de las combinaciones de las máscaras extraídas de las imágenes de probabilidad correspondientes a los α – cortes obtenidos a partir de los conjuntos difusos en una imagen con red pigmentada, cuyas imágenes de probabilidad se muestran en la Fig. 4.19 y algunos ejemplos de máscaras extraídas correspondientes a α – cortes en la Fig. 4.20. Son imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$. 1 y 2: $I_{RP}^{(0,3,0,3)}[0,7]$ y $I_{RP}^{(0,3,0,3)}[0,8]$, respectivamente, nótese que $prop = 0,7$ en el primer caso y $prop = 0,8$ en el segundo. 139

4.22 Sigue con el ejemplo de la Fig. anterior –ejemplo de las combinaciones de las máscaras extraídas de las imágenes de probabilidad correspondientes a los α – cortes obtenidos a partir de los conjuntos difusos–. Son imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$. 3: $I_{RP}^{(0,1,0,1)}[0,9]$; 4: $I_{RP}^{(0,2,0,5)}[0,8]$ 140

4.23 Sigue con el ejemplo de las dos Figs. anteriores –ejemplo de las combinaciones de las máscaras extraídas de las imágenes de probabilidad correspondientes a los α – cortes obtenidos a partir de los conjuntos difusos–. Son imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$. 5: $I_{RP}^{(0,4,0,3)}[0,7]$; 6: $I_{RP}^{(0,5,0,3)}[0,6]$ 141

4.24 Fases del módulo 2 de procesamiento y caracterización de las imágenes de probabilidad y diagnóstico. 143

4.25 Tareas dentro de la fase 2.1 correspondientes a la generación, para cada combinación de valores de ($prop, numMinAgujeros, dist MaxAgujeros, rang MaxTamanyoAgujeros$), de los modelos de clasificación correspondientes a los procesos de aprendizaje supervisado, en la fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente”. 145

4.26 Esta imagen, que tiene el patrón red pigmentada, se ha tomado como ejemplo para ilustrar las diferentes tareas realizadas en esta fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” del módulo 2. Aquí se muestran las imágenes resultado del módulo 1. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} 146

4.27 Sigue con el ejemplo de la Fig. anterior –para una imagen que tiene el patrón red pigmentada y que se ha tomado como ejemplo para ilustrar las diferentes tareas realizadas en esta fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” del módulo 2, se muestran aquí las imágenes resultado del módulo 1–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} 147

ÍNDICE DE FIGURAS

- 4.28 Sigue con el ejemplo de las dos Figs. anteriores –para una imagen que tiene el patrón red pigmentada y que se ha tomado como ejemplo para ilustrar las diferentes tareas realizadas en esta fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” del módulo 2, se muestran aquí las imágenes resultado del módulo 1–. Esta imagen es la imagen de color $I_{red.agujero.otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul. 148
- 4.29 En la tarea 1, ejemplos de máscaras $BW_{red}^{\alpha_{red}}$ y $BW_{agujero}^{\alpha_{agujero}}$ extraídas de las imágenes de probabilidad I_{red} e $I_{agujero}$ correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para α_{red} y $\alpha_{agujero}$ e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,3}$; 2: $BW_{agujero}^{0,3}$; 3: $BW_{red}^{0,4}$; 4: $BW_{agujero}^{0,4}$; 5: $BW_{red}^{0,5}$; 6: $BW_{agujero}^{0,5}$ 150
- 4.30 En la tarea 1, ejemplos de máscaras $BW_{agujerosdered}^{\alpha_{red}}$ de agujeros de $BW_{red}^{\alpha_{red}}$: 1: $BW_{agujerosdered}^{0,3}$; 2: $BW_{agujerosdered}^{0,4}$; 3: $BW_{agujerosdered}^{0,5}$; 4: $BW_{agujerosdered}^{0,6}$ 151
- 4.31 En la tarea 2, las máscaras $BW_{agujerosdered}^{\alpha_{red}}$ de la tarea anterior, modificadas tras la selección de agujeros de tamaño adecuado: 1: $BW_{agujerosdered}^{0,3}$; 2: $BW_{agujerosdered}^{0,4}$; 3: $BW_{agujerosdered}^{0,5}$; 4: $BW_{agujerosdered}^{0,6}$ 152
- 4.32 En la tarea 3, a partir de las $BW_{agujerosdered}^{\alpha_{red}}$ de la tarea anterior y para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (2, 20, 0,8)$, las diferentes imágenes de color $I_{conjuntodesubredes}^{\alpha_{red}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas: 1: $I_{conjuntodesubredes}^{0,3}$; 2: $I_{conjuntodesubredes}^{0,4}$ 154

- 4.33 Sigue con el ejemplo de la Fig. anterior –en la tarea 3, a partir de las $BW_{agujerosdered}^{\alpha_{red}}$ de la tarea anterior y para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (2, 20, 0, 8)$, las diferentes imágenes de color $I_{conjuntodesubredes}^{\alpha_{red}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas–: 3: $I_{conjuntodesubredes}^{0,5}$; 4: $I_{conjuntodesubredes}^{0,6}$ 155
- 4.34 En la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$ en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada (definida en 4.3.2.1), correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0, 5, 2, 20, 0, 8)$. 1: $I_{RP}^{(0,3,0,3)}$; 2: $I_{RP}^{(0,3,0,4)}$ 157
- 4.35 Sigue con el ejemplo de la Fig. anterior –en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$ en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0, 5, 2, 20, 0, 8)$ –. 3: $I_{RP}^{(0,3,0,5)}$; 4: $I_{RP}^{(0,4,0,3)}$ 158
- 4.36 Sigue con el ejemplo de las dos Figs. anteriores –en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$ en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0, 5, 2, 20, 0, 8)$ –. 5: $I_{RP}^{(0,4,0,4)}$; 6: $I_{RP}^{(0,4,0,5)}$ 159
- 4.37 Capas del *framework* software construido. Las dos primeras han sido desarrolladas en el transcurso de la presente investigación. 164

ÍNDICE DE FIGURAS

| | | |
|-----|--|-----|
| 5.1 | Ejemplo de clasificador basado en árbol de decisión, generado a partir de un conjunto de datos etiquetados para el aprendizaje. Se tienen 4 atributos (X_1 , X_2 , X_3 y X_4) y tres posibles decisiones (D_1 , D_2 y D_3). Nótese que las decisiones son tomadas a partir de los valores de los atributos X_3 y X_4 | 172 |
| 5.2 | Ejemplo de curva ROC. Fuente en [Wik14]. | 174 |
| 5.3 | Ejemplo de validación cruzada de k iteraciones (con $k=4$). Fuente en [Wik11]. | 175 |
| 5.4 | A partir de la primera imagen dermatoscópica de ejemplo, ejemplo del proceso de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} | 177 |
| 5.5 | A partir de la primera imagen dermatoscópica de ejemplo, sigue con el ejemplo de la Fig. anterior –proceso de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} | 178 |
| 5.6 | A partir de la primera imagen dermatoscópica de ejemplo, sigue con el ejemplo de las dos Figs. anteriores –proceso de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Esta imagen de color es la imagen $I_{red.agujero.otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul. | 179 |
| 5.7 | A partir de la segunda imagen dermatoscópica de ejemplo, ejemplo del proceso de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} | 180 |

| | | |
|------|--|-----|
| 5.8 | A partir de la segunda imagen dermatoscópica de ejemplo, sigue con el ejemplo de la Fig. anterior –proceso de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} | 181 |
| 5.9 | A partir de la segunda imagen dermatoscópica de ejemplo, sigue con el ejemplo de las dos Figs. anteriores –proceso de detección difusa o <i>fuzzy</i> de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Esta imagen de color es la imagen $I_{red_agujero_otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul. | 182 |
| 5.10 | A partir de la primera imagen, en la tarea 1, ejemplos de máscaras $BW_{red}^{\alpha_{red}}$ extraídas de la imagen de probabilidad I_{red} correspondientes a varios α – <i>cortes</i> obtenidos usando diferentes valores de probabilidad para α_{red} e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,1}$; 2: $BW_{red}^{0,2}$; 3: $BW_{red}^{0,3}$; 4: $BW_{red}^{0,4}$; 5: $BW_{red}^{0,5}$; 6: $BW_{red}^{0,6}$ | 192 |
| 5.11 | A partir de la segunda imagen, en la tarea 1, ejemplos de máscaras $BW_{red}^{\alpha_{red}}$ extraídas de la imagen de probabilidad I_{red} correspondientes a varios α – <i>cortes</i> obtenidos usando diferentes valores de probabilidad para α_{red} e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,1}$; 2: $BW_{red}^{0,2}$; 3: $BW_{red}^{0,3}$; 4: $BW_{red}^{0,4}$; 5: $BW_{red}^{0,5}$; 6: $BW_{red}^{0,6}$ | 193 |
| 5.12 | A partir de la primera imagen, en la tarea 1, ejemplos de máscaras $BW_{agujero}^{\alpha_{agujero}}$ extraídas de la imagen de probabilidad $I_{agujero}$ correspondientes a varios α – <i>cortes</i> obtenidos usando diferentes valores de probabilidad para $\alpha_{agujero}$ e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{agujero}^{0,1}$; 2: $BW_{agujero}^{0,2}$; 3: $BW_{agujero}^{0,3}$; 4: $BW_{agujero}^{0,4}$; 5: $BW_{agujero}^{0,5}$; 6: $BW_{agujero}^{0,6}$ | 194 |

ÍNDICE DE FIGURAS

- 5.13 A partir de la segunda imagen, en la tarea 1, ejemplos de máscaras $BW_{\text{agujero}}^{\alpha_{\text{agujero}}}$ extraídas de la imagen de probabilidad I_{agujero} correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para α_{agujero} e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{\text{agujero}}^{0,1}$; 2: $BW_{\text{agujero}}^{0,2}$; 3: $BW_{\text{agujero}}^{0,3}$; 4: $BW_{\text{agujero}}^{0,4}$; 5: $BW_{\text{agujero}}^{0,5}$; 6: $BW_{\text{agujero}}^{0,6}$ 195
- 5.14 A partir de la primera imagen, en la tarea 1, ejemplos de máscaras $BW_{\text{agujerosdered}}^{\alpha_{\text{red}}}$ de agujeros de $BW_{\text{red}}^{\alpha_{\text{red}}}$: 1: $BW_{\text{agujerosdered}}^{0,1}$; 2: $BW_{\text{agujerosdered}}^{0,2}$; 3: $BW_{\text{agujerosdered}}^{0,3}$; 4: $BW_{\text{agujerosdered}}^{0,4}$; 5: $BW_{\text{agujerosdered}}^{0,5}$; 6: $BW_{\text{agujerosdered}}^{0,6}$ 196
- 5.15 A partir de la segunda imagen, en la tarea 1, ejemplos de máscaras $BW_{\text{agujerosdered}}^{\alpha_{\text{red}}}$ de agujeros de $BW_{\text{red}}^{\alpha_{\text{red}}}$: 1: $BW_{\text{agujerosdered}}^{0,1}$; 2: $BW_{\text{agujerosdered}}^{0,2}$; 3: $BW_{\text{agujerosdered}}^{0,3}$; 4: $BW_{\text{agujerosdered}}^{0,4}$; 5: $BW_{\text{agujerosdered}}^{0,5}$; 6: $BW_{\text{agujerosdered}}^{0,6}$ 197
- 5.16 A partir de la primera imagen, en la tarea 2, las máscaras $BW_{\text{agujerosdered}}^{\alpha_{\text{red}}}$ de la tarea anterior, modificadas tras la selección de agujeros de tamaño adecuado: 1: $BW_{\text{agujerosdered}}^{0,1}$; 2: $BW_{\text{agujerosdered}}^{0,2}$; 3: $BW_{\text{agujerosdered}}^{0,3}$; 4: $BW_{\text{agujerosdered}}^{0,4}$; 5: $BW_{\text{agujerosdered}}^{0,5}$; 6: $BW_{\text{agujerosdered}}^{0,6}$ 198
- 5.17 A partir de la segunda imagen, en la tarea 2, las máscaras $BW_{\text{agujerosdered}}^{\alpha_{\text{red}}}$ de la tarea anterior, modificadas tras la selección de agujeros de tamaño adecuado: 1: $BW_{\text{agujerosdered}}^{0,1}$; 2: $BW_{\text{agujerosdered}}^{0,2}$; 3: $BW_{\text{agujerosdered}}^{0,3}$; 4: $BW_{\text{agujerosdered}}^{0,4}$; 5: $BW_{\text{agujerosdered}}^{0,5}$; 6: $BW_{\text{agujerosdered}}^{0,6}$ 199
- 5.18 A partir de la primera imagen, en la tarea 3, a partir de las $BW_{\text{agujerosdered}}^{\alpha_{\text{red}}}$ de la tarea anterior y para valores de $(\text{numMin Agujeros}, \text{distMax Agujeros}, \text{rangMaxTamanyo Agujeros}) = (2, 20, 0,8)$, las diferentes imágenes de color $I_{\text{conjuntodesubredes}}^{\alpha_{\text{red}}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas: 1: $I_{\text{conjuntodesubredes}}^{0,1}$; 2: $I_{\text{conjuntodesubredes}}^{0,2}$; 3: $I_{\text{conjuntodesubredes}}^{0,3}$; 4: $I_{\text{conjuntodesubredes}}^{0,4}$; 5: $I_{\text{conjuntodesubredes}}^{0,5}$; 6: $I_{\text{conjuntodesubredes}}^{0,6}$ 200

- 5.19 A partir de la segunda imagen, en la tarea 3, a partir de las $BW_{agujerosdered}^{\alpha_{red}}$ de la tarea anterior y para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (2, 20, 0,8)$, las diferentes imágenes de color $I_{conjuntodesubredes}^{\alpha_{red}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas:
 1: $I_{conjuntodesubredes}^{0,1}$; 2: $I_{conjuntodesubredes}^{0,2}$; 3: $I_{conjuntodesubredes}^{0,3}$; 4: $I_{conjuntodesubredes}^{0,4}$; 5: $I_{conjuntodesubredes}^{0,5}$; 6: $I_{conjuntodesubredes}^{0,6}$ 201
- 5.20 A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 1: $I_{RP}^{(0,2,0,3)}$; 2: $I_{RP}^{(0,2,0,4)}$ 203
- 5.21 A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 3: $I_{RP}^{(0,2,0,5)}$; 4: $I_{RP}^{(0,3,0,3)}$ 204
- 5.22 A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 5: $I_{RP}^{(0,3,0,4)}$; 6: $I_{RP}^{(0,3,0,5)}$ 205

ÍNDICE DE FIGURAS

- 5.23 A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 7: $I_{RP}^{(0,4,0,3)}$; 8: $I_{RP}^{(0,4,0,4)}$ 206
- 5.24 A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 9: $I_{RP}^{(0,4,0,5)}$; 10: $I_{RP}^{(0,5,0,3)}$ 207
- 5.25 A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 11: $I_{RP}^{(0,5,0,4)}$; 12: $I_{RP}^{(0,5,0,5)}$ 208
- 5.26 A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 1: $I_{RP}^{(0,2,0,3)}$; 2: $I_{RP}^{(0,2,0,4)}$ 209

- 5.27 A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamañoAgujeros) = (0,5, 2, 20, 0,8)$: 3: $I_{RP}^{(0,2,0,5)}$; 4: $I_{RP}^{(0,3,0,3)}$ 210
- 5.28 A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamañoAgujeros) = (0,5, 2, 20, 0,8)$: 5: $I_{RP}^{(0,3,0,4)}$; 6: $I_{RP}^{(0,3,0,5)}$ 211
- 5.29 A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamañoAgujeros) = (0,5, 2, 20, 0,8)$: 7: $I_{RP}^{(0,4,0,3)}$; 8: $I_{RP}^{(0,4,0,4)}$ 212
- 5.30 A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamañoAgujeros) = (0,5, 2, 20, 0,8)$: 9: $I_{RP}^{(0,4,0,5)}$; 10: $I_{RP}^{(0,5,0,3)}$ 213

ÍNDICE DE FIGURAS

- 5.31 A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamañoAgujeros) = (0,5, 2, 20, 0,8)$: 11: $I_{RP}^{(0,5,0,4)}$; 12: $I_{RP}^{(0,5,0,5)}$ 214
- 5.32 Dos ejemplos claros de presencia del patrón red pigmentada (con la categoría de “presente”), en los cuales el método funciona correctamente. Ejemplos de VP (verdadero positivo). 217
- 5.33 Dos ejemplos claros de no presencia del patrón red pigmentada (con la categoría de “ausente”), en los cuales el método funciona correctamente. Ejemplos de VN (verdadero negativo). 217
- 5.34 Cuatro ejemplos de imágenes categorizadas con patrón red pigmentada (categorizadas como “presente”) en los que la estructura tiene bajo contraste y la red es muy tenue, además en la última de ellas hay muy pocos agujeros, en los cuales el método funciona correctamente. Ejemplos de VP (verdadero positivo). 218
- 5.35 Dos ejemplos de imágenes en las cuales la presencia de pelos dificulta el reconocimiento del patrón red pigmentada, una “presente” y la otra “ausente”, en los cuales el método funciona correctamente. La primera sería un ejemplo de VP (verdadero positivo) y la segunda sería un ejemplo de VN (verdadero negativo). 218
- 5.36 Cuatro ejemplos de imágenes en las cuales la presencia de aceite dificulta el reconocimiento del patrón red pigmentada, dos “presente” y la otras dos “ausente”, en los cuales el método funciona correctamente. Las dos primeras serían ejemplos de VP (verdadero positivo) y las dos siguientes serían ejemplos de VN (verdadero negativo). 219

| | |
|--|-----|
| 5.37 Dos ejemplos de “imágenes frontera”, una “presente” y la otra “ausente”, en las cuales el etiquetado es muy discutible, en los cuales el método no funciona correctamente. La primera sería un ejemplo de FN (falso negativo) y la segunda sería un ejemplo de FP (falso positivo). | 219 |
| A.1 Arquitectura de MELANOPAS | 278 |
| A.2 Computación de la asimetría en una imagen: 1. Preprocesada; 2. Comparación de formas respecto al eje mayor; 3. Comparación de histogramas respecto a eje mayor; 4. Imagen con los ejes; 5. Comparación de formas respecto a eje menor; 6. Comparación de histogramas respecto a eje mayor. La imagen es simétrica en formas con respecto a ambos ejes, y asimétrica en color con respecto a ambos ejes. Por tanto, es asimétrica en ambos ejes. Puntuación: 2.6. . . . | 280 |
| A.3 Computación de los bordes en una imagen: 1. Preprocesada; 2. Imagen con los octantes generados; 3. Corona en el entorno del borde de la lesión donde se examina la abrupción de bordes; 4. Imagen con los límites pintados; 5. Imagen con los radios para el análisis generados; 6. Octante I; 7. Análisis del sector I. La imagen tiene abruptos los sectores: I, II, V, VI y VII. Puntuación: 0,5. . . . | 280 |
| A.4 Clasificación de los colores en dos imágenes. La primera tiene 3 colores. Puntuación: 1,5. La segunda tiene 2 colores. Puntuación: 1,0. | 281 |
| A.5 Computación de estructuras dermatoscópicas (reticular no incluido): primero la imagen, segundo la máscara del patrón (mapa en el caso de áreas homogéneas y desestructuradas). 1. Áreas homogéneas y desestructuradas, puntuación: 0,5; 2. Globular, puntuación: 0,5; 3. Puntos, puntuación: 0,5; 4. Pseudópodos, puntuación: 0,5. . . . | 281 |

ÍNDICE DE FIGURAS

| | | |
|-----|--|-----|
| A.6 | Algunas ventanas de la herramienta software: 1. Imagen original; 2. Preprocesada; 3. Segmentación manual por si se requiere; 4. Segmentada; 5. A: Asimetría; 6. B: Bordes; 7. C: Colores; 8. D: Estructuras Dermatoscópicas; 9. Resultados; 10. Máscara reticular; 11- Áreas homogéneas y desestructuradas; 12. Máscara globular; 13. Máscara puntos; 14. Máscara pseudópodos; 15. Resultados; 16. Informe generado. | 283 |
|-----|--|-----|

Índice de tablas

| | | |
|-----|---|----|
| 2.1 | Relación de los patrones dermatoscópicos objeto de estudio, en cuanto a su reconocimiento, con los indicadores de los metodos médicos. | 41 |
| 2.2 | Objetivos de los trabajos más relevantes de detección y caracterización de patrones dermatoscópicos. En la primera columna, los trabajos seleccionados; en la segunda, para cada trabajo, los patrones cuyo reconocimiento aborda y para las que ha sido seleccionado (RP: Retículo pigmentado, GP: Glóbulos / Puntos, PR: Proyecciones, VAB: Velo azul-blanquecino, HO: Homogéneo, HOAZ: Homogéneo azulado, MP: Manchas de pigmento, HIPO: Hipopigmentación, ER: Estructuras de regresión, VA: Vascular y PA: Paralelo) –lo cual no significa que no pueda tratar más patrones, sino que ha sido seleccionado como relevante para los señalados–; finalmente, en la tercera, los principales objetivos de ese trabajo en el reconocimiento de dichos patrones. | 48 |

ÍNDICE DE TABLAS

| | | |
|-----|---|-----|
| 2.3 | Relación entre trabajos. En la primera columna, los trabajos seleccionados; en la segunda, para cada trabajo, los patrones cuyo reconocimiento aborda y para las que ha sido seleccionado (RP: Retículo pigmentado, GP: Glóbulos / Puntos, PR: Proyecciones, VAB: Velo azul-blanquecino, HO: Homogéneo, HOAZ: Homogéneo azulado, MP: Manchas de pigmento, HIPO: Hipopigmentación, ER: Estructuras de regresión, VA: Vascular y PA: Paralelo) –lo cual no significa que no pueda tratar más patrones, sino que ha sido seleccionado como relevante para los señalados–; en la tercera los trabajos seleccionados relacionados; finalmente, en la cuarta, los trabajos relacionados no seleccionados. | 53 |
| 2.4 | Técnicas usadas en los trabajos seleccionados para las diferentes tareas. En cada línea: Trabajo seleccionado, Tipo de técnica (PDI: Procesamiento Digital de Imagen y EMD: Estadística o Minería de Datos), <i>Tarea</i> y Técnicas (referenciadas, si es necesario). | 74 |
| 2.5 | Resultados numéricos obtenidos en los trabajos seleccionados. En cada línea: Trabajo seleccionado, Tipo de resultado (RPR: Reconocimiento del Patrón Reticular, RPRA: Reconocimiento del Patrón Reticular Atípico, OTR: Otro), <i>Resultado</i> , Número de imágenes y Resultados numéricos (EXA: Exactitud, SE: Sensibilidad, ES: Especificidad y AUC: <i>Area Under Curve</i>) con la descripción, si es necesario. | 83 |
| 2.6 | Resultados de los trabajos más relevantes en el reconocimiento del patrón reticular (EXA: Exactitud, SE: Sensibilidad, ES: Especificidad y AUC: <i>Area Under Curve</i>). | 86 |
| 2.7 | Resultados de los trabajos más relevantes en el reconocimiento del patrón reticular atípico (EXA: Exactitud, SE: Sensibilidad, ES: Especificidad y AUC: <i>Area Under Curve</i>). | 87 |
| 5.1 | Valores obtenidos en los experimentos para los 4 indicadores definidos como más relevantes, usando validación cruzada de 10 iteraciones, agrupando los resultados por subconjuntos de características (AUC: <i>area under curve</i> , EXA: exactitud). | 186 |

| | | |
|-----|---|-----|
| 5.2 | Valores obtenidos en los experimentos para los 4 indicadores definidos como más relevantes, usando validación cruzada de 10 iteraciones, agrupando los resultados por combinaciones de parámetros y mostrando únicamente los 10 primeros relativos a los indicadores 1 y 3 (AUC: <i>area under curve</i> , EXA: exactitud). | 188 |
| 5.3 | Valores obtenidos en los experimentos para los 4 indicadores definidos como más relevantes, usando validación cruzada de 10 iteraciones, agrupando los resultados por combinaciones de parámetros y mostrando únicamente los 10 primeros relativos a los indicadores 2 y 4 (AUC: <i>area under curve</i> , EXA: exactitud). | 189 |
| 5.4 | Resultados de los trabajos más relevantes en el reconocimiento del patrón reticular (SE: sensibilidad, ES: especificidad, EXA: exactitud y AUC: <i>area under curve</i>). | 221 |

*Los ideales son como las estrellas.
No lograremos tocarlas con las ma-
nos, pero al navegante en la inmen-
sidad del océano le sirven de guía
para llegar a su destino.*

Carl Schurz

CAPÍTULO

1

Introducción

En este capítulo se presenta la introducción. En primer lugar, se describe la motivación para la realización de este trabajo de investigación. En segundo lugar, se muestra la hipótesis de partida. En tercer lugar, se detallan los objetivos del trabajo. En cuarto lugar, se describe la metodología de investigación que se ha utilizado. Finalmente, en quinto lugar, se explica la estructura de este documento.

1.1 Motivación

El melanoma es la forma más peligrosa de cáncer de piel, representando aproximadamente el 1,5 % del total de casos de cáncer a nivel mundial [AEC12a]. En los últimos años se ha convertido en un grave problema de salud pública en países como Australia, Nueva Zelanda, Estados Unidos o Sudáfrica, con gran número de individuos de piel blanca y alta incidencia solar. También en España, como en el resto de Europa, el melanoma es un problema muy serio para las autoridades sanitarias [AEC12a]. Por ejemplo, en el año 2014 la incidencia de este tipo de cáncer era de un 2,3 % del total de casos, siendo más frecuente en mujeres (3,1 %) que en hombres (1,8 %) [SEO16]. Y el número de casos sigue creciendo, diagnosticándose unos 3600 casos nuevos cada año [AEC12a].

1. INTRODUCCIÓN

En la lucha contra el melanoma es fundamental la detección precoz. En caso de ser detectado a tiempo, cuando el tumor todavía no ha penetrado en la capa más profunda de la piel, la tasa de supervivencia es del 98 %, bajando al 17 % cuando ya ha entrado en el estado de metástasis [Ski16].

Históricamente, y aún actualmente, el método más utilizado para la detección precoz del melanoma ha sido la inspección visual por parte del médico, buscando “a simple vista” las lesiones sospechosas y realizando para éstas la biopsia. Este método tiene dos problemas: en primer lugar, la precisión diagnóstica de la inspección visual es manifiestamente mejorable, sobre todo si no es realizada por un experto dermatólogo, y además no es reproducible; en segundo lugar, la biopsia es un procedimiento diagnóstico seguro, pero su utilización presenta los inconvenientes de ser un método invasivo y de necesitarse muchos recursos, tanto humanos como materiales. Se hace pues evidente la necesidad de utilizar técnicas no invasivas que den buenos resultados en la detección de melanoma y necesiten pocos recursos.

La más utilizada es, de largo, la dermatoscopia, una técnica no invasiva que consiste en el examen de la piel mediante la utilización de un dermatoscopio, consistente en un sistema óptico y una fuente de luz diseñados para reducir la refracción irregular y la reflexión de la luz en su superficie, que hace posible visualizar en profundidad estructuras, formas y colores que no son accesibles a la simple inspección visual. El dermatoscopio está conectado a un ordenador, en el que se almacena la imagen capturada. La dermatoscopia presenta mejores resultados que la inspección visual: en manos expertas se consigue una sensibilidad del 92 %, frente al 70-85 % que se tenía “a simple vista” [MPA09]. Además, permite la reproducibilidad en el diagnóstico, así como el uso de técnicas de procesamiento digital de imagen. En la Fig. 1.1 se muestran dos imágenes dermatoscópicas de ejemplo.

Existen nuevas técnicas prometedoras alternativas a la dermatoscopia [PH09, RRF10, SM11, GG09, GM11], no obstante la facilidad de adquisición de imágenes, sus buenos resultados y su grado de utilización entre los expertos médicos asegura su utilización durante un largo período de tiempo, de hecho la dermatoscopia se considera como la prueba de referencia o *gold standard* en el cribado o *screening* de melanoma [GM11].




Figura 1.1: Dos imágenes dermatoscópicas de ejemplo, la primera corresponde a un nevo displásico –lesión benigna– y la segunda corresponde a un melanoma. Fuente en [ASP⁺00].

En el diagnóstico de melanoma sobre imágenes dermatoscópicas el procedimiento más usado es el “Método de las 2 Etapas” [MPA⁺07]. Usando este método el dermatólogo, en una primera etapa, debe discernir si la lesión es o no melanocítica a partir de una serie de criterios y, en una segunda etapa, en caso positivo, usar un método de diagnóstico para determinar el grado de malignidad, con el objetivo de decidir si se debe extirpar la lesión cutánea. Los más importantes son el “Análisis de Patrones” [PSW87], la “Regla del ABCD” [SAC94], la “Lista de los 7 puntos” [AFC⁺98] y el “Método de Menzies” [MICM96]. Se trata, en todos ellos, de detectar y caracterizar cuantitativamente una serie de indicadores y realizar el diagnóstico de acuerdo a unos rangos de valores preestablecidos. Los indicadores más relevantes son los llamados patrones o estructuras dermatoscópicas, estructuras complejas de forma y color que se pueden encontrar en imágenes dermatoscópicas tales como las que se presentan en la Fig. 1.2 y que indican información histopatológica. Los patrones más relevantes son: red pigmentada o reticular, glóbulos/puntos, proyecciones radiales, velo azul-blanquecino, homogéneo, homogéneo azulado, manchas de pigmento, hipopigmentación, vascular, estructuras de regresión y patrón paralelo. En cualquier caso, hay que tener en cuenta que su objetivación es particularmente difícil y, en muchas ocasiones, altamente influenciada por la subjetividad del dermatólogo [ASCA03].

Es evidente que la automatización de este proceso mediante un software de diagnóstico asistido por ordenador (CAD: *Computer Aided Diagnosis*) sería de

1. INTRODUCCIÓN

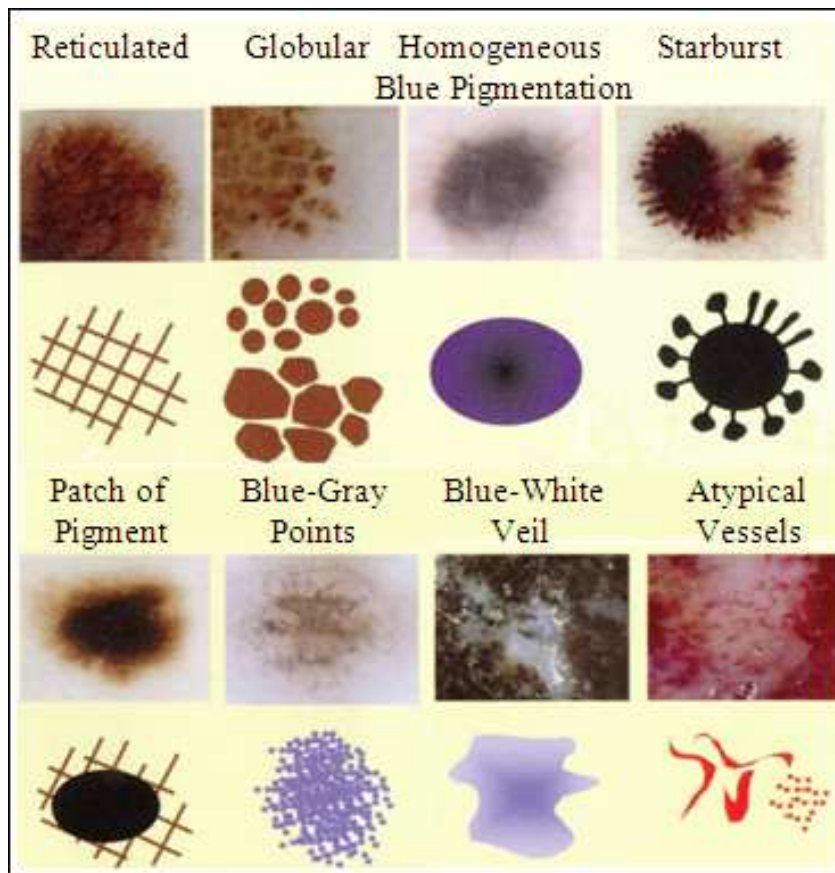


Figura 1.2: Ejemplos de patrones o estructuras dermatoscópicas. Fuente en [MPA09].

gran importancia para la mejora del sistema sanitario, especialmente en apoyo de la medicina primaria ya que, por una parte, podría acelerar la tarea médica y, por otra, proporcionar una evaluación objetiva de la lesión de la piel, disminuyendo la variabilidad inter e intra-observador que se puede encontrar en los diagnósticos realizados por expertos humanos [ASCA03]. Además podría ser utilizado en sistemas automatizados de cribado o *screening* con el fin de detectar melanomas en estados tempranos, sobre plataformas de telemedicina o de otro tipo.

Actualmente es un problema vigente a nivel científico, ya que no existen métodos para el diagnóstico automatizado de melanoma que ofrezcan un alto grado de fiabilidad en el diagnóstico [KG12, GCC⁺16]. También son problemas vigentes a nivel científico los subproblemas que lo componen –la segmentación de la lesión y el reconocimiento de los diferentes indicadores, entre ellos los patrones derma-

toscópicos– [KG12, GCC⁺16].

De hecho, en los últimos años se están realizando a nivel mundial intentos muy serios de realizar progresos importantes en estas cuestiones, como la creación por parte de la *International Society for Digital Imaging of the Skin* (ISDIS) del proyecto *International Skin Imaging Collaboration* (ISIC) para el avance colaborativo en el desarrollo de métodos de imagen para la detección de problemas de piel –y en particular la detección de melanoma– en el cual trabajan profesionales de diferentes disciplinas, especialmente expertos dermatólogos e ingenieros de imagen que, entre otras contribuciones, ha elaborado el Archivo ISIC [Int16] –una gran base de datos de imágenes dermatoscópicas diagnosticadas por expertos dermatólogos, accesible de manera libre– y ha organizado dos grandes retos, en 2016 [GCC⁺16] y en 2017 [Int17], entre equipos de investigación de todo el mundo –en el que por cierto, tal y como se verá, ha participado el equipo de investigación integrado por el doctorando y la directora de la presente tesis, obteniendo buenos resultados– para la solución de diferentes problemas relacionados con la detección automatizada de melanoma.

En este contexto, en la presente investigación se ha acometido un ambicioso objetivo, el diseño y desarrollo de una familia de algoritmos de procesamiento digital de imagen para la segmentación de la lesión y la detección y caracterización de diferentes indicadores, centrándose especialmente en los patrones dermatoscópicos, de cara a ser integrados en una herramienta software para la detección automatizada de melanoma.

Como consecuencia de esta investigación se han realizado aportaciones en: 1. La segmentación de la lesión; 2. El reconocimiento de los siguientes patrones dermatoscópicos: reticular, globular, puntos, ramificaciones lineales/pseudópodos, velo azul-blanquecino, homogéneo, homogéneo azulado, manchas de pigmento e hipopigmentación; 3. La detección y caracterización de los indicadores correspondientes al algoritmo médico “Regla del ABCD”: asimetría, bordes, color y los patrones dermatoscópicos que se computan en este algoritmo médico –incluidos en el punto anterior–; 4. Prototipo software para la detección automatizada de melanoma basado en el algoritmo médico “Regla del ABCD”. Las aportaciones más importantes son el algoritmo de segmentación, el algoritmo de reconocimiento del patrón reticular y el propio prototipo software de ayuda al diagnóstico.

1. INTRODUCCIÓN

La principal contribución de la investigación ha sido el algoritmo de reconocimiento del patrón reticular, un método muy innovador que puede ser utilizado además en otros problemas de reconocimiento de patrones de naturaleza similar. En este documento se explica de manera detallada este algoritmo.

1.2 Hipótesis

En la realización de la presente investigación se ha partido de la siguiente hipótesis:

“Sobre una imagen dermatoscópica es posible realizar de manera automatizada, con un alto nivel de fiabilidad, la segmentación de la lesión y la detección y caracterización de diferentes indicadores, y en particular de los patrones dermatoscópicos. Esta funcionalidad puede ser integrada en un sistema software para el diagnóstico de melanoma basado en alguno de los algoritmos médicos para el diagnóstico de melanoma”.

1.3 Objetivos

Partiendo de la hipótesis planteada, en esta investigación se ha planteado el siguiente objetivo general:

“Diseñar y desarrollar una familia de algoritmos de procesamiento digital de imagen para la segmentación de la lesión y la detección y caracterización de diferentes indicadores, centrándose especialmente en los patrones dermatoscópicos, de cara a ser integrados en un sistema software para el diagnóstico de melanoma basado en alguno de los algoritmos médicos para el diagnóstico de melanoma”.

Este objetivo general se detalla en una secuencia de objetivos específicos:

1. *“Estudiar la práctica médica actual, con el fin de identificar los puntos de mejora y determinar si se justifica la necesidad de la realización de la presente investigación, de cara a mejorar los sistemas de detección de melanoma que existen en la actualidad”.*

2. *“Realizar un estudio exhaustivo del estado del arte a nivel científico-tecnológico de los métodos para la detección automatizada de melanoma, especialmente en los campos donde se van a realizar las principales aportaciones”.*
3. *“Crear una base de datos para el diseño, desarrollo y validación de los algoritmos, con un elevado número de imágenes y clasificada según valoraciones diagnósticas realizadas por expertos dermatólogos”.*
4. *“Construir un framework para el desarrollo de algoritmos de procesamiento digital de imagen”.*
5. *“Diseñar y desarrollar un algoritmo para la segmentación automatizada de la lesión”.*
6. *“Diseñar y desarrollar una familia de algoritmos para la detección y caracterización de los patrones dermatoscópicos”.*
7. *“Evaluar el sistema con el fin de garantizar su fiabilidad y robustez”.*
8. *“Desarrollar un prototipo software para el diagnóstico de melanoma basado en la “Regla del ABCD”, el algoritmo médico más utilizado, en el que se integren los algoritmos desarrollados junto con la detección y caracterización de indicadores propios de este método médico”.*

Se han mostrado los objetivos planteados en esta investigación, por lo que se puede ver muy ambiciosos. En cualquier caso, tal y como se ha comentado anteriormente, este documento está centrado en el algoritmo de reconocimiento del patrón reticular, un método innovador de reconocimiento de patrones que constituye la principal aportación de esta investigación desde el punto de vista científico-tecnológico.

1.4 Metodología

En este trabajo de investigación se pretende mejorar el diagnóstico automatizado de melanoma. Para ello, se realizan contribuciones en la segmentación de la lesión

1. INTRODUCCIÓN

cutánea dentro de la imagen dermatoscópica y la posterior detección y caracterización de diferentes indicadores, centrándose especialmente en los patrones dermatoscópicos presentes en la lesión, de cara a ser integrados en un sistema software basado en un algoritmo médico para el diagnóstico de melanoma. Para conseguir este objetivo, la investigación ha sido llevada a cabo en las siguientes etapas:

1. **Adquisición de conocimiento.** Se estudia la práctica médica actual en este problema, profundizando especialmente en el área de la dermatoscopia, la prueba de referencia o *gold standard* para la detección precoz de melanoma. También se estudian los métodos existentes más relevantes a nivel tecnológico para la detección automatizada de melanoma, especialmente en el ámbito de la segmentación y el reconocimiento de los patrones dermatoscópicos.
2. **Enunciado de la hipótesis y planteamiento de los objetivos.** Se identifica el campo del conocimiento en el que se va a realizar la aportación, en este caso el diagnóstico automatizado de melanoma, especialmente en el ámbito de la segmentación y el reconocimiento de los patrones dermatoscópicos. Se enuncia la hipótesis de partida y se plantean los objetivos del trabajo.
3. **Creación de una base de datos de imágenes dermatoscópicas.** Se crea una base de datos de imágenes dermatoscópicas para el diseño, desarrollo y validación de los algoritmos.
4. **Especificación del sistema.** Se realiza la especificación del sistema, que servirá de base para el posterior diseño y desarrollo de los algoritmos.
5. **Construcción de un framework para el desarrollo de algoritmos de procesamiento digital de imagen.** Para el desarrollo de los algoritmos se construye un framework que permite la utilización de diferentes funcionalidades, entre ellas las técnicas de imagen requeridas.
6. **Diseño y desarrollo de los algoritmos.** Se realiza el diseño y desarrollo de los algoritmos de procesamiento digital de imagen.
7. **Evaluación de los algoritmos.** Se evalúan los diferentes algoritmos desarrollados. Esta evaluación es realizada a partir de las valoraciones diagnósticas realizadas por los expertos dermatólogos.

8. **Elaboración de las conclusiones.** A partir de la evaluación de los algoritmos desarrollados se elaboran las conclusiones.
9. **Difusión de los resultados.** Una vez se ha considerado que los objetivos de la investigación se han conseguido plenamente, se pasa a comunicar los resultados finales de la investigación.

La metodología utilizada en este trabajo de investigación está basada en la *Metodología de Investigación-Acción* [FB73, WA⁺93, BL04], que es una metodología cíclica que está compuesta de los siguientes pasos iterativos: 1. Diagnóstico: se identifica o define el problema. 2. Planificación de la acción a tomar: se consideran las diferentes vías de acción para abordar el problema. 3. Acción: se selecciona la acción a tomar. 4. Evaluación: se estudian las consecuencias de la acción. 5. Especificación del aprendizaje: se identifican los descubrimientos generales.

1.4.1 Equipo de trabajo

Este trabajo de investigación ha sido llevado a cabo por Jose Luis García Arroyo, con la dirección de Begoña García Zapirain y el apoyo del equipo de investigación de Deustotech-Life.

En la parte médica se ha contado con la colaboración de los médicos dermatólogos Jesús Gardezabal y Jose Luis Díaz, de la Unidad de Dermatología del Hospital de Cruces –y también pertenecientes al IMQ (Iguatorio Médico Quirúrgico)–, que han aportado a la investigación su conocimiento como expertos dermatólogos en el ámbito del proyecto de investigación Melanotic –financiado por el Gobierno Vasco en su programa Gaitek– en el que participaba la Universidad de Deusto en colaboración con las empresas IMQ, Maser y GAIA.

1.5 Estructuración del documento

Este documento se ha estructurado en seis capítulos, junto con un apéndice, que se comentan a continuación:

1. **Capítulo 1. Introducción.** Se muestra una introducción a la investigación realizada, presentando la motivación para ser llevada a cabo, la hipótesis de

1. INTRODUCCIÓN

partida, los objetivos definidos y la metodología utilizada, así como la presente estructuración del documento.

2. **Capítulo 2. Estado del arte.** Se aborda el estado del arte, tanto a nivel médico como tecnológico. En la primera sección se estudia el estado del arte a nivel médico. En primer lugar, se describe el melanoma desde el punto de vista médico y se dan cifras a la magnitud de este problema. En segundo lugar, se muestran las técnicas para la detección precoz de melanoma. En tercer lugar, se explica en profundidad la técnica que es considerada como la prueba de referencia o *gold standard* en la detección precoz de melanoma, la dermatoscopia, incidiéndose especialmente en la realización del diagnóstico a partir de la imagen y en la importancia de los patrones dermatoscópicos en dicho diagnóstico. Finalmente, en cuarto lugar, se justifica la realización de la presente investigación, de cara a mejorar la detección precoz de melanoma en la práctica médica actual. En la segunda sección se estudia el estado del arte a nivel tecnológico. En primer lugar, se realiza una contextualización de la presente investigación. En segundo lugar, se muestra una panorámica del estado del arte relativo a la detección y caracterización de los patrones dermatoscópicos. En tercer lugar, se muestran de manera detallada los métodos desarrollados para el reconocimiento del patrón reticular, que se detalla en profundidad en este documento, y se realizan dos comparativas, una a nivel de técnicas de imagen utilizadas y otra a nivel de resultados obtenidos. En cuarto lugar, se hace un breve estudio de los *frameworks* software existentes para el procesamiento digital de imagen. Finalmente, en quinto lugar, se justifica la realización de la presente investigación.
3. **Capítulo 3. Base de datos.** Se presenta la base de datos empleada para el diseño y desarrollo de los algoritmos, así como para su evaluación. En primer lugar, se analizan las características que debe cumplir la base de datos. En segundo lugar, se explican las fuentes utilizadas para su construcción. En tercer lugar, se describe el diseño de la base de datos. Finalmente, en cuarto lugar, se realizan algunas consideraciones de importancia relativas a su etiquetado.

4. **Capítulo 4. Diseño del sistema.** Se presenta el diseño del sistema. Para ello, en primer lugar, se explica el nuevo enfoque metodológico introducido en el presente trabajo y se muestra la especificación del sistema. En segundo lugar, se presenta el diseño de alto nivel del algoritmo, explicando a grandes rasgos sus módulos principales. En tercer lugar, se muestra el diseño de bajo nivel, explicando en detalle dichos módulos y cada una de las fases que los componen. Finalmente, en cuarto lugar, se presenta el *framework* software utilizado para el desarrollo.
5. **Capítulo 5. Resultados.** Se presentan y analizan los resultados correspondientes a los experimentos realizados, de cara a realizar la evaluación del sistema. Para ello, en primer lugar, se muestran los resultados parciales correspondientes a la detección difusa o *fuzzy* de los pixels. En segundo lugar, se examinan los resultados parciales correspondientes a los diferentes modelos de clasificación dura generados para la discriminación entre “ausente” y “presente” y la posterior selección del mejor modelo. Finalmente, en tercer lugar, se muestran los resultados finales obtenidos en el método propuesto, realizando un análisis de los mismos.
6. **Capítulo 6. Conclusiones.** Se presentan las conclusiones derivadas del desarrollo de la presente investigación. Para ello, en primer lugar, se analiza el cumplimiento de los objetivos de la investigación, indicados en el capítulo de introducción. En segundo lugar, se muestran todas las contribuciones realizadas, de manera especialmente detallada las correspondientes al algoritmo de reconocimiento del patrón reticular, que constituye la principal aportación de esta investigación desde el punto de vista científico-tecnológico. En tercer lugar, se describe el impacto científico del trabajo realizado. Finalmente, en cuarto lugar, se analizan las líneas futuras de investigación.
7. **Apéndice A. MELANOPAS: un prototipo software para el diagnóstico de melanoma.** Se muestra el prototipo software MELANOPAS, un sistema de detección automatizada de melanoma diseñado y desarrollado por el autor de esta tesis, basado en el algoritmo médico de la “Regla del ABCD”, en el

1. INTRODUCCIÓN

que se integran los algoritmos diseñados y desarrollados en esta investigación.

Si he logrado ver más lejos, ha sido porque he subido a hombros de gigantes.

Isaac Newton

CAPÍTULO

2

Estado del arte

En este capítulo se aborda el estado del arte, tanto a nivel médico como tecnológico.

En la primera sección se estudia el estado del arte a nivel médico. En primer lugar, se describe el melanoma desde el punto de vista médico y se dan cifras a la magnitud de este problema. En segundo lugar, se muestran las técnicas para la detección precoz de melanoma. En tercer lugar, se explica en profundidad la técnica que es considerada como la prueba de referencia o *gold standard* en la detección precoz de melanoma, la dermatoscopia, incidiéndose especialmente en la realización del diagnóstico a partir de la imagen y en la importancia de los patrones dermatoscópicos en dicho diagnóstico. Finalmente, en cuarto lugar, se justifica la realización de la presente investigación, de cara a mejorar la detección precoz de melanoma en la práctica médica actual.

En la segunda sección se estudia el estado del arte a nivel tecnológico. En primer lugar, se contextualiza la presente investigación –para ello, en primer lugar se explican las tareas que componen el ciclo de vida de un sistema para la detección automatizada de melanoma, en segundo lugar se describen sus posibles enfoques y en tercer lugar se explica el objetivo y alcance de la presente investigación–. En segundo lugar, se muestra una panorámica del estado del arte relativo a la detección y caracterización de los patrones dermatoscópicos. En tercer lugar, se muestran

2. ESTADO DEL ARTE

de manera detallada los métodos desarrollados para el reconocimiento del patrón reticular, que se detalla en profundidad en este documento, y se realizan dos comparativas, una a nivel de técnicas de imagen utilizadas y otra a nivel de resultados obtenidos. En cuarto lugar, se hace un breve estudio de los *frameworks* software existentes para el procesamiento digital de imagen. Finalmente, en quinto lugar, se justifica la realización de la presente investigación.

2.1 Estado del arte a nivel médico

2.1.1 Conceptos médicos. Melanoma. Magnitud del problema en cifras

En esta sección se explican los conceptos médicos subyacentes y la magnitud del problema en cifras. Para ello, en primer lugar, se explica la estructura de la piel humana, en segundo lugar se describen las lesiones de piel o cutáneas, tanto las benignas como las malignas, entre las que se incluye el melanoma, el tipo más peligroso, cuya descripción detallada se trata en tercer lugar. Finalmente, en cuarto lugar, se muestra la magnitud del problema en cifras.

2.1.1.1 La piel humana

La piel es el órgano más extenso del organismo, que nos separa del mundo exterior. Es la primera línea de defensa de nuestro organismo, amortiguando los traumatismos y actuando como barrera contra elementos externos tales como el frío, el calor, los microorganismos o la radiación ultravioleta proveniente del sol. Además, ayuda a regular la temperatura corporal y, por medio de la sudoración, excreta agua y diversos productos de desecho del metabolismo [LO93].

La piel está constituida por tres capas principales, que se muestran en la Fig. 2.1-a. Desde el exterior al interior, podemos distinguir:

Epidermis

Es la capa más externa de la piel. Es un tejido estratificado (formado por más de una capa de células) y escamoso (éstas son de tipo aplanado). La epidermis, tal y

2.1 Estado del arte a nivel médico

como se muestra en la Fig. 2.1-b, está compuesta por las siguientes 5 capas (desde el exterior hasta el interior): estrato córneo, estrato lúcido, estrato granuloso, estrato espinoso y estrato germinativo. Respecto a las células que la componen, tal y como se muestra en dicha figura, está compuesta principalmente de queratinocitos, que contienen la queratina, una proteína caracterizada por su especial dureza. También están presentes los melanocitos, que se comentarán más adelante, que están directamente relacionados con la aparición del melanoma. También están presentes los gránulos lamelares, producidos por los queratinocitos, que son una barrera contra la entrada y salida de agua, las células de Merkel, cuya función se asocia con las terminaciones nerviosas intraepidérmicas, y las células de Langerhans, que son parte del sistema inmunológico. Finalmente, se tienen los melanocitos, de gran relevancia aquí por estar directamente relacionados con la aparición del melanoma.

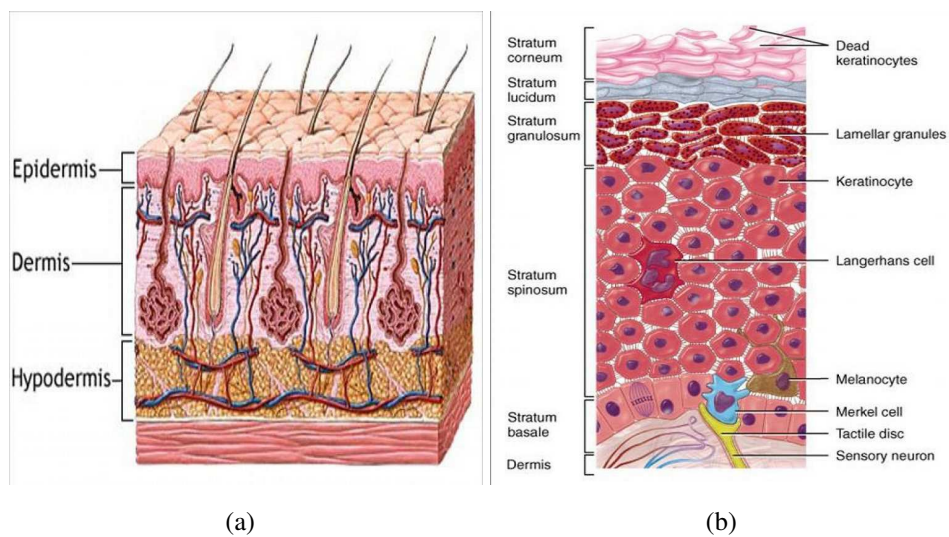


Figura 2.1: a) Capas que forman la piel humana, fuente en [US 15]. b) Capas que forman la epidermis, fuente en [Ana15].

Los **melanocitos** son células de la epidermis cuya función es la producción de melanosomas, que son gránulos que contienen melanina, la proteína responsable de la pigmentación de la piel. Dependiendo de los estímulos externos, tales como la radiación ultravioleta o las hormonas, los melanocitos producen un mayor número de melanosomas, y parte de ellos son transferidos a los queratinocitos adyacentes, lo que produce una mayor pigmentación a la piel y permite una mayor protección

2. ESTADO DEL ARTE

del cuerpo frente a la radiación solar, al absorber la melanina los rayos ultravioleta nocivos [LO93, Ale12].

Dermis

Es la capa en la que se apoya la epidermis y está compuesta de tejido conjuntivo. Es flexible, robusta y gruesa (de 20 a 30 veces más que la epidermis). Posee fibras elásticas, que otorgan a la piel su característica elástica, y fibras de colágeno, responsables de la resistencia de la misma. La dermis está constituida por dos capas de células: la más superficial se llama capa papilar y la más profunda, capa reticular [LO93].

Hipodermis

Es la capa más interna de la piel. Está compuesta de tejido adiposo, formado por adipocitos. La hipodermis está constituida por dos capas: la capa areolar, que es la más externa, y la capa lamelar, que se incrementa cuando las personas ganan peso, debido al aumento de volumen de los adipocitos [LO93].

2.1.1.2 Lesiones de piel

A continuación se van a describir brevemente las lesiones de piel más importantes, mostrando algunos ejemplos gráficos en la Fig. 2.2. En esta clasificación de las lesiones de la piel se utilizan dos criterios. En primer lugar, se diferencia entre lesiones benignas y malignas y, en segundo lugar, entre melanocíticas (originadas en los melanocitos) y no melanocíticas.

Queratosis Seborreica

Son lesiones benignas no melanocíticas, con apariencia similar a las verrugas, originadas en la epidermis que tienen como origen una proliferación de queratinocitos. Pueden presentar o no pigmentación y su color varía desde marrón claro hasta marrón oscuro o negro, teniendo en ocasiones el aspecto de un melanoma. Las queratosis seborreicas son muy frecuentes y generalmente inician su aparición en la edad media. Su eliminación suele hacerse por motivos estéticos [ALL04, MPA09].

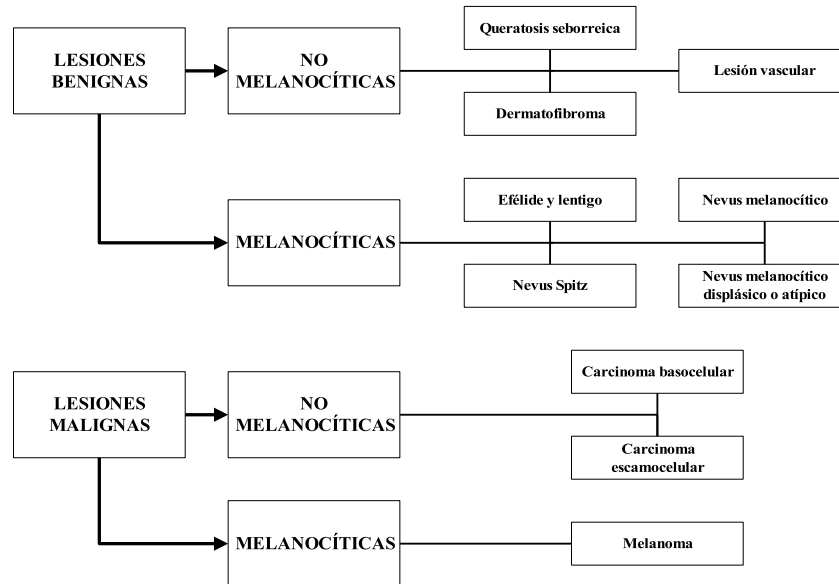


Figura 2.2: Lesiones de la piel más relevantes, clasificadas por los criterios benigna-/malignas y no melanocíticas/melanocíticas.

Lesión vascular

Las lesiones vasculares son lesiones benignas no melanocíticas, que pueden ser congénitas o adquiridas. La característica común es la presencia de “lagunas” rojas. Por su distinta naturaleza se distingue entre hemangiomas, caracterizados por la presencia de un gran número de vasos capilares sobre la piel, y malformaciones vasculares, que pueden ser de diferente tipo [ALL04, MPA09].

Dermatofibroma

Son lesiones benignas no melanocíticas, siendo una de las lesiones benignas más frecuentes. Los dermatofibromas afectan a personas de edad media, algo más a las mujeres, normalmente presentes en brazos y piernas, son duras al tacto e hiperpigmentadas y en ocasiones pueden confundirse con los nevos atípicos e incluso con melanoma. Vistos con aumento, presentan el llamado “parche central blanquecino”. Algunas veces aparecen después de pequeños traumatismos o picaduras de insectos [LO93, ALL04, Ale12].

2. ESTADO DEL ARTE

Efélide y lentigo

Ambas son lesiones benignas melanocíticas. Las efélides o pecas son pequeñas manchas planas de color marrón que aparecen en respuesta a la radiación ultravioleta del sol, afectando especialmente a personas de fototipo claro. Los lentigos son manchas planas de color marrón, a veces de gran tamaño, que se asocian con el daño solar recibido en la piel a lo largo del tiempo, y suelen ser más frecuentes en las personas mayores, de hecho en ocasiones se las llama “manchas de la edad”. Al contrario que las efélides o pecas, que se aligeran o desaparecen cuando ya no existe exposición solar, los lentigos no desaparecen cuando ya no están expuestos al sol. Además, el origen de las efélides o pecas y los lentigos es también diferente. Mientras que las primeras son originadas por un aumento del tamaño de los melanocitos, que producen una mayor cantidad de melanina, los segundos son originados por un aumento del número de melanocitos. Al ser los lentigos una lesión provocada por el daño solar continuado, el riesgo de desarrollar melanoma es mayor en las personas que los poseen [LO93, ALL04, Ale12].

Nevo melanocítico

El nevo melanocítico, también llamado lunar, es una pequeña mancha pigmentada, plana o sobreelevada, de bordes definidos, coloración regular y, frecuentemente, de diámetro pequeño (menor de 6 mm). Se trata de una lesión benigna melanocítica y puede ser de tipo congénito o adquirido. El nevo melanocítico está originado por la proliferación de los melanocitos en la unión dermo-epidérmica.

Con el paso del tiempo, aumenta el número de grupos de melanocitos hacia la dermis, lo que se conoce como nevos melanocíticos compuestos. Cuando los nevos melanocíticos compuestos son localizados exclusivamente en la dermis son conocidos como nevos melanocíticos celulares, dérmicos o intradérmicos. El color y la localización del pigmento (melanina) de un nevo melanocítico se encuentran relacionados: 1. La coloración será marrón si un gran número de las células pigmentadas se encuentran en la epidermis; 2. La coloración será marrón oscuro o negro si además de encontrarse en la epidermis se encuentra en la dermis superficial; 3. La coloración será de un color azulado (nevo azul) en caso de que se localicen en la dermis profunda.

Un tipo especial de nevo melanocítico es el nevo de Spitz, que se muestra con mayor frecuencia en niños y jóvenes, aunque, en algunas ocasiones, puede ser localizado en adultos. Se trata de una lesión benigna con un tamaño normalmente mayor que el de los nevos comunes. Este tipo de nevo varía entre los 6 mm y 2 cm de diámetro. Este tipo de nevo es recomendado extirpar en personas adultas puesto que existe un riesgo de desarrollar melanoma.

Finalmente, hay que señalar que las personas con múltiples nevos melanocíticos tienen un mayor riesgo de desarrollar melanoma [MPA09, Ser14, Ale12].

Nevo melanocítico atípico

Los nevos melanocíticos atípicos, también llamados nevos displásicos o nevos de Clark, son nevos melanocíticos, generalmente algo sobreelevados, de más de 6 mm de diámetro, de bordes irregulares y poco definidos, con pigmentación irregular, con áreas más claras y otras más oscuras. Se trata de lesiones benignas melanocíticas que suelen aparecer a partir de la pubertad y pueden ir apareciendo a lo largo de toda la vida. Pueden aparecer en cualquier parte del cuerpo, no obstante son más frecuentes en el tronco, en el caso de los hombres, y en las pantorrillas, en el caso de las mujeres. La importancia clínica de este tipo de lesión reside en su asociación con el alto riesgo de desarrollar melanoma [MPA09, Ser14, Ale12].

Carcinoma basocelular

El carcinoma basocelular es una lesión maligna no melanocítica, siendo el tipo de cáncer de piel más usual. De hecho, de todos los tipos de cánceres, es el que se da con mayor frecuencia. Suele estar localizada en zonas del cuerpo expuestas al sol, la mayoría de las ocasiones en la cara. Las personas que tienen mayor riesgo son las personas de piel blanca, cabello rubio o rojizo y ojos claros y las personas mayores, presentándose con más frecuencia en hombres que en mujeres. La causa más frecuente es la exposición a la radiación solar. Se origina en los queratinocitos del estrato germinativo, la capa más profunda de la epidermis.

El carcinoma basocelular raramente entra en metástasis y en poquísimas ocasiones causa la muerte. Sin embargo, puede llegar a ser muy peligroso si se introduce en los estratos más profundos de la piel, donde puede dañar órganos importantes si

2. ESTADO DEL ARTE

no es extirpado a tiempo. Existen los siguientes tipos: nodular, quístico, pigmentado, esclerosante y superficial, que tienen diferentes apariencias aunque, en general, la más común es de una lesión sobreelevada, de crecimiento lento, de color rosado o blanco, nacarada, brillante, con pequeños vasos capilares en su interior y que sangra con frecuencia de forma casi espontánea. El carcinoma basocelular pigmentado puede ser en ocasiones difícil de distinguir del melanoma. El tratamiento del carcinoma basocelular es siempre la extirpación o cirugía del tumor y, en caso de no ser posible, la utilización de técnicas alternativas como la radioterapia [ALL04, Ser14, Ale12].

Carcinoma escamocelular

El carcinoma escamocelular es una lesión maligna no melanocítica, siendo el segundo tipo de cáncer de piel más usual, y suele desarrollarse en zonas de piel expuestas al sol, aunque también puede hacerlo en cualquier otra parte del cuerpo, como la lengua o la mucosa bucal. Al igual que sucede con el carcinoma basocelular, las personas que tienen un mayor riesgo son las personas de piel blanca, cabello rubio o rojizo y ojos claros y las personas mayores, presentándose con más frecuencia en hombres que en mujeres, y la causa más frecuente es la exposición a la radiación solar. Se origina en los queranocitos de la epidermis, y comienza cuando los queranocitos atípicos comienzan a invadir la dermis.

En pocas ocasiones, aunque con mayor frecuencia que en el caso del carcinoma basocelular, el carcinoma escamocelular puede entrar en metástasis y propagarse a otras partes del cuerpo, causando la muerte. Este cáncer pasa por diferentes estados. Cuando los queranocitos atípicos crecen en el interior de la epidermis, se denomina queratosis actínica. Cuando han llegado a la frontera con la dermis, se dice que se trata de un carcinoma escamocelular in situ o enfermedad de Bowen. A continuación, cuando se invade la dermis, pasa a un estado invasivo, que posteriormente puede degenerar en metástasis. La apariencia del carcinoma escamocelular es de una lesión sobreelevada, de crecimiento rápido, de color pardo rojizo, y suele estar cubierto de una costra, siendo frecuente que sangre y se llague o ulcere con facilidad. El tratamiento del carcinoma escamocelular es el mismo que en el carcinoma basocelular [ALL04, Ser14, Ale12].

2.1 Estado del arte a nivel médico




Figura 2.3: Ejemplos de lesiones de piel. a) Queratosis seborreica. b) Lesión vascular. c) Dermatofibroma. d) Lentigo. e) Nevo azul. f) Nevo de Spitz. g) Nevo melanocítico atípico. h) Carcinoma basocelular. Fuente en [ASP⁺00].

2. ESTADO DEL ARTE

Melanoma

El melanoma es una lesión maligna melanocítica, siendo el tipo de cáncer de piel más peligroso. Se describirá a continuación.

2.1.1.3 Melanoma

El melanoma es una lesión maligna originada en los melanocitos. La mayoría de los melanomas se originan normalmente a partir de nevos melanocíticos o nevos melanocíticos atípicos preexistentes, aunque no en todos los casos. Es un cáncer de piel no tan común como el carcinoma basocelular o el carcinoma escamocelular, pero sí mucho más grave. Suele darse por igual en hombres y mujeres pero, sin embargo, la localización suele ser diferente: en las mujeres jóvenes predomina en miembros inferiores y en los varones más mayores en tronco, hombros, cuello y cara [Ser14, Ale12].

Al igual que sucede con las otras dos variedades importantes de cáncer de piel, el carcinoma basocelular y el carcinoma escamocelular, el factor más importante de riesgo es la exposición excesiva a la radiación solar. Además existen otros factores de riesgo, tales como la edad, la mayor o menor presencia de lentigos, nevos melanocíticos o nevos melanocíticos atípicos, los antecedentes familiares y el fototipo de la persona [LO93, ALL04, MPA09].

El fototipo de la persona es la capacidad de la piel para asimilar la radiación solar. Depende sobre todo de la capacidad para broncearse y del color de la piel, cabellos y ojos. En la práctica dermatológica se utiliza una clasificación numérica para los fototipos, que oscila entre el I y el VI [Fit88]. Las personas con fototipo más bajo –de piel blanca, cabello rubio o rojizo y ojos claros, que tienen mayor propensión a las quemaduras solares y que casi nunca se broncean con el sol– tienen más riesgo de tener melanoma [Fit88]. Por ello, el cáncer de piel, y especialmente el melanoma, son problemas críticos para los sistemas de salud de países con alta incidencia solar y población con fototipo bajo tales como Estados Unidos, Australia, Nueva Zelanda y Sudáfrica [AEC12a].

Origen del melanoma. Importancia de la detección precoz

El melanoma se origina cuando los melanocitos de la epidermis sufren una mutación, normalmente a causa de la radiación solar, y comienzan a crecer fuera de control y, en consecuencia, a agruparse y provocar lesiones o tumores de modo que desplazan las células sanas y dañan el tejido que se encuentra a su alrededor. Cuando un melanoma se detecta a tiempo, es decir, cuando todavía se encuentra en la epidermis, se puede extirpar y curar fácilmente. Pero, si el melanoma no se detecta y sigue su evolución, puede extenderse hacia dentro y metastatizar hasta alcanzar al sistema linfático o los vasos sanguíneos, y estos dos sistemas pueden actuar como una autopista para las células cancerosas y permitirles un fácil acceso a órganos distantes como los pulmones o el cerebro. Por ello, la detección temprana del melanoma es crucial [ALL04, MPA09].

Niveles de Clark

Los niveles de Clark, que se muestran gráficamente en la Fig. 2.4, comprenden cinco niveles y reflejan el grado de profundidad o penetración en la piel. En el nivel I los tumores son totalmente epidérmicos; en el nivel II la tumoración atraviesa la unión dermo-epidérmica con invasión de la dermis papilar; en el nivel III las tumoraciones ocupan toda la dermis papilar, expandiéndola; en el nivel IV la tumoración se ha infiltrado en la dermis reticular; finalmente, en el nivel V se ha realizado una invasión del tejido graso subcutáneo –la hipodermis– [US 14].

Factores pronósticos del melanoma

La invasión en profundidad se expresa con el espesor o grosor del tumor, descrito por el índice de Breslow, que es el principal valor pronóstico en relación al melanoma.

Otros factores importantes son un alto índice mitótico, correspondiente a un alto porcentaje de células que están en mitosis, y la presencia de ulceración, ambos indicadores de malignidad.

2. ESTADO DEL ARTE




Figura 2.4: Niveles de Clark. Fuente en [Ter14]

Estadios del melanoma

El estadiaje del melanoma utilizado habitualmente por los médicos dermatólogos se rige por la clasificación realizada en el año 2001 por la American Joint Committee on Cancer [BBS⁺01], cuya séptima y actualmente vigente revisión se presenta en [BGS⁺09]. Es accesible vía web en [Ame16b] y en [Ins16] está explicado con detalle. En dicho estadiaje se utilizan los factores pronósticos comentados: índice de Breslow, índice mitótico y presencia de ulceración.

A continuación se muestra la descripción resumida de los diferentes estadios del melanoma:

Estadio 0. Está en una fase de crecimiento radial, que puede durar meses o años, en la cual las células tumorales se extienden radialmente dentro de la epidermis. Se corresponde con el nivel I de Clark. En este estadio la capacidad de metastatizar es nula, y la extirpación quirúrgica consigue la curación al 100 %. Se dice que el melanoma está en estado “in situ”.

Estadios I y II. Entra en una fase de crecimiento vertical, en el que se rompe la unión dermo-epidérmica y se produce la propagación de las células

tumorales hacia la profundidad de la dermis e hipodermis, con diferentes niveles de invasión. Se corresponde con los niveles II, III, IV y V de Clark. El tumor adquiere en estos dos estadios la capacidad de metastatizar. Se dice que el melanoma está en estado “invasivo”.

Estadio III. Entra en una fase de invasión ganglionar, en el que el tumor afecta a los ganglios. En este estadio la afectación de los ganglios ocurre de manera local.

Estadio IV. Entra en metástasis, bien porque la invasión ganglionar empieza a propagarse a distancia, o bien porque se entra en una fase de diseminación hematológica, en la que el tumor se disemina por medio de los vasos sanguíneos. El tumor alcanza a otras partes del cuerpo, tales como pulmón, hígado o cerebro. Se dice que el melanoma está en estado “metastático”.

2.1.1.4 Magnitud del problema en cifras

A continuación se presentan algunas cifras relativas al melanoma, de cara a dar una caracterización de tipo cuantitativo de la magnitud del problema. Estas cifras son relativas al melanoma invasivo, es decir, que está entre los estadios I y IV.

- Actualmente, el melanoma representa aproximadamente el 1,5 % del total de casos de cáncer a nivel mundial [AEC12a].
- La mayor incidencia se encuentra en países como Australia, Nueva Zelanda, Estados Unidos y Sudáfrica, con gran número de individuos de fototipo bajo y alta incidencia solar, en los que se ha convertido en un grave problema de salud pública [AEC12a]. Por ejemplo, en Estados Unidos se estima que, en el año 2016, 76.380 nuevos casos de melanoma han sido diagnosticados, siendo más frecuente en los hombres (46.870) que en las mujeres (29.510), y que ha causado la muerte de 10.130 personas [Ame16a].
- En Europa es más frecuente en el norte y en el oeste, con individuos de fototipo bajo, pero mientras que en todas estas zonas la frecuencia del melanoma tiende a estabilizarse e incluso a disminuir, debido a las medidas tomadas en los últimos años, en el sur y en el este sigue aumentando [AEC12a]. Por

2. ESTADO DEL ARTE

ejemplo, en España, el número de nuevos casos sigue creciendo, diagnosticándose unos 3.600 casos nuevos cada año [AEC12a], teniéndose que, en el año 2012, la incidencia de este tipo de cáncer era de un 2,3 % del total de casos, siendo más frecuente en mujeres (3,1 %) que en hombres (1,8 %) [SEO16].

- La tasa de supervivencia depende del estadio en el que se encuentre el melanoma cuando es detectado, será menor cuanto más avanzado esté. En caso de ser detectado de manera precoz, cuando el tumor todavía no ha afectado a los ganglios ni a otros órganos (estadios I o II), la tasa de supervivencia aproximada a 5 años es del 98 %, disminuyendo al 63 % cuando afecta a los ganglios de manera local (estadio III) y al 17 % cuando entra en un estado de metástasis (estadio IV) [Ski16].

2.1.2 Técnicas para la detección de melanoma

Tal y como se ha comentado, en la lucha contra el melanoma es fundamental la detección precoz. Históricamente, y aún actualmente, el método más utilizado para la detección precoz del melanoma ha sido la inspección visual por parte del médico, buscando “a simple vista” las lesiones sospechosas y realizando para éstas la biopsia, realizándose su extirpación quirúrgica y procediéndose a continuación a su análisis histopatológico. Este método tiene dos problemas: en primer lugar, la precisión diagnóstica de la inspección visual es manifiestamente mejorable, ya que tiene una sensibilidad del 70-85 % [MPA09], sobre todo si no es realizada por un experto dermatólogo, y además no es reproducible; en segundo lugar, la biopsia es un procedimiento diagnóstico seguro, pero su utilización presenta los inconvenientes de ser un método invasivo y de necesitarse muchos recursos, tanto humanos como materiales. Se hace pues evidente la necesidad de utilizar técnicas no invasivas que necesiten pocos recursos y den buenos resultados [MPA09].

Con este objetivo se han desarrollado diferentes técnicas de imagen, no invasivas, para la detección precoz de melanoma. Se describirán a continuación las más relevantes, entre las que se encuentra la dermatoscopia, que está considerada actualmente como la prueba de referencia o *gold standard* en la detección precoz de melanoma [GM11], y que se describirá más detalladamente en 2.1.3. Existen otras

técnicas de detección precoz que no son de imagen, como el estudio de los biomarcadores moleculares y genómica [RPERM⁺14], pero no se entrará aquí en su descripción, ya que están fuera del alcance de esta revisión.

2.1.2.1 Imagen Macroscópica

Es la técnica más sencilla, y consiste en la adquisición de imágenes utilizando cámaras de fotos normales, destinadas al público general. Las consideraciones diagnósticas son similares a las que se pueden tomar con la visión a “simple vista”, añadiendo además las ventajas de la reproducibilidad en el diagnóstico, el uso de las tecnologías de procesamiento digital de imagen y la sencilla integración en plataformas de telemedicina. Es importante señalar que, al mejorar cada vez más las prestaciones de las cámaras de fotos, esto tiene consecuencia directa en la confiabilidad de los diagnósticos sobre las imágenes que se obtienen con éstas [PH09, MPA09].

2.1.2.2 Fotografía de Cuerpo Entero

Consiste en realizar un conjunto de fotografías del cuerpo entero, con el fin de generar un mapa correspondiente a las diferentes lesiones cutáneas que se tienen y realizar una valoración diagnóstica. Se trata de una técnica muy prometedora, que facilita mucho el trabajo de monitorización del paciente, ya que permite de manera automatizada explorar el cuerpo entero y obtener el mapa diagnóstico, así como calcular la evolución de las lesiones en caso de tener datos de fechas anteriores. Sin embargo, requiere de medios materiales complejos, tanto en la captura de las imágenes como en la generación de los mapas de las lesiones de la piel [Kor14]. Además, uno de los principales problemas que tiene esta técnica con respecto a otras como la dermatoscopia es que no puede traspasar la superficie del estrato córneo [SM11]. Existen algunos dispositivos comerciales que trabajan con esta técnica, como el Canfield VECTRA [Can16], que se puede ver en la Fig. 2.5-a.

2.1.2.3 Dermatoscopia

Es una técnica no invasiva que consiste en el examen de la piel mediante la utilización de un dermatoscopio, consistente en un sistema óptico y una fuente de luz

2. ESTADO DEL ARTE

diseñados para reducir la refracción irregular y la reflexión de la luz en su superficie, que hace posible visualizar en profundidad –epidermis, unión dermoepidérmica y dermis superficial– y con aumento estructuras, formas y colores que no son accesibles a la simple inspección visual. El dermatoscopio puede ser conectado a un ordenador, bien en tiempo real o bien posteriormente al examen, en el que se almacena la imagen capturada y se puede visualizar y analizar. La dermatoscopia presenta muy buenos resultados: en manos expertas se consigue una sensibilidad del 92 % [MPA09]. Además, permite la reproducibilidad en el diagnóstico, así como el uso de técnicas de procesamiento digital de imagen [MPA09, GG09, GM11]. La dermatoscopia puede ser usada en sistemas de cribado o *screening* dirigidos a la población con el fin de detectar melanomas de manera precoz, sobre plataformas de telemedicina o de otro tipo [PH09]. Un ejemplo de dermatoscopio, el MoleMax HD [Der16], se puede ver en la Fig. 2.5-b.

2.1.2.4 Imagen Multiespectral

Se capturan imágenes con aumento obtenidas por un dispositivo que usa diferentes longitudes de onda de la luz, que penetran en la piel a diferentes profundidades, lo que permite la visualización de criterios invisibles para otros tipos de imágenes. Utilizando esta técnica se obtienen diferentes imágenes correspondientes a las diferentes bandas del espectro que se manejan. Esta técnica es bastante similar a la dermatoscopia, de hecho en ocasiones se habla de dermatoscopia “multiespectral”, siendo las técnicas diagnósticas también muy parecidas [PH09, SM11]. Un ejemplo de sistema comercial es Melafind [MEL15], que se puede ver en la Fig. 2.5-c.

2.1.2.5 Microscopía Confocal de Reflectancia (MCR)

Es una técnica de imagen no invasiva que utiliza un rayo láser infrarrojo, para crear imágenes en gris en un plano horizontal, correspondientes a las estructuras celulares y la morfología de la epidermis, unión dermoepidérmica y la dermis superficial. Las captura de imágenes se realiza a partir de la diferencia en la reflectividad de las estructuras de tejido diferentes. Al ser la melanina y los melanosomas muy reflectantes, esta modalidad es muy adecuada para el examen de lesiones pigmentadas.

Se trata de una potente herramienta clínica, muy prometedora, sin embargo, aún se requieren estudios clínicos a gran escala para determinar su validez [PH09, SM11]. Un ejemplo de sistema comercial es VivaScope [MAV16], que se puede ver en la Fig. 2.5-d.

2.1.2.6 Ultrasonido de Alta Resolución

También llamada ecografía de alta resolución, esta técnica proporciona imágenes de alta resolución de la piel en el plano vertical. Cuando se usa solo, no es fiable para el diagnóstico, no obstante puede ser utilizado junto con otras técnicas; por ejemplo, es de gran utilidad para observar con detalle la vascularización de los tumores [PH09, SM11]. Un ejemplo de sistema comercial es DermaScan [Cor16].

2.1.2.7 Tomografía de Coherencia Óptica (TCO)

Utiliza una técnica parecida a la ecografía, aunque a diferencia de ésta, que usa ondas de sonido, utiliza ondas de luz que penetran en la epidermis y permiten obtener imágenes de éstas, aunque con menos resolución que otras técnicas como la dermatoscopia o la microscopía confocal de reflectancia. Además, su alcance en profundidad es limitado [PH09, SM11].

2.1.2.8 Imágenes de Resonancia Magnética (IRM) y Tomografía por Emisión de Positrones fusionada con Tomografía Computerizada (TEP/TC)

Se trata de dos técnicas de frecuente uso en la medicina, que permiten la captura de imágenes con información 3D del cuerpo. La primera utiliza el fenómeno de la resonancia magnética nuclear y la segunda usa rayos X y emisión de positrones, la primera con menos resolución pero siendo mucho menos invasiva, y la segunda con más resolución pero siendo muy invasiva para el cuerpo humano, debido a la radiación que penetra en éste. Se han estudiado ambas para ser utilizadas en la detección de melanoma, y se ha concluido que la IRM no permite la discriminación entre lesiones benignas y malignas mientras que usando TEP/TC sí que es posible la discriminación, aunque con baja fiabilidad. En cualquier caso, ambas técnicas tienen aplicaciones útiles, por ejemplo en la medición del espesor y el volumen de un melanoma [PH09, SM11].

2. ESTADO DEL ARTE

2.1.2.9 Conclusiones

Se han mostrado las diferentes técnicas de imagen –no invasivas– más relevantes para la detección precoz de melanoma. Actualmente, tal y como se ha comentado, la dermatoscopia es la prueba de referencia o *gold standard* a nivel médico [GM11], ya que obtiene muy buenos resultados, es barata y además es muy fácil de realizar la captura de imágenes (existen incluso dermatoscopios que se pueden ajustar a un smartphone). Por ello, está muy implantada en los centros médicos. Además, permite la reproducibilidad en el diagnóstico y la integración en plataformas de telemedicina, algo muy importante para realizar el cribado o *screening* [MPA09, GG09, PH09].

2.1.3 Dermatoscopia

En 2.1.2.3 se ha descrito brevemente la dermatoscopia, y en 2.1.2.9 se ha concluido que, en estos momentos, la dermatoscopia es la técnica *gold standard* en la detección precoz de melanoma. A continuación, se va a describir en detalle.

2.1.3.1 Adquisición de imágenes.

Tal y como se ha comentado anteriormente, usando la dermatoscopia es posible visualizar en profundidad –epidermis, unión dermoepidérmica y dermis superficial– y con aumento estructuras, formas y colores que no son accesibles a la simple inspección visual. Existen dos tipos de capturas:

- **Dermatoscopia con Iluminación de Contacto (DIC).** Se utiliza un líquido, normalmente aceite, en la superficie de la piel para reducir la reflexión y la refracción irregular.
- **Dermatoscopia de Luz Polarizada (DLP).** En vez de un líquido se utiliza un dermatoscopio equipado con lentes de luz polarizada, llamado filtro de polarización cruzada.



(a)



(b)



(c)



(d)

Figura 2.5: a) Dispositivo de captura de imágenes de cuerpo entero Canfield VECTRA, fuente en [Can16]. b) Dermatoscopio MoleMax HD, fuente en [Der16]. c) Dermatoscopio multispectral Melafind, fuente en [MEL15]. d) Dispositivo de captura de imágenes de microscopia confocal de reflectancia VivaScope, fuente en [MAV16].

2. ESTADO DEL ARTE

La mayoría de las estructuras y colores observados con dermatoscopia de contacto y dermatoscopia de luz polarizada son equivalentes, aunque existen algunas diferencias. Con dermatoscopia de luz polarizada estructuras como el velo azul-blanquecino y las estructuras de regresión son algo más difíciles de apreciar, mientras que otras como las vasculares se aprecian mejor [MPA09]. Ambas técnicas son igualmente utilizadas, siendo la segunda quizás un poco menos invasiva y más cómoda, ya que no se usa ningún líquido, aunque tiene algo más de complejidad técnica por la necesidad de usar filtros de luz polarizada.

Entre los dermatoscopios más relevantes del mercado y usados en los hospitales de todo el mundo se encuentran las siguientes marcas [WS10]: MoleMax (Derma Medical Systems [Der15a]), FotoFinder (FotoFinder Systems [Fot15]), DBDermomips/DDAX (Biomips [Bio15]), Dermatoscope Delta (Heine [Hei15]), DermLite (DermLite [Der15b]), Melafind (MELA Sciences [MEL15]), MicroDerm (Visio-med AG [Vis15]), Dermoscopix (Dermoscopix [Der15d]) y Dermo Genius (DermosScan [Der15c]).

2.1.3.2 Diagnóstico a partir de imágenes dermatoscópicas

A partir de las imágenes dermatoscópicas capturadas, el dermatólogo valora el grado de malignidad, utilizando los métodos médicos existentes. Se trata, en todos ellos, de detectar y caracterizar cuantitativamente una serie de indicadores y realizar el diagnóstico de acuerdo a unos rangos de valores preestablecidos. Los indicadores más relevantes son los patrones o estructuras dermatoscópicas, que se definen en 2.1.3.3 y cuya explicación detallada y relación con los métodos médicos se realiza en 2.1.3.9. El procedimiento estándar para la diagnosis, el “Método de las 2 Etapas”, se muestra en 2.1.3.4, mostrándose a continuación los métodos médicos más relevantes para el diagnóstico de melanoma: el “Análisis de Patrones” en 2.1.3.5, la “Regla del ABCD” en 2.1.3.6, el “Método de Menzies” en 2.1.3.7 y la “Lista de los 7 puntos” en 2.1.3.8.

2.1.3.3 Patrones o estructuras dermatoscópicas

Son estructuras complejas de forma y color que se pueden encontrar en imágenes dermatoscópicas y que son los indicadores más relevantes de la información

histopatológica [BRO⁺05].

2.1.3.4 “Método de las 2 Etapas”

Para el diagnóstico el procedimiento más usado y estándar es el “Método de las 2 Etapas” [MPA⁺07]. Usando este método el dermatólogo, en una primera etapa, debe discernir si la lesión es o no melanocítica, con una serie de criterios y, en una segunda etapa, en caso positivo, usar un método de diagnóstico para determinar el grado de malignidad, con el objetivo de decidir si se debe extirpar la lesión cutánea. Tal y como se puede ver gráficamente en la Fig. 2.6, en la primera etapa, en primer lugar se debe reconocer alguno de los criterios de lesión melanocítica (Retículo pigmentado, Agregado de glóbulos, Ramificaciones lineales, Pigmentación homogénea azul y Patrón paralelo, si se cumple alguno es lesión melanocítica; en segundo lugar, se evalúan una serie de criterios específicos de diversas lesiones no melanocíticas (Queratosis Seborreica, Carcinoma Basocelular, Dermatofibroma, Lesión Vascular, etc.), si se corresponde a alguna es lesión no melanocítica, en caso contrario se trata de una lesión melanocítica.

En caso de que la lesión sea melanocítica, comienza la segunda etapa, siendo los métodos médicos más relevantes para el diagnóstico de melanoma: el “Análisis de Patrones” y los llamados algoritmos del melanoma (por estar diseñados en forma de algoritmo), la “Regla del ABCD”, la “Lista de los 7 puntos” y el “Método de Menzies”, que se describirán a continuación [MPA09].

2.1.3.5 “Análisis de Patrones”

El “Análisis de Patrones” fue descrito por Pehamberger et al. en 1987 [PSW87] y posteriormente revisado, siendo su última estandarización realizada en [MPA⁺07]. La totalidad de los indicadores son patrones o estructuras dermatoscópicas, diferenciándose entre locales y globales. En el caso de los patrones locales se valora su presencia y caracterización en una parte de la lesión, mientras que en el caso de los globales se valora sólo si están en una parte importante de la lesión.

Existen una reglas importantes que deben considerarse al utilizar éste 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

2. ESTADO DEL ARTE

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.

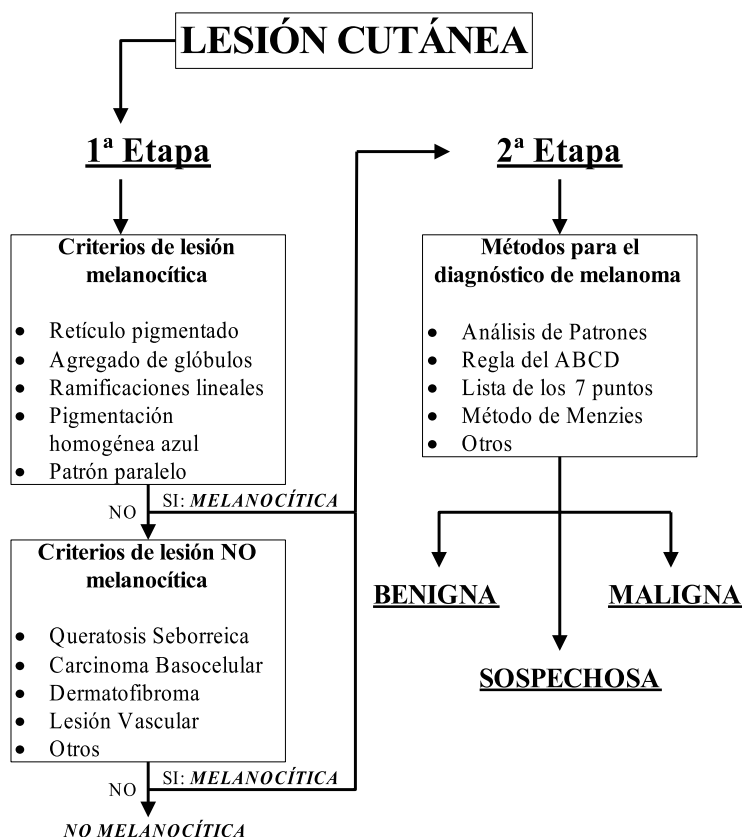


Figura 2.6: Método de las 2 Etapas.

Respecto a los patrones locales, sugieren malignidad la caracterización atípica o irregular de los siguientes: 1. Retículo pigmentado; 2. Glóbulos y/o Puntos; 3. Proyecciones irregulares; 4. Velo azul-blanquecino; 5. Áreas de hipopigmentación; 6. Manchas de pigmento; 7. Estructuras de Regresión; 8. Estructuras vasculares.

Respecto a los patrones globales, se examinan los siguientes: 1. Patrón Reticular; 2. Patrón Globular; 3. Patrón en estallido de estrellas; 4. Patrón homogéneo; 5. Patrón paralelo; 6. Patrón multicomponente (varios patrones de los anteriores); 7. Patrón inespecífico (ningún patrón de los anteriores) [MPA09].

2.1.3.6 “Regla del ABCD”

La “Regla del ABCD” fue descrita por Stolz et al. en 1994 [SAC94]. Es el algoritmo para el diagnóstico del melanoma más popular [MPA09]. Se basa en la valoración de 4 criterios [MPA⁺07]:

“**A**” (**Asimetría**): se divide la lesión pigmentada en dos ejes de 90°, de manera que consigamos la mayor simetría posible, y se valora la asimetría con respecto al color, la forma y estructuras a ambos lados del eje. Se otorga una puntuación de 0 si no existe asimetría en ningún eje, de 1 si existe asimetría en un eje y de 2 si la presenta en ambos ejes.

“**B**” (**Borde**): la lesión es dividida en 8 segmentos y se puntúa con 0,1 cada porción que presente una finalización abrupta del borde.

“**C**” (**Colores**): Se valora la presencia de 6 colores (blanco, marrón claro, marrón oscuro, azul-gris, rojo y negro), 1 punto por cada color.

“**D**” (**Estructuras Dermatoscópicas**): Se consideran 5 estructuras y cada una se puntúa con 1: Retículo pigmentado, Áreas homogéneas y desestructuradas, Puntos, Glóbulos y Ramificaciones lineales/Pseudópodos.

Posteriormente se suman las puntuaciones parciales y se obtiene el Índice Dermatoscópico Total (TDS), determinando el diagnóstico con los siguientes rangos: 1. (TDS < 4,75): BENIGNA; 2. (4,8 ≤ TDS ≤ 5,45): SOSPECHOSA; 3. (5,45 < TDS): MALIGNA.

Existen diversas modificaciones de este método, las más usadas añaden la “E” correspondiendo ésta a la Elevación y/o la Evolución [MPA09].

Aquí hemos descrito la “Regla del ABCD”, que se aplica sobre imágenes dermatoscópicas. Existe también un ABCD clínico, destinado al gran público, en el que se evalúan las lesiones cutáneas en base a criterios de “A” (Asimetría), “B” (Borde), “C” (Colores) y “D”, correspondiendo ésta al Diámetro –en vez de a las Estructuras Dermatoscópicas– y considerándose indicador de malignidad cuando sobrepasa los 6 mm [AEC12b].

2. ESTADO DEL ARTE

2.1.3.7 “Método de Menzies”

El “Método de Menzies” fue descrito por Menzies et al. en 1996 [MICM96]. Se basa en la valoración de 11 criterios, que se dividen en negativos y positivos [MPA⁺07].

Los criterios negativos son: 1. Simetría: simetría de la lesión en lo relativo a los colores y estructuras dermatoscópicas; 2. Monocromía: se valoran los colores marrón claro, marrón oscuro, rojo, azul, negro y gris.

Los criterios positivos son: 1. Velo azul-blanquecino; 2. Despigmentación pseudocatrízal; 3. Múltiples colores: presencia de 5 o 6 colores (marrón claro, marrón oscuro, rojo, azul, gris y negro); 4. Retículo pigmentado prominente; 5. Pseudópodos; 6. Proyecciones radiales; 7. Múltiples puntos marrones; 8. Puntos y glóbulos negros periféricos; 9. Múltiples puntos azul-grises.

Para llegar al diagnóstico de melanoma la lesión no debe presentar ninguno de los 2 criterios negativos y además debe presentar, al menos, uno de los nueve criterios positivos [MPA09].

2.1.3.8 “Lista de los 7 puntos”

El método de la “Lista de los 7 puntos” fue descrito por Argenziano et al. en 1998 [AFC⁺98]. Aunque es un método diferente al “Análisis de Patrones”, está considerado como una simplificación de éste, proponiendo un algoritmo centrado en un conjunto de patrones locales [AFC⁺98, MPA⁺07]

Se basa en la valoración de 7 criterios dermatoscópicos: 1. Retículo pigmentado atípico; 2. Velo azul-blanquecino; 3. Patrón vascular atípico; 4. Proyecciones irregulares; 5. Glóbulos y/o Puntos irregulares; 6. Manchas de pigmento irregulares; 7. Estructuras de regresión.

Los 3 primeros se dice que son criterios mayores y recibirán una puntuación de 2. Los cuatro últimos se dice que son criterios menores y recibirán una puntuación de 1. Si la puntuación total es mayor o igual a 3 se diagnostica como melanoma, en caso contrario como benigna [MPA09].

2.1.3.9 Descripción detallada de los patrones o estructuras dermatoscópicas

En 2.1.3.3 se ha mostrado la definición de los patrones o estructuras dermatoscópicas y se ha explicado su importancia en el diagnóstico de melanoma, analizando en 2.1.3.4, 2.1.3.5, 2.1.3.6, 2.1.3.8 y 2.1.3.7 su papel en los diferentes métodos médicos, en los que se manejan diferentes estructuras dermatoscópicas.

En algunos casos se corresponden totalmente (por ejemplo el retículo pigmentado correspondiente a los criterios locales de “Análisis de Patrones” con el retículo pigmentado de la primera etapa del “Método de las 2 Etapas”). En otros casos hay una relación, aunque no se corresponden exactamente (por ejemplo, el retículo pigmentado atípico de la “Lista de los 7 puntos” es un subconjunto o caracterización del retículo pigmentado de la “Regla del ABCD”).

Se muestran a continuación los patrones más relevantes que se presentan a nivel médico, con sus caracterizaciones, mostrándose algunos de ellos gráficamente en la Fig. 2.7, y posteriormente se relaciona el problema de su reconocimiento con el reconocimiento de los correspondientes indicadores, tanto en la primera etapa del “Método de las 2 Etapas” como en los diferentes métodos médicos.

1. Retículo pigmentado

El retículo pigmentado o red pigmentada es una red de líneas de color marrón o negro sobre un fondo marrón más claro. El típico es aquél con una red homogénea con líneas finas y orificios pequeños, mientras que el atípico tiene líneas gruesas y más oscuras, siendo además heterogéneo e irregular, con orificios de distintos tamaños. Tenemos por tanto que se pueden considerar las caracterizaciones típica/atípica [MPA09, SAHW07].

2. Glóbulos/Puntos

Estructuras de color negro o marrón, de forma circular a ovalada, de diferentes tamaños que se distribuyen de manera regular o irregular por la lesión. La estructura glóbulos/puntos en función del tamaño puede ser discriminado entre glóbulos y puntos (se suele tener el criterio de que si el diámetro es menor que 0.1 mm son puntos). Se pueden considerar las caracterizaciones regular/irregular, relativos a la regularidad en color, forma, tamaño y distribución [MPA09, SAHW07].

2. ESTADO DEL ARTE

3. Proyecciones

Corresponden a estructuras lineales radiadas en la periferia de la lesión que se extienden en la piel normal adyacente y no están claramente combinadas con las líneas del retículo pigmentado. Existen 2 tipos de proyecciones: los pseudópodos y las proyecciones radiales; las primeras tienen una apariencia bulbosa, digitiforme o “en forma de porra”, mientras que las segundas son estructuras lineales radiadas y finas. En función de su grado de regularidad, se pueden considerar las caracterizaciones regular/irregular [MPA09, SAHW07].

4. Velo azul-blanquecino

Pigmentación difusa confluyente azul-grisácea o azul-blanquecina, con ausencia de estructuras en su interior, que no debe ocupar la lesión por completo. Suele estar recubierta por un velo blanquecino que le otorga una apariencia de vidrio esmerilado. En el caso de la estructura velo azul-blanquecino no existen caracterizaciones, sólo se considera su presencia o no [MPA09, SAHW07].

5. Homogéneo

Pigmentación difusa marrón, azul-gris a gris-negro, con ausencia de otras estructuras discernibles. El patrón homogéneo es muy parecido en ocasiones al homogéneo azulado, aunque no es exactamente lo mismo. Sólo se considera su presencia o no [MPA09, SAHW07].

6. Homogéneo azulado

Pigmentación azul en ausencia de otras estructuras discernibles. Sólo se considera su presencia o no [MPA09, SAHW07].

7. Manchas de pigmento

Áreas locales desestructuradas, en ausencia de otras estructuras discernibles, muy pigmentadas, de color marrón, gris o negro y con distribución simétrica o asimétrica en la lesión. Se pueden considerar las caracterizaciones regular/irregular [MPA09, SAHW07].

2.1 Estado del arte a nivel médico




Figura 2.7: Ejemplos de patrones dermatoscópicos. a) Retículo pigmentado. b) Glóbulos. c) Proyecciones. d) Velo azul-blanquecino. e) Hipopigmentación. f) Estructuras de regresión. g) Vascular. h) Paralelo. Fuente en [ASP⁺00].

2. ESTADO DEL ARTE

8. Hipopigmentación

Áreas focales sin estructuras discernibles con mucha menos pigmentación que el resto de la lesión y comprendiendo al menos el 10 % del área total. En el caso del patron hipopigmentación sólo se suele considerar su presencia o no [MPA09, SAHW07].

9. Estructuras de regresión

Áreas blancas de despigmentación similar a una cicatriz y/o gránulos azules en forma de “granos de pimienta”. Se pueden considerar las caracterizaciones áreas blancas/áreas azules/combinación [MPA09, SAHW07].

10. Vascular

Tiene vasos sanguíneos y en función de la forma de éstos se discrimina entre típico y atípico, siendo las estructuras asociadas a la caracterización atípica: vasos puntiformes o “en cabeza de alfiler”, “vasos en horquilla”, vasos lineales con morfología y distribución irregulares, glóbulos rojo-azulados o rojo lechosos y vasos o eritema en el inferior de estructuras de regresión [MPA09, SAHW07].

11. Paralelo

Tiene forma de surcos o crestas, dispuestas de manera paralela. Es típico de las lesiones palmo-plantares. Se considera su presencia o no. [MPA09, SAHW07].

Relación con los métodos médicos

A continuación, en el Cuadro 2.1, se van a mostrar las relaciones, en cuanto a su reconocimiento, de los patrones dermatoscópicos objeto de estudio con los indicadores de los métodos medicos.

2.1 Estado del arte a nivel médico

Cuadro 2.1: Relación de los patrones dermatoscópicos objeto de estudio, en cuanto a su reconocimiento, con los indicadores de los metodos médicos.

| Patrón | 1ª Etapa | A. P. - global | A. P. - local | Regla ABCD | Método Menzies | Lista 7 Puntos |
|-----------------------------|----------------------------|--------------------------|-----------------------------|---|---|---|
| 1. Reticulo pigmentado | Reticulo pig- mentado | Reticular | Reticulo pig- mentado | Reticulo pig- mentado | Reticulo pig- mentado promi- nente | Reticulo pig- mentado atípico |
| 2. Glóbulos / Puntos | Agregado glóbulos | Glóbular | Glóbulos y/o Puntos | Glóbulos, Pun- tos | Múltiples pun- tos marrones, Puntos y glóbu- los negros periféricos | Glóbulos y/o Puntos irregula- res |
| 3. Proyecciones | Ramificaciones lineales | Estallido estre- llas | Proyecciones | Ramificaciones lineales / Pseudópodos | Ramificaciones lineales, Pseudópodos | Proyecciones irregulares |
| 4. Velo azul-blanquecino | | | Velo azul- blanquecino | | Velo azul- blanquecino | Velo azul- blanquecino |
| 5. Homogéneo | | Homogéneo | | Áreas ho- mogéneas y desestructuradas | | |
| 6. Homogéneo azulado | Homogéneo azulado | | | Áreas ho- mogéneas y desestructuradas | | |
| 7. Manchas pigmentadas | | | Manchas pig- mento | Áreas ho- mogéneas y desestructuradas | | Manchas pig- mento irregula- res |
| 8. Hipopigmentación | | | Áreas hipopig- mentación | Áreas ho- mogéneas y desestructuradas | | |
| 9. Estructuras de regresión | | | Estructuras de regresión | | Despigmentación pseudocicatri- zal, Múltiples puntos azul- grises | Estructuras de regresión |
| 10. Vascular | | | Estructuras vas- culares | | | Patrón vascular atípico |
| 11. Paralelo | Paralelo | Paralelo | | | | |

2.1.3.10 Estandarización de la dermatoscopia

Para la dermatoscopia se considera el estado del arte actual a nivel médico, usado como guía estándar, la publicación [MPA⁺07]. Es una evolución del trabajo [ASCA03], relativo al Consensus Net Meeting of 2000 [ASCA03], en el que vía internet 40 expertos de diferentes países probaron la validez de los métodos para el diagnóstico de melanoma más relevantes, ya descritos, sobre 108 imágenes previamente diagnosticadas. En los experimentos realizados, los cuatro métodos tuvieron una sensibilidad similar, entre 82.6 % y 85.7 %. Donde más diferencia hubo fue en la especificidad, siendo la del “Análisis de Patrones”, de 83.4 %, superior a los otros tres (que oscilaban entre 70 % y 71.5 %).

2. ESTADO DEL ARTE

2.1.3.11 Importancia de un diagnóstico automatizado. CADs existentes en el mercado actualmente. Limitaciones

Es evidente que una herramienta software para el diagnóstico asistido por ordenador (CAD: *Computer Aided Diagnosis*) que tuviese muy buenos resultados sería de gran importancia, de cara a mejorar y acelerar las tareas médicas. Además podría ser utilizado en sistemas de cribado o *screening* con el fin de detectar melanomas en estados tempranos, sobre plataformas de telemedicina o de otro tipo.

Actualmente, el diseño y desarrollo de un software de este tipo es un problema vigente a nivel científico [KG12, GCC⁺16]. En cualquier caso, existen varios CADs en el mercado –dirigidos a los profesionales médicos, que son en su mayoría aplicaciones software desarrolladas por las empresas fabricantes de los dermatoscopios, ya comentados en 2.1.3.1. Aunque algunos fabricantes publicitan que sus CADs en conjunción con sus dermatoscopios obtienen muy buenos resultados, como DBDermo-Mips/DDAX (Biomips [Bio15]), Melafind (MELA Sciences [MEL15]), Dermoscopix (Dermoscopix [Der15d]) y Dermo Genius (DermosScan [Der15c]), no existen estudios científicos realizados con gran cantidad de imágenes que corroboren tal hecho [KG12]. Asimismo, desde el punto de vista científico estos CADs tienen el problema de que el diseño de sus algoritmos no es público, teniéndose además que son muy dependientes de los propios dispositivos de captura.

2.1.4 Conclusiones. Justificación de la necesidad desde el punto de vista médico

En 2.1.1.3 se ha mostrado la gran importancia que tiene la detección precoz de melanoma. En 2.1.1.4 se ha visto que es un problema de salud de gran importancia, tanto a nivel mundial como a nivel local, en España. En 2.1.2 se describen las técnicas más relevantes para la detección de melanoma, concluyéndose en 2.1.2.9 que la dermatoscopia es la prueba de referencia o *gold standard*. En 2.1.3.4, 2.1.3.5, 2.1.3.6, 2.1.3.8, 2.1.3.7 y 2.1.3.10 se trata el diagnóstico de melanoma, siendo los indicadores más relevantes los patrones o estructuras dermatoscópicas, que se definen en 2.1.3.3 y se describen con detalle en 2.1.3.9. En 2.1.3.11 se muestra la importancia que podría tener para el sistema médico la automatización de estos diagnósticos y se explica que es un problema vigente a nivel científico.

Se justifica pues desde el punto de vista médico la necesidad de mejorar la automatización del diagnóstico a partir de imágenes dermatoscópicas.

2.2 Estado del arte a nivel tecnológico

2.2.1 Contextualización de la presente investigación en el estado del arte

El propósito de este apartado es realizar una contextualización de la presente investigación en el estado del arte a nivel tecnológico. Para ello, en primer lugar se describe el ciclo de vida de un CAD para el diagnóstico de melanoma, en segundo lugar se explican los dos tipos de enfoques que hay para su diseño y en tercer lugar se explica el objetivo y alcance de la presente investigación.

2.2.1.1 Ciclo de vida de un CAD para la detección de melanoma

En la Fig. 2.8 se muestra el ciclo de vida de un sistema automatizado de detección de melanoma usando la técnica de la dermatoscopia, que se realiza en cinco pasos.

Paso 1: Adquisición de la imagen. Se realiza la adquisición o captura de la imagen dermatoscópica.

Paso 2: Preprocesado de la imagen. Se lleva a cabo el preprocesado de la imagen, con el objetivo de detectar y tratar el ruido que suele aparecer en este tipo de imágenes, tales como pelos, burbujas, flashes, sombras, marcas de tinta en la piel, marcas electrónicas (normalmente identificadores digitales o información de copyright), marcos negros o dispositivos y reglas para medir. En esta tarea, el problema más interesante y relevante, debido a su inevitabilidad en la adquisición de imágenes, es la detección y eliminación de los pelos –que conlleva la posterior restauración de la imagen–. Finalmente, hay que señalar que esta tarea es opcional, es decir, un CAD para la detección de melanoma puede no realizar esta tarea (se delegaría en los algoritmos de reconocimiento de los indicadores dicha funcionalidad).

Paso 3: Segmentación de la lesión. Se efectúa la segmentación de la lesión, obteniendo la región de interés en la imagen dermatoscópica.

2. ESTADO DEL ARTE

Paso 4: Detección y caracterización de indicadores. Se procede a la detección y caracterización de diferentes indicadores, de cara a la posterior realización del diagnóstico.

Paso 5: Diagnóstico. A partir de los indicadores detectados y caracterizados se lleva a cabo un cálculo cuantitativo del grado de malignidad, lo cual permite, en base a unos rangos de valores preestablecidos, la realización del diagnóstico.

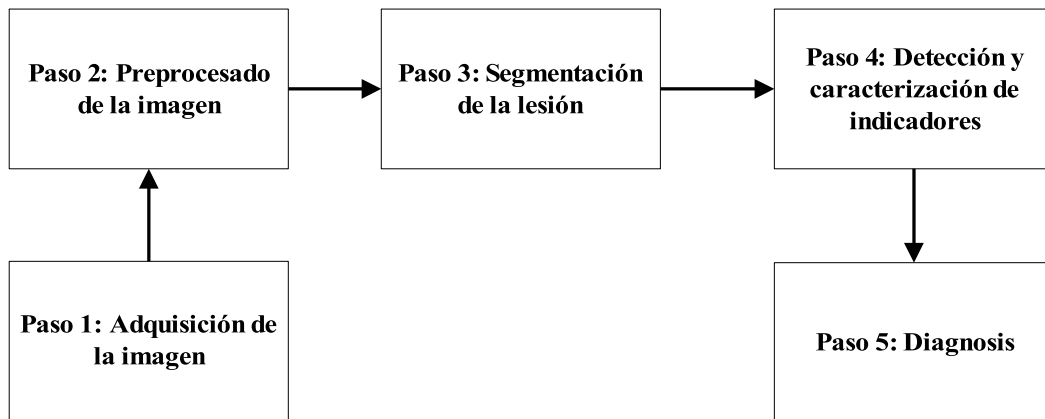


Figura 2.8: Ciclo de vida de un sistema automatizado de detección de melanoma

2.2.1.2 Enfoques de un CAD para la detección de melanoma

Se han mostrado las etapas del ciclo de vida de un sistema automatizado de detección de melanoma. Según se diseñen las etapas 4 y 5, correspondientes a la detección y caracterización de indicadores y posterior diagnóstico, existen dos posibles enfoques:

Primer enfoque. Consiste en basarse en alguno de los algoritmos médicos. Los indicadores que detecta y caracteriza un sistema de este tipo son los correspondientes al algoritmo médico elegido y la diagnosis se realiza de acuerdo a los rangos de valores preestablecidos por éste. Un ejemplo de sistema desarrollado con este primer enfoque es el descrito en [FCT⁺09], que está basado en la “Regla del ABCD”, descrita en 2.1.3.6. Por tanto, en la etapa 4 se tienen en cuenta los indicadores relativos a la asimetría de la lesión, tanto en

forma como en color, el grado de abrupción de los bordes, la cantidad de colores diferentes que tiene y, finalmente, la presencia o no de algunos patrones dermatoscópicos: reticular, globular, puntos, áreas homogéneas y desestructuradas y ramificaciones lineales/pseudópodos y, en la etapa 5, se tienen en cuenta los rangos de valores de la “Regla del ABCD”.

Segundo enfoque. Consiste en utilizar un método no basado en los algoritmos médicos. En un sistema de este tipo, en la etapa 4 se extraen características de la lesión, utilizando diferentes técnicas de imagen, y en la etapa 5 se realiza el diagnóstico, utilizando técnicas de minería de datos, normalmente en un proceso de aprendizaje supervisado (con un clasificador que trabaja sobre las imágenes etiquetadas como melanoma o no melanoma). Un ejemplo de sistema desarrollado con este segundo enfoque es el descrito en [GPR⁺01], en el que se extrae a partir de la imagen un conjunto de características de color y de textura, junto con otras de tipo geométrico, generándose la regla de decisión con el algoritmo de *k*-vecinos más cercanos (kNN: *k-nearest neighbors*) [Bis06].

Normalmente, un sistema de este tipo sirve de ayuda al diagnóstico de un médico, que es el quien al final tiene que tomar la decisión, y el médico habitualmente prefiere que el diagnóstico esté basado en alguno de los algoritmos utilizados habitualmente en la práctica médica –los algoritmos médicos–. Por ello, los sistemas con el primer enfoque suelen ser frecuentemente los preferidos para los médicos.

2.2.1.3 Objetivo y alcance de la presente investigación

Además de los CADs para la detección de melanoma existentes en el mercado actualmente, que se comentaban en 2.1.3.11, se han propuesto diferentes métodos científicos en los últimos años, tanto con el primer enfoque [GPR⁺01, CKU⁺07, IOC⁺08, SKCI14] como con el segundo [DPSF10, FCT⁺09, ACFA13, FVC⁺14]. No obstante, tal y como se comentó la automatización del diagnóstico de melanoma es un problema vigente a nivel científico [KG12, GCC⁺16]. Además, también lo son los subproblemas que lo componen, correspondientes a las diferentes tareas de su ciclo de vida [KG12, GCC⁺16].

En la presente investigación, tal y como se explicaba en 1.3, se tiene como objetivo diseñar y desarrollar una familia de algoritmos de procesamiento digital de

2. ESTADO DEL ARTE

imagen para la segmentación de la lesión y la detección y caracterización de diferentes indicadores, centrándose especialmente en los patrones dermatoscópicos, de cara a ser integrados en un sistema software para el diagnóstico de melanoma basado en alguno de los algoritmos médicos para el diagnóstico de melanoma, en este caso la “Regla del ABCD”. Por tanto, la presente investigación está orientada a la realización de un CAD para la detección de melanoma utilizando el primer enfoque y las principales aportaciones están en las tareas 3, 4 y 5 de su ciclo de vida, tal y como se explicará en 6.2, centrándose especialmente en el reconocimiento de los patrones dermatoscópicos.

En cualquier caso, tal y como también se explicaba en 1.3, la contribución más importante de la investigación desde el punto de vista científico-tecnológico ha sido el algoritmo de reconocimiento del patrón reticular, un método muy innovador que puede ser utilizado además en otros problemas de reconocimiento de patrones de naturaleza similar, y en este documento se presenta de manera detallada este algoritmo.

2.2.2 Estado del arte de la detección y caracterización de los patrones dermatoscópicos

Tras un análisis exhaustivo del estado del arte, se han seleccionado los métodos más relevantes relativos a la detección y caracterización de los diferentes patrones, cumpliendo todos ellos las siguientes condiciones:

- Que muestren el diseño del algoritmo (existen trabajos que reportan realizar la detección de la estructura, pero que no muestran cómo lo realizan).
- Que éste sea innovador y de calidad.

Aunque los diferentes trabajos tratan sobre la detección y caracterización de los diferentes patrones, tienen diferentes objetivos. Los objetivos de los diferentes trabajos se muestran en 2.2.2.1. En los casos en los que el mismo algoritmo es mostrado en diferentes publicaciones, se escoge la más relevante para ese patrón. También existen casos en los que en la misma publicación se muestran métodos correspondientes a varios patrones. En los casos en los que el mismo grupo propone para el mismo patrón enfoques diferentes, se tienen en cuenta los diferentes trabajos. En cualquier caso, dado el carácter de compendio de este trabajo, se presentan

2.2 Estado del arte a nivel tecnológico

todos los trabajos de la temática, relacionándolos con los seleccionados, e incluso relacionando estos últimos entre sí cuando existe la relación, en 2.2.2.2.

Tal y como se ha comentado anteriormente, la mayor contribución de la presente investigación es el algoritmo de reconocimiento del patrón reticular, en el que se centra especialmente este documento, y por ello se detallarán especialmente los trabajos relativos a este patrón, en 2.2.3.

2.2.2.1 Objetivos de los trabajos

A continuación, se van a mostrar, de manera cronológica, los trabajos del estado del arte que se consideran más relevantes en el reconocimiento de los diferentes patrones dermatoscópicos, junto con sus principales objetivos, en el Cuadro 2.2.

Cuadro 2.2: Objetivos de los trabajos más relevantes de detección y caracterización de patrones dermatoscópicos. En la primera columna, los trabajos seleccionados; en la segunda, para cada trabajo, los patrones cuyo reconocimiento aborda y para las que ha sido seleccionado (RP: Retículo pigmentado, GP: Glóbulos / Puntos, PR: Proyecciones, VAB: Velo azul-blanquecino, HO: Homogéneo, HOAZ: Homogéneo azulado, MP: Manchas de pigmento, HIPO: Hipopigmentación, ER: Estructuras de regresión, VA: Vascular y PA: Paralelo) –lo cual no significa que no pueda tratar más patrones, sino que ha sido seleccionado como relevante para los señalados–; finalmente, en la tercera, los principales objetivos de ese trabajo en el reconocimiento de dichos patrones.

| Trabajos seleccionados | Patrones | Objetivos |
|---------------------------------------|----------|---|
| Fischer et al. 1996 [FSG96] | RP | Obtener la estructura de retículo pigmentado. |
| Fleming et al. 1998 [FSZ+98] | GP | Obtener la estructura de glóbulos. |
| Fleming et al. 1999 [FSCZ99] | RP | Obtener la estructura de retículo pigmentado. Caracterización para la diagnosis de melanoma. |
| Murali et al. 2000 [MSM00] | MP | Reconocimiento de las manchas pigmentadas en subimágenes de tamaño 64×64 . Caracterización para la diagnosis de melanoma. |
| Caputo et al. 2002 [CPG02] | RP | Obtener la estructura de retículo pigmentado. Diferenciación entre retículo pigmentado típico y atípico. |
| Anantha et al. 2004 [AMS04] | RP | Reconocimiento del retículo pigmentado: discriminación entre ausencia de retículo pigmentado, retículo pigmentado parcial y retículo pigmentado total, en subimágenes de tamaño 64×64 . Obtener tamaño óptimo de texel para la detección de retículo pigmentado. |
| Yoshino et al. 2004 [YTTO04] | GP | Obtener la estructura de glóbulos. |
| Pellacani et al. 2004 [PGCS04] | MP | Obtener manchas de pigmento. Hay dos tipos: areas oscuras absolutas y relativas. Caracterización para la diagnosis de melanoma. |
| Stoecker et al. 2005 [SGS+05] | MP | Obtener manchas de pigmento. Caracterización para la diagnosis de melanoma. |
| Betta et al. 2005 [BDLF+05] | PR | Reconocimiento de las proyecciones irregulares. |
| Betta et al. 2006 [BDF+06] | VA | Obtener la estructura del patrón vascular (aunque los autores también hablan del patrón vascular atípico, dicho procesamiento no se muestra en el trabajo). |
| Grana et al. 2007 [GDP+07] | RP | Reconocimiento del retículo pigmentado. |
| Tanaka et al. 2008 [TTK+08] | RP-GP-HO | Discriminación entre patrón reticular, globular y homogéneo (patrones globales). |
| Di Leo et al. 2008 [DLPS08] | RP | Reconocimiento del retículo pigmentado atípico. |

Continúa en la siguiente página

Cuadro 2.2 – Viene de la página anterior

| Trabajos seleccionados | Patrones | Objetivos |
|---|----------------|--|
| Celebi et al. 2008 [CIS+08] | VAB | Reconocimiento del velo azul blanquecino del melanoma. |
| Serrano y Acha 2009 [SA09] | RP-GP-HO-PA | Discriminación entre patrón reticular, globular, empedrado, homogéneo y paralelo (patrones globales). |
| Di Leo et al. 2009 [DFP+09] | VAB-ER | Obtener áreas de velo azul blanquecino y caracterización. Obtener áreas de regresión y caracterización. |
| Khan et al. 2009 [KGS+09] | MP | Obtener manchas de pigmento. Caracterización para la diagnosis de melanoma. |
| Madasu y Lovell 2009 [ML09] | MP | Obtener manchas de pigmento. |
| Skrovseth et al. 2010 [SST+10] | RP-GP | Obtener la estructura de retículo pigmentado. Obtener la estructura globular. |
| Shrestha et al. 2010 [SBK+10] | RP | Reconocimiento del retículo pigmentado atípico: discriminación entre áreas con presencia y ausencia de dicho patrón en subimágenes. Obtener tamaño óptimo de texel para la detección de retículo pigmentado atípico. |
| Di Leo et al. 2010 [DPSF10] | PR | Reconocimiento de las manchas de pigmento irregulares. |
| Sadeghi et al. 2011 [SRLA11] | RP | Reconocimiento del retículo pigmentado. |
| Sadeghi et al. 2010 [SRW+10] | RP | Reconocimiento del retículo pigmentado. Reconocimiento del retículo pigmentado atípico, discriminando entre ausencia, típico y atípico. |
| Gola et al. 2011 [GGM11b] | RP-GP-HOAZ | Reconocimiento del retículo pigmentado. Reconocimiento de glóbulos y puntos. Reconocimiento del patrón homogéneo azulado. |
| Wighton et al. 2011 [WLL+11] | RP | Obtener la estructura de retículo pigmentado. |
| Dalal et al. 2011 [DMS+11] | HIPO | Obtener áreas blancas y de hipopigmentación. Caracterización para la diagnosis de melanoma. |
| Stoecker et al. 2011 [SWC+11] | ER | Caracterización de áreas granulares (segmentadas manualmente) para la diagnosis de melanoma. Obtener tamaño óptimo de texel para la detección de áreas granulares. |
| García Arroyo y García Zapirain [GGM11a] | VAB | Reconocimiento del velo azul blanquecino del melanoma. |
| Barata et al. 2012 [BMR12b] | RP | Obtener la estructura de retículo pigmentado, validando contra segmentaciones tomadas por expertos. Reconocimiento del retículo pigmentado. |
| Mirzaalian et al. 2012 [MLH12] | PR | Reconocimiento de proyecciones irregulares, discriminando entre ausencia, regular e irregular. |
| Sadeghi et al. 2012 [SLM+12] | RP-GP-HO-PA | Discriminación entre patrón reticular, globular, empedrado, homogéneo y paralelo (patrones globales). |
| Abbas et al. 2012 [ACF12] | RP-GP-PR-HO-PA | Discriminación entre patrón reticular, globular, empedrado, homogéneo, paralelo y estrellado (patrones globales) en subimágenes. |
| Abbas et al. 2013 (I) [ACFA13] | RP-GP-PR | Implementación de la ‘Regla del ABCD’ para la diagnosis de melanoma. |
| Abbas et al. 2013 (II) [ACS+13] | RP-GP-PR-HO-PA | Discriminación entre patrón reticular, globular, empedrado, homogéneo, paralelo, estrellado y multicomponente (patrones globales). |
| Madooei et al. 2013 [MDSA13] | VAB | Reconocimiento del velo azul blanquecino. |

Continúa en la siguiente página

Cuadro 2.2 – Viene de la página anterior

| Trabajos seleccionados | Patrones | Objetivos |
|--|----------|--|
| Sadeghi et al. 2013 [SLL⁺13] | PR | Reconocimiento de proyecciones. Reconocimiento de proyecciones irregulares, discriminando entre ausencia, regular e irregular. |
| Sáez et al. 2014 [SAS14] | RP-GP-HO | Discriminación entre patrón reticular, globular y homogéneo (patrones globales). |
| García Arroyo y García Zapirain 2014 [GAGZ14] | RP | Reconocimiento del retículo pigmentado. |
| Barhoumi et al. 2014 [BB14] | RP | Reconocimiento del retículo pigmentado. |
| Machado et al. 2015 [MPFP15] | RP | Reconocimiento del retículo pigmentado. |
| García Arroyo y García Zapirain 2015 [GAGZ15] | HIPO | Reconocimiento del patrón hipopigmentación. |
| Kharazmi et al. 2016 [KAL⁺16] | VA | Obtener la estructura del patrón vascular. |
| Machado et al. 2016 [MPFP16] | RP | Reconocimiento del retículo pigmentado. |

Tal y como se puede ver, los trabajos tienen objetivos diferentes, y se comentarán brevemente a continuación. Los más relevantes tienen que ver con el reconocimiento del patrón dermatoscópico. Es decir, a partir de una imagen, se obtiene la estructura correspondiente y se decide si la lesión cutánea tiene el patrón correspondiente o no, mostrándose además los resultados. Es el caso de los trabajos: [MSM00], [AMS04], [BDLF⁺05], [GDP⁺07], [DLPS08], [CIS⁺08], [SBK⁺10], [DPSF10], [SRLA11], [SRW⁺10], [GGM11b], [GGM11a], [BMR12b], [MLH12], [ACFA13], [SLL⁺13], [GAGZ14], [BB14], [MPFP15], [GAGZ15] y [MPFP16]. En algunos de los trabajos se realiza además una discriminación entre las diferentes caracterizaciones. No se realizan en [ACFA13], en el que los reconocimientos de patrones se hacen dentro de un método que implementa la “Regla del ABCD”, por no contemplar este algoritmo médico caracterizaciones, en [GGM11b] para el patrón homogéneo azulado y en [GAGZ15] para el patrón hipopigmentación, porque en estos patrones sólo se contempla la presencia o no, y en [MSM00], [AMS04], [GDP⁺07], [SRLA11], [GGM11b], [BMR12b], [GAGZ14], [BB14], [MPFP15] y [MPFP16]. Entre los que abordan las caracterizaciones están los que van directamente al reconocimiento de la caracterización atypical o irregular del patrón, caso de [BDLF⁺05], [DLPS08], [SBK⁺10], [DPSF10] y [MLH12], y los que abordan por un lado el reconocimiento del patrón y posteriormente la discriminación typical o regular/atypical o irregular, caso de [SRW⁺10] y [SLL⁺13]. En los trabajos [CIS⁺08] y [GGM11a] se realiza el reconocimiento del velo azul blanquecino del melanoma, es decir, se toma la malignidad como caracterización del velo azul blanquecino, al igual que en el trabajo [MSM00], en el cual a partir del reconocimiento de manchas de pigmento de las diferentes subimágenes, se realiza la caracterización para la diagnosis de melanoma. Finalmente, como objetivos secundarios interesantes de estos trabajos, en el trabajo [BMR12b] se contempla el comportamiento de la obtención de la estructura del retículo pigmentado contra segmentaciones tomadas por expertos y en [AMS04] y [SBK⁺10] se calcula el tamaño óptimo del texel para la detección del retículo pigmentado y retículo pigmentado atípico respectivamente.

Con objetivos menos ambiciosos se tienen [FSG96], [FSZ⁺98], [FSCZ99], [CPG02], [YTTO04], [PGCS04], [SGS⁺05], [BDF⁺06], [DFP⁺09], [KGS⁺09], [ML09], [SST⁺10], [WLL⁺11], [DMS⁺11], [MDSA13] y [KAL⁺16], que se centran en obtener la estructura propia del patrón, aunque sin llegar a tratar el proble-

2. ESTADO DEL ARTE

ma de reconocimiento, que es el problema más relevante. Además, en los trabajos [FSCZ99], [PGCS04], [SGS⁺05], [KGS⁺09] y [DMS⁺11] se realiza la caracterización para la diagnosis de melanoma de la estructura detectada. No se consideran estos cinco trabajos como de reconocimiento de patrones ya que realizan las tareas por separado y no contemplan el proceso completo del comportamiento del sistema frente a imágenes cualesquiera y presentando resultados numéricos. En el trabajo [DFP⁺09], además de la detección de los patrones velo azul blanquecino y estructuras de regresión, se realiza la caracterización pero tampoco se pueden considerar reconocimiento de patrones por las mismas razones. En el trabajo [SWC⁺11] también se realiza la caracterización para la diagnosis de melanoma de las estructuras de regresión, aunque en este caso las áreas de interés son segmentadas manualmente, y se calcula además el tamaño óptimo del texel para la detección de las áreas granulares. Finalmente, los trabajos [TTK⁺08], [SA09], [SLM⁺12], [ACF12], [ACS⁺13] y [SAS14] se centran en realizar la discriminación entre diferentes patrones globales.

2.2.2.2 Relaciones con otros trabajos

Han sido seleccionados trabajos de los diferentes grupos de investigación relativos al reconocimiento de los diferentes patrones. No obstante, existen otros trabajos relacionados no seleccionados, por ser trabajos preliminares sobre los que se basan, trabajos que aprovechan los resultados para integrarlos en otros, etc. Para mostrar una referencia completa de todo lo que hay en el estado del arte, aquí se van a mencionar esos trabajos. Respecto a los propios trabajos seleccionados de un mismo grupo de investigación, también normalmente tienen relación entre sí, aunque sean enfocados a diferentes patrones, compartiendo parte del diseño. En la tabla 2.3 se muestran las relaciones existentes para los diferentes trabajos.

Cuadro 2.3: Relación entre trabajos. En la primera columna, los trabajos seleccionados; en la segunda, para cada trabajo, los patrones cuyo reconocimiento aborda y para las que ha sido seleccionado (RP: Retículo pigmentado, GP: Glóbulos / Puntos, PR: Proyecciones, VAB: Velo azul-blanquecino, HO: Homogéneo, HOAZ: Homogéneo azulado, MP: Manchas de pigmento, HIPO: Hipopigmentación, ER: Estructuras de regresión, VA: Vascular y PA: Paralelo) –lo cual no significa que no pueda tratar más patrones, sino que ha sido seleccionado como relevante para los señalados–; en la tercera los trabajos seleccionados relacionados; finalmente, en la cuarta, los trabajos relacionados no seleccionados.

| Trabajos seleccionados | Patrones | Relacionados seleccionados | Relacionados no seleccionados |
|--------------------------------|-------------|--------------------------------------|--|
| Fischer et al. 1996 [FSG96] | RP | | |
| Fleming et al. 1998 [FSZ+98] | GP | [FSCZ99] | |
| Fleming et al. 1999 [FSCZ99] | RP | [FSZ+98] | |
| Murali et al. 2000 [MSM00] | MP | [AMS04] | |
| Caputo et al. 2002 [CPG02] | RP | | |
| Anantha et al. 2004 [AMS04] | RP | [MSM00] | |
| Yoshino et al. 2004 [YTTO04] | GP | | |
| Pellacani et al. 2004 [PGCS04] | MP | | |
| Stoecker et al. 2005 [SGS+05] | MP | | |
| Betta et al. 2005 [BDLF+05] | PR | [BDF+06]-[DLPS08]-[DFP+09]-[DPSF10] | [DLFL+04]-[DLPS+10]-[FBDL+10]-[FVC+14] |
| Betta et al. 2006 [BDF+06] | VA | [BDLF+05]-[DLPS08]-[DFP+09]-[DPSF10] | [DLFL+04]-[DLPS+10]-[FBDL+10]-[FVC+14] |
| Grana et al. 2007 [GDP+07] | RP | | [GCPS06] |
| Tanaka et al. 2008 [TTK+08] | RP-GP-HO | | [TTK+04] |
| Di Leo et al. 2008 [DLPS08] | RP | [BDLF+05]-[BDF+06]-[DFP+09]-[DPSF10] | [DLFL+04]-[DLPS+10]-[FBDL+10]-[FVC+14] |
| Celebi et al. 2008 [CIS+08] | VAB | | [CKAS06] |
| Serrano y Acha 2009 [SA09] | RP-GP-HO-PA | [SAS14] | [MSA09] |
| Di Leo et al. 2009 [DFP+09] | VAB-ER | [BDLF+05]-[BDF+06]-[DLPS08]-[DPSF10] | [DLFL+04]-[DLPS+10]-[FBDL+10]-[FVC+14] |
| Khan et al. 2009 [KGS+09] | MP | | |
| Madasu y Lovell 2009 [ML09] | MP | | |
| Skrovseth et al. 2010 [SST+10] | RP-GP | | |

Continúa en la siguiente página

Cuadro 2.3 – Viene de la página anterior

| Trabajos seleccionados | Patrones | Relacionados seleccionados | Relacionados no seleccionados |
|---|----------------|---|--|
| Shrestha et al. 2010 [SBK ⁺ 10] | RP | | |
| Di Leo et al. 2010 [DPSF10] | PR | [BDLF ⁺ 05]-[BDF ⁺ 06]-[DLPS08]-[DFP ⁺ 09] | [DLFL ⁺ 04]-[DLPS ⁺ 10]-[FBDL ⁺ 10]-[FVC ⁺ 14] |
| Sadeghi et al. 2011 [SRLA11] | RP | [SRW ⁺ 10] | [SRE ⁺ 10]-[SLL ⁺ 11]-[Sad12]-[SWL ⁺ 14] |
| Sadeghi et al. 2010 [SRW ⁺ 10] | RP | [SRLA11] | [SRE ⁺ 10]-[SLL ⁺ 11]-[Sad12]-[SWL ⁺ 14] |
| Gola et al. 2011 [GGM11b] | RP-GP-HOAZ | | [GIGZMZRO10] |
| Wighton et al. 2011 [WLL ⁺ 11] | RP | | [WLM ⁺ 11]-[Wig11] |
| Dalal et al. 2011 [DMS ⁺ 11] | HIPO | | |
| Stoecker et al. 2011 [SWC ⁺ 11] | ER | | |
| García-Arroyo et al. [GGM11a] | VAB | | |
| Barata et al. 2012 [BMR12b] | RP | | [BMR11]-[Bar11]-[BMR12a] |
| Mirzaalian et al. 2012 [MLH12] | PR | | |
| Sadeghi et al. 2012 [SLM ⁺ 12] | RP-GP-HO-PA | | |
| Abbas et al. 2012 [ACF12] | RP-GP-PR-HO-PA | [ACFA13]-[ACS ⁺ 13] | |
| Abbas et al. 2013 (I) [ACFA13] | RP-GP-PR | [ACF12]-[ACS ⁺ 13] | |
| Abbas et al. 2013 (II) [ACS ⁺ 13] | RP-GP-PR-HO-PA | [ACF12]-[ACFA13] | |
| Madooei et al. 2013 [MDSA13] | VAB | | |
| Sadeghi et al. 2013 [SLL ⁺ 13] | PR | | [SLL ⁺ 11]-[Sad12]-[SWL ⁺ 14] |
| Sáez et al. 2014 [SAS14] | RP-GP-HO | [SA09] | [MSA09] |
| García-Arroyo y García-Zapirain 2014 [GAGZ14] | RP | | |
| Barhoumi et al. 2014 [BB14] | RP | | |
| Machado et al. 2015 [MPFP15] | RP | [MPFP16] | |
| García-Arroyo y García-Zapirain 2015 [GAGZ15] | HIPO | | |
| Kharazmi et al. 2016 [KAL ⁺ 16] | VA | | |
| Machado et al. 2016 [MPFP16] | RP | [MPFP15] | |

2.2 Estado del arte a nivel tecnológico

Se comentarán brevemente algunos aspectos relevantes relativos a las relaciones entre estos trabajos. Los trabajos [FSZ⁺98] y [FSCZ99] son parte de un mismo trabajo, tratándose en [FSZ⁺98] sobre retículo pigmentado y glóbulos/puntos, y mejorando en [FSCZ99] el trabajo relativo a retículo pigmentado. El trabajo [AMS04] sobre retículo pigmentado, es una continuación del trabajo realizado en [MSM00], relativo a manchas de pigmento. Los trabajos seleccionados [BDLF⁺05], [BDF⁺06], [DLPS08], [DFP⁺09] y [DPSF10], junto con los no seleccionados [DLFL⁺04], [DLPS⁺10], [FBDL⁺10] y [FVC⁺14] describen el trabajo realizado por este grupo de investigación para desarrollar un CAD para la detección de melanoma basado en el algoritmo médico “7-point- Checklist”. Los trabajos [CIS⁺08], [GDP⁺07], [TTK⁺08] y [GGM11b] son continuación de los trabajos preliminares [CKAS06], [GCPS06], [TTK⁺04] y [GIGZMZRO10], respectivamente. El trabajo [SAS14] es una evolución de [SA09], también seleccionado, que a su vez es continuación del preliminar [MSA09]. El trabajo [SRLA11] sobre retículo pigmentado es extendido en [SRW⁺10], también seleccionado, que además del problema de reconocimiento aborda la caracterización típico/atípico, siendo los trabajos no seleccionados [SRE⁺10] y [SLL⁺11] preliminares de [SRLA11] y [SRW⁺10] respectivamente, siendo [SLL⁺11], que aborda proyecciones además de retículo pigmentado, también un trabajo preliminar del trabajo seleccionado [SLL⁺13] sobre proyecciones, y siendo finalmente los trabajos no seleccionados [Sad12] y [SWL⁺14] un compendio del trabajo del grupo de investigación en retículo pigmentado y proyecciones, que no tiene nada que ver, aún siendo de los mismos autores, con el seleccionado [SLM⁺12] que aborda la discriminación entre varios patrones globales. El trabajo seleccionado [WLL⁺11] tiene básicamente el mismo contenido relativo a retículo pigmentado que [WLM⁺11], mientras que [WLM⁺11] es un compendio del trabajo del grupo de investigación en este tema. El trabajo [BMR12b] tiene a [BMR11], [Bar11] y [BMR12a] como trabajos preliminares. Los trabajos [ACF12], [ACFA13] y [ACS⁺13] comparten parte de su diseño aunque sus objetivos y las técnicas utilizadas son diferentes. Además, estos trabajos tienen algo de relación con los trabajos [MSA09], [SA09] y [SAS14], tanto a nivel de autores como de enfoque de los algoritmos, aunque no es una relación estrecha y por ello no se ponen como relacionados. Finalmente, los trabajos [MPFP15] y [MPFP16], de los mismos autores, tienen el mismo objetivo –el reconocimiento del retículo pigmentado– y cierta relación, pero lo abordan con técnicas diferentes.

2. ESTADO DEL ARTE

2.2.3 Estado del arte de la detección y caracterización del patrón reticular

Los trabajos seleccionados para el patrón reticular, junto con sus objetivos, se han mostrado en 2.2. En este apartado se describe el estado del arte para el patrón reticular de manera detallada. Para ello se muestra, en primer lugar, la descripción detallada del diseño de los métodos, en segundo lugar, un esquema de las técnicas utilizadas en los diferentes trabajos para las diferentes tareas y, en tercer lugar, una comparación de los resultados obtenidos. El estudio de dichos resultados en las diferentes variables estudiadas es la base para la realización de una valoración crítica.

2.2.3.1 Descripción de los métodos más relevantes de reconocimiento del patrón reticular

Fischer et al. 1996

In [FSG96], Fischer et al. presentan un método para la obtención de la red pigmentada de una imagen dermatoscópica. Para ello, en primer lugar realizan una transformación de la imagen a la escala de grises, utilizando la transformación Karhunen-Loeve [GW08]. Tras la segmentación de la imagen –no se entra aquí en las técnicas utilizadas para ésta–, en segundo lugar se utiliza ecualización local de histograma para mejorar el contraste. En tercer lugar, se utilizan operaciones morfológicas a nivel de gris, que permiten la eliminación del ruido. En cuarto lugar, se obtiene la red pigmentada a partir de un valor umbral calculado. No reportan datos acerca de las imágenes utilizadas para testear el método ni sobre los resultados obtenidos. No obstante, para posteriores trabajos que aborden el reconocimiento de la red pigmentada, para la caracterización los autores proponen una extracción de varias características estructurales extraídas a partir de la imagen binaria obtenida, correspondiente a la red pigmentada.

Fleming et al. 1999

En [FSCZ99], Fleming et al. llevan a cabo la detección de la red pigmentada, como aplicación concreta del trabajo [Ste98] –de índole más general y realizado por uno de los autores–. En primer lugar, se transforma la imagen a la escala de grises,

seleccionando el primer plano de la transformación CIE XYZ. En segundo lugar, usan el algoritmo de detección de líneas curvas de Steger, descrito en el mencionado trabajo [Ste98], con el fin de extraer la red, método que además proporciona una medida de las anchuras de las líneas, en función de parámetros preestablecidos. En tercer lugar, se utiliza el modelo Lobregt-Viergever de *snakes* [LV95] para segmentar los agujeros y obtener una medida de éstos. Para testear el algoritmo se utilizaron 69 imágenes (16 nevos comunes, 22 nevos displásicos y 31 melanomas) y se encontraron con ANOVA resultados estadísticos interesantes, relacionadas con las correlaciones de ese tipo de imágenes con anchos de líneas y áreas de agujeros. Se estudiaron distintos indicadores relativos a estos valores, siendo los más relevantes la media de las anchuras de las líneas (nevos comunes: 6,72, nevos displásicos: 7,03 y melanomas: 8,58) y la media de las áreas de los agujeros (nevos comunes: 251, nevos displásicos: 308 y melanomas: 345), obteniéndose además a partir de estos indicadores, utilizando una función de discriminación lineal, la discriminación correcta entre nevus y melanoma en el 80 % de los casos. Sin embargo, no se obtuvo ningún resultado relativo al comportamiento del sistema en el reconocimiento del patrón reticular, es decir, en decidir si la imagen tiene dicho patrón o no.

Caputo et al. 2002

En [CPG02], Caputo et al. presentan un método para la obtención de la red pigmentada y el análisis de su estructura. En primer lugar, se utiliza un filtro de Wiener [Jai89], para eliminar el ruido, seguido de una mejora de la imagen a través de una operación de “estiramiento” del histograma [Jai89], para hacer fácilmente detectable la estructura de red. En segundo lugar, se realiza la extracción de la estructura de red utilizando técnicas de umbral adaptativo [Jai89]. En tercer lugar, se realiza el cálculo del número y áreas de las mallas, utilizando métodos morfológicos. Finalmente, en cuarto lugar, se calculan varios indicadores estadísticos, calculados a partir de los histogramas de las imágenes y las máscaras obtenidas. Se testeó el proceso sobre 14 imágenes, seleccionadas por expertos dermatólogos de un total de 100 imágenes, de las cuáles 7 fueron etiquetadas como “Regular” (estructura regular de la red pigmentada) y 7 como “Irregular” (estructura irregular de la red pigmentada), obteniéndose a partir de los valores obtenidos para los estadísticos

2. ESTADO DEL ARTE

un umbral para la clasificación. Aplicando dicho umbral, 6 de 7 imágenes, en cada categoría, son correctamente clasificadas, obteniéndose por tanto un 85,71 % de exactitud.

Anantha et al. 2004

En [AMS04], Anantha et al. realizan el reconocimiento de la red pigmentada sobre subimágenes de 64×64 pixels. Para ello, en primer lugar se utiliza el software Dullrazor [LNG⁺97] para detectar, eliminar y restaurar los pelos y a continuación se convierte a escala de grises utilizando la fórmula $I_G(x, y) = 0,2989 I_{RGB}(x, y, 0) + 0,587 I_{RGB}(x, y, 1) + 0,114 I_{RGB}(x, y, 2)$. En segundo lugar, utiliza dos métodos diferentes de análisis estadístico de textura para la detección de la red pigmentada, el primero usa las máscaras de energía de Law [Law80] y el segundo usa la *neighborhood gray level dependence matrix* (NGLDM) [SW83], en ambos casos se trata de caracterizar la textura a partir de un conjunto de estadísticos obtenidos sobre el vecindario de cada pixel. Además, de cara a identificar el mejor tamaño de texel (unidad de textura) para la detección, se utilizaron diferentes tamaños para ambas técnicas. El sistema fue testado sobre un total de 155 images, que fueron divididas en bloques de 64×64 pixels, clasificadas posteriormente por expertos dermatólogos entre “No red pigmentada”, “Red pigmentada parcial” y “Red pigmentada completa”. Se obtuvieron los mejores resultados con el primer método, las máscaras de energía de Law, clasificándose correctamente el 80 % de los bloques. Otro resultado importante que se obtiene es el cálculo de la anchura óptima de un texel para el reconocimiento de la red pigmentada, determinándose en 10 pixels $\approx 0,22$ mm con la resolución de las imágenes usadas— para el problema del reconocimiento del patrón reticular.

Grana et al. 2007

En [GDP⁺07], Grana et al. llevan a cabo la detección de la red pigmentada en tres pasos, con un enfoque bastante parecido al trabajo de Fleming et al. [FSCZ99], ya explicado. En primer lugar, se usa el algoritmo de detección de líneas curvas de Steger [Ste98] sobre la imagen previamente transformada a la escala de grises, para la detección de los puntos de la red. En segundo lugar, se enlazan dichos puntos en una línea, teniendo en cuenta la dirección de la línea en sus puntos extremos

y el número de los puntos de la línea conectados a éstos. Se escogen los mejores puntos, a partir de la obtención de umbrales óptimos en la delineación de la estructura, usando análisis discriminante lineal de Fisher, y se unen utilizando interpolación bilineal y operaciones morfológicas a nivel de gris. En tercer lugar, se validan las mallas obtenidas, usando como criterios que hayan podido ser cerradas con las líneas y que tengan valores adecuados de área y de circularidad. El número de mallas válidas obtenidas y su área con respecto al área total de la lesión son las entradas a una función discriminante lineal que clasifica las lesiones entre reticular y no reticular. Se utiliza un conjunto de 100 imágenes, 50 con el patrón red pigmentada y 50 sin él, obteniéndose una sensibilidad del 82 %, una especificidad del 94 % y una exactitud del 88 %.

Tanaka et al. 2008

En [TTK⁺08], Tanaka et al. presentan un algoritmo para la diferenciación de subimágenes con los siguientes tipos de patrones: homogéneo, globular y reticular. Para la diferenciación entre homogéneo, por una parte, y reticular y globular, por otra, se extraen diferentes tipos de características: 7 de intensidad de histograma, 7 de estadística diferencial, 14 de densidad espectral extraídas a partir de la transformada de Fourier, 5 a partir de matrices *run-length* [Tan98] y 13 a partir de matrices de coocurrencia de nivel de gris (GLCM: *gray level co-occurrence matrix* [HSD73]), hasta un total de 46 características. Para la diferenciación entre reticular y globular se realiza un procesado y posterior caracterización, tal y como sigue. En primer lugar se utilizan matrices *run-length* usando intensidad, lo cual permite, en combinación con la aplicación de un valor umbral, la generación de una máscara binaria. En segundo lugar, se obtienen las componentes 8-conexas de las regiones blancas y negras y, a partir de éstas, se calculan 64 características estructurales. Se utilizó una base de datos de 213 imágenes, de las cuáles se obtuvieron 852 subimágenes correspondientes a los tres patrones. Tras la caracterización realizada y el uso de un método de discriminación lineal se obtuvo una exactitud del 94 % en la diferenciación entre las 3 categorías.

2. ESTADO DEL ARTE

Di Leo et al. 2008

En [DLPS08], Di Leo et al. llevan a cabo la detección de la red pigmentada atípica, combinando tras la transformación a la escala de grises –no se reporta la fórmula utilizada– dos técnicas, tal y como se muestra en la Fig. 2.9: la primera estructural, usando métodos morfológicos, y la segunda espectral, basada en el análisis de Fourier, usando la transformada rápida de Fourier, filtros paso alto, transformada rápida de Fourier inversa y, finalmente, técnicas de umbral. Como resultado, se obtiene la máscara de la red pigmentada, que se combina a su vez con la máscara que se ha obtenido como resultado de la segmentación de la lesión cutánea, usando el método de Otsu [Ots79]. La gestión de los artefactos distorsionadores (pelos, ...) no se reporta. Para la caracterización de la red pigmentada y su diferenciación entre las categorías “Ausente”, “Típica” y “Atípica” se usan 9 características cromáticas y 4 espaciales, calculadas a partir de las estructuras obtenidas. Se utilizó el clasificador C4.5 [Qui93] sobre un total de 173 imágenes (43, 53 y 77 de cada tipo). No se muestran resultados numéricos de la clasificación obtenida a partir del árbol de decisión generado, únicamente se reportan los relativos a la diferenciación entre “No atípica” (“Ausente” y “Típica”) y “Atípica” (“Atípica”), principal objetivo del trabajo, obteniéndose más del 85 % de sensibilidad y especificidad (no se presentan los valores exactos). Es éste un trabajo importante en el problema del reconocimiento del patrón reticular por sus buenos resultados, que además se ha integrado en un CAD completo [DPSF10].

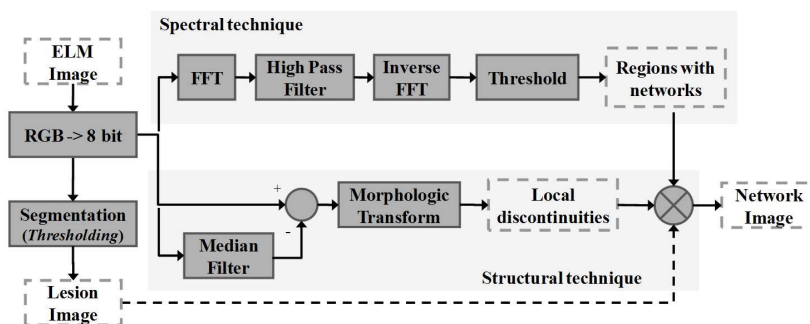


Figura 2.9: Visión de alto nivel del método de Di Leo et al. 2008. Reimpreso con permisos de [DLPS08].

Serrano y Acha 2009

En [SA09], Serrano y Acha proponen un algoritmo basado en campos aleatorios de Markov (MRF: *Markov random fields*) [Li01] que realiza en subimágenes la diferenciación entre diferentes patrones dermatoscópicos: reticular, globular, empedrado, homogéneo y paralelo. Para ello, se pasa a diferentes espacios de colores (RGB, YIQ, HSV y CIE Lab) y se modela cada plano como un MRF siguiendo un modelo condicional simétrico finito (FSCM: *finite symmetric conditional model*) [KC83]. Se realiza aprendizaje supervisado sobre una base de datos de 100 subimágenes de tamaño 40×40 , 20 de cada patrón. No se detallan ni las fuentes ni la manera en que fueron elegidos estas subimágenes. El análisis estadístico se realiza suponiendo que las características de los MRF en los tres planos de color siguen una distribución normal multivariante, testeándose el modelo con dos asunciones diferentes: el método 1, con la asunción de la independencia interplanos, y el método 2, sin dicha asunción. Además, se prueba también con un tercer método, que usa la técnica de los k-vecinos más cercanos [Bis06]. Los mejores resultados se obtienen con el espacio de colores CIE Lab y con el método 2, es decir con normal multivariante sin la asunción de la independencia interplanos, alcanzando una exactitud del 86 % en el problema de clasificación entre los 5 patrones. En el caso concreto de la discriminación del patrón reticular se obtiene una exactitud del 90 %.

Skrovseth et al. 2010

En [SST⁺10], Skrovseth et al. presentan algunas funcionalidades de un CAD para la detección de melanoma que están desarrollando. Uno de los módulos de dicho CAD realiza la detección reticular, clasificando los distintos pixels de la imagen entre los que pertenecen a la red pigmentada y los que no. Para ello, se definen a nivel de pixel 20 características de textura, no se explica cuáles, y se utiliza un clasificador lineal para seleccionar las tres más significativas y obtener los umbrales óptimos para la clasificación. No se reporta información acerca de la base de datos utilizada ni sobre los resultados obtenidos.

2. ESTADO DEL ARTE

Shrestha et al. 2010

En el trabajo [SBK⁺10], Shrestha et al. presentan un algoritmo para el reconocimiento de áreas de red pigmentada atípica (RPA). Se utilizan 10 características de textura obtenidas a partir de la matriz de coocurrencia de nivel de gris (GLCM: *gray level co-occurrence matrix*) [HSD73] correspondientes a la media y el rango de cada una de las siguientes medidas de textura: energía, inercia, correlación, diferencia inversa y entropía. Además de la discriminación entre las áreas RPA y las no RPA es un objetivo importante del trabajo obtener la mejor distancia (valor d) de las matrices GLCM en el cálculo de la textura, por ello se construyen 5 GLCMs por cada imagen, utilizando diferentes distancias de pixel (valor d): 6, 12, 20, 30 y 40. Se tiene una base de datos de 106 imágenes, 28 melanomas y 78 nevus displásicos, marcando un experto dermatólogo en cada imagen diferentes regiones como áreas de RPA o áreas de no ARPA, no se reporta el total de áreas. Se ejecuta el proceso de aprendizaje supervisado utilizando seis clasificadores: BayesNet, AD-Tree, DecisionStump, J48, NBTree y Random Forest, todos ellos implementados en la herramienta software de minería de datos WEKA [The16a], no presentándose diferencias significativas entre los diferentes clasificadores. La característica más relevante resulta ser la media de la correlación, que permite obtener una exactitud del 95,4 %. Se obtiene además que la distancia óptima para la discriminación, es de 20 pixels, lo cual equivale, con la resolución de las imágenes empleadas, a un tamaño de texel de 0,2 mm. Al igual que en el estudio de Anantha et al. [AMS04], mencionado anteriormente, se llega a la conclusión de que el tamaño de texel es relevante para la discriminación, siendo además los valores óptimos obtenidos en ambos trabajos similares (0,22 mm en el caso del estudio de Anantha et al. y 0,2 mm en el caso de Shrestha et al.).

Sadeghi et al. 2011

En [SRLA11], Sadeghi et al. proponen un método para el reconocimiento de la red pigmentada, basado en la detección de los agujeros de la red, que consta de varios pasos, tal y como se puede ver en la Fig. 2.10. Tras la segmentación, realizada siguiendo el trabajo [WSLA09] por parte de este mismo equipo de investigación, en primer lugar, se transforma la imagen a la escala de gris escogiendo el canal verde de RGB, se utiliza un filtro paso-alto sobre la imagen para resaltar la red y a conti-

nuación se usa un filtro laplaciano del gaussiano (LoG: *laplacian of gaussian*) para capturar los cambios “claro-oscuro-claro”, obteniendo como resultado una máscara con los pixels que pueden ser parte de la estructura. En segundo lugar, se unen las componentes 8-conexas de dicha máscara para crear una estructura de grafo. En tercer lugar, se buscan los subgrafos ciclicos utilizando el algoritmo *iterative loop counting algorithm* (ILCA) [Kir14], eliminando otras estructuras redondeadas tales como puntos, glóbulos y burbujas de aceite. Esto permite, a partir de los subgrafos correctamente extraídos, identificar los agujeros de la red pigmentada, y en conjunción con la máscara binaria obtenida anteriormente, obtener la estructura reticular. En cuarto lugar, se genera otra estructura de grafo, correspondiendo cada nodo a un agujero de la red pigmentada detectada y uniendo éstos con aristas de acuerdo a las distancia entre ellos. Finalmente, en quinto lugar se realiza la clasificación a partir una característica de tipo “ratio de densidad” de nombre *Densidad*, calculada de la siguiente manera: $Densidad = \frac{|E|}{|V| \log(AreaLesion)}$, donde $|E|$ es el número de aristas en el grafo, $|V|$ es el número de nodos en el grafo y $|AreaLesion|$ es el área de la lesión. Se establece un valor umbral, si es superior a dicho valor se clasifica como “Presente” y en caso contrario como “Ausente”. Se probó el método con 500 imágenes con una exactitud del 94,3 %. Es éste un trabajo importante por sus buenos resultados en el problema del reconocimiento del patrón reticular, que además fue escalado en el trabajo posterior [SRW⁺10], que se verá a continuación.

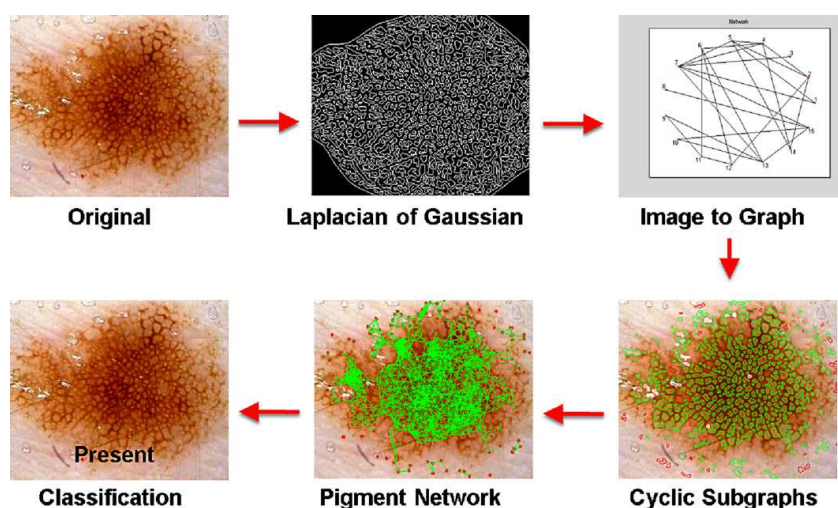


Figura 2.10: Esquema del método propuesto por Sadeghi et al. 2011. Reimpreso con permisos de [SRLA11].

2. ESTADO DEL ARTE

Sadeghi et al. 2010

En [SRW⁺10], Sadeghi et al. extienden el trabajo previo [SRLA11] a la clasificación entre “Ausente”, “Típica” y “Atípica”, tal y como se muestra en la Fig. 2.11. Para los tres primeros pasos, correspondientes a la detección de la estructura de red pigmentada, se utiliza dicho trabajo realizándose a continuación la extracción de 69 características de 4 tipos: 1. Estructurales (20): caracterizando la anchura de la red y los tamaños de los agujeros, así como sus variaciones en la lesión; 2. Geométricas (2): para estudiar la “uniformidad” de la red. Al “ratio de densidad” definido en [SRW⁺10], se añade un “ratio de irregularidad de agujeros”; 3. Cromáticas (37): a partir de los espacios de color RGB, HSV y CIE Lab; 4. Texturales (10): a partir de los mismos 5 estadísticos propuestos en [SBK⁺10], correspondientes a la matriz de coocurrencia de nivel de gris (GLCM: *gray level co-occurrence matrix*) [HSD73]. Una vez extraídos los valores de las características se genera el modelo utilizando el algoritmo LogitBoost [FHT⁺00]. Sobre un total de 436 imágenes (161 “Ausente”, 154 “Típica” y 121 “Atípica”) se obtuvo un 82,3 % de exactitud en el problema de clasificación entre “Ausente”, “Típica” y “Atípica” y, en los experimentos relativos a la diferenciación entre “Ausente” y “Presente”, se obtuvo una exactitud del 93,3 %. Al igual que el trabajo anteriormente referenciado, este es un trabajo importante en el problema del reconocimiento del patrón reticular por sus buenos resultados.

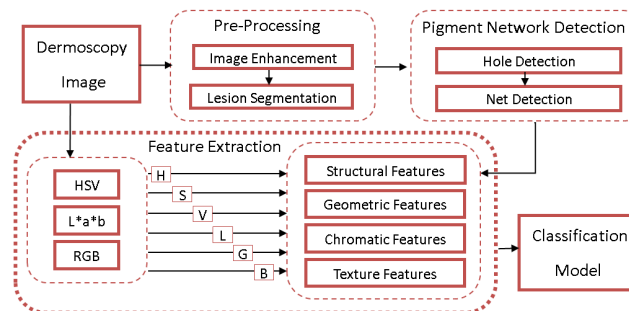


Figura 2.11: Visión de alto nivel del método propuesto por Sadeghi et al. 2010. Re-impreso con permisos de [SRW⁺10].

Gola et al. 2011

En el trabajo [GGM11b], Gola et al. presentan un sistema software para la detección de melanoma a partir de la “Regla del ABCD” en el cual el patrón reticular es uno de los indicadores. Para ello, en primer lugar se convierte la imagen a gris, usando la fórmula: $I_G(x, y) = 1/3 I_{RGB}(x, y, 0) + 1/3 I_{RGB}(x, y, 1) + 1/3 I_{RGB}(x, y, 2)$. En segundo lugar, se combinan técnicas espectrales y el algoritmo de detección de bordes de Canny [Can86], que permiten la obtención de varias máscaras. En tercer lugar, sobre dichas máscaras se realizan diferentes operaciones morfológicas, obteniéndose como resultado la máscara de la estructura reticular. El número de agujeros de la red resulta ser la característica más relevante para discriminar si existe o no patrón reticular en la lesión. Se tiene una base de datos de 150 imágenes, 20 de ellas con el patrón reticular. Se utiliza una función discriminante lineal para el cálculo del umbral óptimo, obteniéndose una exactitud del 90 % en la detección de las imágenes con red pigmentada.

Wighton et al. 2011

En [WLL⁺11], Wighton et al. presentan un algoritmo con diferentes objetivos, entre ellos la detección de la red pigmentada, en el que se utiliza aprendizaje supervisado, a partir de una caracterización basada en características de color, correspondientes al espacio CIE Lab, y espectrales, correspondientes a la aplicación de filtros gaussianos y laplaciano del gaussiano (LoG: *laplacian of gaussian*) en varias escalas, seguido de análisis discriminante lineal para la reducción de la dimensionalidad y el método bayesiano máximo de la probabilidad a posteriori (MAP: *maximum a posteriori probability*), utilizando distribuciones gaussianas multivariantes, para la generación del modelo. Se toman las muestras de una base de datos de 40 imágenes, 20 “Ausente” y 20 “Presente”, marcándose los pixels como “No lesión” (pixels fuera de la lesión), “Ausente” (pixels dentro de la lesión no reticulares) y “Presente” (pixels dentro de la lesión no reticulares). Se realizó el experimento sobre un total de 734 imágenes, sin resultados reportados en el problema de la detección de la red pigmentada.

2. ESTADO DEL ARTE

Barata et al. 2012

En el trabajo [BMR12b], Barata et al. presentan un método para la detección de la red pigmentada. Tal y como se puede ver en la Fig. 2.12, se realiza el proceso en tres etapas. En primer lugar, se realiza el preprocesado de la imagen, para ello se pasan las imágenes a la escala de grises, utilizando un trabajo anterior [SNM⁺09] en el cual se concluía que el canal de color más adecuado es el que presenta la mayor entropía, y realizándose a continuación la detección y eliminación de reflejos y pelos (no se entra en las técnicas utilizadas, ya que no es el propósito aquí tratar el preprocesado). En segundo lugar, se realiza un realce de la imagen de tal manera que se resalte la red y posteriormente se usa un banco de N filtros direccionales, seleccionando los pixels que forman la red pigmentada a partir de un valor umbral establecido T_R , y generando una máscara de pixels, de la cual se seleccionan posteriormente todas las componentes 8-conexas que tengan un área superior a A_{min} , obteniéndose como resultado la estructura de la red pigmentada. En tercer lugar, se calculan 5 características morfológicas, que son usadas para el entrenamiento de un clasificador Adaboost [FS95]. El método es probado sobre una base de datos de 200 imágenes, 112 “Ausente” y 88 “Presente”, tuneando los parámetros N , T_R y A_{min} con análisis ROC y obteniendo unos resultados de sensibilidad y especificidad del 91,1 % y 82,1 %, respectivamente. También se realizó un experimento sobre un subconjunto de imágenes para probar a nivel de pixels el comportamiento del método, comparando las máscaras reticulares obtenidas contra un conjunto de máscaras previamente segmentados manualmente por expertos dermatólogos, obteniéndose una sensibilidad de 57,6 % y una especificidad de 85,4 %. Es éste un trabajo importante en el problema del reconocimiento del patrón reticular por sus buenos resultados.

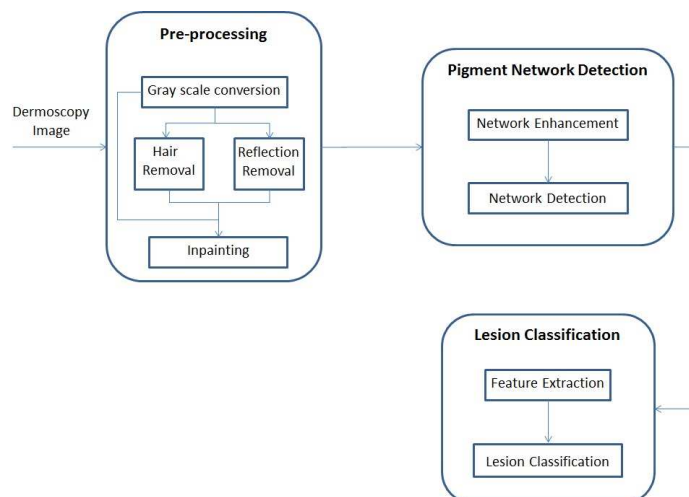


Figura 2.12: Visión de alto nivel del método propuesto por Barata et al. 2012. Reimpreso con permisos de [BMR12b].

Abbas et al. 2012

En [ACF12], Abbas et al. presentan un algoritmo que discrimina entre 6 patrones dermatoscópicos: reticular, globular, empedrado, homogéneo, cresta paralela y estrellado. En primer lugar, transforman la imagen al espacio de color CIE Lab y realizan el preprocesado, detectando y eliminando artefactos distorsionadores, y a continuación realizan la segmentación (no se entra en las técnicas aquí). A continuación, se extraen características de color, relativas al porcentaje de ocurrencia de los 6 colores típicos que se presentan en las lesiones de las imágenes dermatoscópicas y su grado de simetría, y características de textura, extraídas usando marco discreto de ondículas (DWF: *discrete wavelet frame*) [Uns95] y patrón binario local (LBP: *local binary pattern*) [OPM02]. Tanto las características de color como las de textura se extraen con una ventana deslizante de 16×16 pixels y, como resultado final, se obtiene un vector con 2 características de color y 6 de textura. La base de datos tiene 180 imágenes, 30 de cada patrón. El entrenamiento y las pruebas se realizan usando máquinas de vectores soporte multiclase (M-SVM: *multiclass support vector machines*) [WW99], obteniendo en la detección del patrón reticular unos resultados de sensibilidad de 90 %, especificidad de 93 % y AUC de 0,94.

2. ESTADO DEL ARTE

Abbas et al. 2013 (I)

En [ACFA13], Abbas et al. del mismo grupo de investigación que el trabajo anterior [ACF12] presentan un sistema de reconocimiento de melanoma basado en la “Regla del ABCD”, siendo el patrón reticular uno de sus indicadores. Respecto al patrón reticular, en primer lugar se realiza el preprocesado y la segmentación de la imagen de la misma manera que en [ACF12], extrayéndose a continuación las características de color, también de manera similar a [ACF12], y de textura, obtenidas usando la transformada de Radon [KVRP10] y patrón binario local (LBP: *local binary pattern*) [OPM02], diferentes de las extraídas en el trabajo [ACF12], aunque inspiradas en la misma idea. Las características correspondientes a este indicador se guardan con las otras correspondientes a los otros indicadores de ABCD, en un vector de características sobre el cual se realiza un proceso de selección de características usando selección secuencial flotante (SFFS: *sequential floating forward selection*) y se genera el modelo utilizando máquinas de vectores soporte (SVM: *support vector machines*). Sobre una base de datos de 120 imágenes el método obtiene en la detección de melanoma una sensibilidad de 88,2 %, una especificidad de 91,30 % y un AUC de 0,880. Acerca de la detección del patrón reticular no se reportan resultados.

Abbas et al. 2013 (II)

En [ACS⁺13], Abbas et al. del mismo grupo de investigación que los trabajos anteriores [ACF12, ACFA13] y también del grupo de Serrano y Acha [SA09], presentan un método que realiza la discriminación en subimágenes de 450×450 pixels entre 7 patrones dermoscópicos: reticular, globular, empedrado, homogéneo, cresta paralela, estrellado y multicomponente. Para ello, en primer lugar se realiza una transformación al espacio de color CIECAM02 y, a continuación, se extraen características de color, las mismas que en los trabajos anteriores [ACF12, ACFA13], y textura, obtenidas utilizando el algoritmo transformación de pirámides orientables (SPT: *steerable pyramids transformation*) de descomposición, basado en descomposición de ondículas (*wavelets*) [FA91, SFAH92]. Una vez extraídas las características, se realiza un proceso de selección mediante análisis de componentes principales (PCA: *principal component analysis*), que permite obtener las más significativas. Usando un aprendizaje multi-etiqueta con los datos extraídos se genera un mode-

lo de clasificación de los patrones, usando el algoritmo AdaBoost.MH [SS00] con salida multi-clase, llamado AdaBoost.MC, que implementa estrategias de máximo de la probabilidad a posteriori (MAP: *maximum a posteriori probability*) y ranqueo (*ranking*). En una base de datos de 350 subimágenes, 50 de cada patrón, los resultados en la detección del patrón reticular son de 87,11 % de sensibilidad, 97,96 % de especificidad y 0,981 de AUC. El modelo generado se prueba asimismo contra otros dos, generados por máquinas de vectores soporte multi-etiqueta (ML-SVM: *multi-label SVM –support vector machines–*) y k-vecinos más cercanos multi-etiqueta (ML-kNN: *multi-label kNN –K-nearest neighbors–*) respectivamente, obteniendo la mejor exactitud con el modelo AdaBoost.MC.

Sáez et al. 2014

En [SSA14], Sáez et al. del mismo grupo de investigación que los trabajos previos [SA09, ACS⁺13], llevan a cabo la clasificación de imágenes dermatoscópicas entre tres patrones: reticular, globular y homogéneo. Para el entrenamiento se utilizan dos conjuntos diferentes de imágenes, el primero con imágenes completas y el segundo con trozos de imagen extraídos de las imágenes originales, correspondientes a los diferentes patrones. El conjunto para el testing está compuesto de lesiones completas, y para analizar la lesión entera, la lesión se divide en trozos superpuestos, utilizando para éstos un tamaño óptimo establecido experimentalmente de 81×81 pixels. El algoritmo consta de varios pasos, en primer lugar, se convierte al espacio de color CIE Lab. En segundo lugar, tras la segmentación realizada, la lesión cutánea es modelada usando campos aleatorios de Markov (MRF: *Markov random fields*) [Li01] en los diferentes planos, tal y como se sugiere en el trabajo [XFZ06], siguiendo un modelo condicional simétrico finito (FSCM: *finite symmetric conditional model*) [KC83]. Para la obtención de las características de textura, se utilizan tres modelos diferentes, en los conjuntos de entrenamiento de trozos de imágenes e imágenes con las lesiones enteras: un modelo gaussiano, un modelo gaussiano mixto y un modelo bolsa de características (BoF: *bag-of-features*). Para cada caso, la clasificación se realiza con un enfoque de tipo consulta de imágenes basada en el contenido (CBIR: *content-based image retrieval*), utilizando diferentes métricas de distancia y el algoritmo de k-vecinos más cercanos [Bis06] para la clasificación final. Se utiliza una base de datos de 90 imágenes, 30 de cada patrón, obteniéndose

2. ESTADO DEL ARTE

los mejores resultados con el modelo gaussiano mixto y la métrica de distancia propuesta en [SCLG05], obteniendo una exactitud del 75,33 % en el reconocimiento del patrón reticular y del 78,44 % en el problema de la clasificación entre los tres patrones.

García-Arroyo y García-Zapirain 2014

En [GAGZ14], García-Arroyo y García-Zapirain presentan un algoritmo para el reconocimiento de la red pigmentada a partir de imágenes dermatoscópicas, que consta de dos bloques, tal y como se puede ver en la Fig. 2.13. En el primer bloque, se lleva a cabo un proceso de aprendizaje supervisado para obtener una máscara con los pixels candidatos a formar parte de la red pigmentada. Para ello, se extraen características de color –canales de RGB, rgb (RGB normalizado), HSV, CIE XYZ, CIE Lab y CIE Luv)– y de textura, tomadas de la imagen convertida a gris con la fórmula $I_G(x, y) = 0,2989 I_{RGB}(x, y, 0) + 0,587 I_{RGB}(x, y, 1) + 0,114 I_{RGB}(x, y, 2)$, de dos tipos: espectrales –tras la aplicación de un banco de filtros gaussianos, valores obtenidos a partir de los operadores de Sobel, hessiano, gaussiano y diferencia de gaussianos (DoG: *difference of gaussians*)– y estadísticas –usando la matriz de coocurrencia de nivel de gris (GLCM: *gray level co-occurrence matrix* [HSD73])– y, a continuación, se utiliza el clasificador C4.5 [Qui93] para obtener la máscara. En el segundo bloque, se realizan operaciones estructurales sobre dicha máscara: en primer lugar, se seleccionan las componentes 8-conexas mayores que un área umbral; en segundo lugar, se itera cada una con el fin de determinar si tiene estructura reticular –primero buscando agujeros más grandes que un valor umbral y a continuación comprobando las siguientes condiciones: si el porcentaje de área de dichos agujeros es mayor que un valor umbral y si el número de agujeros es mayor que un valor umbral, calculando además el valor total de agujeros; en tercer lugar, se lleva a cabo la diagnosis sobre si tiene o no estructura reticular a partir del número total de agujeros, comprobando si es mayor o no que un valor umbral y en caso positivo se genera la máscara de la red pigmentada. El método fue probado en un total de 220 imágenes, 100 con el patrón reticular y 120 con ausencia de dicho patrón, alcanzando unos resultados de 83,64 % de exactitud, 86 % de sensibilidad y 81,67 % de especificidad. Es éste un trabajo importante en el problema del reconocimiento del patrón reticular por sus buenos resultados.

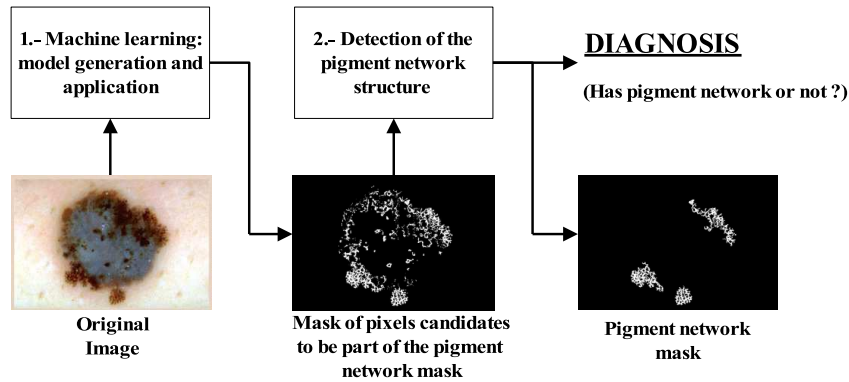


Figura 2.13: Visión de alto nivel del método propuesto por García-Arroyo y García-Zapirain 2014. Reimpreso con permisos de [GAGZ14].

Barhoumi y Baâzaoui 2014

En [BB14], Barhoumi y Baâzaoui presentan un algoritmo para la detección de la red pigmentada a partir de imágenes dermatoscópicas. Para ello, en primer lugar se utiliza el software Dullrazor [LNG⁺97] para detectar, eliminar y restaurar los pelos y posteriormente se realiza la segmentación. En segundo lugar, se transforma la imagen a gris seleccionando el canal de verde de RGB. En tercer lugar, se aplica un filtro laplaciano del gaussiano (LoG: *laplacian of gaussian*) que permite detectar agujeros de la red pigmentada y otras estructuras de la lesión, discriminando a continuación los agujeros de la red con respecto a otras estructuras ovaladas tales como glóbulos, puntos, burbujas y otras estructuras ovaladas utilizando una función de pertenencia gaussiana probabilística que permite la decisión difusa sobre las diferentes estructuras, a partir de la aplicación de un valor umbral establecido de manera empírica. A partir de estos agujeros se crea una estructura de grafo, de la cual se extraen la característica *Densidad*, correspondiente a la densidad del grafo y calculada de la siguiente manera: $Densidad = \frac{NE}{NN \cdot \log(LA)}$, siendo NA el número aristas, NN el número de nodos y LA el área de la lesión. El método fue probado en un total de 122 imágenes, 82 con el patrón reticular y 40 con ausencia de dicho patrón, alcanzando unos resultados de 0,821 de AUC y 85 % de exactitud.

2. ESTADO DEL ARTE

Machado et al. 2015

En [MPFP15], Machado et al. presentan un algoritmo para la detección de la red pigmentada a partir de imágenes dermatoscópicas. El método se aplica sobre subimágenes de tamaño 100×100 , que pueden tener o no el patrón reticular. Para ello, se realiza una transformación a la escala de grises seleccionando el canal que presenta una mayor entropía –tal y como se hace en [SNM⁺09, BMR12b]– y a continuación se extrae un conjunto de características de textura a partir de la matriz de coocurrencia de nivel de gris (GLCM: *gray level co-occurrence matrix* [HSD73]) y las máscaras de energía de Laws [Law80], realizando el proceso de aprendizaje supervisado con el algoritmo AdaBoost [FS95] en una forma adaptada según el trabajo [VJ04]. El método fue probado en un total de 228 subimágenes obtenidas de 55 imágenes, alcanzando unos resultados de 90,16 % de sensibilidad y 86,67 % de especificidad.

Machado et al. 2016

En [MPFP16], Machado et al. –del mismo grupo de investigación del trabajo anterior– presentan un nuevo método para la detección del patrón reticular, esta vez sobre imágenes completas. En el método no se realiza preprocesado ni segmentación, transformando en primer lugar la imagen a gris usando el canal con mayor entropía, al igual que en el trabajo comentado anteriormente de los mismos autores [MPFP15]. En segundo lugar, se utiliza la transformación *curvelet* [CDDY06], una técnica no adaptativa para la representación multiescala de objetos que es una extensión del concepto de ondículas (*wavelets*). En tercer lugar, para la descomposición de las imágenes se testean diferentes escalas, de las cuáles se seleccionan las 9 que dan mejores resultados. En cuarto lugar, a partir de cada una de dichas subbandas *curvelet* se calculan las siguientes características estadísticas: media, desviación estándar, energía, entropía y homogeneidad. Finalmente, en quinto lugar se realiza un proceso de aprendizaje supervisado utilizando el algoritmo AdaBoost [FS95] en una forma adaptada según el trabajo [VJ04] (al igual que en [MPFP15]). El método fue probado en un total de 90 imágenes, alcanzando unos resultados de 82,35 % de sensibilidad y 76,79 % de especificidad.

2.2.3.2 Técnicas utilizadas en los métodos de reconocimiento del patrón reticular

A continuación se describen las técnicas utilizadas en los trabajos del estado del arte relativos a la detección y caracterización del patrón reticular. Estas técnicas se han clasificado en dos categorías:

1. Procesamiento digital de imagen
2. Estadística o minería de datos

En el Cuadro 2.4 se muestran, por cada trabajo, las técnicas usadas en las diferentes tareas.

Cuadro 2.4: Técnicas usadas en los trabajos seleccionados para las diferentes tareas. En cada línea: Trabajo seleccionado, Tipo de técnica (PDI: Procesamiento Digital de Imagen y EMD: Estadística o Minería de Datos), *Tarea* y Técnicas (referenciadas, si es necesario).

| Trabajo seleccionado | Tipo | Tarea | Técnicas |
|---|------|--|---|
| Fischer et al. 1996 [FSG96] | PDI | <i>Transformación a escala de grises</i> | Transformación Karhunen-Loeve [GW08] |
| | PDI | <i>Mejora del contraste para la detección de la red</i> | Ecuilibración local de histograma |
| | PDI | <i>Eliminación del ruido</i> | Operaciones morfológicas a nivel de gris |
| | PDI | <i>Obtención de la red pigmentada</i> | Calcular valor umbral |
| Fleming et al. 1999 [FSCZ99] | PDI | <i>Transformación a la escala de grises</i> | Primer plano de la transformación de color CIE XYZ |
| | PDI | <i>Extracción de la red</i> | Algoritmo de detección de líneas curvas de Steger [Ste98] |
| | PDI | <i>Segmentación de los agujeros</i> | Modelo Lobregt-Viergever de <i>snakes</i> [LV95] |
| | EMD | <i>Análisis estadístico</i> | ANOVA. Función discriminante lineal |
| Caputo et al. 2002 [CPG02] | PDI | <i>Filtrado previo para eliminar el ruido</i> | Filtro de Wiener [Jai89] |
| | PDI | <i>Filtrado previo para mejorar la imagen</i> | Operación de estiramiento del histograma [Jai89] |
| | PDI | <i>Extracción de la estructura de red</i> | Técnicas de umbral adaptativo [Jai89] |
| | PDI | <i>Caracterización de la red</i> | Cálculo de indicadores estadísticos |
| | EMD | <i>Análisis estadístico</i> | Selección y aplicación de umbrales |
| Anantha et al. 2004 [AMS04] | PDI | <i>Transformación a la escala de grises</i> | $I_G(x, y) = 0,2989 I_{RGB}(x, y, 0) + 0,587 I_{RGB}(x, y, 1) + 0,114 I_{RGB}(x, y, 2)$ |
| | PDI | <i>Análisis de textura para obtener la red pigmentada</i> | Laws energy masks [Law80] |
| | PDI | <i>Análisis de textura para obtener la red pigmentada</i> | <i>Neighborhood GrayLevel Dependence Matrix</i> (NGLDM) [SW83] |
| | PDI | <i>Caracterización de la red</i> | Características estructurales |
| | EMD | <i>Análisis estadístico</i> | Selección y aplicación de umbrales |
| Grana et al. 2007 [GDP ⁺ 07] | PDI | <i>Detección de los puntos de la red</i> | Algoritmo de detección de líneas curvas de Steger [Ste98] |
| | EMD | <i>Selección de los mejores puntos pertenecientes a la red</i> | Análisis discriminante lineal de Fisher |
| | PDI | <i>Enlazar los puntos de la red</i> | Interpolación bilineal y operaciones morfológicas a nivel de gris |
| | PDI | <i>Validación de las mallas obtenidas</i> | Valores de área y de circularidad |
| | EMD | <i>Análisis estadístico</i> | Función discriminante lineal |

Continúa en la siguiente página

Cuadro 2.4 – Viene de la página anterior

| Trabajo seleccionado | Tipo | Tarea | Técnicas |
|---------------------------------------|------|---|---|
| Tanaka et al. 2008 [TTK+08] | PDI | <i>Discriminación entre homogéneo por una parte y globular y reticular por otra</i> | Características de: intensidad de histograma, estadística diferencial, densidad espectral extraídas a partir de la transformada de Fourier, matrices <i>run-length</i> [Tan98] y a partir de matrices de coocurrencia de nivel de gris (GLCM: <i>gray level co-occurrence matrix</i> [HSD73]) |
| | PDI | <i>Discriminación entre reticular y globular</i> | Matrices <i>run-length</i> usando intensidad, selección y aplicación de un valor umbral y obtención de componentes 8-conexas, a partir de las cuales se calculan características estructurales |
| | EMD | <i>Análisis estadístico</i> | Función discriminante lineal |
| Di Leo et al. 2008 [DLPS08] | PDI | <i>Transformación a la escala de grises</i> | No se reporta la fórmula utilizada |
| | PDI | <i>Obtener la red pigmentada atípica</i> | Método estructural, usando métodos morfológicos |
| | PDI | <i>Obtener la red pigmentada atípica</i> | Método basado en el análisis de Fourier, usando la transformada rápida de Fourier, filtros paso alto, transformada rápida de Fourier inversa y, finalmente, técnicas de umbral |
| | PDI | <i>Caracterización de la red</i> | Características cromáticas y espaciales |
| | EMD | <i>Generación del modelo</i> | Clasificador C4.5 [Qui93] |
| Serrano y Acha 2009 [SA09] | PDI | <i>Transformación a la escala de grises</i> | Transformación al espacio de color CIE Lab |
| | PDI | <i>Caracterización de patrones</i> | Campos aleatorios de Markov (MRF: <i>Markov random fields</i>) [Li01], siguiendo un modelo condicional simétrico finito (FSCM: <i>finite symmetric conditional model</i>) [KC83] |
| | EMD | <i>Análisis estadístico (seleccionado)</i> | Distribución normal multivariante, sin la asunción de la independencia interplanos |
| | EMD | <i>Análisis estadístico (no seleccionados)</i> | Distribución normal multivariante, con la asunción de la independencia interplanos, y k-vecinos más cercanos |
| Skrovseth et al. 2010 [SST+10] | PDI | <i>Caracterización de los pixels de la red pigmentada</i> | Medidas de textura (no se reporta cuales) |
| | EMD | <i>Análisis estadístico</i> | Clasificador lineal |
| Shrestha et al. 2010 [SBK+10] | PDI | <i>Obtención de la red pigmentada</i> | Matrices de coocurrencia de nivel de gris (GLCM: <i>gray level co-occurrence matrix</i> [HSD73]) |
| | PDI | <i>Caracterización de la red</i> | Características estructurales |
| | EMD | <i>Generación del modelo</i> | Seis clasificadores implementados en WEKA [The16a]: BayesNet, AD-Tree, DecisionStump, J48, NBTree y Random Forest |
| Sadeghi et al. 2011 [SRLA11] | PDI | <i>Transformación a la escala de grises</i> | Canal verde de RGB |
| | PDI | <i>Resaltar la red pigmentada</i> | Afilado con un filtro paso-alto |

Continúa en la siguiente página

Cuadro 2.4 – Viene de la página anterior

| Trabajo seleccionado | Tipo | Tarea | Técnicas |
|--|------|---|---|
| | PDI | Detección de la red pigmentada: capturar los cambios “claro-oscuro-claro” | Filtro laplaciano del gaussiano (LoG: <i>laplacian of gaussian</i>) |
| | PDI | Detección de la red pigmentada: estructura de grafo | Operaciones morfológicas sobre las componentes 8-conexas |
| | PDI | Detección de la red pigmentada: seleccionar las submáscaras | Búsqueda de los subgrafos ciclicos utilizando el algoritmo <i>iterative loop counting algorithm</i> (ILCA) [Kir14] |
| | PDI | Caracterización de la red | A partir de la estructura de grafo, cálculo de un “ratio de densidad” |
| | EMD | Decisión entre “Ausente” y “Presente” | Selección y aplicación de un valor umbral relativo al “ratio de densidad” |
| Sadeghi et al. 2010 [SRW⁺10] | PDI | Transformación a la escala de grises | Canal verde de RGB |
| | PDI | Resaltar la red pigmentada | Afilado con un filtro paso-alto |
| | PDI | Detección de la red pigmentada: capturar los cambios “claro-oscuro-claro” | Filtro laplaciano del gaussiano (LoG: <i>laplacian of gaussian</i>) |
| | PDI | Detección de la red pigmentada: estructura de grafo | Operaciones morfológicas sobre las componentes 8-conexas |
| | PDI | Detección de la red pigmentada: seleccionar las submáscaras | Búsqueda de los subgrafos ciclicos utilizando el algoritmo <i>iterative loop counting algorithm</i> (ILCA) [Kir14] |
| | PDI | Caracterización de la red | Características estructurales: relativas a la anchura de la red y los tamaños de los agujeros, así como sus variaciones en la lesión |
| | PDI | Caracterización de la red | Características geométricas: “ratio de densidad” y “ratio de irregularidad de agujeros” |
| | PDI | Caracterización de la red | Características cromáticas: a partir de los espacios de color RGB, HSV y CIE Lab |
| | PDI | Caracterización de la red | Características de textura: basadas en la matriz de coocurrencia de nivel de gris (GLCM: <i>gray level co-occurrence matrix</i>) [HSD73] |
| | EMD | Generación del modelo | Algoritmo LogitBoost [FHT ⁺ 00] |
| Gola et al. 2011 [GGM11b] | PDI | Transformación a la escala de grises | $I_G(x, y) = 1/3 I_{RGB}(x, y, 0) + 1/3 I_{RGB}(x, y, 1) + 1/3 I_{RGB}(x, y, 2)$ |
| | PDI | Detección de la red pigmentada | Métodos espectrales |
| | PDI | Detección de la red pigmentada | Algoritmo de detección de bordes de Canny [Can86] |
| | PDI | Refinamiento de la red pigmentada obtenida | Operaciones morfológicas |
| | PDI | Caracterización de la red | Características estructurales |
| | EMD | Análisis estadístico | Función discriminante lineal |
| Wighton et al. 2011 [WLL⁺11] | PDI | Caracterización de los pixels de la red pigmentada | Características de color, correspondientes al espacio CIE Lab |

Continúa en la siguiente página

Cuadro 2.4 – Viene de la página anterior

| Trabajo seleccionado | Tipo | Tarea | Técnicas |
|--|------|---|---|
| | PDI | <i>Caracterización de los pixels de la red pigmentada</i> | Características de textura espectrales correspondientes a la aplicación de filtros gaussianos y laplaciano del gaussiano (LoG: <i>laplacian of gaussian</i>) |
| | PDI | <i>Caracterización de la red</i> | Características estructurales |
| | EMD | <i>Generación del modelo</i> | Distribuciones gaussianas multivariantes. Método bayesiano máximo de la probabilidad a posteriori (MAP: <i>maximum a posteriori probability</i>) |
| Barata et al. 2012 [BMR12b] | PDI | <i>Transformación a la escala de grises</i> | Selección del canal RGB con mayor entropía |
| | PDI | <i>Detección de la red pigmentada</i> | Banco de filtros direccionales |
| | PDI | <i>Detección de la red pigmentada</i> | Métodos morfológicos |
| | PDI | <i>Caracterización de la red pigmentada</i> | Características estructurales |
| | EMD | <i>Generación del modelo</i> | Clasificador Adaboost [FS95] |
| Abbas et al. 2012 [ACF12] | PDI | <i>Transformación de espacio de color</i> | Transformación al espacio de color CIE Lab |
| | PDI | <i>Caracterización de la red pigmentada</i> | Características de color: porcentaje de ocurrencia y su grado de simetría, respecto a los 6 colores típicos que se presentan en las lesiones |
| | PDI | <i>Caracterización de la red pigmentada</i> | Características de textura basadas en marco discreto de ondículas (DWF: <i>discrete wavelet frame</i>) [Uns95] |
| | PDI | <i>Caracterización de la red pigmentada</i> | Características de textura basadas en patrón binario local (LBP: <i>local binary pattern</i>) [OPM02] |
| | EMD | <i>Generación del modelo</i> | Máquinas de vectores soporte multiclase (M-SVM: <i>multiclass support vector machines</i>) [WW99] |
| Abbas et al. 2013 (I) [ACFA13] | PDI | <i>Transformación de espacio de color</i> | Transformación al espacio de color CIE Lab |
| | PDI | <i>Caracterización de la red pigmentada</i> | Características de color: porcentaje de ocurrencia y su grado de simetría, respecto a los 6 colores típicos que se presentan en las lesiones |
| | PDI | <i>Caracterización de la red pigmentada</i> | Características de textura basadas en la transformada de Radon [KVRP10] y patrón binario local (LBP: <i>local binary pattern</i>) [OPM02] |
| | EMD | <i>Selección de características</i> | Selección secuencial flotante (SFFS: <i>sequential floating forward selection</i>) |
| | EMD | <i>Generación del modelo</i> | Máquinas de vectores soporte (SVM: <i>support vector machines</i>) |
| Abbas et al. 2013 (II) [ACS+13] | PDI | <i>Transformación de espacio de color</i> | Transformación al espacio de color CIE Lab |
| | PDI | <i>Caracterización de la red pigmentada</i> | Características de color: porcentaje de ocurrencia y su grado de simetría, respecto a los 6 colores típicos que se presentan en las lesiones |

Continúa en la siguiente página

Cuadro 2.4 – Viene de la página anterior

| Trabajo seleccionado | Tipo | Tarea | Técnicas |
|---|------|--|--|
| | PDI | Caracterización de la red pigmentada | Características de textura basadas en el algoritmo de transformación de pirámides orientables (SPT: <i>steerable pyramids transformation</i>) de descomposición, basado en descomposición de ondículas (<i>wavelets</i>) [FA91, SFAH92] |
| | EMD | Selección de características | Análisis de componentes principales (PCA: <i>principal component analysis</i>) |
| | EMD | Generación del modelo | AdaBoost.MC: extensión del algoritmo AdaBoost.MH [SS00] con salida multi-clase, implementando estrategias de máximo de la probabilidad a posteriori (MAP: <i>maximum a posteriori probability</i>) y ranqueo (<i>ranking</i>) |
| Sáez et al. 2014 [SSA14] | PDI | Transformación de espacio de color | Transformación al espacio de color CIE Lab |
| | PDI | Caracterización de patrones | Campos aleatorios de Markov (MRF: <i>Markov random fields</i>) [Li01], siguiendo un modelo condicional simétrico finito (FSCM: <i>finite symmetric conditional model</i>) [KC83] |
| | PDI | Caracterización de patrones | Características de textura basadas en el modelo gaussiano |
| | PDI | Caracterización de patrones | Características de textura basadas en un modelo gaussiano mixto |
| | PDI | Caracterización de patrones | Características de textura basadas en un modelo bolsa de características (BoF: <i>bag-of-features</i>) |
| | EMD | Generación del modelo | Algoritmo de k-vecinos más cercanos (kNN: <i>k-nearest neighbors</i>) |
| García-Arroyo y García-Zapirain 2014 [GAGZ14] | PDI | Caracterización de los pixels de la red pigmentada | Características de color basadas en los espacios de color RGB, rgb (RGB normalizado), HSV, CIE XYZ, CIE Lab y CIE Luv |
| | PDI | Caracterización de los pixels de la red pigmentada | Características de textura espectrales basadas en la aplicación de un banco de filtros gaussianos y posterior extracción de características a partir del operador de Sobel, gaussiano, diferencia de gaussianos (DoG: <i>difference of gaussians</i>) y operador hessiano |
| | PDI | Caracterización de los pixels de la red pigmentada | Características de textura espectrales basadas en la matriz de coocurrencia de nivel de gris (GLCM: <i>gray level co-occurrence matrix</i>) [HSD73] |
| | EMD | Generación del modelo para la selección de los pixels de la red pigmentada | C4.5 decision tree classifier [Qui93] |
| | PDI | Detección y caracterización de la estructura de red | Operaciones estructurales |
| | EMD | Decisión entre “Ausente” y “Presente” | Selección y aplicación de un valor umbral relativo al número de agujeros |
| Barhoumi et al. 2014 [BB14] | PDI | Transformación a la escala de grises | Canal verde de RGB |
| | PDI | Detección de agujeros de la red pigmentada y otras estructuras | Filtro laplaciano del gaussiano (LoG: <i>laplacian of gaussian</i>) |

Continúa en la siguiente página

Cuadro 2.4 – Viene de la página anterior

| Trabajo seleccionado | Tipo | Tarea | Técnicas |
|-------------------------------------|------------------------------|---|--|
| | PDI PDI EMD | <i>Discriminación entre agujeros y otras estructuras</i> <i>Caracterización de la red pigmentada</i> <i>Decisión entre “Ausente” y “Presente”</i> | Función de pertenencia gaussiana probabilística Creación de estructura de grafo y cálculo de un “ratio de densidad” Selección y aplicación de un valor umbral relativo al “ratio de densidad” |
| Machado et al. 2015 [MPFP15] | PDI PDI PDI EMD | <i>Transformación a la escala de grises</i> <i>Análisis de textura</i> <i>Análisis de textura</i> <i>Generación del modelo</i> | Selección del canal RGB con mayor entropía Basado en la matriz de coocurrencia de nivel de gris (GLCM: <i>gray level co-occurrence matrix</i>) [HSD73] Basado en las máscaras de energía de Law [Law80] Clasificador Adaboost [FS95] en una forma adaptada según el trabajo [VJ04] |
| Machado et al. 2016 [MPFP16] | PDI PDI PDI EMD | <i>Transformación a la escala de grises</i> <i>Descomposición de las imágenes en diferentes escalas</i> <i>Extracción de características de textura</i> <i>Generación del modelo</i> | Selección del canal RGB con mayor entropía Transformación <i>curvelet</i> [CDDY06] –extensión del concepto de ondículas (<i>wavelets</i>)–, seleccionando las 9 escalas que dan mejores resultados A partir de cada una de dichas sub-bandas <i>curvelet</i> se calculan las siguientes características estadísticas: media, desviación estándar, energía, entropía y homogeneidad Clasificador Adaboost [FS95] en una forma adaptada según el trabajo [VJ04] |

2. ESTADO DEL ARTE

Tal y como se puede observar, la mayoría de los trabajos incluyen las siguientes técnicas. En primer lugar, una transformación de la imagen a la escala de grises (utilizando diferentes espacios de color), realizándose sobre la imagen en gris un análisis de textura, junto con otros tipos de análisis, combinado en la mayoría de las ocasiones con operaciones morfológicas. En segundo lugar, sobre el resultado, en forma de máscara con la región candidata a ser la estructura reticular, se extraen diferentes características (incluyendo en la mayoría de las ocasiones operaciones morfológicas/geométricas/estructurales), para su caracterización sobre si tiene patrón reticular o no, o si, en caso de reticular, si éste es típico o atípico. Finalmente, en tercer lugar, los valores calculados alimentan un proceso de aprendizaje supervisado, que es tratado bien realizando una selección empírica de valores umbrales, bien utilizando una función estadística o bien un clasificador.

A grandes rasgos, este es el patrón general que siguen la mayoría de los trabajos. No obstante, tal y como se puede observar, difieren en las técnicas utilizadas al igual que también en los objetivos que se persiguen, tal y como se comentó en 2.2.2.1.

En la obtención de la estructura reticular se tienen técnicas de diferente tipo: color [DLPS08, SRLA11, WLL⁺11, ACF12, ACFA13, ACS⁺13, GAGZ14], detección de líneas [FSG96, FSCZ99, GDP⁺07, GGM11b, ACFA13], selección y aplicación de valores umbrales [FSG96, CPG02, TTK⁺08, DLPS08], características espectrales [TTK⁺08, DLPS08, SRLA11, SRW⁺10, GGM11b, WLL⁺11, BMR12b, GAGZ14, BB14], GLCM [SBK⁺10, SRW⁺10, GAGZ14, MPFP15], patrón binario local (LBP: *local binary pattern*) [ACF12, ACFA13], *snakes* [FSCZ99], máscaras de energía de Laws [AMS04, MPFP15], *Neighborhood GrayLevel Dependence Matrix* (NGLDM) [AMS04], campos aleatorios de Markov (MRF: *Markov random fields*) [SA09, SSA14], marco discreto de ondículas (DWF: *discrete wavelet frame*) [ACF12], transformación de pirámides orientables (SPT: *steerable pyramids transformation*) [ACS⁺13] y transformación *curvelet* [MPFP16].

En el tratamiento de la estructura reticular obtenida, casi todos los trabajos usan técnicas morfológicas. Como se ha comentado, el principal objetivo de la mayoría de los estudios es determinar si tiene patrón reticular o no y en caso afirmativo puede abordarse también la discriminación entre típica y atípica. Para ello, la mayoría de los trabajos incluyen una caracterización morfológica/geométrica/estructural de la estructura reticular [CPG02, AMS04, GDP⁺07, DLPS08, SBK⁺10, SRLA11, SRW⁺10, GGM11b, WLL⁺11, BMR12b, GAGZ14, BB14, MPFP15, MPFP16], y

en algunos casos realizando un mapeo a una estructura de grafo [SRLA11, SRW⁺10, BB14]. En algunos casos se usan características cromáticas en dicha caracterización [DLPS08, SRLA11, WLL⁺11, ACF12, ACFA13, ACS⁺13, SSA14, GAGZ14].

Respecto a los modelos estadísticos y de minería de datos generados, en algunos casos simplemente se obtienen unos valores umbrales que se utilizan en la decisión [CPG02, SRLA11, BB14], en otras ocasiones se usan funciones estadísticas [FSCZ99, GDP⁺07, TTK⁺08, SA09, SST⁺10, GGM11b, WLL⁺11] y, finalmente, en otros trabajos se utilizan clasificadores [DLPS08, SA09, SBK⁺10, SRW⁺10, BMR12b, ACF12, ACFA13, ACS⁺13, SSA14, GAGZ14, MPFP15, MPFP16].

2.2.3.3 Comparación de resultados obtenidos en los métodos de reconocimiento del patrón reticular

A continuación se presentan los resultados obtenidos en los diferentes métodos descritos, realizándose una comparación entre ellos. Los diferentes resultados obtenidos en cada uno de los estudios han sido categorizados como:

1. Reconocimiento del patrón reticular
2. Reconocimiento del patrón reticular atípico
3. Otros

Tal y como se verá a continuación los métodos seleccionados tratan, además de la propia obtención de la estructura reticular, el reconocimiento del patrón reticular (diferenciación entre “Ausente” y “Presente”) –que se engloban en la primera categoría–, el reconocimiento del patrón reticular atípico (diferenciación entre “Ausente” y “Típico” por un lado y “Atípico” por otro) –que se engloban en la segunda categoría– y, finalmente, hay métodos que únicamente se centran en la obtención de la estructura reticular, sin ofrecer resultados del problema de reconocimiento de patrones (reticular o reticular atípico), no mostrando resultados cuantitativos o bien presentando resultados de otro tipo –que se engloban en la tercera categoría–.

La información cuantitativa se suele mostrar en forma de datos de sensibilidad, especificidad, exactitud y algunas veces AUC sobre una base de datos previamente etiquetada. No obstante, tal y como se ha comentado, existen ocasiones en las que se añade información cuantitativa de otro tipo o, incluso, en muchos de los trabajos

2. ESTADO DEL ARTE

no se reportan resultados cuantitativos, aunque se han incluido aquí por el interés que tiene el diseño de sus algoritmos.

Respecto a la bondad de los métodos seleccionados, además de los datos numéricos existen otras variables a tener en cuenta. Uno de los más relevantes es el número de imágenes que se han utilizado, existen trabajos que tienen más imágenes y otros que tienen menos. Evidentemente, un algoritmo es más fiable cuando tiene más imágenes contra las que se ha testado.

Otras variables importantes son el número de fuentes de imágenes y la dificultad de éstas. En primer lugar, si las imágenes están extraídas de diferentes fuentes, con diferentes características, implica una mayor robustez frente a las diferentes condiciones de adquisición. En segundo lugar, cuando las imágenes elegidas para probar el método son de una mayor dificultad, esto también redundará en una mayor fiabilidad y robustez de éste. En el caso del número de fuentes ninguno de los trabajos especifica más de un número de fuentes (sólo en el caso de [SRW⁺10] se usan dos atlas diferentes para los tests, pero ambos son obtenidos de la misma fuente de datos, por lo que consideraremos como una única fuente), por tanto no se va a tener en cuenta estos datos en el análisis. La cuestión de la dificultad de las imágenes, además de que es evidentemente un tema difícil de objetivar, es un aspecto del cual apenas se da información en los trabajos, por lo que tampoco se tendrá en cuenta aquí.

En el Cuadro 2.5 se presenta un resumen de los resultados obtenidos en los diferentes trabajos descritos en el estado del arte, que como se puede comprobar son de muy diversos tipos.

Cuadro 2.5: Resultados numéricos obtenidos en los trabajos seleccionados. En cada línea: Trabajo seleccionado, Tipo de resultado (RPR: Reconocimiento del Patrón Reticular, RPRA: Reconocimiento del Patrón Reticular Atípico, OTR: Otro), *Resultado*, Número de imágenes y Resultados numéricos (EXA: Exactitud, SE: Sensibilidad, ES: Especificidad y AUC: *Area Under Curve*) con la descripción, si es necesario.

| Trabajo seleccionado | Tipo | Resultado | N | Resultados numéricos |
|---|-----------------------------|---|-----|--|
| Fischer et al. 1996 [FSG96] | No hay resultados numéricos | | | |
| Fleming et al. 1999 [FSCZ99] | OTR | <i>Media de anchuras de las líneas</i> | 69 | Nevos comunes: 6,72, Nevos displásicos: 7,03 y Melanomas: 8,58 |
| | OTR | <i>Media de áreas de los agujeros</i> | 69 | Nevos comunes: 251, Nevos displásicos: 308 y Melanomas: 345 |
| | OTR | <i>Discriminación entre nevus y melanoma</i> | 69 | 80 % EXA, usando valores de media de anchuras de las líneas y media de área de los agujeros |
| Caputo et al. 2002 [CPG02] | OTR | <i>Diferenciación entre red pigmentada típica y atípica</i> | 14 | 85,71 % EXA, en la diferenciación entre 7 típicos y 7 atípicos |
| Anantha et al. 2004 [AMS04] | OTR | <i>Tamaño óptimo de un texel para el reconocimiento de la red pigmentada</i> | 155 | 10 pixels (0,22 mm, con la resolución de las imágenes usadas) |
| | OTR | <i>Detección de la red pigmentada en subimágenes: discriminación entre no red pigmentada, red pigmentada parcial y red pigmentada total</i> | 155 | 80 % EXA en subimágenes de tamaño 64 × 64 |
| Grana et al. - 2007 [GDP ⁺ 07] | RPR | <i>Detección de la red pigmentada</i> | 100 | 82 % SE, 94 % ES y 88 % EXA |
| Tanaka et al. - 2008 [TTK ⁺ 08] | OTR | <i>Discriminación en subimágenes entre patrones globales reticular, globular y homogéneo</i> | 852 | 94 % EXA en 852 subimágenes |
| Di Leo et al. 2008 [DLPS08] | RPRA | <i>Detección de la red pigmentada atípica</i> | 173 | Más de 85 % SE y más de 85 % ES |
| Serrano y Acha 2009 [SA09] | OTR | <i>Discriminación en subimágenes entre patrones globales reticular, globular, empedrado, homogéneo y paralelo</i> | 100 | 86 % EXA en 100 subimágenes de tamaño 40 × 40 (20 por cada patrón) |
| | OTR | <i>Discriminación en subimágenes entre patrones reticular y otros: globular, empedrado, homogéneo y paralelo</i> | 100 | 90 % EXA in 100 subimágenes de tamaño 40 × 40 (20 por cada patrón) |
| Skrovseth et al. 2010 [SST ⁺ 10] | No hay resultados numéricos | | | |
| Shrestha et al. 2010 [SBK ⁺ 10] | OTR | <i>Tamaño óptimo de las matrices GLCM en la detección de red pigmentada</i> | 106 | 20 pixels (tamaño de texel de 0,2 mm, con la resolución de las imágenes usadas, aproximadamente 4-5 texels por mm) |

Continúa en la siguiente página

Cuadro 2.5 – Viene de la página anterior

| Trabajo seleccionado | Tipo | Output | N | Resultados numéricos |
|---|-----------------------------|--|-----|--|
| | OTR | Detección en subimágenes de la red pigmentada atípica: discriminación entre áreas RPA y no RPA | 106 | 95,4 % EXA en áreas (subimágenes) RPA y no RPA marcadas en las imágenes |
| Sadeghi et al. 2011 [SRLA11] | RPR | Detección de la red pigmentada | 500 | 94,3 % EXA |
| Sadeghi et al. 2010 [SRW ⁺ 10] | RPR | Detección de la red pigmentada | 436 | 93,3 % EXA |
| | RPRA | Detección de la red pigmentada atípica: discriminación entre “Ausente”, “Típica” y “Atípica” | 436 | 82,3 % EXA |
| Gola et al. 2011 [GGM11b] | RPR | Discriminación del patrón reticular | 150 | 90 % EXA (20 imágenes reticulares en la base de datos de imágenes) |
| Wighton et al. 2011 [WLL ⁺ 11] | No hay resultados numéricos | | | |
| Barata et al. 2012 [BMR12b] | OTR | Detección de pixels reticulares | 200 | 57,6 % SE y 85,4 % ES, respecto a las segmentaciones realizadas por expertos |
| | RPR | Detección de la red pigmentada | 155 | 91,1 % SE y 82,1 % ES |
| Abbas et al. 2012 [ACF12] | OTR | Discriminación entre patrones globales reticular y otros: globular, empedrado, homogéneo, cresta paralela y estrellado | 100 | 90 % SE, 93 % ES y 0,94 AUC |
| Abbas et al. 2013 (I) [ACFA13] | No hay resultados numéricos | | | |
| Abbas et al. 2013 (II) [ACS ⁺ 13] | OTR | Discriminación en subimágenes entre patrones globales reticular y otros: globular, empedrado, homogéneo, cresta paralela, estrellado y multicomponente | 350 | 87,11 % SE, 97,96 % ES y 0,981 AUC en 350 subimágenes de tamaño 450 × 450 |
| Sáez et al. 2014 [SSA14] | OTR | Discriminación entre patrones globales reticular, globular y homogéneo | 90 | 78,44 % EXA |
| | OTR | Discriminación entre patrones globales reticular y otros: globular y homogéneo | 90 | 75,33 % EXA |
| García-Arroyo y García-Zapirain 2014 [GAGZ14] | RPR | Detección de la red pigmentada | 220 | 86 % SE, 81,67 % ES y 83,64 % EXA |
| Barhoumi et al. 2014 [BB14] | RPR | Detección de la red pigmentada | 122 | 85 % EXA y 0,821 AUC |
| Machado et al. 2015 [MPFP15] | OTR | Detección en subimágenes del patrón reticular | 228 | 90,16 % SE y 86,67 % ES en 228 subimágenes de tamaño 100 × 100 |
| Machado et al. 2016 [MPFP16] | RPR | Detección de la red pigmentada | 90 | 82,35 % SE y 76,79 % ES |

2.2 Estado del arte a nivel tecnológico

Tal y como se puede observar, existen algunos trabajos que no tienen resultados numéricos [FSG96, SST⁺10, WLL⁺11, ACFA13]. Se han incluido en este trabajo debido a que proponían algoritmos innovadores, de interés para el estado del arte. No obstante, el hecho de no presentar resultados cuantitativos implica que son métodos de los cuáles no se puede asegurar que tengan una buena fiabilidad y robustez.

Algunos resultados no son propiamente acerca del reconocimiento de patrones reticular o reticular atípico. En [FSCZ99] el trabajo se centra en buscar las características de las estructuras reticulares (obtienen como las más relevantes la media de anchuras de las líneas y la media de áreas de los agujeros) y en cómo a partir de éstas se discrimina entre nevo y melanoma. En [CPG02] se discrimina entre red pigmentada típica y atípica, aunque no lo categorizamos como reconocimiento de patrón reticular atípico ya que no existen imágenes donde no hay patrón reticular. Los estudios [TTK⁺08, SA09, ACF12, ACS⁺13, SSA14] discriminan entre diferentes patrones globales (reticular, globular y homogéneo en [TTK⁺08], reticular, globular, empedrado, homogéneo y paralelo en [SA09], reticular, globular, empedrado, homogéneo, cresta paralela y estrellado en [ACF12], reticular, globular, empedrado, homogéneo, cresta paralela, estrellado y multicomponente en [ACS⁺13] y reticular, globular y homogéneo en [SSA14]), usando en [TTK⁺08, SA09, ACS⁺13] subimágenes con estos patrones y en [ACF12, SSA14] imágenes completas. En los trabajos [AMS04, MPFP15] se realiza la detección de red pigmentada y en [SBK⁺10] de red pigmentada atípica, en ambos casos sobre subimágenes. Finalmente, los estudios [AMS04, SBK⁺10] obtienen la medida óptima del texel para realizar el reconocimiento del patrón reticular usando análisis de texturas, obteniendo ambos resultados similares.

Respecto a los trabajos cuyo objetivo es el reconocimiento del patrón reticular [GDP⁺07, SRLA11, SRW⁺10, GGM11b, BMR12b, GAGZ14, BB14, MPFP16], en el Cuadro 2.6 se presenta una tabla resumen con los resultados de los trabajos en el que se centra la atención en los tamaños de las base de datos de imágenes empleadas y los resultados obtenidos para analizar la fiabilidad de los diferentes métodos:

Teniendo en cuenta el número de imágenes y los resultados numéricos, podemos considerar como métodos más fiables del estado del arte [SRLA11, SRW⁺10, BMR12b, GAGZ14]. Todos ellos tienen altos índices de fiabilidad y han sido pro-

2. ESTADO DEL ARTE

| Trabajos | # Imágenes | Resultados |
|--|------------|--------------------------------------|
| Grana et al. 2007 [GDP ⁺ 07] | 100 | 82 % SE 94 % ES 88 % EXA |
| Sadeghi et al. 2011 [SRLA11] | 500 | 94,30 % EXA |
| Sadeghi et al. 2010 [SRW ⁺ 10] | 436 | 93,30 % EXA |
| Gola et al. 2011 [GGM11b] | 150 | 90 % EXA |
| Barata et al. 2012 [BMR12b] | 200 | 91,1 % SE 82,1 % ES |
| García-Arroyo y García-Zapirain 2014 [GAGZ14] | 220 | 86 % SE 81,67 % ES 83,64 % EXA |
| Barhoumi et al. 2014 [BB14] | 122 | 85 % EXA 0,821 AUC |
| Machado et al. 2016 [MPFP16] | 90 | 82,35 % SE 76,79 ES |

Cuadro 2.6: Resultados de los trabajos más relevantes en el reconocimiento del patrón reticular (EXA: Exactitud, SE: Sensibilidad, ES: Especificidad y AUC: *Area Under Curve*).

bados sobre bases de datos de de un mínimo de 200 imágenes completas. El principal problema de [GGM11b] es el bajo número de imágenes reticulares (20 imágenes) y el problema de [GDP⁺07, BB14, MPFP16] es el número de imágenes. En el estudio [BMR12b] el modelo se ha contrastado, además de contra el etiquetado de las imágenes, respecto a las segmentaciones realizadas por expertos, obteniéndose buenos resultados en la detección de pixels reticulares.

Respecto a los trabajos cuyo objetivo es el reconocimiento del patrón reticular atípico [SBK⁺10, SRW⁺10], el Cuadro 2.7 presenta un resumen de los resultados de los trabajos de detección de la red pigmentada atípica, en el se centra la atención en los tamaños de las base de datos de imágenes empleadas y los resultados

obtenidos, para analizar la fiabilidad de los diferentes métodos:

| Trabajos | # Imágenes | Resultados |
|--------------------------------|------------|--------------------|
| Di Leo et al. 2008 [DLPS08] | 173 | 85 % SE 85 % ES |
| Barata et al. 2012 [BMR12b] | 436 | 82,3 EXA |

Cuadro 2.7: Resultados de los trabajos más relevantes en el reconocimiento del patrón reticular atípico (EXA: Exactitud, SE: Sensibilidad, ES: Especificidad y AUC: *Area Under Curve*).

Teniendo en cuenta el número de imágenes y los resultados numéricos, podemos considerar ambos trabajos como métodos fiables del estado del arte [DLPS08, SRW⁺10], ya que tienen altos índices de fiabilidad y han sido probados sobre bases de datos de un mínimo de 173 imágenes completas.

2.2.4 Software para el desarrollo de los algoritmos de procesamiento digital de imagen

En el desarrollo de algoritmos complejos una de las decisiones más relevantes es la elección del software que se va a utilizar para su implementación, que debe cumplir una serie de características deseables, que se mostrarán aquí. A continuación se describirán las tecnologías software más relevantes que existen en la actualidad para el procesamiento digital de imagen con el fin de mostrar las posibles alternativas existentes que se han tenido en cuenta en esta investigación. En relación a las mencionadas características deseables se toma la decisión, que se explicará en 4.4.

2.2.4.1 Características

Las características deseables que deben cumplir una tecnología software para el desarrollo de algoritmos de procesamiento digital de imagen son:

- Ser de uso gratuito o bien existir licencias pagadas por la Universidad para labores de docencia e investigación.
- Tener muchas funcionalidades de imagen.

2. ESTADO DEL ARTE

- Ser fácilmente integrable con otras librerías de imagen, minería de datos, estadística, ...
- Permitir desarrollar con facilidad los algoritmos y los experimentos sobre los algoritmos.
- Que exista un conocimiento previo o *background* en el grupo de investigación.
- Estar en un lenguaje de programación serio.
- Existir un IDE serio para realizar los desarrollos en dicho lenguaje de programación.
- Ser fácilmente integrable en aplicaciones y plataformas software.
- Escalar fácilmente a una arquitectura paralela.

2.2.4.2 CVIPtools

CVIPtools (*Computer Vision and Image Processing Tools*) [SIU14, Umb10] es una herramienta software libre para el procesamiento digital de imagen, desarrollado por la Southern Illinois University Edwardsville (SIUE). Es compatible únicamente con Windows (en anteriores versiones también se soportaba en UNIX), siendo su versión más reciente CVIPtools 5.5d.

CVIPtools soporta múltiples funciones de procesamiento digital de imagen y el desarrollo de algoritmos automatizados, bien utilizando un lenguaje batch propietario, o bien utilizando los lenguajes de programación C/C++ y C# e invocando a las DLLs. Además contiene dos potentes herramientas de desarrollo: CVIP-ATAT (*Algorithm Test and Analysis Tool*), que permite el testeo y análisis de algoritmos, y CVIP-FEPC (*Feature Extraction and Pattern Classification*), que permite la extracción de características y posterior reconocimiento de patrones.

2.2.4.3 OpenCV

OpenCV (*Open Computer Vision*)[Ope14b, Ope14a] es una librería software libre de visión artificial originalmente desarrollada por Intel, que actualmente es gestionada por la OpenCV Foundation. Está soportada para Windows, Linux, Mac OS,

iOS y Android. OpenCV está construida en C/C++, siendo éste el lenguaje de programación en el que se suele desarrollar el software que usa OpenCV. No obstante, también tiene interfaces para Python y Java, que permiten desarrollos con estos lenguajes, aunque en este caso la integración no se realiza de manera tan natural.

OpenCV es probablemente la librería con mejores prestaciones en visión artificial ya que tiene un API muy extensa, está muy testado por la gran cantidad de desarrollos que soporta y tiene un código muy optimizado para aplicaciones que necesiten una buena eficiencia.

2.2.4.4 PIL (Python Imaging Library)/Pillow

PIL (*Python Imaging Library*) [Fre14] es una librería software libre para el procesamiento digital de imagen que permite el desarrollo de algoritmos de procesamiento digital de imagen en el lenguaje de programación Python [Pyt14], un lenguaje de programación de última generación de tipo multiparadigma, en el que aparecen los paradigmas de la programación orientada a objetos, la programación imperativa y la programación funcional, para conformar un lenguaje de programación de muy alto nivel. Pillow [Fre14] es la librería heredera de PIL, que actualmente está incluida en el API de la última versión de Python.

Además de la potencia del Python como lenguaje, el desarrollo de algoritmos con PIL/Pillow tiene la gran ventaja de poder utilizar SciPython [Sci14] un ecosistema software orientado al desarrollo de software científico con múltiples funcionalidades en los campos de las matemáticas, ciencia e ingeniería.

2.2.4.5 Matlab

Matlab [Mat14b] es un lenguaje de programación imperativo (aunque se le han añadido características de programación orientada a objetos), integrado en un IDE propietario con una extensa API de funciones matemáticas y con gran número de utilidades para el desarrollo de algoritmos científicos. Las diferentes funcionalidades y utilidades están incluidas en diferentes toolboxes, entre ellos el Image Processing Toolbox [Mat14a], especialmente orientado al desarrollo de algoritmos de procesamiento digital de imagen.

El entorno Matlab es uno de los más utilizados en el ámbito universitario para el desarrollo de los algoritmos de imagen. La principal razón es el gran número

2. ESTADO DEL ARTE

de funcionalidades matemáticas y utilidades implementadas, integradas en un mismo entorno, que además están implementadas de manera eficiente, con un costo computacional optimizado. Otro importante factor favorable a su utilización es el hecho de que Matlab se suele aprender por los alumnos a lo largo de los estudios, lo que hace sea un lenguaje en el que los investigadores ya se encuentran familiarizados. Por ello, existen numerosas funciones de Matlab desarrolladas por la comunidad universitaria accesibles vía web.

2.2.4.6 Java Advanced Imaging (JAI)

Java Advanced Imaging (JAI) [Sun14, jav16] es una librería de software libre Java, extensión del API estándar de Java [Ora15a], desarrollada por Sun Microsystems (ahora propiedad de Oracle), para el procesamiento digital de imagen.

Uno de los mayores problemas que tiene esta librería es que, aunque oficialmente está en evolución, en la práctica lleva varios años sin evolucionar de manera significativa. No obstante, el tener gran número de funcionalidades y el hecho de estar programado en Java ha posibilitado que hayan sido numerosos los proyectos de éxito desarrollados con este framework y que pueden ser utilizados en una aplicación que utilice esta librería.

2.2.4.7 ImageJ

ImageJ [US 16] es una herramienta software para el procesamiento digital de imagen desarrollada por el US National Institute of Health (NIH). Está escrita en Java y provee de un lenguaje propietario tipo batch para el desarrollo de algoritmos, aunque también es posible vía API el desarrollo de aplicaciones Java utilizando sus funcionalidades.

Aunque el framework ImageJ original tiene ciertamente muchas deficiencias desde el punto de vista de la orientación a objetos y el diseño de patrones software, el haber sido durante años una de las pocas herramientas libres para el procesamiento digital de imagen, el estar escrito en Java y el permitir la fácil escalabilidad mediante un sistema de plugins ha posibilitado que existan numerosas funcionalidades complejas desarrolladas para este framework. De hecho, en el año 2014 se ha presentado la nueva versión ImageJ v2 [Ima16], actualmente en estado beta, que mejora las deficiencias de diseño de la anterior y provee de gran número de nuevas

funcionalidades. Otra versión de gran relevancia es Fiji [Fij16b], una extensión de ImageJ y compatible con ImageJ e ImageJ v2, que está orientada al uso en ciencias naturales y que también provee de gran número de funcionalidades.

2.2.5 Conclusiones. Justificación de la necesidad desde el punto de vista tecnológico

En las conclusiones correspondientes al estado del arte a nivel médico 2.1.4 se justificaba desde el punto de vista médico la necesidad de abordar la automatización del diagnóstico sobre imágenes dermatoscópicas.

Dentro de la presentación del estado del arte a nivel tecnológico, en 2.2.1 –correspondiente a la contextualización de la presente investigación– se afina aún más, explicando en 2.2.1.3 –correspondiente al objetivo y alcance de la presente investigación– que son problemas vigentes a nivel científico, además de la propia automatización del diagnóstico de melanoma, los subproblemas que lo componen, correspondientes a las diferentes tareas de su ciclo de vida, explicando en dicho contexto el objetivo de la investigación (presentado anteriormente en 1.3): diseñar y desarrollar una familia de algoritmos de procesamiento digital de imagen para la segmentación de la lesión y la detección y caracterización de diferentes indicadores, centrándose especialmente en los patrones dermatoscópicos, de cara a ser integrados en un sistema software para el diagnóstico de melanoma basado en alguno de los algoritmos médicos para el diagnóstico de melanoma, en este caso la “Regla del ABCD”.

De hecho, tal y como se comentaba en el capítulo 1 de introducción (en 1.1), en los últimos años se están realizando a nivel mundial intentos muy serios de realizar progresos importantes en estas cuestiones, como la creación por parte de la *International Society for Digital Imaging of the Skin* (ISDIS) del proyecto *International Skin Imaging Collaboration* (ISIC) para el avance colaborativo en el desarrollo de métodos de imagen para la detección de problemas de piel –y en particular la detección de melanoma– en el cual trabajan profesionales de diferentes disciplinas, especialmente expertos dermatólogos e ingenieros de imagen que, entre otras contribuciones, ha elaborado el Archivo ISIC [Int16] –una gran base de datos de imágenes dermatoscópicas diagnosticadas por expertos dermatólogos, accesible de manera libre– y ha organizado dos grandes retos, en 2016 [GCC⁺16] y en 2017

2. ESTADO DEL ARTE

[Int17], entre equipos de investigación de todo el mundo –en el que por cierto, tal y como se explicará en 6.3.4.4 y 6.3.4.5, ha participado el equipo de investigación integrado por el doctorando y la directora de la presente tesis, obteniendo buenos resultados– para la solución de diferentes problemas relacionados con la detección automatizada de melanoma, correspondientes a las diferentes tareas de su ciclo de vida.

Por tanto, se justifica desde el punto de vista científico-tecnológico la realización de la presente investigación.

Hay tres principales medios de adquirir conocimiento: la observación de la naturaleza, la reflexión y la experimentación. La observación recoge datos, la reflexión los combina; la experimentación verifica el resultado de esa combinación.

Denis Diderot

CAPÍTULO

3

Base de datos

En este capítulo se presenta la base de datos empleada para el diseño y desarrollo de los algoritmos, así como para su evaluación. En primer lugar, se analizan las características que debe cumplir la base de datos. En segundo lugar, se explican las fuentes utilizadas para su construcción. En tercer lugar, se describe el diseño de la base de datos. Finalmente, en cuarto lugar, se realizan algunas consideraciones de importancia relativas a su etiquetado.

3.1 Características que debe cumplir la base de datos

Tanto para la realización del diseño y desarrollo de los algoritmos como para su evaluación es necesario disponer de una buena base de datos de imágenes. Dicha base de datos debería cumplir las siguientes características:

1. Para su diseño y construcción se cuenta con la participación de expertos dermatólogos.
2. La calidad de las imágenes es buena y de características similares a las que se tiene en real.
3. Existe un alto número de imágenes, con diferentes casuísticas.

3. BASE DE DATOS

La base de datos construida en la presente investigación cumple estas características, como se verá a continuación.

3.2 Fuentes utilizadas en su construcción

Para la construcción de la base de datos se ha utilizado como fuente de imágenes el Atlas Interactivo de Dermatoscopia de Argenziano et al. 2000 [ASP⁺00]. Es un atlas con más de 2500 imágenes dermatoscópicas recopiladas en diferentes hospitales del mundo por un grupo de expertos dermatólogos, liderados por G. Argenziano y H.P. Soyer, dos de los mayores expertos en dermatoscopia a nivel mundial, siendo el primero el autor principal del algoritmo médico para el diagnóstico de melanoma “Lista de los 7 puntos” [AFC⁺98], explicado en 2.1.3.8. Entre las imágenes incluidas están las imágenes que fueron analizadas en el Consensus Net Meeting del año 2000 [ASCA03], comentado en 2.1.3.10.

Las imágenes han sido capturadas usando dermatoscopios de iluminación de contacto y de luz polarizada. Tienen un tamaño de 768×512 pixels y aumento de 10x, con una resolución de 72 ppp (pixels por pulgada). Están comprimidas en formato JPG, utilizando para ello compresión de calidad máxima.

Esta es la fuente de datos más importante a nivel mundial en este campo. La mayoría de las investigaciones más relevantes de reconocimiento de patrones dermatoscópicos del estado del arte, ya comentadas, han sido realizadas con esta base de datos, en particular los principales estudios del estado del arte en el reconocimiento del patrón reticular [DLPS08, SRLA11, SRW⁺10, BMR12b, GAGZ14].

3.3 Diseño de la base de datos

En el Atlas Interactivo de Dermatoscopia las imágenes están clasificadas de acuerdo a las siguientes patologías: 1. Carcinoma basocelular; 2. Nevus azul; 3. Nevus de Clark; 4. Nevus combinado; 5. Nevus congénito; 6. Nevus dermal; 7. Dermatófibroma; 8. Lentigo; 9. Melanoma in situ; 10. Melanoma (menos de 0,76 mm); 11. Melanoma (0,76 mm - 1,5 mm); 12. Melanoma (más de 1,5 mm); 13. Melanoma metastático; 14. Melanosis; 15. Misceláneo; 16. Nevus recurrente; 17. Nevus de Reed/Spitz; 18. Queratosis seborreica; 19. Lesión vascular. Estas patologías han sido diagnosticadas por expertos dermatólogos teniéndose que, en el caso de las

lesiones dudosas y malignas, existe una validación de tipo histopatológico.

Para muchas de las imágenes también existen diagnósticos realizados por expertos respecto a los métodos médicos de “Análisis de Patrones” [PSW87] –explicado en 2.1.3.5–, “Regla del ABCD” [SAC94] –explicado en 2.1.3.6– y “Lista de los 7 puntos” [AFC⁺98] –explicado en 2.1.3.8–. También existen diagnósticos respecto al reconocimiento de los patrones dermatoscópicos. Sobre este conjunto de datos se han seleccionado diferentes subconjuntos para el diseño, desarrollo y evaluación de diferentes algoritmos.

En el caso del patrón reticular, cuyo algoritmo de reconocimiento se presenta de manera detallada en este documento, se tienen los siguientes campos para cada imagen: “ausente” y “presente”. Sobre este conjunto de datos se seleccionaron al azar un subconjunto de 875 imágenes, 326 “ausente” y 549 “presente”, correspondiendo aproximadamente esta distribución de imágenes a los porcentajes de ambas clases en el propio atlas [ASP⁺00]. Este subconjunto de imágenes conforma la base de datos utilizada para el diseño, desarrollo y evaluación del algoritmo de reconocimiento del patrón reticular.

Finalmente, tal y como se explicará más adelante en 4.2.4, y aunque el algoritmo de reconocimiento del patrón reticular no necesita de una segmentación previa, por cuestiones de método –este algoritmo está pensado para ser integrado en un sistema de detección automatizada de melanoma en el que se realiza la segmentación antes de la detección y caracterización de los diferentes indicadores– se parte de una imagen con la lesión segmentada. El autor de este método ha desarrollado un algoritmo de segmentación que presenta muy buenos resultados, que se muestra en 6.2.5, no obstante, también por cuestiones de método, con el fin de aislar el comportamiento del algoritmo de reconocimiento del patrón reticular con respecto a los posibles errores que pudiese tener el método de segmentación, se ha tomado la decisión de realizar una segmentación manual de las imágenes. Dicha segmentación ha sido realizada por el autor de esta tesis con la orientación y validación de los expertos médicos que colaboraron en esta investigación –además del cotejo con las segmentaciones realizadas y publicadas por otros grupos de investigación de las imágenes correspondientes al atlas público utilizado [ASP⁺00]– y como resultado se han generado 875 máscaras.

3. BASE DE DATOS

3.4 Consideraciones sobre el etiquetado

El etiquetado de la base de datos está realizado por expertos dermatólogos de gran prestigio. No obstante, en algunas clasificaciones, por ejemplo en el caso de los patrones dermatoscópicos el etiquetado tiene cierto grado de subjetividad. De hecho, en el mayor experimento de validación realizado hasta la fecha, el Consensus Net Meeting of 2000 [ASCA03] –comentado en 2.1.3.10–, en el que se evaluaron un total de 108 lesiones dermatoscópicas por parte de 40 expertos dermatólogos, se constató una considerable variabilidad inter e intra-observador en las diagnósticos realizadas relativas a los patrones dermatoscópicos.

En general, cuando se realiza un sistema de reconocimiento de patrones la decisión del sistema se valida contra un etiquetado, usando normalmente técnicas de aprendizaje supervisado. Por ejemplo, si el etiquetado fuese relativo a la presencia o no de melanoma, habiéndose realizado una diagnóstico histopatológica –es decir, realizando las biopsias–, este etiquetado sería totalmente objetivo y la subjetividad sería nula. Sin embargo, en el caso del presente sistema la validación se realiza frente a un etiquetado con cierto grado de subjetividad, y esto hay que tenerlo en cuenta en el diseño, desarrollo y evaluación del sistema. Sobre este tema se volverá en el capítulo de diseño del sistema –en 4.1.2.2– y en el capítulo de resultados –en 5.3–.

Si no lo puedes explicar con simplicidad, es que no lo entiendes bien.

Albert Einstein

CAPÍTULO

4

Diseño del Sistema

Este capítulo, en el que se presenta el diseño del sistema, es el más importante del presente documento, ya que es aquí donde se encuentran las principales aportaciones. Para ello, en primer lugar, se explica el nuevo enfoque metodológico introducido en el presente trabajo y se muestra la especificación del sistema. En segundo lugar, se presenta el diseño de alto nivel del algoritmo, explicando a grandes rasgos sus dos módulos principales. En tercer lugar, se muestra el diseño de bajo nivel, explicando en detalle dichos módulos y cada una de las fases que los componen. Finalmente, en cuarto lugar, se presenta el *framework* software utilizado para el desarrollo. Junto con la explicación detallada de las diferentes tareas del algoritmo se realiza una breve explicación teórica de los conceptos más relevantes utilizados.

4.1 Especificación

4.1.1 Nuevo enfoque metodológico, una aportación de la presente tesis

Tal y como se vio en el capítulo del estado del arte, en la sección de los antecedentes tecnológicos 2.2, en la gran mayoría de los trabajos del estado del arte que

4. DISEÑO DEL SISTEMA

tratan el reconocimiento de patrones sobre imágenes dermatoscópicas se parte de la descripción médica, sin realizar una adecuada traducción al área de la ingeniería. Sin tener que llegar al extremo de tener que utilizar un lenguaje de especificación difusa [SHB⁺08], sí que se echa de menos una descripción más formal, en la que se establezca de manera rigurosa qué se pretende hallar, ya que en la mayoría de las ocasiones hay que deducir del diseño del sistema qué es lo que quería hacer el autor. Una cosa es lo que dicen los libros de medicina, otra es lo que interpretan los expertos médicos y, finalmente, otra muy diferente es la especificación formal de lo que busca el algoritmo, susceptible de ser posteriormente parametrizado, que es de lo que se debe de partir para su diseño.

Al hilo de las carencias metodológicas observadas en los trabajos de este tipo, se presenta un nuevo enfoque metodológico que pretende convertirse en referencia para futuros estudios de reconocimiento de patrones sobre imágenes dermatoscópicas, aplicable también a problemas similares en otros tipos de imágenes. Este nuevo enfoque metodológico es una de las contribuciones realizadas en este trabajo e introduce la especificación del sistema como tarea obligatoria antes de su diseño y desarrollo, dentro del ciclo de vida de construcción del sistema de reconocimiento del patrón dermatoscópico, siendo esta especificación la base para la realización de un proceso de parametrización –en forma de parámetros configurables (con sus rangos de valores) y valores umbrales establecidos– en el que se sustenta el diseño y desarrollo del algoritmo y la realización de los experimentos.




Figura 4.1: Nuevo enfoque metodológico para la realización de un sistema de reconocimiento de un patrón dermatoscópico, en el que se introduce la especificación del sistema, que permite su posterior parametrización, como tarea obligatoria antes de su diseño y desarrollo dentro del ciclo de vida de construcción del sistema.

Tal y como se puede ver en la Fig. 4.1, en primer lugar, se comienza con la definición del patrón, tal y como aparece en los libros de medicina. En segundo

lugar, sobre la base de esta definición se realiza un proceso de traducción a un lenguaje más formal, a partir del estudio exhaustivo de las imágenes dermatoscópicas de la base de datos –es decir la diferente casuística existente–, la información proveniente de los expertos dermatólogos y la clasificación de las imágenes por éstos realizada, con vistas a realizar la objetivación. Una vez realizado esto, se lleva a cabo la especificación del sistema de reconocimiento de patrones, en el presente trabajo en forma de conjunto de requisitos escritos en lenguaje natural estructurado. Lo cual permite una posterior parametrización –en forma de parámetros configurables (con sus rangos de valores) y valores umbrales establecidos–. Sobre la base de esta especificación, en tercer lugar se diseñan y desarrollan los algoritmos y, a continuación, en cuarto y último lugar, se realizan las pruebas o experimentos para la validación del sistema. Además, hay que reseñar que, tal y como se puede ver, no se trata de un modelo en cascada estricto, sino que se trata de un modelo de tipo iterativo, en el que el sistema se va refinando yendo de adelante hacia atrás en diferentes iteraciones.

A continuación se muestra la especificación realizada para el patrón red pigmentada. En primer lugar, en 4.1.2, se explica el estudio del patrón para su objetivación y, en segundo lugar, en 4.1.3, se muestra la especificación del sistema.

4.1.2 Estudio del patrón para su objetivación

En este subapartado se va a estudiar el patrón para su objetivación, a partir de la definición del patrón y el estudio de las imágenes y su etiquetado por parte de los expertos, de cara a la realización de la especificación del sistema en 4.1.3. En primer lugar, en 4.1.2.1, se estudia la descripción o caracterización del patrón, en segundo lugar, en 4.1.2.2, se realiza una discusión sobre el etiquetado y la influencia que tiene la subjetividad en el mismo y, en tercer lugar, en 4.1.2.3, se tratan algunos de los elementos distorsionadores que, si bien normalmente no dificultan al experto humano en el diagnóstico, sí son una fuente de problemas para el sistema automatizado.

4.1.2.1 Estudio de la descripción o caracterización del patrón red pigmentada

Se partirá de la definición dada en 2.1.3.9, en la que se define este patrón de la siguiente manera:

4. DISEÑO DEL SISTEMA

El patrón red pigmentada o retículo pigmentado o reticular es una red de líneas de color marrón o negro sobre un fondo marrón más claro. El típico es aquél con una red homogénea con líneas finas y orificios pequeños, mientras que el atípico tiene líneas gruesas y más oscuras, siendo además heterogéneo e irregular, con orificios de distintos tamaños.

Junto con la definición del patrón red pigmentada se muestran los ejemplos. Tal y como se ha comentado en el capítulo 3, las imágenes con la presencia de este patrón han sido etiquetadas con la categoría de “presente” y las imágenes sin la presencia de dicho patrón han sido etiquetadas con la categoría de “ausente” por parte de expertos dermatólogos. Éstas son las categorías que nos interesan aquí.

Ejemplos claros de imágenes con la categoría de “presente” se tienen en la Fig. 4.2, mientras que ejemplos claros de imágenes con la categoría de “ausente” se tienen en la Fig. 4.3.

Menos clara es la visualización de la presencia o no presencia del patrón en imágenes de otro tipo. Por ejemplo, en la Fig. 4.4 se muestran 4 ejemplos de imágenes categorizadas como “presente” en los que la estructura tiene bajo contraste y la red es muy tenue, y además en la última de ellas hay muy pocos agujeros.



Figura 4.2: Dos ejemplos claros de presencia del patrón red pigmentada (con la categoría de “presente”).




Figura 4.3: Dos ejemplos claros de no presencia del patrón red pigmentada (con la categoría de “ausente”).




Figura 4.4: Cuatro ejemplos de imágenes categorizadas con patrón red pigmentada (categorizadas como “presente”) en los que la estructura tiene bajo contraste y la red es muy tenue, además en la última de ellas hay muy pocos agujeros.

4. DISEÑO DEL SISTEMA

4.1.2.2 Consideraciones sobre el etiquetado de la base de datos y la influencia de la subjetividad sobre el mismo

Cuando se realiza un sistema de reconocimiento de patrones la decisión del sistema se valida contra un etiquetado, usando normalmente técnicas de aprendizaje supervisado. Este etiquetado previo puede tener o no tener subjetividad, y en caso de que la tenga ésta puede ser de mayor o menor grado. Si el etiquetado fuese, por ejemplo, para la presencia o no de melanoma, una diagnosis histopatológica (es decir, realizando las biopsias), sería totalmente objetivo y la subjetividad sería nula. Sin embargo, en el caso del presente sistema, la validación se realiza frente a etiquetado con cierto grado de subjetividad, ya que se trata de valoraciones relativas al patrón dermatoscópico red pigmentada realizadas por expertos humanos.

De hecho, en el propio Consensus Net Meeting del año 2000 [ASCA03], comentado en 2.1.3.10, en algunas de las imágenes, se constató cierta variabilidad inter e intraobservador en el diagnóstico de los patrones.

En línea con lo anterior, existen algunas imágenes en las cuáles es muy difícil discernir el patrón, incluso para el experto humano y, además, debido a la subjetividad en la valoración por parte de los expertos, existen incluso algunas “imágenes frontera” en las que, aunque el sistema funcione bien, pueda existir un diagnóstico incorrecto respecto al etiquetado previo. Por ejemplo, en la Fig. 4.5 se muestran dos ejemplos de “imágenes frontera”, una “presente” y la otra “ausente”, en las cuales el etiquetado es muy discutible.

Son consideraciones importantes, que hay que tener presentes.




Figura 4.5: Dos ejemplos de “imágenes frontera”, una “presente” y la otra “ausente”, en las cuales el etiquetado es muy discutible.

4.1.2.3 Elementos distorsionadores

Finalizaremos este estudio hablando de los elementos distorsionadores que, si bien normalmente no dificultan al experto humano en el diagnóstico, sí son una fuente de problemas para el sistema automatizado. Mostraremos dos de los que más incidencia tienen en el patrón red pigmentada, la presencia de pelos, de la cual se tienen dos imágenes (una “presente” y la otra “ausente”) en la Fig. 4.6, y la presencia de aceite, de la cual se tienen cuatro imágenes (dos “presente” y dos “ausente”) en la Fig. 4.7.




Figura 4.6: Dos ejemplos de imágenes en las cuales la presencia de pelos dificulta el reconocimiento del patrón red pigmentada, una “presente” y la otra “ausente”.

4.1.3 Especificación del sistema

Tras el estudio realizado del patrón red pigmentada, se ha llevado a cabo la especificación del sistema, que se presenta aquí en forma de conjunto de requisitos escritos en lenguaje natural estructurado:

1. Para que una imagen tenga el patrón red pigmentada tiene que contener una estructura de este tipo en alguna parte de la lesión. Dicha estructura tiene forma de red, de colores marrón claro, marrón oscuro, gris o negro, siendo los agujeros de color más claro que la red. En algunas ocasiones puede suceder que exista poco contraste o que la red sea muy tenue.
2. Se tiene una textura muy característica tanto en los pixels de tipo “red” como en los de tipo “agujero”.

4. DISEÑO DEL SISTEMA




Figura 4.7: Cuatro ejemplos de imágenes en las cuales la presencia de aceite dificulta el reconocimiento del patrón red pigmentada, dos “presente” y la otras dos “ausente”.

3. Esta forma de red se compone de una o varias estructuras en forma de red (subredes), con una o varias celdas juntas en cada una. Debe haber en total más de un agujero.
4. Aunque la malla de la red es de anchura diferente dentro de la misma lesión (especialmente en los casos atípicos), normalmente dicha anchura suele ser similar a nivel local. De la misma manera, aunque las celdas pueden ser de tamaño diferente dentro de la misma lesión (especialmente en los casos atípicos), normalmente suelen ser consistentes en tamaño con otras a nivel local.
5. Existe a nivel global del conjunto de imágenes un rango para dichos tamaños que se corresponde con las resoluciones de las imágenes objetos de estudio (en caso de que cambiasen éstas, también cambiarían dichos rangos).
6. Hay que tener en cuenta que un sistema de reconocimiento de un patrón dermatoscópico, en este caso red pigmentada o reticular, es validado contra un

etiquetado previo realizado por expertos dermatólogos, que es de naturaleza subjetiva, en contraposición con, por ejemplo, un sistema diagnóstico que decida si una lesión tiene melanoma o no, habiendo sido ésta diagnosticada de manera histopatológica, un etiquetado que es de naturaleza puramente objetiva.

7. En línea con lo anterior, existen algunas imágenes en las cuáles es muy difícil discernir el patrón, incluso para el experto humano y, además, debido a la subjetividad en la valoración por parte de los expertos, existen incluso algunas “imágenes frontera”, cuyo etiquetado es muy discutible, en las que, aunque el sistema funcione bien, pueda existir un diagnóstico incorrecto respecto al etiquetado previo.

Estos requerimientos, además de conformar la especificación del sistema, son la base para la realización de un proceso de parametrización –en forma de parámetros configurables (con sus rangos de valores) y valores umbrales establecidos–, tal y como y como se explica en 4.3.2.1 y 4.3.2.2.

4.2 Diseño de alto nivel

4.2.1 Motivación de la clasificación difusa o *fuzzy* de los pixels

A partir de la especificación se realiza el diseño del algoritmo que, a grandes rasgos, consiste en realizar una clasificación de los pixels en las tres categorías presentes en la definición del patrón –“red”, “agujero” y “otro”– y, a continuación, realizar un procesamiento de las regiones correspondientes a dichas categorías en base a la descripción del patrón para su reconocimiento.

Si se examina la diferente casuística de imágenes (por ejemplo, las Figs. 4.2 y 4.4), se puede comprobar que las características de color y textura de los pixels varían enormemente en las diferentes imágenes y en las diferentes estructuras de red pigmentada, pudiéndose dar que un pixel con unas determinadas características corresponda a una categoría en un sitio y que otro pixel con características similares corresponda a otra categoría en otro sitio. Por ello, una clasificación de los pixels de tipo fuerte o *hard* se adapta mal al problema y el enfoque más adecuado es realizar una clasificación de tipo difuso o *fuzzy*, también llamado blando o *soft*, que ha

4. DISEÑO DEL SISTEMA

sido el adoptado aquí. Como consecuencia, si se realiza un proceso de aprendizaje supervisado, las tres regiones obtenidas serán de tipo difuso. Esto es implementado aquí con la generación de tres imágenes de probabilidad, que posteriormente serán procesadas para la caracterización mediante la extracción múltiple de α – cortes o α – cuts a partir de dichas regiones difusas, tal y como se verá.

4.2.2 Esquema del diseño de alto nivel

En la Fig. 4.8 se muestra gráficamente el esquema del diseño de alto nivel, cuya explicación detallada se realiza en 4.3. Antes de comenzar la ejecución del sistema, se realiza la **Segmentación de la lesión** en la imagen, siendo por tanto la imagen original y la lesión segmentada los inputs o entradas del sistema, que consta de dos módulos: **1. Detección difusa o fuzzy de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad**, en el que a partir de la imagen original I se generan tres imágenes de probabilidad I_{red} , $I_{agujero}$ e I_{otro} , correspondiendo el valor de cada pixel (x, y) en cada imagen a la probabilidad de éste de pertenecer a “red”, “agujero” y “otro”, respectivamente. **2. Procesamiento y caracterización de las imágenes de probabilidad y diagnosis**, en el que a partir del procesamiento de las imágenes de probabilidad y su posterior caracterización se realiza la diagnosis, diferenciando entre “ausente” y “presente”, que es el output o salida del sistema.

A continuación, y en relación al ciclo de vida de un CAD para la detección de melanoma que se explicaba en 2.2.1.1, se comentarán dos aspectos relevantes del sistema de reconocimiento del patrón reticular –que se ubicaría en el paso 4–: la ausencia de procesado previo –correspondiente al paso 2– y la segmentación de la lesión –correspondiente al paso 3–.

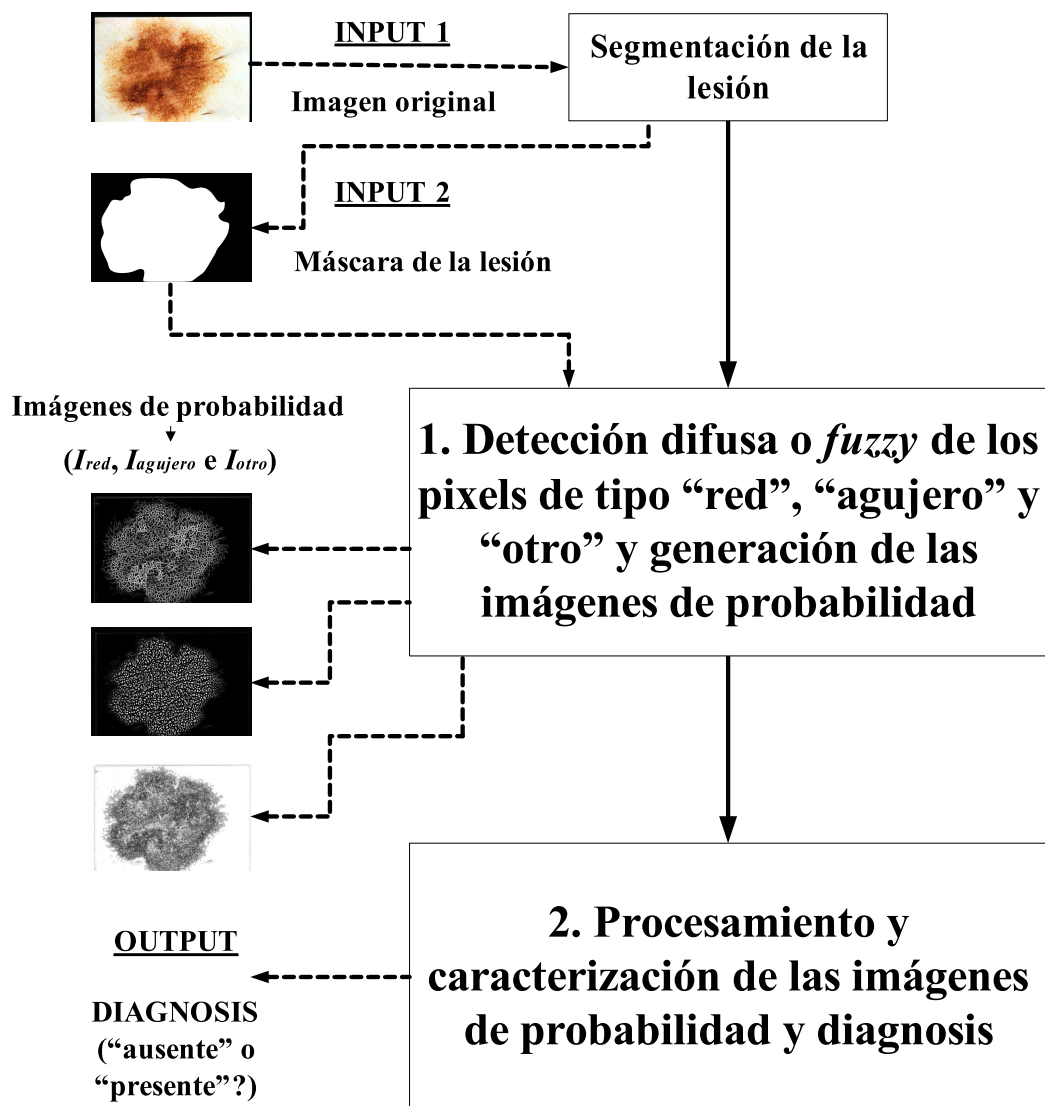


Figura 4.8: Diagrama de alto nivel del sistema.

4. DISEÑO DEL SISTEMA

4.2.3 Procesado previo de la imagen

En la mayoría de los métodos de reconocimiento de patrones dermatoscópicos se suele realizar un preprocesado previo a la imagen con el fin de detectar y eliminar artefactos distorsionadores tales como pelos, reflejos, marcas, reglas o burbujas. Sin embargo, esto es a menudo una fuente de errores ya que, por una parte, en el proceso de detección grupos de pixels que forman parte de un patrón pueden ser incorrectamente reconocidos como parte de los artefactos y, por otra, en el proceso de eliminación de artefactos –la restauración– de la imagen puede suceder que ésta sea modificada erróneamente. Para evitar esto, en este método no se realiza un preprocesado previo de la imagen teniéndose que en el propio algoritmo de reconocimiento del patrón se tiene en cuenta la posible presencia de artefactos distorsionadores.

4.2.4 Segmentación de la lesión

La gran mayoría de los trabajos del estado del arte para el reconocimiento del patrón reticular parten de una segmentación previa de la lesión. En este algoritmo se parte también de una segmentación previa de la lesión por razones metodológicas: porque se quiere aislar su diseño, desarrollo y validación de cuestiones externas y porque, además, este algoritmo está pensado para ser integrado en un sistema de detección automatizada de melanoma en el que se realiza la segmentación antes de la detección y caracterización de los diferentes indicadores, tal y como se veía en 2.2.1.1.

El autor de este método ha desarrollado un algoritmo de segmentación que presenta muy buenos resultados, que se muestra en 6.2.5. No obstante, también por razones metodológicas, con el fin de aislar el comportamiento de este algoritmo de reconocimiento del patrón reticular con respecto a los posibles errores que pudiese tener el método de segmentación, se utilizaron segmentaciones manuales, tal y como se explica en el capítulo de base de datos, en 3.3.

En cualquier caso, hay que señalar que, como se verá, tal y como está diseñado el propio algoritmo de reconocimiento del patrón reticular puede obtener la estructura de la red pigmentada y determinar si existe el patrón sin necesidad de la segmentación previa. Realmente, ésta sólo es necesaria con el fin de evitar el efecto que puede causar la posible presencia –normalmente muy fina y tenue– de la red

pigmentada en la piel que está en el exterior de la lesión, algo que sólo dará problemas al algoritmo de reconocimiento del patrón reticular en el caso de que la lesión además no tenga el patrón reticular, lo cual se da en poquísimas ocasiones.

A continuación, en la Fig. 4.9, se muestran gráficamente las máscaras de segmentación correspondientes a 4 imágenes que se van a utilizar en los ejemplos gráficos correspondientes a las diferentes tareas del método propuesto.




Figura 4.9: Máscaras de segmentación correspondientes a 4 imágenes de ejemplo.

4.3 Diseño de bajo nivel

4.3.1 Módulo 1: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad

4.3.1.1 Esquema del módulo 1

En este módulo, los pixels de la imagen dermatoscópica se clasifican de manera difusa o *fuzzy* en las categorías “red”, “agujero” y “otro” a partir de un proceso de aprendizaje supervisado, lo cual permite la generación de tres imágenes de probabilidad correspondientes a dichas categorías.

Tal y como se puede ver en la Fig. 4.10, este módulo consta de 4 fases. En primer lugar, se toman muestras de pixels, que se etiquetan en las tres categorías diferentes. En segundo lugar, se realiza una extracción de características de color y textura adecuadas para realizar la discriminación. En tercer lugar, se utiliza un clasificador difuso para generar un modelo de clasificación difuso, asignando a cada pixel una probabilidad de pertenecer a cada categoría, lo cual permite la creación de tres conjuntos difusos μ_{red} , $\mu_{agujero}$ y μ_{otro} sobre el conjunto de los pixels de la imagen. Finalmente, en cuarto lugar, a partir de estos conjuntos difusos se construyen las tres imágenes de probabilidad I_{red} , $I_{agujero}$ e I_{otro} .

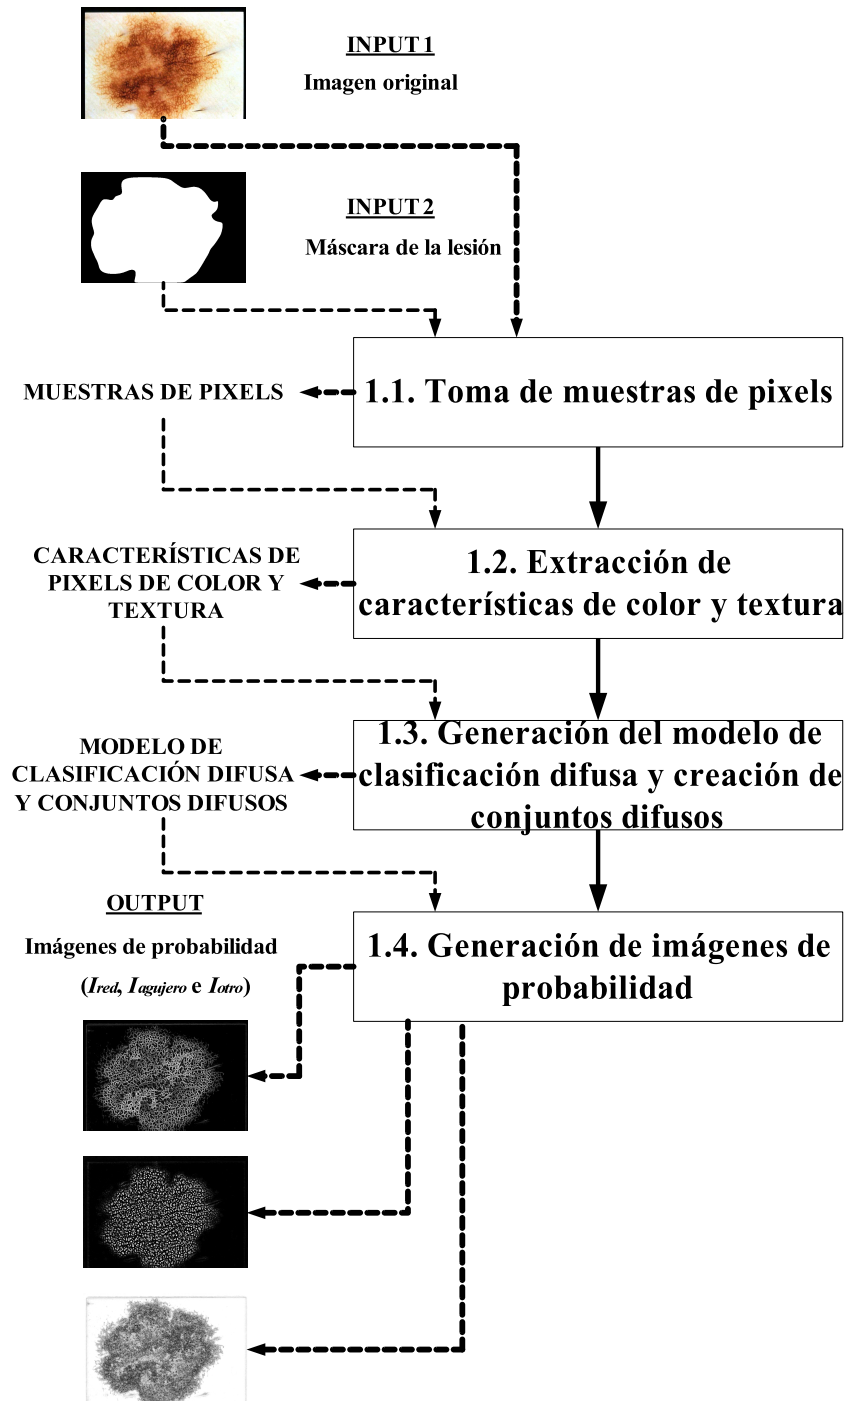


Figura 4.10: Fases del módulo 1 de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad.

4. DISEÑO DEL SISTEMA

4.3.1.2 1.1. Toma de muestras de pixels

Se han seleccionado muestras de pixels de 50 imágenes de los diferentes tipos (“ausente” y “presente”) que se han etiquetado en las categorías “red”, “agujero” y “otro”, correspondientes a los pixels que están en la red, los que están en los agujeros y el resto. Se ha intentado que la cantidad de pixels muestreados esté balanceada en relación al tamaño de las muestras de las tres categorías y, también, en la medida de lo posible, respecto a la diferente casuística existente en cada una de las categorías, en lo relativo a los tipos y tamaños de redes y agujeros, en el caso de “red” y “agujero”, y seleccionando ejemplares de pixels pertenecientes a la piel, a otros patrones dermatoscópicos y a artefactos –que son ruido de la imagen– tales como pelos, reflejos, marcas, reglas o burbujas, en el caso de “otro”. En cualquier caso, como se verá, en su mismo diseño este método tiene un mecanismo autocorrector frente a las diferentes realizaciones de este proceso de muestreo.

4.3.1.3 1.2. Extracción de características de color y textura

Con el fin de realizar la caracterización de los pixels pertenecientes a “red”, “agujero” y “otro” se extraen una serie de características, de tal manera que se discrimine lo mejor posible entre esas categorías [GW08, PGS06, MD09]. En total se calculan 159 características que, tal y como se muestra gráficamente en la Fig. 4.11, son de dos tipos:

- **Características de color:** Se extraen características correspondientes a los Modelos de Color RGB, rgb (coordenadas cromáticas de RGB), HSV, CIE XYZ, CIE Lab y CIE Luv, correspondientes a los valores de sus diferentes canales [GW08]. Se calculan 16 características en total.
- **Características de textura:** Se extraen características de textura sobre la imagen convertida a las escala de grises con la típica fórmula: $I_G(x, y) = \frac{1}{3}I_{red}(x, y) + \frac{1}{3}I_{green}(x, y) + \frac{1}{3}I_{blue}(x, y)$. La extracción se realiza tanto sobre la imagen de gris como sobre las imágenes resultantes de la aplicación de un Banco de Filtros Gaussianos, es decir tras la convolución con la Función Gaussiana, de fórmula: $G_\sigma(x, y) = \frac{1}{2\pi\sigma^2}e^{-\frac{x^2+y^2}{2\sigma^2}}$, con los valores de σ de la forma $\sigma = 2^m$, con $m = 0, 1, 2, \dots, m_{max}$ y $m_{max} = 4$. Las características

que se extraen son relativas a: Valores de los pixels, Diferencia de Gaussianas (Difference of Gaussian o “DoG”), Operador de Sobel, Operadores Hessianos, Operador Laplaciano, Estadísticos de textura y Filtros de Gabor. Se calculan 143 características en total.

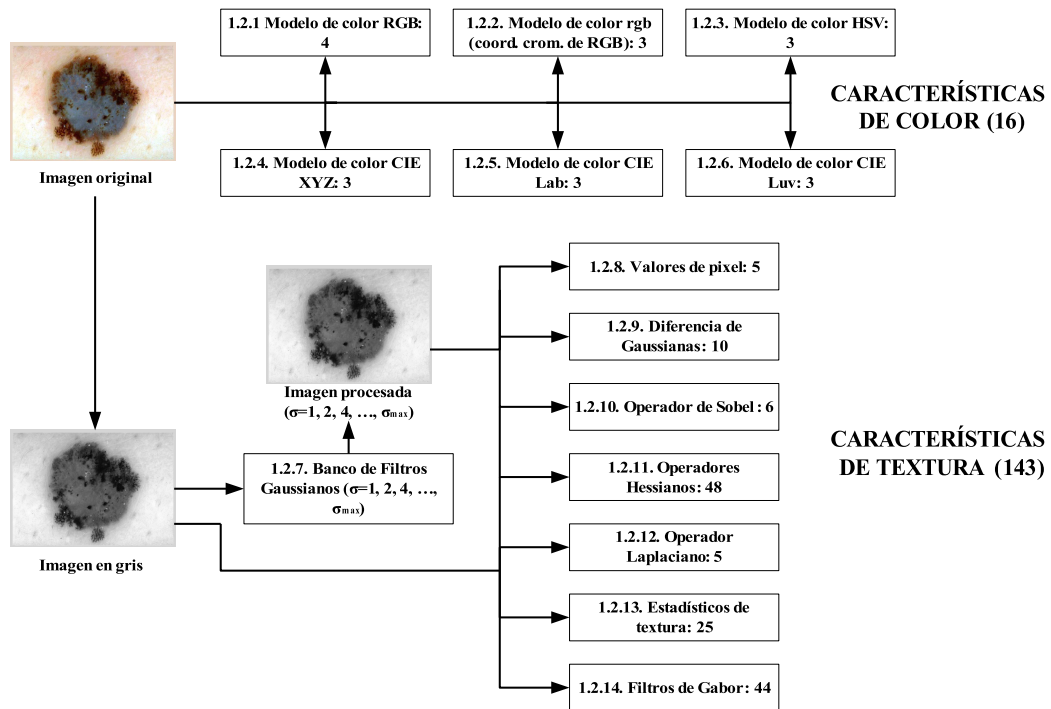


Figura 4.11: Tareas correspondientes a la fase 1.2 de extracción de características de los pixels.

1.2.1. Modelo de color RGB

Se extraen 4 características, 3 correspondientes a los diferentes canales del Modelo de color RGB y 1 correspondiente al valor de gris tras la transformación $I_G(x, y) = \frac{1}{3}I_{red}(x, y) + \frac{1}{3}I_{green}(x, y) + \frac{1}{3}I_{blue}(x, y)$ [jav16, US 16].

FUNDAMENTOS. El Modelo de color RGB

Fue definido en 1920 por W. David Wright y John Guild, que de manera independiente establecieron sus bases [FBH⁺97]. El Modelo de color RGB (Red: rojo,

4. DISEÑO DEL SISTEMA

Blue: azul, Green: verde) está formado por los colores primarios de la luz. Está basado en el sistema de coordenadas cartesianas y se puede describir utilizando un cubo, en el que los tres ejes de coordenadas son R , G y B , tal y como se puede ver en la Fig. 4.12. Su implementación depende de las capacidades del sistema utilizado, normalmente se utiliza una profundidad de color de 24 bits, con 8 bits (256 valores posibles) por canal, con un rango de valores entre 0 y 255. Es el modelo de color más ampliamente utilizado y para obtener los valores de otros modelos de color hay que usar transformaciones, de tipo lineal o no lineal según el caso [LG01, GW08, PP10].




Figura 4.12: El Modelo de color RGB se puede describir utilizando un cubo, en el que los tres ejes de coordenadas son R , G y B . En este caso se utilizan valores entre 0 y 255. En las dos primeras se puede ver las direcciones ascendentes y descendentes de las tres dimensiones, en la tercera un ejemplo para el valor RGB (83,150,60). Fuente en [Wik15].

1.2.2. Modelo de color rgb (coordenadas cromáticas de RGB)

Se extraen 3 características del Modelo de color rgb (coordenadas cromáticas de RGB), correspondientes a los diferentes canales [jav16, US 16].

FUNDAMENTOS. El Modelo de color rgb (coordenadas cromáticas de RGB)

El Modelo de color rgb es frecuentemente utilizado para la caracterización cromática. A partir de las coordenadas (R, G, B) del Modelo RGB se calculan las coordenadas (r, g, b) como sigue [GW08]:

$$r = \frac{R}{R + G + B}$$

$$g = \frac{G}{R + G + B}$$

$$b = \frac{B}{R + G + B}$$

Mientras que el Modelo RGB es un volumen en el espacio 3D, el Modelo rgb es una superficie, ya que se ha perdido la dimensión del brillo.

1.2.3. Modelo de color HSV

Se extraen 3 características del Modelo de color HSV, correspondientes a los diferentes canales [jav16, US 16].

FUNDAMENTOS. El Modelo de color HSV

Fue definido en 1978 por Alvy Ray Smith [Smi78]. El Modelo de color HSV (Hue: matiz, Saturation: saturación, Value: valor) es el resultado de una transformación no lineal del Modelo de color RGB que viene dada, suponiendo los tres canales (R, G, B) en el rango $[0, 1]$, $MAX = \max(R, G, B)$ y $MIN = \min(R, G, B)$, por las ecuaciones [LG01, GW08, PP10]:

$$H = \begin{cases} \text{no definido} & \text{si } MAX = MIN \\ 60^\circ * \frac{G - B}{MAX - MIN} + 0^\circ & \text{si } MAX = R \text{ y } G \geq B \\ 60^\circ * \frac{G - B}{MAX - MIN} + 360^\circ & \text{si } MAX = R \text{ y } G < B \\ 60^\circ * \frac{B - R}{MAX - MIN} + 120^\circ & \text{si } MAX = G \\ 60^\circ * \frac{R - G}{MAX - MIN} + 240^\circ & \text{si } MAX = B \end{cases}$$

$$S = \begin{cases} 0 & \text{si } MAX = 0 \\ 1 - \frac{MIN}{MAX} & \text{en otro caso} \end{cases}$$

$$V = MAX$$

Tal y como se puede ver en la Fig. 4.13, este modelo puede representarse con coordenadas cilíndricas, correspondiendo el ángulo –definido entre 0° y 360° – al

4. DISEÑO DEL SISTEMA

matiz (que representa el color), el radio –definido entre 0 y 1– a la saturación (que representa la pureza del color, lo que significa que en valores altos está más alejado de los tonos grisáceos y que en valores bajos está más cercano) y la altura –definido entre 0 y 1– al valor (también llamado intensidad o brillo, que representa el nivel de brillo o luminosidad). Este modelo de color es una representación más cercana que el RGB a la forma en que los humanos perciben los colores y sus propiedades [GW08].




Figura 4.13: El Modelo de color HSV se puede describir como un cono, correspondiendo el ángulo a la H, el radio a la S y la altura a la V. Fuente en [Wik05].

1.2.4. Modelo de color CIE XYZ

Se extraen 3 características del Modelo de color CIE XYZ, correspondientes a los diferentes canales [jav16, US 16].

FUNDAMENTOS. El Modelo de color CIE XYZ

La Comisión Internacional de la Iluminación (conocida por la sigla CIE, de su nombre en francés Commission Internationale de l'Éclairage) [CIE17] es la autoridad internacional en luz, iluminación, color y espacios de color, y fue fundada en 1931. Precisamente en ese año se definió el Modelo de color CIE XYZ (también llamado CIE 1931 XYZ), tras la realización de diferentes experimentos relativos a la adaptación del Modelo RGB al ojo humano [WS82].

Mientras que el Modelo de color RGB está formado por los colores primarios de la luz, el Modelo de color CIE XYZ tiene en cuenta los tres tipos de células

receptoras de color o conos del ojo humano, que reciben estímulos ante diferentes rangos de longitud de onda. Como resultado de los experimentos realizados se llegó a la conclusión de que el abanico de colores que pueden percibir es superior al definido en el Modelo RGB, por ello existe una relación de inclusión entre el Modelo RGB y el Modelo CIE XYZ [LG01].

Además, otra aportación de este Modelo de color fue la división en su definición del concepto de color en dos partes: brillo o luminosidad y cromaticidad. El espacio CIE XYZ fue deliberadamente diseñado de tal manera que el parámetro Y es una medida del brillo y que la cromaticidad se determine en función de los tres valores X , Y y Z , a través de dos parámetros derivados x e y (hay un tercero z , pero queda definido a partir de estos dos, como se verá, así que no contiene información). Suponiendo por ejemplo los tres canales (R, G, B) en el rango $[0, 1]$, los tres valores X, Y y Z se calculan con las siguientes fórmulas [LG01, PP10]:

$$X = 0,4124R + 0,3576G + 0,1805B$$

$$Y = 0,2126R + 0,7152G + 0,0722B$$

$$Z = 0,0193R + 0,1192G + 0,9505B$$

El Y se correspondería, como se ha dicho, con el brillo mientras que los valores de cromaticidad se calculan a partir de los valores de X, Y y Z :

$$x = \frac{X}{X + Y + Z}$$

$$y = \frac{Y}{X + Y + Z}$$

$$z = \frac{Z}{X + Y + Z} = 1 - x - y$$

1.2.5. Modelo de color CIE Lab

Se extraen 3 características del Modelo de color CIE Lab, correspondientes a los diferentes canales [jav16, US 16].

4. DISEÑO DEL SISTEMA

FUNDAMENTOS. El Modelo de color CIE Lab

El Modelo de color CIE Lab (también llamado CIE 1976 L*a*b*) fue definido por el CIE [CIE17] en 1976 a partir del Modelo CIE XYZ [Rob77]. El objetivo del CIE Lab es producir un espacio de color más “perceptivamente lineal” que otros espacios de color, entendiéndose “perceptivamente lineal” en el sentido de que un cambio de la misma cantidad en un valor de color debe producir un cambio de similar importancia visual para un individuo humano. Por ello, es el modelo usado habitualmente para describir los colores que puede percibir el ojo humano [WS82, PP10].

Los valores L , a y b del Modelo de color CIE Lab están definidos a partir de los valores del Modelo CIE XYZ y de los valores correspondientes en éste al blanco de referencia (X_n , Y_n y Z_n) tal y como sigue [LG01, PP10]:

$$\begin{aligned}L &= 116f(Y/Y_n) - 16 \\a &= 500(f(X/X_n) - f(Y/Y_n)) \\b &= 200(f(Y/Y_n) - f(Z/Z_n))\end{aligned}$$

donde:

$$f(t) = \begin{cases} t^{1/3} & \text{para } t > (\frac{6}{29})^3 \\ \frac{1}{3}(\frac{29}{6})^2 t + \frac{4}{29} & \text{para otro valor} \end{cases}$$

1.2.6. Modelo de color CIE Luv

Se extraen 3 características del Modelo de color CIE Luv, correspondientes a los diferentes canales [jav16, US 16].

FUNDAMENTOS. El Modelo de color CIE Luv

El Modelo de color CIE Luv (también llamado CIE 1976 L*u*v*) fue definido por el CIE [CIE17] en 1976 a partir del Modelo CIE XYZ, al igual que el Modelo CIE Lab, con el propósito –al igual que este último– de producir un espacio de color “perceptivamente lineal”, pero en este caso dirigido a los gráficos de ordenador [Rob77]. De hecho, la CIE recomienda utilizar el Modelo CIE Lab para la carac-

terización de superficies y tintes coloreados, mientras que el Modelo CIE Luv es recomendado para la caracterización de las pantallas en color. Por ello, el Modelo de color CIE Luv es el más utilizado en gráficos de ordenador [WS82, PP10].

Los valores L , u y v del Modelo de color CIE Luv están definidos a partir de los valores del Modelo CIE XYZ, siendo Y_n , u'_n y v'_n los valores correspondientes en éste al blanco de referencia (u'_n y v'_n tras la posterior transformación definida), tal y como sigue [LG01, PP10]:

$$L = \begin{cases} \left(\frac{29}{3}\right)^3 Y/Y_n & \text{para } Y/Y_n \leq \left(\frac{6}{29}\right)^3 \\ 116(Y/Y_n)^{1/3} - 16 & \text{para } Y/Y_n > \left(\frac{6}{29}\right)^3 \end{cases}$$
$$u = 13L(u' - u'_n)$$
$$v = 13L(v' - v'_n)$$

donde:

$$u' = \frac{4X}{X + 15Y + 3Z}$$
$$v' = \frac{9Y}{X + 15Y + 3Z}$$

1.2.7. Banco de Filtros Gaussianos

Se realiza la aplicación de un banco de filtros gaussianos sobre la imagen de gris con los valores de σ de la forma $\sigma = 2^m$, con $m = 0, 1, 2, \dots, m_{max}$ y $m_{max} = 4$ [Fij16b, Fij16d, Fij16a, Fij16c].

FUNDAMENTOS. Los Filtros Gaussianos

Un Filtro Gaussiano es un filtro frecuentemente utilizado en procesamiento digital de imagen. Es de tipo paso-bajo y por tanto suprime rangos de frecuencias altas, lo cual implica el efecto de un difuminado o emborronamiento de todas aquellas características asociadas con altas frecuencias, como fronteras, saltos o ruido (por ello, este tipo de filtros se llaman también filtros de suavizado). La utilización de los filtros paso-bajo, además, es normalmente necesaria para la reducción de ruido antes de la aplicación de filtros como el Operador de Sobel, siendo el Filtro

4. DISEÑO DEL SISTEMA

Gaussiano especialmente utilizado en esta tarea [PGS06].

Matemáticamente, el Filtro Gaussiano aplicado a la imagen I , que llamaremos L , para todo punto (x, y) de la imagen, es el resultado de la convolución de la imagen en gris $I(x, y)$ con la Función Gaussiana $G_\sigma(x, y) = \frac{1}{2\pi\sigma^2}e^{-\frac{x^2+y^2}{2\sigma^2}}$, cuya descripción gráfica corresponde a la Campana de Gauss 2D centrada sobre el origen de coordenadas, con la desviación típica σ , tal y como se muestra en la Fig. 4.14. Es decir, utilizando el operador $*$ de convolución, $L(x, y; \sigma) = I(x, y) * G_\sigma(x, y)$, $\forall(x, y)$ [GW08, PGS06].

El valor de σ determina el grado de suavizado, es decir, cuanto mayor sea el valor de σ del Filtro Gaussiano que se aplica a la imagen, mayor será el difuminado o emborronamiento.




Figura 4.14: Campana de Gauss 2D. Fuente en [Wik06].

1.2.8. Valores de pixel

Se calcula el valor de cada pixel en las diferentes imágenes. Se extraen 5 características en total: 1 por cada σ (la correspondiente a la imagen de gris no se incluye ya que se considera una característica de color y es una de las características del Modelo de color RGB).

1.2.9. Diferencia de Gaussianas

Se calcula la Diferencia de Gaussianas $DoG_{\sigma_i\sigma_j}(x, y)$ en cada pixel, a partir de la aplicación de los diferentes Filtros Gaussianos. Se realiza para los diferentes pares de valores (σ_i, σ_j) , tales que $i > j$ y $\sigma_m = 2^m$, con $m = 0, 1, \dots, m_{max}$ y $m_{max} = 4$. Se extraen 10 características en total: correspondiendo a las 10 posibles combinaciones de valores de (σ_i, σ_j) [Fij16b, Fij16d, Fij16a, Fij16c].

FUNDAMENTOS. La Diferencia de Gaussianas

Para todo punto (x, y) de una imagen I , los valores σ_1 y σ_2 , con $0 < \sigma_1, 0 < \sigma_2$ y $\sigma_1 \neq \sigma_2$, las Funciones Gaussianas $G_{\sigma_1}(x, y)$ y $G_{\sigma_2}(x, y)$ y los resultados de la aplicación de los Filtros Gaussianos correspondientes a dichas Funciones Gaussianas sobre la imagen $I(x, y)$, llamados $L(x, y; \sigma_1)$ y $L(x, y; \sigma_2)$, se define la Diferencia de Gaussianas (DoG: *Difference of Gaussians*) como la diferencia entre estas últimas. Es decir, $DoG_{\sigma_1\sigma_2}(x, y) = L(x, y; \sigma_1) - L(x, y; \sigma_2)$, redondeándose a cero los valores negativos [GW08, PGS06].

La Diferencia de Gaussianas es un filtro que se utiliza frecuentemente para la detección de bordes, en conjunción con otros filtros, escogiéndose normalmente valores de σ_1 y σ_2 tales que $\sigma_1 < \sigma_2$ [PGS06], tal y como se hace en este caso.

1.2.10. Operador de Sobel

Se calcula el Operador de Sobel en cada pixel, tanto sobre la imagen original como sobre los resultados de la aplicación de los Filtros Gaussianos, obteniéndose el módulo del gradiente. Se extraen 6 características en total: 1 de la imagen de gris + 1 por cada σ [Fij16b, Fij16d, Fij16a, Fij16c].

4. DISEÑO DEL SISTEMA

FUNDAMENTOS. El Operador de Sobel

Dada una función $f : \mathbb{R}^n \rightarrow \mathbb{R}$, real de n variables reales, si todas las derivadas parciales existen, se define el Vector Gradiente de f como ∇f , donde $\forall \mathbf{x} \in \mathbb{R}^n$,

$\nabla f(\mathbf{x})_i = \frac{\delta f(\mathbf{x})}{\delta x_i} \forall i$, tomando la siguiente forma:

$$\nabla f = \begin{bmatrix} \frac{\delta f}{\delta x_1} & \frac{\delta f}{\delta x_2} & \cdots & \frac{\delta f}{\delta x_n} \end{bmatrix}$$

El Vector Gradiente apunta en dirección del incremento máximo de la función, correspondiendo su módulo a la magnitud de dicho cambio.

En procesamiento digital de imagen, el Operador de Sobel es utilizado para la detección de bordes. Se basa en el cálculo del Vector Gradiente para cada punto $\mathbf{x} = (x, y)$ de una imagen I , teniéndose que, en cada punto, este operador permite obtener la magnitud del mayor cambio posible, la dirección de éste y el sentido de oscuro a claro [GW08].

El Operador de Sobel se aplica aquí tanto sobre la imagen original como tras la aplicación de los Filtros Gaussianos (ya que se trata de un procedimiento habitual para, antes de realizar la detección de bordes, suavizar la imagen con el fin de aminorar el ruido).

Por tanto, para todo punto (x, y) de la imagen I , en el caso de ser aplicado sobre la imagen original $I(x, y)$ se tiene el gradiente: $\nabla I(x, y) = \begin{bmatrix} I_x(x, y) & I_y(x, y) \end{bmatrix}$, y en caso de ser aplicado a la imagen original $I(x, y)$ tras la aplicación del Filtro Gaussiano correspondiente a la Función Gaussiana $G_\sigma(x, y)$, con $0 < \sigma$, llamado $L(x, y; \sigma)$, se tiene el gradiente: $\nabla L(x, y; \sigma) = \begin{bmatrix} L_x(x, y; \sigma) & L_y(x, y; \sigma) \end{bmatrix}$, utilizando la notación I_x, I_y, L_x y L_y para las derivadas parciales [GW08, PGS06].

El valor utilizado aquí, tal y como se ha comentado, es el módulo del gradiente y tendrá valores pequeños en puntos con poca variación de intensidad y valores más grandes en aquellos que tengan una mayor variación, correspondiéndose obviamente los puntos de los bordes con aquellos puntos de la imagen en los que hay un mayor incremento y por consiguiente un mayor valor.

1.2.11. Operadores Hessianos

Se calcula la Matriz Hessiana en cada pixel, tanto sobre la imagen original como sobre los resultados de la aplicación de los Filtros Gaussianos, y a continuación

se calculan 8 valores correspondientes a dicha matriz (Operadores Hessianos): Módulo, Traza, Determinante, Primer autovalor, Segundo autovalor, Orientación, Gamma-normalizado del cuadrado de la diferencia de los autovalores y Cuadrado del Gamma-normalizado de la diferencia de los autovalores. Estos valores se describirán a continuación. Se extraen 48 características en total: 8 de la imagen de gris + 8 por cada σ [Fij16b, Fij16d, Fij16a, Fij16c].

FUNDAMENTOS. Operadores Hessianos

Dada una función $f : \mathbb{R}^n \rightarrow \mathbb{R}$, real de n variables reales, si todas las segundas derivadas parciales existen, se define la Matriz Hessiana de f como H_f , donde

$\forall \mathbf{x} \in \mathbb{R}^n$, $H_f(\mathbf{x})_{i,j} = \frac{\delta^2 f(\mathbf{x})}{\delta x_i \delta x_j} \forall (i, j)$, tomando la siguiente forma:

$$H_f = \begin{bmatrix} \frac{\delta^2 f}{\delta x_1^2} & \frac{\delta^2 f}{\delta x_1 \delta x_2} & \cdots & \frac{\delta^2 f}{\delta x_1 \delta x_n} \\ \frac{\delta^2 f}{\delta x_2 \delta x_1} & \frac{\delta^2 f}{\delta x_2^2} & \cdots & \frac{\delta^2 f}{\delta x_2 \delta x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\delta^2 f}{\delta x_n \delta x_1} & \frac{\delta^2 f}{\delta x_n \delta x_2} & \cdots & \frac{\delta^2 f}{\delta x_n^2} \end{bmatrix}$$

En procesamiento digital de imagen, la Matriz Hessiana de la imagen es muy utilizada, especialmente tras la aplicación de los Filtros Gaussianos, ya que los valores obtenidos a partir de ésta, llamados Operadores Hessianos, son muy relevantes para la caracterización de los puntos de interés [LG01, PGS06].

La Matriz Hessiana se calcula aquí tanto sobre la imagen original como sobre los resultados de la aplicación de los Filtros Gaussianos. Para los puntos $\mathbf{x} = (x, y)$ de la imagen I , en el caso de ser aplicada sobre la imagen original $I(x, y)$ se tiene la Matriz Hessiana $H(I(x, y)) = \begin{bmatrix} I_{xx}(x, y) & I_{xy}(x, y) \\ I_{yx}(x, y) & I_{yy}(x, y) \end{bmatrix}$, y en caso de ser calculada sobre el resultado de la aplicación del Filtro Gaussiano correspondiente a la Función Gaussiana $G_\sigma(x, y)$, con $0 < \sigma$, sobre la imagen original $I(x, y)$, llamado $L(x, y; \sigma)$, se tiene la Matriz Hessiana $H(x, y; \sigma) = \begin{bmatrix} L_{xx}(x, y; \sigma) & L_{xy}(x, y; \sigma) \\ L_{yx}(x, y; \sigma) & L_{yy}(x, y; \sigma) \end{bmatrix}$, utilizando la notación I_{xx} , I_{xy} , I_{yx} , I_{yy} , L_{xx} , L_{xy} , L_{yx} y L_{yy} para las derivadas

4. DISEÑO DEL SISTEMA

parciales [PGS06].

Los valores obtenidos a partir de esta Matriz Hessiana (los Operadores Hessianos) utilizados aquí son algunos de los más relevantes. Si, por simplicidad en la notación, renombramos los elementos de la matriz como $\begin{bmatrix} a & b \\ c & d \end{bmatrix}$, se verá a continuación la descripción de los valores utilizados:

1. Módulo: $\sqrt{a^2 + bc + d^2}$.
2. Traza: $a + d$.
3. Determinante: $ad - cb$.
4. Primer autovalor: $\frac{a + d}{2} + \sqrt{\frac{4b^2 + (a - d)^2}{2}}$.
5. Segundo autovalor: $\frac{a + d}{2} - \sqrt{\frac{4b^2 + (a - d)^2}{2}}$.
6. Orientación: $\frac{1}{2} \arccos(4b^2 + (a - d)^2)$.
7. Gamma-normalizado del cuadrado de la diferencia de los autovalores:
 $t^4(a - d)^2((a - d)^2 + 4b^2)$, donde $t = 1^{3/4}$.
8. Cuadrado del Gamma-normalizado de la diferencia de los autovalores:
 $t^2((a - d)^2 + 4b^2)$, donde $t = 1^{3/4}$.

1.2.12 Operador Laplaciano

Se calcula el Laplaciano [PGS06] en cada pixel. Se extraen 5 características en total: 1 por cada σ [Fij16b, Fij16d, Fij16a, Fij16c].

FUNDAMENTOS. El Operador Laplaciano

El Laplaciano de una función se corresponde con la traza de la Matriz Hessiana, explicada en el párrafo anterior correspondiente a los Operadores Hessianos, siendo un operador muy utilizado –especialmente tras la aplicación de los Filtros Gaussianos– ya que estos valores son muy relevantes para la caracterización de

puntos de interés, nombrándose habitualmente como Laplaciano de la Gaussiana (LoG: *Laplacian of Gaussian*) [LG01, PGS06]. Este valor ha sido calculado anteriormente como uno de los 8 valores calculados a partir de la Matriz Hessiana $H(x, y; \sigma)$ de la imagen $I(x, y)$ tras la aplicación del Filtro Gaussiano correspondiente a la Función Gaussiana $G_\sigma(x, y)$, con $0 < \sigma$, llamado $L(x, y; \sigma)$. En este apartado se calcula ese mismo valor, variando ligeramente el cálculo con la aplicación de una escala diferente y la realización de redondeos correspondientes a dicha escala [Fij16a].

1.2.13. Estadísticos de textura

Se calculan diferentes estadísticos de radio σ en cada pixel: media, varianza, mediana, mínimo y máximo. Se extraen 25 características en total: 5 por cada σ [Fij16b, Fij16d, Fij16a, Fij16c].

FUNDAMENTOS. Los Estadísticos de textura

Para la caracterización de la textura es frecuente la utilización de estadísticos calculados en una vecindad del pixel. Los estadísticos que se utilizan aquí, y que son calculados para el conjunto de pixels que están dentro de un radio determinado por el valor σ , son: media, varianza, mediana, mínimo y máximo [PGS06, SHB⁺08]. Debido a su simplicidad no se entrará en su descripción.

1.2.14. Filtros de Gabor

Se calculan los filtros de Gabor en cada pixel, para diferentes valores de λ , θ , ψ , σ y γ . Se extraen 44 características en total, correspondientes a diferentes combinaciones de valores de dichos parámetros [Fij16b, Fij16d, Fij16a, Fij16c].

FUNDAMENTOS. Los Filtros de Gabor

El Filtro de Gabor, presentado por el físico Dennis Gabor en 1946 [Gab46], se puede definir como una oscilación de onda plana con una longitud de onda λ y un desfase inicial ψ , que puede ser orientada con cualquier ángulo θ con respecto al Eje X, con una envolvente gaussiana 2D centrada en el origen de coordenadas, siendo σ_x la anchura del eje mayor de la envolvente gaussiana y σ_y la anchura del eje

4. DISEÑO DEL SISTEMA

menor de dicha envolvente. Es un filtro pasobanda elíptico y orientado, localizado tanto en el dominio espacial como en el de frecuencia, y es usado frecuentemente en procesamiento digital de imagen para la detección de texturas [PGS06]. Se definirá a continuación.

Para todo punto (x, y) de la imagen I y para los valores λ (descrito), θ (descrito), ψ (descrito), σ (la desviación de la envolvente gaussiana, se calcula como $\sigma = \sigma_x$) y γ (la elipticidad de la envolvente gaussiana, se calcula como $\gamma = \sigma_x/\sigma_y$), se define el filtro g , que tiene componentes real e imaginaria representando las correspondientes direcciones ortogonales.

La parte real es:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \cos\left(\frac{2\pi x'}{\lambda} + \psi\right) \cdot e^{-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}}$$

La parte imaginaria es:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \sin\left(\frac{2\pi x'}{\lambda} + \psi\right) \cdot e^{-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}}$$

Con:

$$\begin{cases} x' = x \cos \theta + y \sin \theta \\ y' = -x \sin \theta + y \cos \theta \end{cases} .$$

Esta función se convoluciona posteriormente con la imagen $I(x, y)$ para un conjunto de valores de los parámetros $\lambda, \theta, \psi, \sigma$ y γ [PGS06, SHB⁺08]. Aquí se han utilizado 44 combinaciones de valores de dichos parámetros, tal y como se ha comentado.

4.3.1.4 1.3. Generación del modelo de clasificación difusa y creación de conjuntos difusos

Tras la extracción de las características de color y textura, y a partir de los valores obtenidos en los diferentes pixels, etiquetados en las diferentes categorías, se utiliza un clasificador difuso para generar un modelo de clasificación difusa. Este modelo

permite obtener para cada uno de los pixels de la imagen I sus probabilidades de pertenecer a las categorías “red”, “agujero” y “otro”. Los fundamentos teóricos se explican a continuación, mientras que el clasificador utilizado en esta tarea y los resultados obtenidos se explican en el capítulo de Resultados, en la sección 5.1.

Si consideramos que la imagen I es de tamaño $w \times h$ y definimos el conjunto de pixels $X = [0, w - 1] \times [0, h - 1]$, podemos definir tres conjuntos difusos μ_{red} , $\mu_{agujero}$ y μ_{otro} de X tal y como sigue:

1. $\mu_{red} : X \rightarrow [0, 1]$
2. $\mu_{agujero} : X \rightarrow [0, 1]$
3. $\mu_{otro} : X \rightarrow [0, 1]$

Cumpléndose que para cada pixel $(x, y) \in X$ los valores $\mu_{red}(x, y)$, $\mu_{agujero}(x, y)$ y $\mu_{otro}(x, y)$ son las probabilidades dadas por la clasificación difusa.

Estos conjuntos difusos cumplen dos condiciones:

- En primer lugar, son no nulos, es decir se cumple que $\sum_{(x,y) \in X} \mu_{red}(x, y) > 0$, $\sum_{(x,y) \in X} \mu_{agujero}(x, y) > 0$ y $\sum_{(x,y) \in X} \mu_{otro}(x, y) > 0$.
- En segundo lugar, se cumple que $\forall (x, y) \in X, \mu_{red}(x, y) + \mu_{agujero}(x, y) + \mu_{otro}(x, y) = 1$.

Por ello, podemos considerar la familia de conjuntos difusos $\{\mu_{red}, \mu_{agujero}, \mu_{otro}\}$ como una partición difusa de X . Los fundamentos teóricos de la lógica difusa se explican en este mismo subapartado.

FUNDAMENTOS. Aprendizaje supervisado. Clasificación. Clasificación dura y clasificación difusa o blanda

El aprendizaje supervisado es una técnica que realiza un entrenamiento controlado a partir de unos datos de entrada que permite deducir una función de esos datos. La función deducida puede ser un valor numérico en caso de problemas de regresión, o una etiqueta de clase en caso de problemas de clasificación [Bis06].

Aquí nos centraremos en los problemas de clasificación, en los que se parte de un conjunto de datos o muestras etiquetados y, tras la utilización de un algoritmo

4. DISEÑO DEL SISTEMA

de clasificación o clasificador, es posible realizar inferencias sobre el total de los datos, asignando a cada uno de los elementos una determinada clase –en el caso de la clasificación dura (*hard*)–, o la probabilidad de pertenencia a cada una de las clases –en el caso de la clasificación difusa o blanda (*fuzzy* o *soft*)– [Bis06].

Existen diferentes tipos de clasificadores, cada uno de los cuáles tiene sus ventajas e inconvenientes, y muchos de ellos no soportan la clasificación difusa o blanda. No hay un clasificador que funcione mejor en todos los problemas, ya que dependiendo de las características de los datos funcionan mejor unos u otros. Algunos de los tipos de clasificadores más relevantes son los basados en redes neuronales, máquinas de vectores soporte (SVM: *support vector machines*), K-vecinos más cercanos, clasificador bayesiano ingenuo, funciones de base radial y árboles de decisión. En concreto, en este trabajo se utilizan dos clasificadores basados en árboles de decisión –que se explican en 5.1–, en concreto el llamado Selvas Aleatorias (*Random Forest*) [Bre01] –que se explica en 5.1– y el C4.5 [Qui93] –que se explica en 5.2–. El primero soporta la clasificación difusa y el segundo no.

FUNDAMENTOS. Lógica difusa o borrosa y Conjuntos difusos

La lógica tradicional es de naturaleza booleana, en el sentido que las proposiciones pueden ser ciertas o falsas, contemplándose únicamente ambos casos o, de manera equivalente, los elementos pueden pertenecer o no a un conjunto, contemplándose únicamente ambos casos. La lógica difusa o borrosa, que fue formulada por primera vez por el ingeniero Lotfi A. Zadeh [Zad65], es una extensión de la lógica tradicional que posibilita la utilización de conceptos de pertenencia a conjuntos especificados de manera imprecisa, algo muy común en la manera de pensar humana –tales como “personas delgadas” o “temperaturas medias”– llamados conjuntos difusos o borrosos (*fuzzy sets*) [KY95].

Para ilustrar el concepto de conjunto de difuso, pongamos por ejemplo el conjunto de “hombres altos”. En la lógica clásica, a partir del universo del conjunto de hombres deberíamos establecer un umbral de altura, por ejemplo 1,78 metros, de tal manera que los hombres con altura mayor o igual a dicho umbral estarían en el conjunto, y los que tienen una altura menor no. Sin embargo, no parece muy lógico decir que un hombre de 1,77 metros no es alto y uno de 1,78 metros sí, ni tratar de la misma manera a uno que mida 1,77 metros que a otro que mida 1,49 metros. El

enfoque de la lógica difusa considera que el conjunto “hombres altos” es un conjunto que no tiene una frontera clara para pertenecer o no a él. Por ello se define una función que especifica la transición de alto a no alto, asignando a cada valor de altura un grado de pertenencia al conjunto, con valores en el intervalo $[0, 1]$. En ese sentido, la lógica tradicional es un caso particular de la lógica difusa, en el que la función de pertenencia asigna 1 a los hombres con altura mayor o igual que 1,78 metros, y 0 en caso contrario (es una función de tipo escalón) [Zad78].

Formalmente, dado un universo de discurso X , un conjunto difuso $A \subset X$ se define mediante una función de pertenencia $\mu_A : X \rightarrow [0, 1]$, que define $\forall x \in X$ el grado de pertenencia $\mu_A(x)$. Un conjunto clásico o nítido (*crisp*) $B \subset X$ se puede definir por extensión (listando sus elementos), por comprensión (describiendo las propiedades de sus elementos) y mediante una función de pertenencia $\mu_B : X \rightarrow \{0, 1\}$, que define $\forall x \in X$ el grado de pertenencia $\mu_B(x)$, pero nótese que en este caso, al contrario de lo que sucede en los conjuntos difusos, los valores de la función de pertenencia sólo pueden ser 0 ó 1, es decir, una función de tipo escalón, tal y como se ha comentado anteriormente. Esto se puede ver gráficamente en la Fig. 4.15 [Zad78, KY95].




Figura 4.15: A nivel gráfico, diferencia entre un conjunto nítido (*crisp*) y un conjunto difuso (*fuzzy*). Fuente en [Wik09].

Una familia de conjuntos difusos $\{A_i : i = 1, \dots, n\}$ se dice que es una partición de X si se cumplen las siguientes condiciones:

1. $\sum_{x \in X} \mu_{A_i}(x) > 0 \forall i \in \{1, \dots, n\}$

4. DISEÑO DEL SISTEMA

$$2. \sum_{i=1}^n \mu_{A_i}(x) = 1 \quad \forall x \in X$$

Un clasificador difuso o *fuzzy* genera siempre una partición sobre el conjunto donde es aplicado, compuesta por la familia de conjuntos difusos correspondientes a las diferentes clases.

Finalmente, se define un α – corte o α – cut $[\mu]_\alpha \subset X$, dado un conjunto difuso μ de un conjunto X y un valor $0 \leq \alpha \leq 1$, como $[\mu]_\alpha = \{(x, y) \in X : \mu(x, y) \leq \alpha\}$. Los α – cortes permiten la generación de conjuntos nítidos de interés a partir de valores numéricos $0 \leq \alpha \leq 1$.

4.3.1.5 1.4. Generación de imágenes de probabilidad

A partir de los conjuntos difusos μ_{red} , $\mu_{agujero}$ y μ_{otro} se generan tres imágenes de probabilidad (imágenes de gris) I_{red} , $I_{agujero}$ e I_{otro} de tamaño $w \times h$ y escala de gris en $[0, 255]$. Se definen como sigue, $\forall (x, y) \in X$:

1. $I_{red}(x, y) = 255 \cdot \mu_{red}(x, y)$
2. $I_{agujero}(x, y) = 255 \cdot \mu_{agujero}(x, y)$
3. $I_{otro}(x, y) = 255 \cdot \mu_{otro}(x, y)$

Evidentemente, se cumple que $\forall (x, y) \in X: I_{red}(x, y) + I_{agujero}(x, y) + I_{otro}(x, y) = 255$.

Estas imágenes de probabilidad muestran las probabilidades de los pixels de forma gráfica. Además, aprovechando el hecho de que son tres imágenes, se puede construir una imagen de color $I_{red_agujero_otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul. Esta nueva imagen es equivalente a las tres imágenes de probabilidad y permite ver mucho más claramente de manera gráfica el resultado de la clasificación difusa de los pixels. Todo esto se muestra en las Figs. 4.16, 4.17 y 4.18.




Figura 4.16: Ejemplo del proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} .

4. DISEÑO DEL SISTEMA




Figura 4.17: Sigue con el ejemplo de la Fig. anterior –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} .




Figura 4.18: Sigue con el ejemplo de las dos Figs. anteriores –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Esta imagen de color es la imagen $I_{red.agujero.otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul.

4. DISEÑO DEL SISTEMA

4.3.2 Módulo 2: Procesamiento y caracterización de las imágenes de probabilidad y diagnóstico

4.3.2.1 Motivación de las combinaciones de las máscaras extraídas a partir de las imágenes de probabilidad correspondientes a los α – cortes o α – cuts obtenidos a partir de los conjuntos difusos. Parámetros α_{red} , $\alpha_{agujero}$ y $prop$

La idea inicial del algoritmo era, a grandes rasgos, obtener las máscaras BW_{red} , $BW_{agujero}$ y BW_{otro} correspondientes a los pixels clasificados de manera dura en las categorías “red”, “agujero” y “otro” y, a continuación, buscar los agujeros de la red pigmentada en los agujeros de BW_{red} que coincidan “aproximadamente” con su intersección con $BW_{agujero}$. Esto suponía que, en primer lugar, la máscara $BW_{agujerosdered}$ se obtiene a partir de BW_{red} , como la unión de los agujeros de BW_{red} (es decir, la unión de los componentes 8-conexos $C_{agujerosdered} \subset \mathbb{C}(BW_{red})$ que no tocan el borde de la imagen) y, en segundo lugar, el “aproximadamente” corresponde a un valor umbral de proporción thr_prop establecido de antemano, que determina que se seleccionen como agujeros de la red pigmentada aquellos $C_{agujerosdered} \subset \mathbb{C}(BW_{red})$ tales que $\frac{|C_{agujerosdered} \cap BW_{agujero}|}{|C_{agujerosdered}|} > thr_prop$. Es una idea innovadora, pero tiene el problema de que, tal y como se ha explicado en 4.2.1, la clasificación dura no se adapta bien al reconocimiento de este patrón, que es de naturaleza difusa, al igual que el fijar un único valor thr_prop para la selección de agujeros.

Por ello, se ha realizado una variación sobre esta idea usando un enfoque difuso. Por un lado, thr_prop se puede parametrizar para tomar diferentes valores $prop$. Por el otro, a partir de las imágenes de probabilidad I_{red} e $I_{agujero}$, obtenidas en el módulo 1 y correspondientes a los conjuntos difusos μ_{red} y $\mu_{agujero}$, se pueden extraer máscaras, correspondientes a α – cortes o α – cuts obtenidos a partir de los conjuntos difusos usando diferentes parámetros correspondientes a valores de probabilidad α_{red} y $\alpha_{agujero}$, que son posteriormente combinadas. Realmente, tal y como se explicará más adelante en 4.3.2.2, estos parámetros surgen de los requisitos 1 y 2 de la especificación del sistema que se muestra en 4.1.3, relativos a la definición y caracterización de la red y los agujeros.

Combinaciones de máscaras extraídas a partir de los valores de α_{red} , $\alpha_{agujero}$ y $prop$.

A partir de las imágenes de probabilidad, y para los diferentes valores de α_{red} y $\alpha_{agujero}$, se extraen las máscaras correspondientes a los α – cortes:

1. $BW_{red}^{\alpha_{red}} = \{(x, y) \in X : I_{red}(x, y) \leq 255 \cdot \alpha_{red}\}$, obtenida a partir de I_{red} para un valor de α_{red} y el correspondiente α – corte $[\mu_{red}]_{\alpha_{red}}$.
2. $BW_{agujero}^{\alpha_{agujero}} = \{(x, y) \in X : I_{agujero}(x, y) \leq 255 \cdot \alpha_{agujero}\}$, obtenida a partir de $I_{agujero}$ para un valor de $\alpha_{agujero}$ y el correspondiente α – corte $[\mu_{agujero}]_{\alpha_{agujero}}$.

Posteriormente, tras ser intersectadas con la máscara de segmentación –con el fin de asegurar la ejecución del proceso en el área de interés–, estas máscaras se pueden combinar, de tal manera que se puede aplicar la idea inicial para cada combinación de $(\alpha_{red}, \alpha_{agujero}, prop)$, obteniendo como resultado el conjunto de agujeros seleccionados, correspondiente a las componentes 8-conexas

$$C_{agujerosdered}^{\alpha_{red}} \subset BW_{agujerosdered}^{\alpha_{red}} \text{ (agujeros de } BW_{red}^{\alpha_{red}} \text{) tales que}$$

$$\frac{|C_{agujerosdered}^{\alpha_{red}} \cap BW_{agujero}^{\alpha_{agujero}}|}{|C_{agujerosdered}^{\alpha_{red}}|} > prop.$$

Con el fin de abarcar una amplia casuística de los parámetros α_{red} , $\alpha_{agujero}$ y $prop$ (renombrados aquí como α_{red}^i , $\alpha_{agujero}^j$ y $prop^k$ respectivamente), se escogen los siguientes valores posibles:

1. $(0,1 \leq \alpha_{red}^i \leq 0,9)$ con $i = 0, 1, \dots, 8$ y cumpliendo $\alpha_{red}^{i+1} - \alpha_{red}^i = 0,1 \forall i$
2. $(0,1 \leq \alpha_{agujero}^j \leq 0,9)$ con $j = 0, 1, \dots, 8$ y cumpliendo $\alpha_{agujero}^{j+1} - \alpha_{agujero}^j = 0,1 \forall j$
3. $(0,5 \leq prop^k \leq 0,9)$ con $k = 0, 1, \dots, 4$ y cumpliendo $prop^{k+1} - prop^k = 0,1 \forall k$

Interpretación gráfica

El resultado de cada combinación se puede ver gráficamente construyendo una imagen de color de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$ con $BW_{red}^{\alpha_{red}}$

4. DISEÑO DEL SISTEMA

en rojo y las componentes 8-conexas $C_{agujerosdered}^{\alpha_{red}} \subset BW_{agujerosdered}^{\alpha_{red}}$ (agujeros de $BW_{red}^{\alpha_{red}}$) en azul o verde, dependiendo de si $\frac{|C_{agujerosdered}^{\alpha_{red}} \cap BW_{agujero}^{\alpha_{agujero}}|}{|C_{agujerosdered}^{\alpha_{red}}|}$ es $\leq prop$ (agujeros no seleccionados) o $> prop$ (seleccionados).

Se ilustra gráficamente lo anterior, en una imagen con el patrón red pigmentada: en la Fig. 4.19 se tiene la imagen junto con las imágenes de probabilidad generadas tras la ejecución del módulo 1, en la Fig 4.20 se muestran las máscaras extraídas de las imágenes de probabilidad I_{red} e $I_{agujero}$ correspondientes a varios α – cortes obtenidos usando varios valores de α_{red} y $\alpha_{agujero}$ y, finalmente, las Figs. 4.21, 4.22 y 4.23 se presentan varias imágenes de color de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$, correspondientes a diferentes combinaciones de valores de α_{red} , $\alpha_{agujero}$ y $prop$.

Intuitivamente, se puede observar que para cada trozo de una red pigmentada (red y agujeros) de una imagen existen diferentes valores de $(\alpha_{red}, \alpha_{agujero}, prop)$ tales que dicho trozo es detectado, en el sentido de que existen agujeros seleccionados –agujeros en verde presentes en $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$, como se muestra en las Figs. 4.21, 4.22 y 4.23– conectados a la malla de red. También se puede ver que, en las imágenes que no tienen red pigmentada, se tiende a que, en cuanto suben un poco los valores de las probabilidades, no se obtienen agujeros seleccionados. Es importante señalar que, como consecuencia de esta caracterización, este algoritmo lleva incorporado un mecanismo autocorrector frente al resultado del proceso de aprendizaje supervisado realizado en el primer módulo ya que, aunque varíen las distribuciones de probabilidad de los pixels de estar en la red, agujeros u otros, el método sigue funcionando bien, lo cual hace que este método sea muy robusto frente al proceso de muestreo de los pixels. Este enfoque es una gran contribución de este trabajo al estado del arte.

Como se verá, la discriminación entre “ausente” y “presente” que se realiza en este módulo 2 está basada en la idea básica para la detección de red pigmentada expuesta aquí. A continuación se abordará el resto de la parametrización obtenida a partir de la especificación del sistema –lo cual se explica a continuación– y el posterior proceso de caracterización.




Figura 4.19: Ejemplo del proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad, en una imagen con red pigmentada. La primera imagen es la original I . Las tres siguientes son las imágenes de probabilidad (imágenes de gris) I_{red} , $I_{agujero}$ e I_{otro} . La quinta es la imagen de color $I_{red_agujero_otro}$.

4. DISEÑO DEL SISTEMA




Figura 4.20: Ejemplo de las máscaras extraídas de las imágenes de probabilidad I_{red} e $I_{agujero}$ de la Fig. 4.19 correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para α_{red} y $\alpha_{agujero}$ e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,3}$, 2: $BW_{agujero}^{0,3}$; 3: $BW_{red}^{0,4}$, 4: $BW_{agujero}^{0,4}$; 5: $BW_{red}^{0,5}$, 6: $BW_{agujero}^{0,5}$.




Figura 4.21: Ejemplo de las combinaciones de las máscaras extraídas de las imágenes de probabilidad correspondientes a los α – *cortes* obtenidos a partir de los conjuntos difusos en una imagen con red pigmentada, cuyas imágenes de probabilidad se muestran en la Fig. 4.19 y algunos ejemplos de máscaras extraídas correspondientes a α – *cortes* en la Fig. 4.20. Son imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$. 1 y 2: $I_{RP}^{(0,3,0,3)}[0,7]$ y $I_{RP}^{(0,3,0,3)}[0,8]$, respectivamente, nótese que $prop = 0,7$ en el primer caso y $prop = 0,8$ en el segundo.

4. DISEÑO DEL SISTEMA




Figura 4.22: Sigue con el ejemplo de la Fig. anterior –ejemplo de las combinaciones de las máscaras extraídas de las imágenes de probabilidad correspondientes a los α – cortes obtenidos a partir de los conjuntos difusos–. Son imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})} [prop]$. 3: $I_{RP}^{(0,1,0,1)} [0,9]$; 4: $I_{RP}^{(0,2,0,5)} [0,8]$.




Figura 4.23: Sigue con el ejemplo de las dos Figs. anteriores –ejemplo de las combinaciones de las máscaras extraídas de las imágenes de probabilidad correspondientes a los α –cortes obtenidos a partir de los conjuntos difusos–. Son imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$. 5: $I_{RP}^{(0,4,0,3)}[0,7]$; 6: $I_{RP}^{(0,5,0,3)}[0,6]$.

4. DISEÑO DEL SISTEMA

4.3.2.2 Motivación de la parametrización obtenida a partir de la especificación del sistema. Parámetros $numMinAgujeros$, $distMaxAgujeros$ y $rangMaxTamanyoAgujeros$. Valores umbrales $thr_minTamanyoAgujero$, $thr_maxTamanyoAgujero$ y $thr_numMinTotalAgujeros$

A partir de la especificación del sistema, mostrada en 4.1.3, se realiza el proceso de parametrización. Los parámetros α_{red} , $\alpha_{agujero}$ y $prop$, que han sido ya descritos en 4.3.2.1, surgen de los requisitos 1 y 2, relativos a la definición y caracterización de la red y los agujeros. Los posibles valores considerados también han sido descritos.

El concepto de subred surge del requisito 3, que da lugar al valor umbral $thr_numMinTotalAgujeros = 2$, y de los requisitos 3 y 4 se obtiene la caracterización de una subred a partir de tres parámetros: $rangMaxTamanyoAgujeros$, correspondiente al número mínimo de agujeros que debe tener cada subred, $distMaxAgujeros$, correspondiente a la distancia máxima que debe haber entre los centroides de los agujeros de la subred, y $rangMaxTamanyoAgujeros$, correspondiente a la uniformidad de tamaños de los agujeros de la subred, entendiéndose esto como que, si $mediaTamanyoAgujeros$ es la media de los tamaños de los agujeros de la subred, los tamaños de todos los agujeros deben estar entre $(1 - rangMaxTamanyoAgujeros).mediaTamanyoAgujeros$ y $(1 + rangMaxTamanyoAgujeros).mediaTamanyoAgujeros$, lo que implica que la relación de los tamaños $tamanyo1$ y $tamanyo2$ entre cualesquiera dos agujeros de la subred debe de cumplir que $\frac{tamanyo1}{tamanyo2} \leq \frac{(1+rangMaxTamanyoAgujeros)}{(1-rangMaxTamanyoAgujeros)}$.

En este trabajo se consideran los siguientes valores para estos parámetros: para $numMinAgujeros$: 1, 2 y 3, para $distMaxAgujeros$: 10, 15, 20 y 25 y para $rangMaxTamanyoAgujeros$: 0,5, 0,65 y 0,8.

Los valores umbrales $thr_minTamanyoAgujero = 10$ y $thr_maxTamanyoAgujero = 200$ se establecen de manera experimental a partir del requisito 5 con el objetivo de establecer un amplio rango, de tal manera que sólo se contemplan los agujeros cuyo tamaño está en ese rango. Finalmente, los requisitos 6 y 7 se tienen en cuenta para el proceso de aprendizaje supervisado que se realiza en este módulo a partir del etiquetado de las imágenes como “ausente” y “presente”.

4.3.2.3 Esquema del módulo 2

Tal y como se puede ver en la Fig. 4.24, este módulo consta de 3 fases. En primer lugar, se generan diferentes modelos de clasificación dura, para las diferentes combinaciones de valores de (*prop*, *numMinAgujeros*, *distMaxAgujeros*, *rangMaxTamanyoAgujeros*), correspondientes a los procesos de aprendizaje supervisado llevados a cabo utilizando el etiquetado de la base de datos con respecto al patrón red pigmentada, entre “ausente” y “presente”, realizado por los expertos dermatólogos y descrito en el capítulo 3. En segundo lugar, se selecciona el mejor modelo de clasificación. Esto permite, en tercer lugar, realizar la diagnosis, discriminando la imágenes entre “ausente” y “presente”.

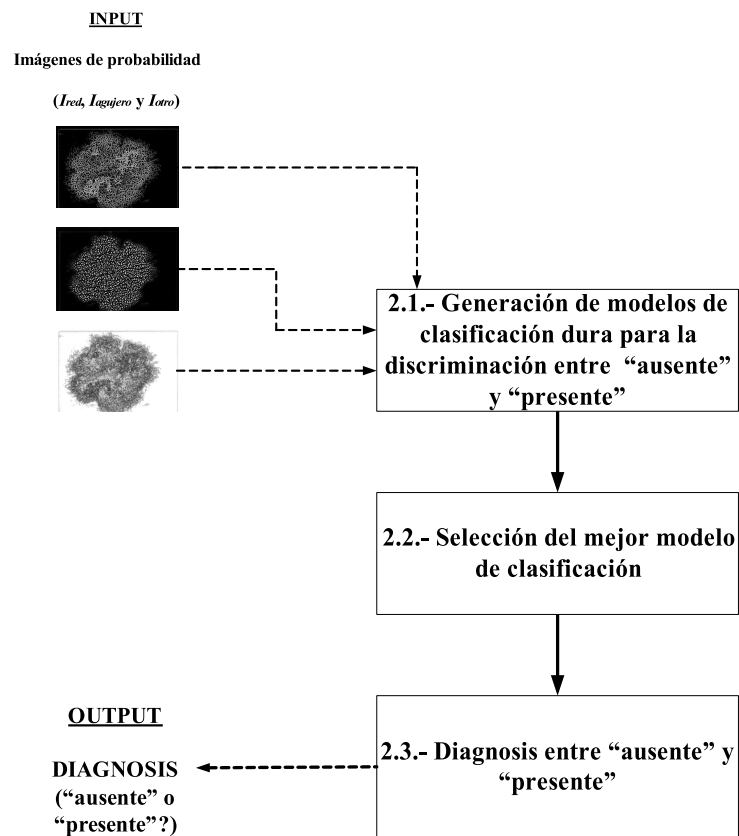


Figura 4.24: Fases del módulo 2 de procesamiento y caracterización de las imágenes de probabilidad y diagnosis.

4. DISEÑO DEL SISTEMA

4.3.2.4 2.1. Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente”

En esta fase, a partir del conjunto de imágenes se generan diferentes modelos de clasificación dura para la discriminación entre “ausente” y “presente”, correspondientes a las diferentes combinaciones de valores de (*prop*, *numMinAgujeros*, *distMaxAgujeros*, *rangMaxTamanyoAgujeros*). Según los posibles valores numéricos establecidos para dichos parámetros, el número de modelos de clasificación generados es: $180 = 5 * 3 * 4 * 3$. Tal y como se muestra en la Fig. 4.25, la generación de cada uno de ellos consta de 6 tareas, que se explicarán a continuación. Las 2 primeras tareas se realizan una única vez, mientras que las 4 siguientes se hacen 180 veces, una por cada combinación de parámetros.

Vamos a ilustrar las diferentes tareas con una imagen ejemplo, que tiene el patrón red pigmentada. En las Figs. 4.26, 4.27 y 4.28 se muestra la imagen junto con las imágenes de probabilidad generadas tras la ejecución del módulo 1.

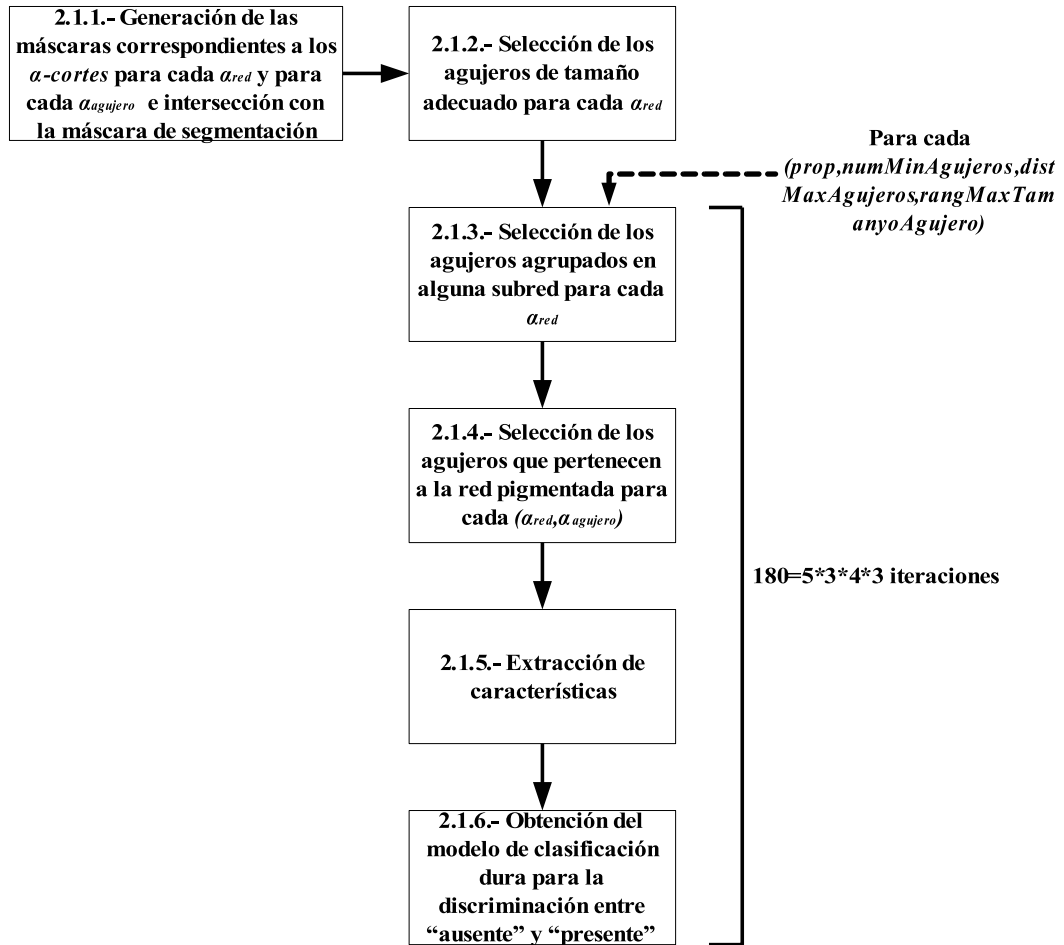


Figura 4.25: Tareas dentro de la fase 2.1 correspondientes a la generación, para cada combinación de valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros)$, de los modelos de clasificación correspondientes a los procesos de aprendizaje supervisado, en la fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente”.

4. DISEÑO DEL SISTEMA




Figura 4.26: Esta imagen, que tiene el patrón red pigmentada, se ha tomado como ejemplo para ilustrar las diferentes tareas realizadas en esta fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” del módulo 2. Aquí se muestran las imágenes resultado del módulo 1. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} .




Figura 4.27: Sigue con el ejemplo de la Fig. anterior –para una imagen que tiene el patrón red pigmentada y que se ha tomado como ejemplo para ilustrar las diferentes tareas realizadas en esta fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” del módulo 2, se muestran aquí las imágenes resultado del módulo 1–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} .

4. DISEÑO DEL SISTEMA




Figura 4.28: Sigue con el ejemplo de las dos Figs. anteriores –para una imagen que tiene el patrón red pigmentada y que se ha tomado como ejemplo para ilustrar las diferentes tareas realizadas en esta fase de generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” del módulo 2, se muestran aquí las imágenes resultado del módulo 1–. Esta imagen es la imagen de color $I_{red.agujero.otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul.

2.1.1. Generación de las máscaras correspondientes a los α – cortes para cada α_{red} y para cada $\alpha_{agujero}$ e intersección con la máscara de segmentación

Tal y como se explica en 4.3.2.1, a partir de la imagen I_{red} se generan las diferentes máscaras $BW_{red}^{\alpha_{red}}$ correspondientes a los α – cortes relativos a los valores de α_{red} y, para cada una de éstas, se obtiene la máscara $BW_{agujerosdered}^{\alpha_{red}}$ correspondiente a la unión de los agujeros de $BW_{red}^{\alpha_{red}}$ –es decir, la unión de los componentes 8-conexos $C_{agujerosdered}^{\alpha_{red}} \subset \mathbb{C}(BW_{red}^{\alpha_{red}})$ que no tocan el borde de la imagen–. Del mismo modo, a partir de $I_{agujero}$, se generan las diferentes máscaras $BW_{agujero}^{\alpha_{agujero}}$ correspondientes a los α – cortes relativos a los valores de $\alpha_{agujero}$. Una vez hecho esto, se intersecan estas máscaras con la máscara de segmentación que se ha obtenido previamente a la ejecución del presente método, tal y como se muestra en 4.2.4. Como resultado de esta tarea, y dados los posibles valores numéricos establecidos, se crean 9 máscaras de cada tipo. Se ven algunos ejemplos de los $BW_{red}^{\alpha_{red}}$ y $BW_{agujero}^{\alpha_{agujero}}$ en la Fig. 4.29 y de los $BW_{agujerosdered}^{\alpha_{red}}$ (cuya modificación se realizará en las dos siguientes tareas) en la Fig. 4.30.

2.1.2. Selección de los agujeros de tamaño adecuado para cada α_{red}

Se realiza para cada una de las máscaras $BW_{agujerosdered}^{\alpha_{red}}$. Se seleccionan los agujeros $C_{agujerosdered}^{\alpha_{red}}$ de tamaño adecuado, es decir, aquellos que cumplen la condición $thr_minTamanyoAgujero \leq |C_{agujerosdered}^{\alpha_{red}}| \leq thr_maxTamanyoAgujero$, como se comentó en 4.3.2.2. Como resultado de esta tarea, se tiene una modificación de las $BW_{agujerosdered}^{\alpha_{red}}$. Se ven algunos ejemplos de los $BW_{agujerosdered}^{\alpha_{red}}$ modificados en esta tarea en la Fig. 4.31.

4. DISEÑO DEL SISTEMA




Figura 4.29: En la tarea 1, ejemplos de máscaras $BW_{red}^{\alpha_{red}}$ y $BW_{agujero}^{\alpha_{agujero}}$ extraídas de las imágenes de probabilidad I_{red} e $I_{agujero}$ correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para α_{red} y $\alpha_{agujero}$ e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,3}$; 2: $BW_{agujero}^{0,3}$; 3: $BW_{red}^{0,4}$; 4: $BW_{agujero}^{0,4}$; 5: $BW_{red}^{0,5}$; 6: $BW_{agujero}^{0,5}$.




Figura 4.30: En la tarea 1, ejemplos de máscaras $BW_{agujerosdered}^{\alpha_{red}}$ de agujeros de $BW_{red}^{\alpha_{red}}$: 1: $BW_{agujerosdered}^{0,3}$; 2: $BW_{agujerosdered}^{0,4}$; 3: $BW_{agujerosdered}^{0,5}$; 4: $BW_{agujerosdered}^{0,6}$.

4. DISEÑO DEL SISTEMA




Figura 4.31: En la tarea 2, las máscaras $BW_{agujerosdered}^{\alpha_{red}}$ de la tarea anterior, modificadas tras la selección de agujeros de tamaño adecuado: 1: $BW_{agujerosdered}^{0,3}$; 2: $BW_{agujerosdered}^{0,4}$; 3: $BW_{agujerosdered}^{0,5}$; 4: $BW_{agujerosdered}^{0,6}$.

2.1.3. Selección de los agujeros agrupados en alguna subred para cada α_{red}

Se realiza para cada una de las máscaras $BW_{agujerosdered}^{\alpha_{red}}$. La selección de agujeros implica la creación de un conjunto $ConjuntoDeSubredes^{\alpha_{red}}$ en función de los parámetros ($numMinAgujeros$, $distMaxAgujeros$, $rangMaxTamanyoAgujeros$) descritos en 4.3.2.2, que contendría las diferentes subredes $Subred^{\alpha_{red}}$.

En primer lugar, se recorren los diferentes agujeros $C_{agujerosdered}^{\alpha_{red}} \subset BW_{agujerosdered}^{\alpha_{red}}$ y se calcula el centroide de cada uno de ellos. Se crea el conjunto $ConjuntoDeSubredes^{\alpha_{red}}$ compuesto de las diferentes subredes $Subred^{\alpha_{red}}$, cada una de las cuáles es un grupo de agujeros “cercaños”, es decir, cuyos centroides estén a una distancia menor o igual que $distMaxAgujeros$. El algoritmo para ello consiste en ir cogiendo de uno en uno los agujeros $C_{agujerosdered}^{\alpha_{red}} \subset BW_{agujerosdered}^{\alpha_{red}}$ y calcular la distancia de su centroide a los centroides de cada uno de los agujeros de cada una de las subredes $Subred^{\alpha_{red}} \in ConjuntoDeSubredes^{\alpha_{red}}$, comprobando

do la condición de ser $\leq distMaxAgujeros$. Si no encuentra ningún agujero que cumpla dicha condición en ninguna subred, se crea una nueva subred con dicho agujero $C_{agujerosdered}^{\alpha_{red}}$ como elemento. Si encuentra uno o más agujeros que cumplan dicha condición en sólo una subred, se añade el agujero $C_{agujerosdered}^{\alpha_{red}}$ a dicha subred. Si encuentra uno o más agujeros que cumplan dicha condición en más de una subred se fusionan todas estas subredes y a continuación se añade el agujero $C_{agujerosdered}^{\alpha_{red}}$ a la subred resultante de la fusión.

En segundo lugar, a cada una de las subredes $Subred^{\alpha_{red}}$ de $ConjuntoDeSubredes^{\alpha_{red}}$ se le aplica el criterio de que a nivel local exista una uniformidad de tamaños. Para ello, se calcula la media de tamaños de la subred $mediaTamanyoAgujeros$ y se eliminan de ésta los agujeros $C_{agujerosdered}^{\alpha_{red}}$ cuyo tamaño no esté entre $(1 - rangMaxTamanyoAgujeros).mediaTamanyoAgujeros$ y $(1 + rangMaxTamanyoAgujeros).mediaTamanyoAgujeros$.

En tercer lugar, se eliminan de $ConjuntoDeSubredes^{\alpha_{red}}$ las subredes cuyo número de agujeros sea $< numMinAgujeros$.

Como observación, es cierto que, por ejemplo en una subred de tamaño grande, el segundo proceso eliminaría muchos agujeros que no deberían ser excluidos, o que tras la supresión de estos agujeros quedarían algunos agujeros más alejados; sin embargo, no hay que olvidar que lo que se está haciendo no es exactamente obtener la máscara de la red pigmentada, sino que todo este procesamiento se realiza con vistas a obtener una descripción cuantitativa en forma de características, en la que lo que se busca es la discriminación, ya que el objetivo es, no olvidemos, el reconocimiento del patrón de red pigmentada.

Como resultado de esta tarea, se tiene la creación de los diferentes $ConjuntoDeSubredes^{\alpha_{red}}$, que a su vez supone la consiguiente modificación de las diferentes $BW_{agujerosdered}^{\alpha_{red}}$, quitándose los agujeros que no pertenezcan a ninguna subred). Cada conjunto de subredes correspondiente a cada valor de α_{red} se puede ver gráficamente construyendo una imagen de color del conjunto de subredes $I_{conjuntodesubredes}^{\alpha_{red}}$, en el que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas, tal y como se muestra en las Figs. 4.32 y 4.33.

4. DISEÑO DEL SISTEMA




Figura 4.32: En la tarea 3, a partir de las $BW_{agujeros}^{\alpha_{red}}$ de la tarea anterior y para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujero) = (2, 20, 0, 8)$, las diferentes imágenes de color $I_{conjuntodesubredes}^{\alpha_{red}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas: 1: $I_{conjuntodesubredes}^{0,3}$; 2: $I_{conjuntodesubredes}^{0,4}$.




Figura 4.33: Sigue con el ejemplo de la Fig. anterior –en la tarea 3, a partir de las $BW_{agujeros}^{\alpha_{red}}$ de la tarea anterior y para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (2, 20, 0, 8)$, las diferentes imágenes de color $I_{conjuntodesubredes}^{\alpha_{red}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas–: 3: $I_{conjuntodesubredes}^{0,5}$; 4: $I_{conjuntodesubredes}^{0,6}$.

4. DISEÑO DEL SISTEMA

2.1.4. Selección de los agujeros que pertenecen a la red pigmentada para cada $(\alpha_{red}, \alpha_{agujero})$

Tras la selección de los agujeros agrupados, en esta tarea es donde se aplican las ideas expuestas en la motivación 4.3.2.1. Se realizan las combinaciones de las máscaras extraídas a partir de las imágenes de probabilidad correspondientes a los α – cortes obtenidos a partir de los conjuntos difusos, para cada una de las diferentes combinaciones de valores $(\alpha_{red}, \alpha_{agujero})$, en el siguiente orden:

$$\begin{aligned} &for(\alpha_{red} = 0,1; \alpha_{red} \leq 0,9; \alpha_{red} = \alpha_{red} + 1)\{ \\ &\quad for(\alpha_{agujero} = 0,1; \alpha_{agujero} \leq 0,9; \alpha_{agujero} = \alpha_{agujero} + 1)\{ \\ &\quad \quad \dots \} \} \end{aligned}$$

En primer lugar, se recorren los agujeros $C_{agujerosdered}^{\alpha_{red}} \subset BW_{agujerosdered}^{\alpha_{red}}$ y se seleccionan aquellos que cumplan que $\frac{|C_{agujerosdered}^{\alpha_{red}} \cap BW_{agujero}^{\alpha_{agujero}}|}{|C_{agujerosdered}^{\alpha_{red}}|} > prop$. Se crea $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})} \subset BW_{agujerosdered}^{\alpha_{red}}$ como la unión de todos los agujeros seleccionados.

En segundo lugar, se eliminan los agujeros seleccionados $C_{agujerosdered}^{\alpha_{red}} \subset BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ que pertenezcan a las subredes $Subred^{\alpha_{red}}$ de $ConjuntoDeSubredes^{\alpha_{red}}$ tales que el número de agujeros seleccionados de dicha subred $Subred^{\alpha_{red}}$ sea $< numMinAgujeros$.

En tercer lugar, hay agujeros seleccionados si y sólo si su suma es $\geq thr_numMinTotalAgujeros$.

Como resultado de esta tarea, se obtienen los agujeros seleccionados en $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ en cada iteración correspondiente a cada $(\alpha_{red}, \alpha_{agujero})$. El resultado obtenido puede verse gráficamente en la imagen de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop]$, definida anteriormente en 4.3.2.1, cuya definición puede ser escalada tomando en cuenta todos los parámetros que intervienen en la parametrización a $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}[prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujero]$. Al igual que el resto de las otras definiciones de variables realizadas en las tareas 3-6, esta variable es dependiente de los valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros)$, y al igual que en el resto de las variables esta notación puede relajarse a $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, tal y como se puede ver en las Figs. 4.34, 4.35 y 4.36

El procesamiento realizado en esta tarea está directamente relacionado con la siguiente tarea de extracción de características, como se verá.




Figura 4.34: En la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$ en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada (definida en 4.3.2.1), correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$. 1: $I_{RP}^{(0,3,0,3)}$; 2: $I_{RP}^{(0,3,0,4)}$.

4. DISEÑO DEL SISTEMA




Figura 4.35: Sigue con el ejemplo de la Fig. anterior –en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$ en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$ -. 3: $I_{RP}^{(0,3,0,5)}$; 4: $I_{RP}^{(0,4,0,3)}$.




Figura 4.36: Sigue con el ejemplo de las dos Figs. anteriores –en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$ en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$ –. 5: $I_{RP}^{(0,4,0,4)}$; 6: $I_{RP}^{(0,4,0,5)}$.

4. DISEÑO DEL SISTEMA

2.1.5. Extracción de características

En esta tarea se buscan características que discriminen bien en el problema de reconocimiento de patrones. Para realizar la selección de características se ha hecho un estudio que contempla los diferentes tipos de imágenes, con y sin red pigmentada, y cómo funciona la selección de los agujeros pertenecientes a la red pigmentada en iteraciones correspondientes a los diferentes valores de $(\alpha_{red}, \alpha_{agujero})$.

Se ha comprobado que, en las imágenes que tienen red pigmentada, tanto en los casos en los que ésta es muy clara como en aquellos en los que es difícil de discernir, incluso en aquéllos en los que hay pocos agujeros, se cumple que los agujeros existentes en la estructura se obtienen en muchas iteraciones, incluso con valores de probabilidad $(\alpha_{red}, \alpha_{agujero})$ altos. También se ha comprobado que, en las imágenes que no tienen red pigmentada, en los casos muy claros no se selecciona nada y, en aquellos en los que es menos claro por diferentes razones –como la presencia de artefactos distorsionadores (tales como pelo, reflejos, marcas de reglas o burbujas de aire), la presencia de otras estructuras dermatoscópicas (tales como puntos/glóbulos, ramificaciones, ...) o la presencia de regiones de pixels con similares texturas a la red pigmentada– es bastante usual que se seleccionen “supuestos agujeros”, con valores de probabilidad $(\alpha_{red}, \alpha_{agujero})$ bajos pero, cuando las probabilidades aumentan, estos “supuestos agujeros” se dejan de obtener.

Esto demuestra que el método funciona muy bien en el discernimiento del patrón frente a artefactos distorsionadores –lo cual hace que en este método no sea necesario un preprocesado previo– y frente a otras estructuras dermatoscópicas.

Tomando en consideración las observaciones anteriores, se extraen cinco características:

1. *probRedMax*: de las iteraciones $(\alpha_{red}, \alpha_{agujero})$, el máximo valor de α_{red} en el cual hay agujeros seleccionados.
2. *probAgujeroMax*: de las iteraciones $(\alpha_{red}, \alpha_{agujero})$, con $\alpha_{red} = probRedMax$, el máximo valor de $\alpha_{agujero}$ en el cual hay agujeros seleccionados. Evidentemente, esta característica sólo tiene sentido cuando se combina con *probRedMax*.
3. *numProbabilidades*: número de iteraciones $(\alpha_{red}, \alpha_{agujero})$ en las cuáles hay agujeros seleccionados.

4.4 Software para el desarrollo de los algoritmos de procesamiento digital de imagen

4. *numAgujeros*: suma de todos los agujeros seleccionados para cada una de las diferentes iteraciones $(\alpha_{red}, \alpha_{agujero})$.
5. *numSubredes*: suma de todos los grupos en los que hay agujeros seleccionados para cada una de las diferentes iteraciones $(\alpha_{red}, \alpha_{agujero})$.

2.1.6. Obtención del modelo de clasificación dura para la discriminación entre “ausente” y “presente”

Para la combinación de parámetros $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros)$, se utiliza un clasificador duro para generar un modelo de clasificación dura para la discriminación entre “ausente” y “presente” a partir de los valores de las características para las imágenes etiquetadas en las categorías “ausente” y “presente”. El clasificador usado y los resultados obtenidos se explican en el capítulo de Resultados, en la sección 5.2.

4.3.2.5 2.2. Selección del mejor modelo de clasificación

Se analizan los diferentes modelos de clasificación correspondientes a las diferentes combinaciones de parámetros $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros)$ y se selecciona el mejor. Esto se explica en detalle en el capítulo de Resultados, en la sección 5.2.

4.3.2.6 2.3. Diagnósis entre “ausente” y “presente”

Una vez elegido el mejor modelo de clasificación, ya se tienen las reglas de decisión para llevar a cabo la diagnóstico. En el capítulo de Resultados, en la sección 5.3, se analizan los resultados obtenidos.

4.4 Software para el desarrollo de los algoritmos de procesamiento digital de imagen

4.4.1 Tecnologías utilizadas

En 2.2.4 se han comentado los *frameworks* software más relevantes que existen en la actualidad para realizar el procesamiento digital de imagen y se han identi-

4. DISEÑO DEL SISTEMA

ficado las características más relevantes para su valoración. En relación a dichas características se ha efectuado la elección, que se explica a continuación.

Las opciones de CVIPtools, OpenCV y PIL (Python Imaging Library)/Pillow fueron inicialmente descartadas por no existir un conocimiento previo o *background* en el grupo de investigación y –en el caso de CVIPtools y OpenCV– por no ser fácilmente integrables en entornos multiplataforma.

La opción de Matlab ha sido la opción descartada que ha tenido más peso entre todas las barajadas. Las ventajas han sido comentadas en 2.2.4.5 y contaba además con los puntos a favor de tenerse las licencias compradas y de haber experiencia en el desarrollo con Matlab en el grupo de investigación. Para el desarrollo de algoritmos sencillos Matlab es la opción óptima, ya que resulta muy rápida y sencilla su implementación. Sin embargo, cuando el nivel de desarrollo alcanza cierto nivel de complejidad es cuando empiezan a vislbrarse los problemas de Matlab. En primer lugar, Matlab no es un lenguaje de programación de propósito general y fuertemente validado, como pueden ser C/C++, Java, C# o Phyton, que asegure buenas prestaciones y robustez al desarrollador. En segundo lugar, El IDE es muy inferior a otros entornos tales como el Visual Studio para .NET o Eclipse para C/C++, Java o Phyton. En tercer lugar, no existe un gran número de librerías *open source* que puedan ser integradas, como es el caso de Java o, cada vez más, Phyton. En cuarto lugar, aunque el desarrollo de los algoritmos y los experimentos sobre éstos es fácilmente realizable, no lo es su integración con componentes software que pueden ser utilizados en los experimentos, tales como bases de datos, algo que en el caso de Java es fácilmente realizable con frameworks de alto nivel del tipo JPA (*Java Persistence API*) [Ora16c] –y en otros lenguajes serios con frameworks de diseño similar–. En quinto lugar, uno de los principales problemas que tiene Matlab es la difícil integración en aplicaciones software y en diferentes plataformas (escritorio, web, móvil, ...), algo que se realiza de manera natural en otros lenguajes, muchos de los cuáles son multiplataforma de manera nativa, como Java, C# o Phyton. Esto resulta ser un problema muy serio, ya que cuando se desarrollan algoritmos en Matlab, el integrarlos en una aplicación externa supone frecuentemente un gran problema que en muchas de las ocasiones se tiene que solventar con una traducción del código fuente a otro lenguaje de programación, algo que es muchas veces muy complejo por las propias dificultades que pone la compañía propietaria del Matlab. Finalmente, en sexto lugar, hay que señalar que, aunque Matlab provee

4.4 Software para el desarrollo de los algoritmos de procesamiento digital de imagen

de un sistema propietario para la ejecución de aplicaciones en entorno paralelo, la configuración de éste es costosa, tanto en dinero (las licencias cuestan más), como en desarrollo, que por un lado es más sencillo, ya que el framework Matlab da soporte a muchas de las tareas, pero por otro es más difícil, ya que su implementación no se adhiere a estándares de facto para este tipo de tareas, tales como Apache Hadoop [Apa16a] o Apache Spark [Apa16c], a lo que hay que añadir el problema de integración en diferentes plataformas, ya comentado anteriormente.

En cualquier caso, hay que destacar que Matlab es el entorno en el que se han hecho muchas de las pruebas iniciales con éxito, ya que se trata de un excelente *framework* para el desarrollo y ejecución de funciones matemáticas.

Se ha elegido finalmente Java [Ora15a] como lenguaje de programación y JAI (*Java Advanced Imaging*) [Sun14, jav16], ImageJ [US 16] y Fiji [Fij16b] como librerías de imagen, que junto a otras librerías software escritas en Java –las más importantes de ellas Weka [The16b] para la minería de datos y Apache Common Maths Library [Apa16d] para las funciones matemáticas– se han integrado en el *framework* de imagen desarrollado en la presente investigación.

Las razones para su elección son muchas. En primer lugar, Java es un lenguaje de programación muy serio, gratuito, multiplataforma, fácilmente integrable en aplicaciones de diferente tipo, con un API extensa –por ejemplo JDBC (*Java Database Connectivity*) [Ora16b] y JPA (*Java Persistence API*) [Ora16c] para bases de datos– y con el manto de protección de una empresa muy importante –Oracle (antes Sun Microsystems)– y una comunidad de desarrolladores extensa a nivel mundial, en el que además existía un conocimiento previo o *background* en el grupo de investigación. En segundo lugar, es el lenguaje más utilizado a nivel mundial [TIO15] y el más utilizado con mucha diferencia en el entorno universitario, existiendo por ello multitud de librerías software *open source* para diferentes propósitos. En tercer lugar, existe un IDE (*Integrated Development Environment*) muy serio como el Eclipse [Ecl16] –el usado en esta investigación– para el desarrollo de software. Además, es un lenguaje en el que existen multitud de *frameworks* para el procesamiento paralelo, como el Fork/Join [Ora16a] incluido en el API de Java u otros como el Apache Hadoop [Apa16a] o el Apache Spark [Apa16c], algo hoy día cada vez más relevante para el escalado de algoritmos.

4. DISEÑO DEL SISTEMA

4.4.2 *Framework* software construido

Como se ha comentado, las tecnologías utilizadas posibilitan el acceso a un gran número de funcionalidades existentes. Éste ha sido el punto de partida para escalar –a nivel de desarrollo software– en el transcurso de esta investigación, en la que se ha desarrollado un completo *framework* software con un gran número de funciones, agrupadas en librerías, para la implementación de diferentes funcionalidades, tanto en procesamiento digital de imagen como en otras tareas. Esta es una gran contribución de esta investigación, tal y como se explica en 6.2.

Tal y como se ha explicado, el lenguaje de programación utilizado ha sido el Java. En la Fig. 4.37 se presentan las 3 capas que componen dicho software. La primera capa corresponde a los algoritmos de alto nivel desarrollados en la presente investigación. La segunda capa está formada por el conjunto de utilidades implementadas por el autor de esta tesis para el soporte de diferentes funcionalidades necesarias para el desarrollo de los algoritmos. La tercera capa está compuesta por las librerías externas utilizadas, que son utilizadas por las utilidades implementadas. Como se puede ver, las dos primeras capas son desarrolladas en el transcurso de la presente investigación y la tercera capa corresponde a recursos externos utilizados.




Figura 4.37: Capas del *framework* software construido. Las dos primeras han sido desarrolladas en el transcurso de la presente investigación.

A continuación se explican brevemente el diseño del *framework* software construido. En primer lugar se presentan los algoritmos de alto nivel desarrollados (primera capa), en segundo lugar se explican las utilidades implementadas (segunda capa) y en tercer lugar se muestran las librerías externas utilizadas (tercera capa).

4.4.2.1 Algoritmos de alto nivel desarrollados

Los algoritmos de alto nivel desarrollados en la presente investigación son:

4.4 Software para el desarrollo de los algoritmos de procesamiento digital de imagen

- Reconocimiento del patrón reticular (tal y como se puede ver en 6.2.1)
- Segmentación de la lesión (tal y como se puede ver en 6.2.5)
- Reconocimiento del patrón globular (tal y como se puede ver en 6.2.6)
- Reconocimiento del patrón puntos (tal y como se puede ver en 6.2.7)
- Reconocimiento del patrón ramificaciones lineales/pseudópodos (tal y como se puede ver en 6.2.8)
- Reconocimiento del patrón velo azul-blanquecino (tal y como se puede ver en 6.2.9)
- Reconocimiento del patrón homogéneo (tal y como se puede ver en 6.2.10)
- Reconocimiento del patrón homogéneo azulado (tal y como se puede ver en 6.2.11)
- Reconocimiento del patrón manchas de pigmento (tal y como se puede ver en 6.2.12)
- Reconocimiento del patrón hipopigmentación (tal y como se puede ver en 6.2.13)
- Reconocimiento de los indicadores asimetría, bordes y color correspondientes al algoritmo médico “Regla del ABCD” (tal y como se puede ver en 6.2.14)
- Prototipo software para el diagnóstico de melanoma (tal y como se puede ver en 6.2.15)

También se han empleado las utilidades implementadas en este *framework* en otros algoritmos de alto nivel desarrollados en otras investigaciones, como:

- La herramienta software **DICOMPAS** para la caracterización articular sobre imágenes DICOM de cine-MRI (tal y como se puede ver en 6.3.5.3).
- La herramienta software **NODULEPAS** para la ayuda al diagnóstico, que implementa algoritmos avanzados de procesamiento digital de imagen para la monitorización de pacientes con cáncer de pulmón (tal y como se puede ver en 6.3.5.3).

4. DISEÑO DEL SISTEMA

4.4.2.2 Utilidades implementadas

Se ha desarrollado un extenso conjunto de utilidades para el soporte de diferentes funcionalidades:

- Funcionalidades de procesamiento digital de imagen.
- Funcionalidades de minería de datos.
- Funcionalidades estadísticas.
- Funcionalidades matemáticas.
- Funcionalidades de integración con otras plataformas.
- Funcionalidades de integración con bases de datos.
- Otras funcionalidades.

Como se ha comentado anteriormente, el gran número de utilidades desarrolladas ha sido clave para el desarrollo de los diferentes algoritmos.

4.4.2.3 Librerías externas utilizadas

Para el desarrollo de las utilidades se han utilizado diferentes librerías externas:

- Funcionalidades de procesamiento digital de imagen: JAI (*Java Advanced Imaging*) [Sun14, jav16], ImageJ [US 16] y Fiji image processing software [Fij16b].
- Funcionalidades de minería de datos: Weka [The16b].
- Funcionalidades estadísticas: Weka [The16b] y Apache Common Maths Library [Apa16d].
- Funcionalidades matemáticas: Apache Common Maths Library [Apa16d].
- Funcionalidades de integración con otras plataformas: diferentes APIs –para web, servicios SOAP (*Simple Object Access Protocol*), servicios REST (*Representational State Transfer*), ...– incluidas en Java EE (*Java Enterprise Edition*) [Ora15b].

4.4 Software para el desarrollo de los algoritmos de procesamiento digital de imagen

- Funcionalidades de integración con bases de datos: JDBC (*Java DataBase Connectivity*) [Ora16b] y JPA (*Java Persistence API*) [Ora16c].
- Otras funcionalidades: diferentes APIs incluidas en Java SE (*Java Standard Edition*) [Ora15c], Java EE (*Java Enterprise Edition*) [Ora15b] y algunos proyectos relevantes de Apache [Apa16b].

El principio de la ciencia, casi la definición, es el siguiente: “La prueba de todo conocimiento es el experimento”. El experimento es el único juez de la verdad científica.

Richard Feynman

CAPÍTULO

5

Resultados

En este capítulo se analizan los resultados correspondientes a los experimentos realizados, de cara a la evaluación del sistema. Para ello, en primer lugar, se muestran los resultados parciales correspondientes a la detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” realizada en el Módulo 1. En segundo lugar, se examinan los resultados parciales correspondientes a los diferentes modelos de clasificación dura para la discriminación entre “ausente” y “presente” obtenidos en el Módulo 2 y la posterior selección del mejor modelo. Finalmente, en tercer lugar se presentan los resultados finales obtenidos con el método propuesto. Es importante señalar que en esta tesis, en la que se realizan contribuciones en el área del procesado digital de imagen, los resultados gráficos son altamente significativos para ilustrar los resultados del algoritmo, y por ello en este capítulo se ofrece buen número de ejemplos. Junto con la explicación detallada de los resultados del método se realiza una breve explicación teórica de los conceptos más relevantes utilizados.

5. RESULTADOS

5.1 Resultados parciales: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”

A continuación se muestran los resultados parciales correspondientes a la detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” realizada en el Módulo 1, descrito en 4.3.1. Para ello, en primer lugar, se muestran los resultados numéricos del proceso de aprendizaje supervisado y, en segundo lugar, se presentan dos ejemplos gráficos de dichos resultados, obtenidos tras su aplicación sobre las imágenes.

5.1.1 Resultados numéricos

Tal y como se ha comentado en 4.3.1.4, el objetivo de la detección difusa o *fuzzy* de los pixels que se realiza en el módulo 1, que se explica en 4.3.1, es obtener reglas difusas de pertenencia para cada uno de los pixels. Para ello, se utilizó la implementación RandomForest incluida en el software Weka [The16b] del clasificador Selva Aleatoria o *Random Forest* [Bre01], que se explica a continuación en 5.1.1.2, un clasificador que ofrece esta funcionalidad –un clasificador difuso– y que ofrece resultados muy buenos en términos de fiabilidad, siendo además muy rápido, con bajo coste computacional [GBS06], algo especialmente crítico para conseguir que el algoritmo sea eficiente, ya que hay que computar cada uno de los 768×512 pixels de las diferentes imágenes.

En el proceso de aprendizaje supervisado se tomaron un conjunto de 9196 muestras de pixels obtenidas de 50 imágenes de los diferentes tipos (“ausente” y “presente”) correspondientes a la base de datos descrita en el capítulo 3 y etiquetadas en las categorías de “red”, “agujero” y “otro”, obteniéndose tras el procesamiento con el clasificador Selva Aleatoria una exactitud de 94,1 % y una AUC de 0,99, utilizando validación cruzada de 10 iteraciones. Estos conceptos se explican en 5.1.1.3 y 5.1.1.4.

Son unos buenos ratios, y es evidente que el resultado obtenido en este primer módulo es de gran importancia, ya que el resto del algoritmo se apoya en él. No obstante, tal y como se comentaba en 4.3.2.1, este algoritmo lleva incorporado un mecanismo autocorrector frente al resultado del proceso de aprendizaje supervisado realizado en el primer módulo ya que, aunque varíen las distribuciones de

5.1 Resultados parciales: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”

probabilidad de los pixels de estar en la red, agujeros u otros, el método sigue funcionando bien, lo cual hace que este método sea muy robusto frente al proceso de muestreo de los pixels. Esto es consecuencia de la posterior caracterización que se realiza en el módulo 2 a partir de las imágenes de probabilidad correspondientes a esta detección difusa, que se explica en 4.3.2, lo cual hay que tener presente en la interpretación de los resultados de este proceso, tanto los numéricos como los gráficos que se presentan a continuación en 5.1.2.

5.1.1.1 FUNDAMENTOS: Clasificadores basados en árbol de decisión

Los clasificadores basados en árboles de decisión son un tipo de clasificadores que pueden ser representados gráficamente como árboles. Los nodos interiores representan las condiciones o estados posibles de los atributos, características o variables del problema y los nodos finales u hojas constituyen la decisión final del clasificador. Se puede ver gráficamente un ejemplo en la Fig. 5.1.

Existen diferentes clasificadores, que utilizan diferentes algoritmos para la construcción del árbol a partir de los datos de entrenamiento. Todos ellos soportan la clasificación dura y algunos de ellos soportan también la clasificación difusa o blanda, como el clasificador Selva Aleatoria o *Random Forest* que se utiliza aquí en la detección difusa de los pixels y que se explica a continuación, y otros sólo soportan la clasificación dura, como el clasificador C4.5 que se utiliza aquí en el reconocimiento del patrón y que se explica en 5.2.1.1.

5.1.1.2 FUNDAMENTOS: Clasificador Selva Aleatoria o *Random Forest*

El algoritmo Selva Aleatoria o *Random Forest* es un clasificador desarrollado por el estadístico Leo Breiman basado en árboles de decisión. Genera como resultado un árbol de decisión que está compuesto, a su vez, de varios sub-árboles de decisión. Para la clasificación de cada instancia, genera un vector de entrada para cada uno de los árboles de la combinación. Cada árbol genera una clasificación y el clasificador global elige aquella que ha obtenido la mayor cantidad de votos [Bre01].

5. RESULTADOS

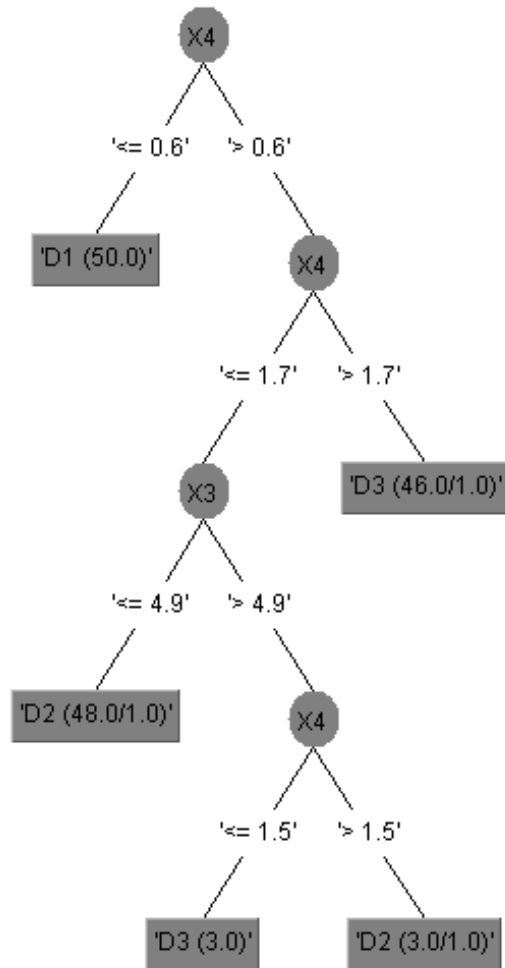


Figura 5.1: Ejemplo de clasificador basado en árbol de decisión, generado a partir de un conjunto de datos etiquetados para el aprendizaje. Se tienen 4 atributos (X1, X2, X3 y X4) y tres posibles decisiones (D1, D2 y D3). Nótese que las decisiones son tomadas a partir de los valores de los atributos X3 y X4.

5.1 Resultados parciales: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”

Para generar los árboles de decisión, de naturaleza aleatoria y que componen la llamada selva aleatoria, se elige un subconjunto aleatorio del conjunto total de datos. A continuación, se calcula la mejor división posible para ese subconjunto de características. Se repite el proceso para cada nodo del árbol de decisión y, finalmente, cuando el árbol está creado, no se hace una poda del mismo, al contrario que en la mayoría de métodos para la construcción de árboles de decisión [Bre01].

Es un algoritmo frecuentemente utilizado por sus buenos resultados en la clasificación de los datos y su bajo coste computacional [GBS06]. Además, soporta la clasificación difusa o blanda.

5.1.1.3 FUNDAMENTOS: Exactitud, sensibilidad, especificidad y AUC

Supongamos que tenemos un estimador para una variable estadística discreta binaria –es decir, que sólo admite dos resultados, positivo y negativo– y probamos dicho estimador contra un conjunto de datos etiquetados de prueba. Este estimador asignará a cada instancia del conjunto de datos –de la cual, al estar etiquetada, ya se sabe el valor de la variable binaria– un valor positivo o negativo.

Se puede, por tanto, dividir las diferentes instancias del conjunto de prueba en cuatro grupos: VP (verdaderos positivos), FN (falsos negativos), FP (falsos positivos) y VN (verdaderos negativos).

Definimos las siguientes medidas del estimador en relación a los datos de prueba:

$$exactitud = \frac{VP + VN}{VP + FN + VN + FP}$$

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

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

Normalmente, los estimadores realizan sus estimaciones en función de los valores de parámetros que incorporan en su descripción y suele ser interesante analizar el comportamiento de la sensibilidad y la especificidad en relación a dichos valores por medio de las llamadas curvas características operativas del receptor (ROC: *receiver operating curve*), en las cuáles se representa la *sensibilidad*, en el eje de las Y , y $(1 - especificidad)$, en el Eje de las X , para las diferentes parametrizaciones del estimador. Un ejemplo de curva ROC se puede ver en la Fig. 5.2.

5. RESULTADOS




Figura 5.2: Ejemplo de curva ROC. Fuente en [Wik14].

El análisis de la curva ROC, o simplemente análisis ROC, permite la selección de los modelos óptimos, usando diferentes criterios o estadísticos. El más utilizado en el ámbito de los clasificadores es el área bajo la curva ROC (*AUC: area under curve*), que permite realizar la comparación entre diferentes modelos de clasificación [HL05].

En el caso de poseer dos pruebas diagnósticas distintas, se utiliza el *AUC* como método de elección, ya que se trata de una medida global, además de independiente del punto de corte. Por esto, en el ámbito sanitario, las curvas ROC también se denominan curvas de rendimiento diagnóstico.

5.1.1.4 FUNDAMENTOS: Validación cruzada

La validación cruzada o *cross-validation* es una técnica que permite analizar los resultados de un análisis estadístico, asegurando que los datos son independientes del grupo formado con datos de entrenamiento y el grupo formado con datos de prueba. Su funcionamiento se basa en calcular la media aritmética obtenida de cada

5.1 Resultados parciales: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”

grupo formado, con la finalidad de estimar cómo de preciso es el modelo [Bis06].

Existen diferentes tipos de validaciones cruzadas, aquí se utiliza la validación cruzada de k iteraciones o *k-fold cross-validation*. En este tipo de validación los datos de muestra se dividen en k subconjuntos, donde uno de los subconjuntos es siempre utilizado como subconjunto de prueba y el resto de subconjuntos ($k - 1$) se utilizan para entrenar el clasificador. La validación cruzada se realiza durante k iteraciones, siendo cada subconjunto utilizado como datos de prueba en la validación. Por cada iteración se calcula la media aritmética de los resultados obteniendo un único resultado. La validación cruzada es un método muy preciso ya que se evalúa en cada iteración con diferentes combinaciones de datos. Sin embargo, tiene como inconveniente que es un proceso lento desde el punto de vista computacional [Bis06]. En cuanto a la elección del número de iteraciones, se puede realizar en función de diferentes criterios, siendo el tamaño del conjunto de datos el criterio más relevante. No obstante, lo más común es utilizar validación cruzada de 10 iteraciones (*10-fold cross-validation*) [RTL09]. Se puede ver gráficamente este proceso en la Fig. 5.3.

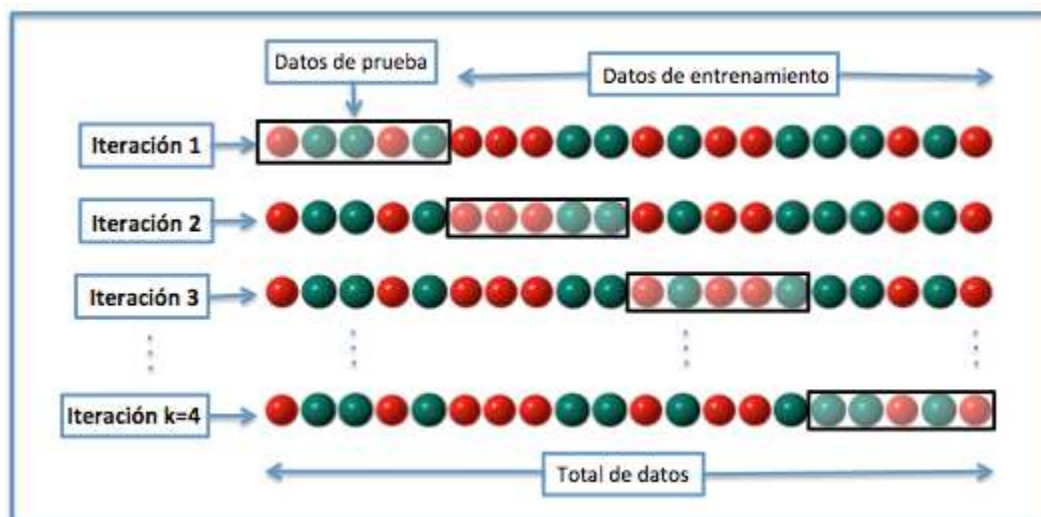


Figura 5.3: Ejemplo de validación cruzada de k iteraciones (con $k=4$). Fuente en [Wik11].

5. RESULTADOS

5.1.2 Ejemplos gráficos

Se van a mostrar a continuación –en las Figs. 5.4, 5.5 y 5.6, por una parte, y las Figs. 5.7, 5.8 y 5.9, por otra– dos ejemplos gráficos de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”, cuyo diseño se ha descrito en 4.3.1. Estas mismas dos imágenes se utilizarán en los ejemplos gráficos que se muestran en 5.2.2, correspondientes al módulo 2.

Como se puede ver, ambas imágenes tienen el patrón reticular. En el caso de la primera de las imágenes es más clara la presencia del patrón, sin embargo en la segunda de las imágenes dicha presencia no es tan clara, ya que la red es más tenue y además tiene menos retículos.

5.1 Resultados parciales: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”




Figura 5.4: A partir de la primera imagen dermatoscópica de ejemplo, ejemplo del proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} .

5. RESULTADOS




Figura 5.5: A partir de la primera imagen dermatoscópica de ejemplo, sigue con el ejemplo de la Fig. anterior –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} .

5.1 Resultados parciales: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”




Figura 5.6: A partir de la primera imagen dermatoscópica de ejemplo, sigue con el ejemplo de las dos Figs. anteriores –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Esta imagen de color es la imagen $I_{red_agujero_otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul.

5. RESULTADOS




Figura 5.7: A partir de la segunda imagen dermatoscópica de ejemplo, ejemplo del proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad. La primera imagen es la original I . La segunda, imagen de gris, es la imagen de probabilidad I_{red} .

5.1 Resultados parciales: Detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”




Figura 5.8: A partir de la segunda imagen dermatoscópica de ejemplo, sigue con el ejemplo de la Fig. anterior –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Estas dos imágenes de gris son las imágenes de probabilidad $I_{agujero}$ e I_{otro} .

5. RESULTADOS




Figura 5.9: A partir de la segunda imagen dermatoscópica de ejemplo, sigue con el ejemplo de las dos Figs. anteriores –proceso de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro” y generación de las imágenes de probabilidad–. Esta imagen de color es la imagen $I_{red.agujero.otro}$, resultante de asignar I_{red} al canal de rojo, $I_{agujero}$ al canal de verde e I_{otro} al canal de azul.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo

Sobre las imágenes de probabilidad obtenidas en el primer módulo se realiza en el segundo módulo un proceso de parametrización y posterior caracterización que permite, tras la realización de aprendizaje supervisado, la generación de diferentes modelos de clasificación dura –correspondientes a las diferentes combinaciones de parámetros– para la discriminación entre “ausente” y “presente”, tal y como se explica en 4.3.2.4, y la posterior selección del mejor modelo, tal y como se describe en 4.3.2.5. Aquí se muestran los resultados parciales correspondientes.

Para ello, en primer lugar, se presentan los resultados numéricos de los diferentes modelos de clasificación dura, realizándose la selección del mejor modelo y, en segundo lugar, se muestran dos ejemplos gráficos del proceso de caracterización realizado sobre las imágenes.

5.2.1 Resultados numéricos. Selección del mejor modelo

Tal y como se describe en 4.3.2.4, se generan modelos de clasificación dura para la discriminación entre “ausente” y “presente”, correspondientes a las 180 diferentes combinaciones de parámetros $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujero) \in \{0,5, 0,6, 0,7, 0,8, 0,9\} \times \{1, 2, 3\} \times \{10, 15, 20, 15\} \times \{0,5, 0,65, 0,8\}$.

Cada uno de ellos es generado utilizando la base de datos usada en este trabajo (descrita en el capítulo 3), que consiste en 875 imágenes, 326 “ausente” y 549 “presente”, correspondiendo aproximadamente esta distribución de imágenes a los porcentajes de ambas clases en el propio Atlas [ASP⁺00] –fuente de las imágenes de la base de datos– a partir de los valores extraídos, correspondientes a las 5 características $\{probRedMax, probAgujeroMax, numProbabilidades, numAgujeros, numSubredes\}$, y utilizando el Clasificador C4.5 [Qui93], un clasificador con muy buenas prestaciones y bajo coste computacional [WZA06], que se explica a continuación en 5.2.1.1, usando la implementación J48 incluida en el software Weka [The16b].

De cara a seleccionar el mejor modelo, la AUC y la exactitud son usados como

5. RESULTADOS

criterios para validar la fiabilidad y robustez de los modelos, siendo el AUC particularmente relevante cuando la base de datos no está balanceada, como es aquí el caso [HL05].

También es objeto de este análisis el seleccionar las características más relevantes de cara a simplificar el modelo resultante. Para realizar esto, y como únicamente se han contemplado 5 características, en vez de realizar el procedimiento habitual –analizar cada modelo de clasificación y realizar un análisis de sus características más relevantes– es posible validar por fuerza bruta los diferentes subconjuntos posibles de características. Para ello, por cada modelo de clasificación se obtienen $2^5 - 1 = 31$ modelos de clasificación, correspondiendo cada uno a un subconjunto de características.

Por tanto, se evaluaron un total de $5580 = 180 * 31$ modelo de clasificación, utilizando validación cruzada de 10 iteraciones. Los máximos valores de AUC y exactitud obtenidos fueron 0,912 y 88,91 % respectivamente. Buscando la mayor fiabilidad y robustez, únicamente fueron seleccionados dos modelos que cumplían las condiciones de tener una alta AUC ($\geq 0,9$) y una gran exactitud ($\geq 88\%$):

1. **Modelo 1.** AUC: 0,901, Accuracy: 88 %, (0,5, 20, 2, 0,65), $\{numProbabilidades, numAgujeros, numSubredes\}$.
2. **Modelo 2.** AUC: 0,912, Accuracy: 88 %, (0,5, 20, 2, 0,8), $\{numProbabilidades, numAgujeros\}$.

Obviamente, se seleccionó el que tenía mayor AUC, que además era el más simplificado, con sólo dos características. Este modelo de clasificación corresponde, como se ha mostrado, a la combinación de parámetros (0,5, 20, 2, 0,8) y el subconjunto de características $\{numProbabilidades, numAgujeros\}$, obteniendo AUC de 0,912 (la máxima AUC de todos los modelos) y una exactitud del 88 % (muy cerca de la máxima exactitud), con una sensibilidad de 90,71 % y una especificidad de 83,44 %, que fueron seleccionados como los resultados del método.

Es de señalar que existen modelos de clasificación en los que, para un determinado subconjunto de características y para una cierta combinación de parámetros se obtiene valores de exactitud ligeramente superiores. Sin embargo, en estos modelos la AUC fue menor (evidente, 0,912 es el mayor valor de AUC) y en algunos casos, además, la especificidad bajaba notablemente o el modelo era menos simpli-

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo

ficado. El objetivo aquí no es sacar el mejor valor de exactitud, sino que el modelo sea además simplificado, fiable y robusto, de ahí los criterios utilizados.

Para estos modelos, además del principal objetivo –obtener el mejor modelo de clasificación– es interesante llevar a cabo un estudio de los resultados tanto desde el punto de vista de los subconjuntos de características como desde el punto de vista de las combinaciones de parámetros. Para este propósito, se han definido 4 indicadores, que se describen más abajo. Por un lado, se agrupan los resultados por subconjuntos de características, como se puede ver en el Cuadro 5.1 –que muestra los resultados de los 31 subconjuntos de características– y, por el otro, se agrupan los resultados por combinaciones de parámetros, como se puede ver en los Cuadros 5.2 y 5.3, que muestran los resultados de las 10 combinaciones de parámetros con los resultados más altos en cada uno de los indicadores 1 y 3 (Cuadros 5.2) y 2 y 4 (Cuadro 5.3) que se describen a continuación.

Se pueden ver a continuación los 4 indicadores definidos como más relevantes para dicha descripción así como los valores obtenidos correspondientes a éstos en los experimentos: en la columna 1 se muestra el subconjunto de características (en Cuadro 5.1) / la combinación de parámetros (en Cuadros 5.2 y 5.3); en la 2, el indicador 1: la **media de AUC** obtenida, en los 180 modelos correspondientes a las diferentes combinaciones de parámetros (en Cuadro 5.1) / en los 31 modelos correspondientes a los diferentes subconjuntos de características (en Cuadros 5.2 y 5.3); en la 3, el indicador 2: el **máximo valor de AUC**: en la 4, la combinación de parámetros (en Cuadro 5.1) / el subconjunto de características (en Cuadros 5.2 y 5.3) correspondiente a ese valor máximo; en la 5, el indicador 3: la **media de las exactitudes** obtenidas; en la 6, el indicador 4: el **máximo valor de exactitud**; finalmente, en la 7, la combinación de parámetros (en Cuadro 5.1) / el subconjunto de características (en Cuadros 5.2 y 5.3) correspondiente a ese valor máximo.

5. RESULTADOS

| Características | Media AUC | AUC Max | Parámetros AUC Max | Media EXA | EXA Max | Parámetros EXA Max |
|------------------------|------------------|----------------|---------------------------|------------------|----------------|---------------------------|
| {1, 2, 3, 4, 5} | 0,845 | 0,902 | (0,6, 15, 2, 0,65) | 84,56 | 88,46 | (0,5, 25, 2, 0,5) |
| {1, 2, 3, 4} | 0,834 | 0,903 | (0,5, 10, 2, 0,8) | 84,66 | 88,57 | (0,5, 25, 2, 0,5) |
| {1, 2, 3, 5} | 0,806 | 0,902 | (0,6, 15, 2, 0,65) | 83,79 | 88,11 | (0,5, 10, 2, 0,65) |
| {1, 2, 4, 5} | 0,835 | 0,893 | (0,8, 15, 2, 0,8) | 83,66 | 87,54 | (0,8, 20, 2, 0,65) |
| {1, 3, 4, 5} | 0,846 | 0,905 | (0,6, 15, 2, 0,65) | 84,69 | 88,69 | (0,8, 15, 2, 0,8) |
| {2, 3, 4, 5} | 0,846 | 0,902 | (0,5, 10, 2, 0,8) | 84,7 | 88,69 | (0,5, 25, 2, 0,5) |
| {1, 2, 3} | 0,778 | 0,878 | (0,5, 20, 2, 0,8) | 83,86 | 87,66 | (0,6, 15, 3, 0,65) |
| {1, 2, 4} | 0,823 | 0,889 | (0,8, 10, 3, 0,8) | 83,94 | 87,54 | (0,7, 15, 3, 0,65) |
| {1, 2, 5} | 0,796 | 0,869 | (0,6, 15, 2, 0,65) | 82,19 | 86,63 | (0,7, 10, 2, 0,65) |
| {1, 3, 4} | 0,837 | 0,905 | (0,6, 15, 2, 0,65) | 84,72 | 88,69 | (0,6, 15, 3, 0,5) |
| {1, 3, 5} | 0,796 | 0,905 | (0,6, 15, 2, 0,65) | 83,85 | 87,77 | (0,5, 10, 2, 0,5) |
| {1, 4, 5} | 0,826 | 0,886 | (0,7, 25, 3, 0,65) | 83,25 | 88,91 | (0,6, 15, 3, 0,65) |
| {2, 3, 4} | 0,835 | 0,906 | (0,6, 15, 2, 0,65) | 84,74 | 88,69 | (0,5, 25, 2, 0,5) |
| {2, 3, 5} | 0,793 | 0,899 | (0,6, 15, 2, 0,65) | 83,8 | 88,34 | (0,5, 10, 2, 0,65) |
| {2, 4, 5} | 0,768 | 0,846 | (0,9, 15, 1, 0,65) | 80,46 | 83,43 | (0,5, 10, 3, 0,5) |
| {3, 4, 5} | 0,848 | 0,909 | (0,5, 20, 2, 0,8) | 84,86 | 88,69 | (0,5, 25, 2, 0,5) |
| {1, 2} | 0,759 | 0,845 | (0,6, 15, 3, 0,8) | 82,1 | 84,91 | (0,5, 10, 3, 0,8) |
| {1, 3} | 0,761 | 0,879 | (0,5, 20, 2, 0,8) | 83,65 | 87,66 | (0,5, 20, 3, 0,65) |
| {1, 4} | 0,815 | 0,864 | (0,6, 10, 3, 0,8) | 83,47 | 86,17 | (0,7, 15, 3, 0,65) |
| {1, 5} | 0,76 | 0,866 | (0,8, 10, 3, 0,8) | 81,29 | 85,37 | (0,8, 10, 2, 0,5) |
| {2, 3} | 0,76 | 0,878 | (0,6, 15, 3, 0,5) | 83,6 | 87,66 | (0,5, 20, 3, 0,65) |
| {2, 4} | 0,701 | 0,808 | (0,9, 10, 3, 0,65) | 80,3 | 84,0 | (0,9, 10, 3, 0,5) |
| {2, 5} | 0,599 | 0,797 | (0,9, 10, 3, 0,8) | 73,18 | 83,77 | (0,9, 10, 3, 0,8) |
| {3, 4} | 0,837 | 0,912 | (0,5, 20, 2, 0,8) | 84,87 | 88,69 | (0,5, 25, 2, 0,5) |
| {3, 5} | 0,778 | 0,905 | (0,6, 15, 2, 0,65) | 83,84 | 88,0 | (0,5, 10, 2, 0,5) |
| {4, 5} | 0,755 | 0,841 | (0,8, 15, 1, 0,65) | 80,78 | 84,23 | (0,7, 25, 1, 0,5) |
| {1} | 0,677 | 0,764 | (0,7, 10, 3, 0,5) | 80,1 | 83,66 | (0,7, 15, 3, 0,65) |
| {2} | 0,453 | 0,516 | (0,5, 25, 1, 0,5) | 63,39 | 68,46 | (0,9, 10, 3, 0,5) |
| {3} | 0,745 | 0,876 | (0,5, 20, 2, 0,8) | 83,61 | 87,66 | (0,5, 20, 3, 0,65) |
| {4} | 0,69 | 0,807 | (0,9, 10, 3, 0,65) | 80,45 | 84,0 | (0,9, 10, 3, 0,5) |
| {5} | 0,584 | 0,76 | (0,7, 10, 3, 0,65) | 73,27 | 83,09 | (0,9, 10, 3, 0,8) |

Cuadro 5.1: Valores obtenidos en los experimentos para los 4 indicadores definidos como más relevantes, usando validación cruzada de 10 iteraciones, agrupando los resultados por subconjuntos de características (AUC: *area under curve*, EXA: exactitud).

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo

Una vez analizados los resultados obtenidos en el Cuadro 5.1, usando los mismos criterios para generar modelos simplificados, robustos y fiables, se encontró que el mejor subconjunto de características es el compuesto por $\{3, 4\}$, llamadas $\{numProbabilidades, numAgujeros\}$, con el que se obtuvieron los mayores valores en los indicadores 2 y 3, el 2º en el 4 y el 5º en el 1, lo cual significa que estas características contienen la mayoría de la información. La característica con mayor importancia fue *numProbabilidades*, que obtiene AUC de 0,876, precisamente con la misma combinación de parámetros (0,5, 20, 2, 0,8) correspondiente al modelo elegido como mejor.

Comparando en los Cuadros 5.2 y 5.3 las 180 combinaciones de parámetros, se puede ver que las combinaciones (0,5, 20, 2, 0,8) y (0,6, 15, 2, 0,65) estuvieron entre las mejores elecciones. Tal y como se muestra, el primero tiene el mayor valor en el indicador 3, el 3º en el 1 y el 7º en el 4, mientras que el segundo tiene en dichos indicadores el 2º, 2º y 9º, respectivamente. La primera de las combinaciones tiene sus buenos resultados en conjunción con las características $\{numProbabilidades, numAgujeros\}$, correspondiendo precisamente el mejor modelo de clasificación a esta combinación de parámetros y este subconjunto de características. Otro interesante resultado son los malos resultados de las combinaciones de parámetros tales que $numMinAgujeros = 1$, que están en los últimos puestos en todos los indicadores (esto no se ve en estas tablas que únicamente contienen los mejores resultados).

5. RESULTADOS

| Parámetros | Media AUC | AUC Max | Caract. AUC Max | Media EXA | EXA Max | Caract. EXA Max |
|---|-----------|---------|-----------------|-----------|---------|-----------------|
| <i>10 primeros en el indicador 1 Media de AUC</i> | | | | | | |
| (0,5, 10, 2, 0,8) | 0,815 | 0,903 | {1, 2, 3, 4} | 83,74 | 87,77 | {3, 4} |
| (0,6, 15, 2, 0,65) | 0,811 | 0,909 | {3, 4} | 82,72 | 88,0 | {3, 4, 5} |
| (0,5, 20, 2, 0,8) | 0,811 | 0,912 | {3, 4} | 82,3 | 88,0 | {3, 4} |
| (0,6, 15, 3, 0,5) | 0,807 | 0,881 | {1, 3, 4} | 84,27 | 88,69 | {1, 3, 4} |
| (0,5, 15, 2, 0,8) | 0,806 | 0,903 | {1, 3, 4} | 83,02 | 87,77 | {1, 2, 3, 5} |
| (0,5, 15, 3, 0,65) | 0,802 | 0,899 | {1, 3, 4, 5} | 83,87 | 87,54 | {2, 3, 5} |
| (0,6, 15, 2, 0,8) | 0,802 | 0,901 | {3, 4, 5} | 82,63 | 87,77 | {3, 4, 5} |
| (0,7, 25, 3, 0,65) | 0,801 | 0,894 | {3, 4} | 83,43 | 87,31 | {1, 3, 4} |
| (0,8, 10, 3, 0,8) | 0,801 | 0,889 | {1, 2, 4} | 82,28 | 85,26 | {2, 3} |
| (0,8, 10, 2, 0,65) | 0,801 | 0,902 | {3, 5} | 83,25 | 87,66 | {1, 3, 5} |
| (0,9, 10, 3, 0,65) | 0,801 | 0,851 | {1, 4, 5} | 82,79 | 86,74 | {1, 2, 3, 4} |
| (0,9, 10, 3, 0,5) | 0,8 | 0,877 | {3, 4, 5} | 82,95 | 85,37 | {1, 2, 3} |
| <i>10 primeros en el indicador 3 Media de EXA</i> | | | | | | |
| (0,5, 10, 2, 0,65) | 0,78 | 0,869 | {1, 2, 3, 5} | 84,55 | 88,34 | {2, 3, 5} |
| (0,7, 15, 3, 0,65) | 0,757 | 0,866 | {1, 3, 4} | 84,34 | 87,54 | {1, 2, 4} |
| (0,6, 15, 3, 0,5) | 0,807 | 0,881 | {1, 3, 4} | 84,27 | 88,69 | {1, 3, 4} |
| (0,5, 10, 3, 0,65) | 0,778 | 0,846 | {1, 2, 5} | 84,24 | 87,2 | {3, 4} |
| (0,5, 10, 3, 0,8) | 0,777 | 0,881 | {1, 2, 4} | 84,12 | 87,2 | {2, 3, 4, 5} |
| (0,5, 15, 3, 0,5) | 0,772 | 0,879 | {1, 2, 4, 5} | 84,03 | 87,2 | {1, 2, 3} |
| (0,5, 10, 2, 0,5) | 0,784 | 0,86 | {1, 2, 3, 5} | 84,0 | 88,57 | {3, 4, 5} |
| (0,7, 10, 2, 0,8) | 0,778 | 0,873 | {1, 4, 5} | 83,95 | 87,54 | {3, 4} |
| (0,5, 15, 3, 0,65) | 0,802 | 0,899 | {1, 3, 4, 5} | 83,87 | 87,54 | {2, 3, 5} |
| (0,7, 10, 2, 0,5) | 0,782 | 0,878 | {3, 5} | 83,87 | 86,86 | {2, 3, 4, 5} |
| (0,9, 10, 3, 0,8) | 0,792 | 0,868 | {1, 2, 3, 4} | 83,87 | 86,74 | {1, 3, 5} |
| (0,6, 10, 3, 0,5) | 0,767 | 0,841 | {1, 2, 5} | 83,86 | 86,4 | {1, 3, 4, 5} |

Cuadro 5.2: Valores obtenidos en los experimentos para los 4 indicadores definidos como más relevantes, usando validación cruzada de 10 iteraciones, agrupando los resultados por combinaciones de parámetros y mostrando únicamente los 10 primeros relativos a los indicadores 1 y 3 (AUC: *area under curve*, EXA: exactitud).

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo

| Parámetros | Media AUC | AUC Max | Caract. AUC Max | Media EXA | EXA Max | Caract. EXA Max |
|---|-----------|---------|-----------------|-----------|---------|-----------------|
| <i>10 primeros en el indicador 2 AUC Máximo</i> | | | | | | |
| (0,5, 20, 2, 0,8) | 0,811 | 0,912 | {3, 4} | 82,3 | 88,0 | {3, 4} |
| (0,6, 15, 2, 0,65) | 0,811 | 0,909 | {3, 4} | 82,72 | 88,0 | {3, 4, 5} |
| (0,5, 10, 2, 0,8) | 0,815 | 0,903 | {1, 2, 3, 4} | 83,74 | 87,77 | {3, 4} |
| (0,5, 15, 2, 0,8) | 0,806 | 0,903 | {1, 3, 4} | 83,02 | 87,77 | {1, 2, 3, 5} |
| (0,8, 10, 2, 0,65) | 0,801 | 0,902 | {3, 5} | 83,25 | 87,66 | {1, 3, 5} |
| (0,5, 20, 2, 0,65) | 0,788 | 0,901 | {3, 4, 5} | 83,79 | 88,34 | {1, 2, 3, 4} |
| (0,6, 15, 2, 0,8) | 0,802 | 0,901 | {3, 4, 5} | 82,63 | 87,77 | {3, 4, 5} |
| (0,5, 25, 2, 0,8) | 0,791 | 0,9 | {3, 4} | 82,31 | 86,74 | {1, 3, 5} |
| (0,6, 15, 3, 0,65) | 0,791 | 0,9 | {1, 2, 3, 4, 5} | 83,84 | 88,91 | {1, 4, 5} |
| (0,5, 15, 3, 0,65) | 0,802 | 0,899 | {1, 3, 4, 5} | 83,87 | 87,54 | {2, 3, 5} |
| (0,6, 10, 3, 0,65) | 0,777 | 0,897 | {2, 3, 5} | 83,76 | 86,63 | {1, 2, 3} |
| (0,6, 25, 2, 0,65) | 0,775 | 0,896 | {2, 3, 4} | 82,07 | 86,63 | {1, 3, 4} |
| <i>10 primeros en el indicador 4 EXA Máxima</i> | | | | | | |
| (0,6, 15, 3, 0,65) | 0,791 | 0,9 | {1, 2, 3, 4, 5} | 83,84 | 88,91 | {1, 4, 5} |
| (0,5, 25, 2, 0,5) | 0,766 | 0,884 | {1, 2, 3, 4, 5} | 83,76 | 88,69 | {2, 3, 4, 5} |
| (0,6, 15, 3, 0,5) | 0,807 | 0,881 | {1, 3, 4} | 84,27 | 88,69 | {1, 3, 4} |
| (0,8, 15, 2, 0,8) | 0,791 | 0,894 | {2, 3, 4, 5} | 82,67 | 88,69 | {1, 3, 4, 5} |
| (0,5, 10, 2, 0,5) | 0,784 | 0,86 | {1, 2, 3, 5} | 84,0 | 88,57 | {3, 4, 5} |
| (0,5, 25, 3, 0,8) | 0,775 | 0,887 | {3, 4} | 82,85 | 88,46 | {3, 4} |
| (0,5, 10, 2, 0,65) | 0,78 | 0,869 | {1, 2, 3, 5} | 84,55 | 88,34 | {2, 3, 5} |
| (0,5, 20, 2, 0,65) | 0,788 | 0,901 | {3, 4, 5} | 83,79 | 88,34 | {1, 2, 3, 4} |
| (0,5, 20, 2, 0,8) | 0,811 | 0,912 | {3, 4} | 82,3 | 88,0 | {3, 4} |
| (0,5, 25, 3, 0,65) | 0,767 | 0,869 | {1, 2, 4} | 83,52 | 88,0 | {3, 4, 5} |
| (0,6, 15, 2, 0,65) | 0,811 | 0,909 | {3, 4} | 82,72 | 88,0 | {3, 4, 5} |
| (0,6, 15, 3, 0,8) | 0,797 | 0,895 | {3, 4} | 83,8 | 88,0 | {3, 4, 5} |

Cuadro 5.3: Valores obtenidos en los experimentos para los 4 indicadores definidos como más relevantes, usando validación cruzada de 10 iteraciones, agrupando los resultados por combinaciones de parámetros y mostrando únicamente los 10 primeros relativos a los indicadores 2 y 4 (AUC: *area under curve*, EXA: exactitud).

5. RESULTADOS

5.2.1.1 FUNDAMENTOS: Clasificador C4.5

El algoritmo C4.5 [Qui93] es un clasificador desarrollado por el ingeniero Ross Quinlan basado en árboles de decisión, extensión del algoritmo previo ID3 [Qui86] del mismo autor. Este algoritmo construye árboles de decisión a partir de un conjunto de datos etiquetados usando el concepto de entropía de la información, que mide la incertidumbre asociada con una variable aleatoria.

Formalmente, se parte de:

1. Un conjunto de muestras o datos de entrenamiento $S = \{s_1, s_2, \dots, s_n\}$, donde $\forall i = 1, \dots, n$ se tiene que $s_i = \{x_{i1}, x_{i2}, \dots, x_{im}\}$ es el vector correspondiente a cada muestra y $\forall j = 1, \dots, m$ se tiene que x_{ij} son las características del mismo.
2. Un conjunto $C = \{c_1, c_2, \dots, c_n\}$, donde $\forall i = 1, \dots, n$ se tiene que c_i indica a qué clase pertenece la muestra s_i .

El proceso consiste en recorrer cada nodo del árbol, dividiendo las muestras en subconjuntos de una clase y otra seleccionando el que los divide de manera más eficaz. Para realizar esta selección, el algoritmo C4.5 usa como criterio seleccionar el atributo con la mayor diferencia de entropía. Tras ello, el árbol es dividido de manera recursiva obteniendo sublistas hasta llegar a los siguientes casos base:

- Las listas se encuentran formadas por muestras de una misma clase. En este caso, el nodo de hoja resultante es el del valor de la muestra.
- Las características no ofrecen una mayor diferencia de entropía. Cuando esto sucede, se calcula el valor esperado creando un nodo de decisión en un nivel superior del árbol.
- El valor de la clase no ha sido visto anteriormente. De forma similar al caso anterior, se calcula el valor esperado creando un nodo de decisión en un nivel superior del árbol.

Es un algoritmo frecuentemente utilizado por sus buenos resultados en la clasificación de los datos y su bajo coste computacional [WZA06]. No soporta la clasificación difusa o blanda, únicamente soporta la clasificación dura.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo

5.2.2 Ejemplos gráficos

Se continúa con las dos imágenes de ejemplo utilizadas en 5.1.2, donde se mostraba gráficamente el resultado de la aplicación del módulo 1 de detección difusa o *fuzzy* de los pixels de tipo “red”, “agujero” y “otro”. A continuación –en las Figs. 5.10, 5.11, 5.12, 5.13, 5.14, 5.15, 5.16, 5.17, 5.18, 5.19, 5.20, 5.21, 5.22, 5.23, 5.24, 5.25, 5.26, 5.27, 5.28, 5.29, 5.30, 5.31– se van a mostrar varios ejemplos gráficos con el resultado de la aplicación sobre estas imágenes de la generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” del módulo 2, cuyo diseño se ha descrito en 4.3.2.4.

Tal y como se comentaba, ambas imágenes tienen el patrón reticular. En el caso de la primera de las imágenes es muy clara la presencia del patrón, sin embargo en la segunda de las imágenes dicha presencia no es tan clara, ya que la red es más tenue y además tiene menos retículos.

En el caso de los ejemplos correspondientes a la tarea 3, se muestran para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (2, 20, 0,8)$ y, en el caso de los ejemplos de la tarea 4, se muestran para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$, en ambos casos valores correspondientes al mejor modelo.

5. RESULTADOS

5.2.2.1 Tarea 1: Generación de las máscaras correspondientes a los α – cortes para cada α_{red} y para cada $\alpha_{agujero}$ e intersección con la máscara de segmentación




Figura 5.10: A partir de la primera imagen, en la tarea 1, ejemplos de máscaras $BW_{red}^{\alpha_{red}}$ extraídas de la imagen de probabilidad I_{red} correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para α_{red} e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,1}$; 2: $BW_{red}^{0,2}$; 3: $BW_{red}^{0,3}$; 4: $BW_{red}^{0,4}$; 5: $BW_{red}^{0,5}$; 6: $BW_{red}^{0,6}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.11: A partir de la segunda imagen, en la tarea 1, ejemplos de máscaras $BW_{red}^{\alpha_{red}}$ extraídas de la imagen de probabilidad I_{red} correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para α_{red} e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{red}^{0,1}$; 2: $BW_{red}^{0,2}$; 3: $BW_{red}^{0,3}$; 4: $BW_{red}^{0,4}$; 5: $BW_{red}^{0,5}$; 6: $BW_{red}^{0,6}$.

5. RESULTADOS




Figura 5.12: A partir de la primera imagen, en la tarea 1, ejemplos de máscaras $BW_{agujero}^{\alpha_{agujero}}$ extraídas de la imagen de probabilidad $I_{agujero}$ correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para $\alpha_{agujero}$ e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{agujero}^{0,1}$; 2: $BW_{agujero}^{0,2}$; 3: $BW_{agujero}^{0,3}$; 4: $BW_{agujero}^{0,4}$; 5: $BW_{agujero}^{0,5}$; 6: $BW_{agujero}^{0,6}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.13: A partir de la segunda imagen, en la tarea 1, ejemplos de máscaras $BW_{agujero}^{\alpha_{agujero}}$ extraídas de la imagen de probabilidad $I_{agujero}$ correspondientes a varios α – cortes obtenidos usando diferentes valores de probabilidad para $\alpha_{agujero}$ e intersectando con la máscara de segmentación (mostrada en la Fig. 4.9): 1: $BW_{agujero}^{0,1}$; 2: $BW_{agujero}^{0,2}$; 3: $BW_{agujero}^{0,3}$; 4: $BW_{agujero}^{0,4}$; 5: $BW_{agujero}^{0,5}$; 6: $BW_{agujero}^{0,6}$.

5. RESULTADOS




Figura 5.14: A partir de la primera imagen, en la tarea 1, ejemplos de máscaras $BW_{agujeros}^{\alpha_{red}}$ de agujeros de $BW_{red}^{\alpha_{red}}$: 1: $BW_{agujeros}^{0,1}$; 2: $BW_{agujeros}^{0,2}$; 3: $BW_{agujeros}^{0,3}$; 4: $BW_{agujeros}^{0,4}$; 5: $BW_{agujeros}^{0,5}$; 6: $BW_{agujeros}^{0,6}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.15: A partir de la segunda imagen, en la tarea 1, ejemplos de máscaras $BW_{agujerosdered}^{\alpha_{red}}$ de agujeros de $BW_{red}^{\alpha_{red}}$: 1: $BW_{agujerosdered}^{0,1}$; 2: $BW_{agujerosdered}^{0,2}$; 3: $BW_{agujerosdered}^{0,3}$; 4: $BW_{agujerosdered}^{0,4}$; 5: $BW_{agujerosdered}^{0,5}$; 6: $BW_{agujerosdered}^{0,6}$.

5. RESULTADOS

5.2.2.2 Tarea 2: Selección de los agujeros de tamaño adecuado para cada α_{red}




Figura 5.16: A partir de la primera imagen, en la tarea 2, las máscaras $BW_{agujerosdered}^{\alpha_{red}}$ de la tarea anterior, modificadas tras la selección de agujeros de tamaño adecuado: 1: $BW_{agujerosdered}^{0,1}$; 2: $BW_{agujerosdered}^{0,2}$; 3: $BW_{agujerosdered}^{0,3}$; 4: $BW_{agujerosdered}^{0,4}$; 5: $BW_{agujerosdered}^{0,5}$; 6: $BW_{agujerosdered}^{0,6}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.17: A partir de la segunda imagen, en la tarea 2, las máscaras $BW_{agujerosdered}^{\alpha_{red}}$ de la tarea anterior, modificadas tras la selección de agujeros de tamaño adecuado: 1: $BW_{agujerosdered}^{0,1}$; 2: $BW_{agujerosdered}^{0,2}$; 3: $BW_{agujerosdered}^{0,3}$; 4: $BW_{agujerosdered}^{0,4}$; 5: $BW_{agujerosdered}^{0,5}$; 6: $BW_{agujerosdered}^{0,6}$.

5. RESULTADOS

5.2.2.3 Tarea 3: Selección de los agujeros agrupados en alguna subred para cada α_{red}




Figura 5.18: A partir de la primera imagen, en la tarea 3, a partir de las $BW_{agujeros}^{\alpha_{red}}$ de la tarea anterior y para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (2, 20, 0, 8)$, las diferentes imágenes de color $I_{conjuntodesubredes}^{\alpha_{red}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas: 1: $I_{conjuntodesubredes}^{0,1}$; 2: $I_{conjuntodesubredes}^{0,2}$; 3: $I_{conjuntodesubredes}^{0,3}$; 4: $I_{conjuntodesubredes}^{0,4}$; 5: $I_{conjuntodesubredes}^{0,5}$; 6: $I_{conjuntodesubredes}^{0,6}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.19: A partir de la segunda imagen, en la tarea 3, a partir de las $BW_{agujeros}^{\alpha_{red}}$ de la tarea anterior y para valores de $(numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (2, 20, 0, 8)$, las diferentes imágenes de color $I_{conjuntodesubredes}^{\alpha_{red}}$, en las que se pinta de un color diferente cada una de las subredes en las que se agrupan los agujeros, que además son numeradas: 1: $I_{conjuntodesubredes}^{0,1}$; 2: $I_{conjuntodesubredes}^{0,2}$; 3: $I_{conjuntodesubredes}^{0,3}$; 4: $I_{conjuntodesubredes}^{0,4}$; 5: $I_{conjuntodesubredes}^{0,5}$; 6: $I_{conjuntodesubredes}^{0,6}$.

5. RESULTADOS

5.2.2.4 Tarea 4: Selección de los agujeros que pertenecen a la red pigmentada para cada $(\alpha_{red}, \alpha_{agujero})$

A partir del procesamiento anterior se seleccionan los agujeros de la estructura reticular de cara a la posterior extracción de características.

Esto gráficamente se puede ver en las imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados).

Tal y como se ha comentado anteriormente, se muestran para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$, valores correspondientes al seleccionado como mejor modelo.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.20: A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 1: $I_{RP}^{(0,2,0,3)}$; 2: $I_{RP}^{(0,2,0,4)}$.

5. RESULTADOS




Figura 5.21: A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 3: $I_{RP}^{(0,2,0,5)}$; 4: $I_{RP}^{(0,3,0,3)}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.22: A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 5: $I_{RP}^{(0,3,0,4)}$; 6: $I_{RP}^{(0,3,0,5)}$.

5. RESULTADOS




Figura 5.23: A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 7: $I_{RP}^{(0,4,0,3)}$; 8: $I_{RP}^{(0,4,0,4)}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.24: A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 9: $I_{RP}^{(0,4,0,5)}$; 10: $I_{RP}^{(0,5,0,3)}$.

5. RESULTADOS




Figura 5.25: A partir de la primera imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 11: $I_{RP}^{(0,5,0,4)}$; 12: $I_{RP}^{(0,5,0,5)}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo




Figura 5.26: A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 1: $I_{RP}^{(0,2,0,3)}$; 2: $I_{RP}^{(0,2,0,4)}$.

5. RESULTADOS




Figura 5.27: A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 3: $I_{RP}^{(0,2,0,5)}$; 4: $I_{RP}^{(0,3,0,3)}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo





Figura 5.28: A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 5: $I_{RP}^{(0,3,0,4)}$; 6: $I_{RP}^{(0,3,0,5)}$.

5. RESULTADOS




Figura 5.29: A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 7: $I_{RP}^{(0,4,0,3)}$; 8: $I_{RP}^{(0,4,0,4)}$.

5.2 Resultados parciales: Generación de modelos de clasificación dura para la discriminación entre “ausente” y “presente” y selección del mejor modelo





Figura 5.30: A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 9: $I_{RP}^{(0,4,0,5)}$; 10: $I_{RP}^{(0,5,0,3)}$.

5. RESULTADOS



Figura 5.31: A partir de la segunda imagen, en la tarea 4, imágenes de detección de la red pigmentada $I_{RP}^{(\alpha_{red}, \alpha_{agujero})}$, en las que se muestran gráficamente los agujeros que pertenecen a la red pigmentada, correspondientes a $BW_{agujerosseleccionados}^{(\alpha_{red}, \alpha_{agujero})}$ (en verde los agujeros seleccionados y en azul los no seleccionados), para valores de $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$: 11: $I_{RP}^{(0,5,0,4)}$; 12: $I_{RP}^{(0,5,0,5)}$.

5.3 Resultados finales: Reconocimiento del patrón red pigmentada o reticular

5.3 Resultados finales: Reconocimiento del patrón red pigmentada o reticular

Tal y como se ha visto en 5.2.1, se ha seleccionado el subconjunto de características $\{numProbabilities, numAgujeros\}$ y la combinación de parámetros $(prop, numMinAgujeros, distMaxAgujeros, rangMaxTamanyoAgujeros) = (0,5, 2, 20, 0,8)$, teniendo el modelo resultante una AUC de 0,912 y una exactitud del 88 %, con una sensibilidad de 90,71 % y una especificidad de 83,44 %. Estos son considerados los resultados de este método.

A continuación, en primer lugar, se va a realizar un análisis del comportamiento del método ante la diferente casuística de imágenes presente en la base de datos y, en segundo lugar, se va a llevar a cabo una comparación entre el método propuesto y los métodos más relevantes del estado del arte.

5.3.1 Análisis del comportamiento del método frente a las imágenes de la base de datos

Analizando la diagnosis realizada en las 875 imágenes, se observa que el algoritmo es muy fiable y robusto, teniendo éxito incluso con imágenes en las que es difícil el reconocimiento del patrón. La mayoría de los errores corresponden a imágenes en las cuales es difícil discernir la presencia del patrón o en imágenes en las cuáles su etiquetado tiene cierto grado de subjetividad, algo especialmente relevante en el caso de las “imágenes frontera”, cuyo etiquetado es muy discutible, en las que, aunque el sistema funcione bien, pueda existir un diagnóstico incorrecto respecto al etiquetado previo. Realmente, tal y como se comentaba en la especificación del sistema en 4.1.3, en el análisis de los resultados hay que tener en cuenta que un sistema de reconocimiento de un patrón dermatoscópico, en este caso red pigmentada o reticular, es validado contra un etiquetado previo realizado por expertos dermatólogos, que es de naturaleza subjetiva, en contraposición con, por ejemplo, un sistema diagnóstico que decida si una lesión tiene melanoma o no, habiendo sido ésta diagnosticada de manera histopatológica, que es un etiquetado de naturaleza puramente objetiva.

Se observa además que el método reconoce bien el patrón aún en presencia de artefactos, tal y como se puede ver por ejemplo en las Figs. 5.35 y 5.36. De

5. RESULTADOS

hecho, tal y como se comentaba en 4.2.3, frente a la mayoría de los trabajos del estado del arte para el reconocimiento del patrón reticular, en este algoritmo no se necesita realizar un preprocesado previo de la imagen con el fin de detectar y eliminar artefactos distorsionadores tales como pelos, reflejos, marcas, reglas o burbujas, y de hecho no se recomienda hacerlo ya que puede dar lugar a errores, bien en el proceso de detección porque grupos de pixels que forman parte de un patrón puedan ser incorrectamente reconocidos como parte de los artefactos, o bien en el proceso de eliminación de los artefactos –la restauración– de la imagen porque ésta sea modificada erróneamente.

Asimismo, se comprueba que el algoritmo es robusto frente a la no segmentación, tal y como se puede ver en las imágenes de probabilidad generadas en el módulo 1, por ejemplo en las Figs. 4.16, 4.17, 4.18, 4.19, 4.26, 4.27, 4.28, 5.4, 5.5, 5.6, 5.7, 5.8 y 5.9. De hecho este algoritmo no necesita en casi la totalidad de las ocasiones una segmentación previa. Realmente, ésta sólo es necesaria con el fin de evitar el efecto que puede causar la posible presencia –normalmente muy fina y tenue– de la red pigmentada en la piel que está en el exterior de la lesión, algo que sólo dará problemas al algoritmo de reconocimiento del patrón reticular en el caso de que la lesión además no tenga el patrón reticular, lo cual se da en poquísimas ocasiones.

También se puede comprobar que en este método funciona muy bien la discriminación del patrón reticular con respecto a otros patrones dermatoscópicos, tal y como se puede ver por ejemplo en todas las Figs. que se muestran a continuación. Ello es consecuencia de cómo se ha realizado el diseño del algoritmo de reconocimiento del patrón reticular (patrón definido a partir de dos subpatrones, enfoque difuso, caracterización, ...).

A continuación –en las Figs. 5.32, 5.33, 5.34, 5.35, 5.36 y 5.37– se van a mostrar los resultados del método frente a algunos ejemplos de la base de datos de imágenes.

5.3 Resultados finales: Reconocimiento del patrón red pigmentada o reticular




Figura 5.32: Dos ejemplos claros de presencia del patrón red pigmentada (con la categoría de “presente”), en los cuales el método funciona correctamente. Ejemplos de VP (verdadero positivo).



Figura 5.33: Dos ejemplos claros de no presencia del patrón red pigmentada (con la categoría de “ausente”), en los cuales el método funciona correctamente. Ejemplos de VN (verdadero negativo).

5. RESULTADOS




Figura 5.34: Cuatro ejemplos de imágenes categorizadas con patrón red pigmentada (categorizadas como “presente”) en los que la estructura tiene bajo contraste y la red es muy tenue, además en la última de ellas hay muy pocos agujeros, en los cuales el método funciona correctamente. Ejemplos de VP (verdadero positivo).




Figura 5.35: Dos ejemplos de imágenes en las cuales la presencia de pelos dificulta el reconocimiento del patrón red pigmentada, una “presente” y la otra “ausente”, en los cuales el método funciona correctamente. La primera sería un ejemplo de VP (verdadero positivo) y la segunda sería un ejemplo de VN (verdadero negativo).

5.3 Resultados finales: Reconocimiento del patrón red pigmentada o reticular




Figura 5.36: Cuatro ejemplos de imágenes en las cuales la presencia de aceite dificulta el reconocimiento del patrón red pigmentada, dos “presente” y la otras dos “ausente”, en los cuales el método funciona correctamente. Las dos primeras serían ejemplos de VP (verdadero positivo) y las dos siguientes serían ejemplos de VN (verdadero negativo).




Figura 5.37: Dos ejemplos de “imágenes frontera”, una “presente” y la otra “ausente”, en las cuales el etiquetado es muy discutible, en los cuales el método no funciona correctamente. La primera sería un ejemplo de FN (falso negativo) y la segunda sería un ejemplo de FP (falso positivo).

5. RESULTADOS

5.3.2 Comparación entre el método propuesto y los métodos más relevantes del estado del arte

En el capítulo del estado del arte, en 2.2.3.3, se han mostrado los resultados de los métodos más relevantes del estado del arte en el reconocimiento del patrón reticular. A continuación, en el Cuadro 5.4, se muestra la comparación numérica entre el método propuesto y dichos métodos.

Tal y como se puede ver, el método propuesto tiene la mayor cantidad de imágenes del estado del arte, un total de 875, teniendo además los mejores resultados, con la posible excepción del trabajo de Sadeghi et al. [SRLA11], que tiene una exactitud algo más alta. Para realizar una mejor comparación con este trabajo se necesitaría tener más datos acerca de la generación del modelo de clasificación en dicho trabajo y las imágenes empleadas, además de otras métricas de evaluación como AUC, sensibilidad y especificidad.

En cualquier caso, examinando los diseños de estos métodos se hace evidente que el método propuesto aquí es mucho mejor. En estos tres métodos se realiza la detección de la red y agujeros usando –en los dos primeros casos tras una transformación de la imagen a la escala de grises– un filtro laplaciano del gaussiano (LoG: *laplacian of gaussian*) en el primero, un banco de filtros direccionales en el segundo y un proceso de aprendizaje supervisado a nivel de pixels a partir de características de color y textura –espectrales y estadísticas– en el tercero y, posteriormente, se utilizan diferentes operaciones morfológicas y estructurales para la posterior caracterización. Parece claro que el enfoque difuso o *fuzzy* planteado aquí es superior.

5.3 Resultados finales: Reconocimiento del patrón red pigmentada o reticular

| Trabajos | # Imágenes | Resultados |
|--|-------------------|---|
| Sadeghi et al. 2011 [SRLA11] | 500 | 94,30 % EXA |
| Barata et al. 2012 [BMR12b] | 200 | 91,1 % SE 82,1 % ES |
| García-Arroyo y García-Zapirain 2014 [GAGZ14] | 220 | 86 % SE 81,67 % ES 83,64 % EXA |
| TRABAJO PROPUESTO | 875 | 90,71 % SE 83,44 % ES 88 % EXA 0,912 AUC |

Cuadro 5.4: Resultados de los trabajos más relevantes en el reconocimiento del patrón reticular (SE: sensibilidad, ES: especificidad, EXA: exactitud y AUC: *area under curve*).

Now this is not the end. It is not even the beginning of the end. But it is, perhaps, the end of the beginning.

Winston Churchill

CAPÍTULO

6

Conclusiones

En este capítulo se presentan las conclusiones derivadas del desarrollo de la presente investigación. Para ello, en primer lugar, se analiza el cumplimiento de los objetivos de la investigación, indicados en el capítulo de introducción. En segundo lugar, se muestran todas las contribuciones realizadas, de manera especialmente detallada las correspondientes al algoritmo de reconocimiento del patrón reticular, que constituye la principal aportación de esta investigación desde el punto de vista científico-tecnológico. En tercer lugar, se describe el impacto científico del trabajo realizado. Finalmente, en cuarto lugar, se analizan las líneas futuras de investigación.

6.1 Cumplimiento de objetivos

En esta sección vamos a analizar el cumplimiento de los objetivos de la investigación, indicados en el capítulo de introducción 1.3.

El objetivo general que se ha planteado en esta investigación es: *“Diseñar y desarrollar una familia de algoritmos de procesamiento digital de imagen para la segmentación de la lesión y la detección y caracterización de diferentes indicadores, centrándose especialmente en los patrones dermatoscópicos, de cara a*

6. CONCLUSIONES

ser integrados en un sistema software para el diagnóstico de melanoma basado en alguno de los algoritmos médicos para el diagnóstico de melanoma”.

Este objetivo general se detalla en una secuencia de objetivos específicos, cuyo grado de cumplimiento se va a analizar a continuación:

1. *“Estudiar la práctica médica actual, con el fin de identificar los puntos de mejora y determinar si se justifica la necesidad de la realización de la presente investigación, de cara a mejorar los sistemas de detección de melanoma que existen en la actualidad”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en la contribución **Estudio del estado del arte relativo a los métodos para la detección automatizada de melanoma, especialmente exhaustivo en las áreas en las que se ha centrado la investigación 6.2.2.**

2. *“Realizar un estudio exhaustivo del estado del arte a nivel científico-tecnológico de los métodos para la detección automatizada de melanoma, especialmente en los campos donde se van a realizar las principales aportaciones”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en la contribución **Estudio del estado del arte relativo a los métodos para la detección automatizada de melanoma, especialmente exhaustivo en las áreas en las que se ha centrado la investigación 6.2.2.**

3. *“Crear una base de datos para el diseño, desarrollo y validación de los algoritmos, con un elevado número de imágenes y clasificada según valoraciones diagnósticas realizadas por expertos dermatólogos”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en la contribución **Creación de base de datos de imágenes dermatoscópicas 6.2.3.**

4. *“Construir un framework para el desarrollo de algoritmos de procesamiento digital de imagen”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en la contribución **Framework software para el desarrollo de algoritmos de procesamiento digital de imagen 6.2.4.**

5. *“Diseñar y desarrollar un algoritmo para la segmentación automatizada de la lesión”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en la contribución **Segmentación de la lesión** 6.2.5.

6. *“Diseñar y desarrollar una familia de algoritmos para la detección y caracterización de los patrones dermatoscópicos”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en las contribuciones relativas al **Reconocimiento de los patrones reticular, globular, puntos, ramificaciones lineales/pseudópodos, velo azul-blanquecino, homogéneo, homogéneo azulado, manchas de pigmento e hipopigmentación** 6.2.1, 6.2.6, 6.2.7, 6.2.8, 6.2.9, 6.2.10, 6.2.11, 6.2.12 y 6.2.13.

7. *“Evaluar el sistema con el fin de garantizar su fiabilidad y robustez”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en **todas las contribuciones** mostradas en 6.2.

8. *“Desarrollar un prototipo software para el diagnóstico de melanoma basado en la “Regla del ABCD”, el algoritmo médico más utilizado, en el que se integren los algoritmos desarrollados junto con la detección y caracterización de indicadores propios de este método médico”.*

Este objetivo se ha cumplido correctamente, tal y como se puede ver en las contribuciones **Reconocimiento de los indicadores asimetría, bordes y color correspondientes al algoritmo médico “Regla del ABCD”** 6.2.15 y **Prototipo software para el diagnóstico de melanoma** 6.2.15, así como en **todo el resto de las contribuciones** mostradas en 6.2.

6.2 Contribuciones

A continuación se muestran las contribuciones realizadas en la presente investigación.

Tal y como se ha comentado anteriormente, la principal contribución es el algoritmo de reconocimiento del patrón reticular, que se presenta de manera detallada en el presente documento.

Además, otras contribuciones muy destacadas son el algoritmo de segmentación de la lesión y el prototipo software MELANOPAS para el diagnóstico de melanoma en el que se han integrado la mayoría de los algoritmos desarrollados en la presente la investigación.

6. CONCLUSIONES

Finalmente, otras contribuciones importantes, aunque no de tanta relevancia como las anteriores, han sido realizadas en el estudio del estado del arte, en la creación de una base de datos de imágenes dermatoscópicas, en la construcción de un *framework* software para el desarrollo de algoritmos de procesamiento digital de imagen, en los algoritmos de reconocimiento de los patrones dermatoscópicos globular, puntos, ramificaciones lineales/pseudópodos, velo azul-blanquecino, homogéneo, homogéneo azulado, manchas de pigmento e hipopigmentación y en el algoritmo de reconocimiento de los indicadores asimetría, bordes y color correspondientes al algoritmo médico “Regla del ABCD”.

En la explicación de cada una de las diferentes contribuciones se muestran además diferentes indicadores correspondientes a su impacto científico (que se describen en 6.3).

Hay además tres indicadores que son comunes a todas las contribuciones, que se mostrarán aquí en vez de repetirse en cada subapartado y que se enumeran a continuación.

Indicadores comunes a todas las contribuciones

1. Artículo del periódico Cinco Días sobre la investigación (que se muestra en 6.3.4.1).
2. Primer Premio en el Certamen de Trabajos Estudiantiles del CIITI 2014 a la tesis doctoral (que se muestra en 6.3.4.2).
3. Áccesit (Segundo Premio) en la XI Edición del Premio UD-GRUPO SANTANDER (Convocatoria 2015) de Investigación, por el trabajo “TICs como ayuda a diagnósticos de lesiones dermatológicas con riesgo de melanoma”, concedido al grupo de investigación eVida, formado por Begoña García-Zapirain, Amaia Méndez, Ibon Oleagordia, José Luis García y Andrés Gola (que se muestra en 6.3.4.3).

6.2.1 Reconocimiento del patrón reticular

El algoritmo para el reconocimiento del patrón reticular **es la principal contribución de esta investigación**. Indicadores de esta contribución son los artículos “Recognition of pigment network pattern in dermoscopy images based on fuzzy clas-

sification of pixels” (que se muestra en 6.3.1.5) y “Detection of pigment network in dermoscopy images using supervised machine learning and structural analysis” (que se muestra en 6.3.1.1), el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

Este algoritmo ha sido explicado de manera detallada en este documento, y examinaremos en este apartado sus aportaciones con respecto al estado del arte.

6.2.1.1 Diseño innovador del algoritmo

Esta es la principal aportación del algoritmo, su diseño innovador que, tal y como se ha comentado en este documento, parte de la descripción del patrón reticular como patrón compuesto de dos subpatrones: red y agujero. En primer lugar, se realiza la clasificación difusa o *fuzzy* de los pixels en las tres categorías presentes en la definición del patrón (“red”, “agujero” y “otro”), lo cual permite la creación de los correspondientes tres conjuntos difusos y la consiguiente generación de las tres imágenes de probabilidad que mapean a éstos. En segundo lugar, se realiza la caracterización del patrón reticular a partir de un proceso de parametrización –derivado de la especificación del sistema– y el posterior cálculo de diferentes características calculadas a partir de las combinaciones de máscaras extraídas de las imágenes de probabilidad correspondientes a los α -cortes obtenidos de los conjuntos difusos.

Aunque, evidentemente, la innovación es el algoritmo en su conjunto, vamos a examinar a continuación diferentes aspectos del algoritmo que son aportaciones en innovación.

Patrón definido a partir de dos subpatrones

Es una aportación de este algoritmo la definición de este patrón complejo a partir de dos subpatrones más simples: patrón red y patrón agujero, cuya descripción se realiza a partir de la especificación del sistema tras un proceso de parametrización, utilizando un enfoque difuso y realizando una caracterización a partir de dicho enfoque difuso utilizando α -cortes.

6. CONCLUSIONES

Enfoque difuso o probabilístico

Es una aportación importante de este trabajo el enfoque difuso o probabilístico, que permite el uso de imágenes con mapas de probabilidad, de cara a la detección y caracterización de los diferentes patrones dermatoscópicos. Por ejemplo, en el caso de los trabajos del estado del arte examinados de reconocimiento del patrón reticular, se intentaba detectar la red pigmentada y/o los agujeros, generando máscaras binarias correspondientes a estas estructuras, y posteriormente se realizaban procesos sobre dichas estructuras, con un posterior cálculo de características de color y/o de textura y/o morfológicas y/o geométricas para realizar su caracterización. Sin embargo, como se demuestra en esta tesis, esta manera de proceder no proporciona tanta información y flexibilidad como el uso de los mapas de probabilidad y su adecuado procesamiento posterior para realizar la caracterización.

Parametrización desde la especificación del sistema

Tal y como se comenta en 6.2.1.6, es una contribución de la presente investigación el establecimiento de un nuevo enfoque metodológico para trabajos de este tipo, en el que se parte de la especificación del sistema, que permite una posterior parametrización. Fijaremos aquí la atención en este aspecto del algoritmo, que es una aportación en sí misma, este proceso de parametrización realizado de manera rigurosa –en forma de parámetros configurables (con sus rangos de valores) y valores umbrales establecidos– que se integra con el diseño del algoritmo y que, tras la realización de los experimentos, permite la selección de los valores óptimos.

Caracterización a partir de máscaras extraídas de las imágenes de probabilidad correspondientes a los α -cortes obtenidos de los conjuntos difusos

Intuitivamente, el enfoque difuso o probabilístico proporciona una información muy rica en la definición de este patrón. Sin embargo, a partir de esta información es necesario realizar un proceso de caracterización que permita –a partir de datos cuantitativos– realizar el reconocimiento del patrón, decidiendo si una determinada imagen tiene ese patrón o no. En esta tarea, es una aportación de este algoritmo la utilización de máscaras extraídas de las imágenes de probabilidad correspondientes a los α -cortes obtenidos de los conjuntos difusos, que se combinan y permiten obtener el conjunto de características, de cara a alimentar al clasificador.

6.2.1.2 No necesidad de realizar un preprocesado previo

Frente a la mayoría de los trabajos del estado del arte para el reconocimiento del patrón reticular, en este algoritmo –por su propia naturaleza– no se necesita realizar un preprocesado previo de la imagen con el fin de detectar y eliminar artefactos distorsionadores tales como pelos, reflejos, marcas, reglas o burbujas. De hecho, no se recomienda hacerlo, ya que puede dar lugar a errores, bien en el proceso de detección porque grupos de pixels que forman parte de un patrón puedan ser incorrectamente reconocidos como parte de los artefactos, o bien en el proceso de eliminación de los artefactos –la restauración– de la imagen porque ésta sea modificada erróneamente.

6.2.1.3 Robusto frente a la no segmentación de la lesión

La gran mayoría de los trabajos del estado del arte para el reconocimiento del patrón reticular parten de una segmentación previa de la lesión. En este algoritmo se parte también de una segmentación previa de la lesión porque se quiere aislar su diseño, desarrollo y validación de cuestiones externas y porque, además, este algoritmo está pensado para ser integrado en un sistema de detección automatizada de melanoma en el que se realiza la segmentación antes de la detección y caracterización de los diferentes indicadores. No obstante, es evidente que, tal y como está diseñado, este algoritmo no necesita en casi la totalidad de las ocasiones una segmentación previa. Realmente, ésta sólo es necesaria con el fin de evitar el efecto que puede causar la posible presencia –normalmente muy fina y tenue– de la red pigmentada en la piel que está en el exterior de la lesión, algo que sólo dará problemas al algoritmo de reconocimiento del patrón reticular en el caso de que la lesión además no tenga el patrón reticular, lo cual se da en poquísimas ocasiones.

6.2.1.4 Gran capacidad de discriminación entre este patrón y otros patrones dermatoscópicos

Este algoritmo mejora a la totalidad de los trabajos del estado del arte en la discriminación del patrón reticular con respecto a otros patrones dermatoscópicos. La mayoría de los trabajos más relevantes reportan hacer esta tarea utilizando criterios morfológicos o geométricos, con respecto a las estructuras de red o de agujeros obtenidas pero, claramente, por cuestiones evidentes de diseño, este tipo de dis-

6. CONCLUSIONES

criminación es muy inferior a la planteada aquí –patrón definido a partir de dos subpatrones, enfoque difuso, etc.–.

6.2.1.5 Gran fiabilidad del método

Este método ha sido testado contra una base de datos de 875 imágenes –por mucho, la más grande en el estado del arte en el reconocimiento del patrón reticular– extraída de un Atlas de Dermatoscopia público, alcanzando excelentes resultados, una AUC de 0,912, una exactitud del 88 %, una sensibilidad del 90,71 % y una especificidad del 83,44 %, los mejores del estado del arte –junto con otro trabajo, tal y como se explica en 5.3.2–, lo cual muestra su fiabilidad.

6.2.1.6 Establecimiento de un nuevo enfoque metodológico para trabajos de este tipo

En la gran mayoría de los trabajos del estado del arte que tratan el reconocimiento de patrones sobre imágenes dermatoscópicas se parte de la descripción médica, sin realizar una adecuada traducción al área de la ingeniería, echándose de menos una descripción más formal, en la que se establezca de manera rigurosa qué se pretende hallar, ya que en la mayoría de las ocasiones hay que deducir del diseño del sistema qué es lo que quería hacer el autor. Una cosa es lo que dicen los libros de medicina, otra es lo que interpretan los expertos médicos y, finalmente, otra muy diferente es la especificación formal de lo que busca el algoritmo, susceptible de ser posteriormente parametrizado, que es de lo que se debe de partir para su diseño.

Al hilo de las carencias metodológicas observadas en los trabajos de este tipo, se presenta un nuevo enfoque metodológico que pretende convertirse en referencia para futuros estudios de reconocimiento de patrones sobre imágenes dermatoscópicas, aplicable también a problemas similares en otros tipos de imágenes. Este nuevo enfoque metodológico es una de las contribuciones realizadas en este trabajo e introduce la especificación del sistema como tarea obligatoria antes de su diseño y desarrollo, dentro del ciclo de vida de construcción del sistema de reconocimiento del patrón dermatoscópico, siendo esta especificación la base para la realización de un proceso de parametrización –en forma de parámetros configurables (con sus rangos de valores) y valores umbrales establecidos– en el que se sustenta el diseño y desarrollo del algoritmo y la realización de los experimentos.

6.2.1.7 Puede ser utilizado en otros problemas de reconocimiento de patrones de naturaleza similar

Es evidente que, tal y como está diseñado, el algoritmo de reconocimiento del patrón reticular puede ser utilizado en otros problemas de reconocimiento de patrones de naturaleza similar, adoptando todas o algunas de las ideas, según los puntos que tengan en común.

6.2.2 Estudio del estado del arte relativo a los métodos para la detección automatizada de melanoma, especialmente exhaustivo en las áreas en las que se ha centrado la investigación

Se ha realizado un estudio del estado del arte relativo a los métodos para la detección automatizada de melanoma, especialmente exhaustivo en las áreas en las que se ha centrado la investigación. Además del capítulo del estado del arte del presente documento otros indicadores de esta contribución son el artículo “Segmentation of skin lesions based on fuzzy classification of pixels and histogram thresholding” (que se muestra en 6.3.1.6) y los dos extensos estados del arte realizados en los capítulos de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2) y “Comparison of image processing techniques for reticular pattern recognition in melanoma detection” (que se muestra en 6.3.1.3). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.3 Creación de base de datos de imágenes dermatoscópicas

Se ha creado una base de datos para el diseño, desarrollo y validación de los algoritmos, con un elevado número de imágenes y clasificada según valoraciones diagnósticas realizadas por expertos dermatólogos. Además del capítulo de la base de datos del presente documento –en el que se describe la base de datos utilizada en gran parte de los algoritmos (y en particular en el algoritmo de reconocimiento del patrón reticular), extraídas de un atlas público de imágenes– también tenemos como indicadores los retos del ISIC 2016 y 2017 para la segmentación de una lesión en una imagen dermatoscópica (que se muestran en 6.3.4.4 y 6.3.4.5) –para dichos algoritmos de segmentación se utiliza el repositorio de imágenes de la *International*

6. CONCLUSIONES

Society for Digital Imaging of the Skin (ISDIS)–. Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2. Esta contribución no es de mucha importancia, ya que se han utilizado imágenes capturadas por otros equipos médicos, aunque sí que ha habido que realizar cierto trabajo de marcado de imágenes y estructuración.

6.2.4 *Framework* software para el desarrollo de algoritmos de procesamiento digital de imagen

Es también una contribución relevante de esta investigación la construcción de un *framework* software para el desarrollo de algoritmos de procesamiento digital de imagen, que proporciona un gran número de funcionalidades, tanto en procesamiento digital de imagen como en otras tareas relacionadas. Indicadores de esta contribución son la herramienta software “MELANOPAS” (que se muestra en 6.3.3.1), así como otras no directamente relacionados con la presente investigación, como las herramientas software **DICOMPAS** 6.3.5.3 –para la caracterización articular sobre imágenes DICOM de cine-MRI– y **NODULEPAS** 6.3.5.3 –para la ayuda al diagnóstico, que implementa algoritmos avanzados de procesamiento digital de imagen para la monitorización de pacientes con cáncer de pulmón–. Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.5 Segmentación de la lesión

El algoritmo para la segmentación de la lesión **es una contribución muy destacada de esta investigación**. Indicadores de esta contribución son el artículo “Segmentation of skin lesions based on fuzzy classification of pixels and histogram thresholding” (que se muestra en 6.3.1.6), los retos del ISIC 2016 y 2017 para la segmentación de una lesión en una imagen dermatoscópica (que se muestran en 6.3.4.4 y 6.3.4.5), el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indi-

cadore comunes que se muestran en la presentación de 6.2.

6.2.6 Reconocimiento del patrón globular

El algoritmo para el reconocimiento del patrón globular es una contribución de esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.7 Reconocimiento del patrón puntos

El algoritmo para el reconocimiento del patrón puntos es una contribución de esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.8 Reconocimiento del patrón ramificaciones lineales/pseudópodos

El algoritmo para el reconocimiento del patrón ramificaciones lineales/pseudópodos es una contribución de esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6. CONCLUSIONES

6.2.9 Reconocimiento del patrón velo azul-blanquecino

El algoritmo para el reconocimiento del patrón velo azul-blanquecino es una contribución de esta investigación. Indicadores de esta contribución son las comunicaciones escritas de congreso “Blue-white veil and dark-red patch of pigment pattern recognition in dermoscopic images using machine-learning techniques” y “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestran en 6.3.2.1 y 6.3.2.2, respectivamente) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.10 Reconocimiento del patrón homogéneo

El algoritmo para el reconocimiento del patrón homogéneo es una contribución de esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.11 Reconocimiento del patrón homogéneo azulado

El algoritmo para el reconocimiento del patrón homogéneo azulado es una contribución de esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.12 Reconocimiento del patrón manchas de pigmento

El algoritmo para el reconocimiento del patrón manchas de pigmento es una contribución de esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), las comunicaciones escritas de congreso “Blue-white veil and dark-red patch of pigment pattern recognition in dermoscopic images using machine-learning techniques” y “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestran en 6.3.2.1 y 6.3.2.2, respectivamente) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.13 Reconocimiento del patrón hipopigmentación

El algoritmo para el reconocimiento del patrón hipopigmentación es una contribución de esta investigación. Indicadores de esta contribución son el artículo “Hypopigmentation pattern recognition in dermoscopy images for melanoma detection” (que se muestra en 6.3.1.4), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.14 Reconocimiento de los indicadores asimetría, bordes y color correspondientes al algoritmo médico “Regla del ABCD”

El algoritmo para el reconocimiento de los indicadores asimetría, bordes y color correspondientes al algoritmo médico “Regla del ABCD” es una contribución de esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1).

6. CONCLUSIONES

Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

6.2.15 Prototipo software para el diagnóstico de melanoma

El Prototipo software para el diagnóstico de melanoma MELANOPAS es **una contribución muy destacada de esta investigación**, ya que en él se han integrado todos los algoritmos desarrollados en esta investigación. Indicadores de esta contribución son el capítulo de libro “Automated detection of melanoma in dermoscopic images” (que se muestra en 6.3.1.2), la comunicación escrita de congreso “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” (que se muestra en 6.3.2.2) y el software “MELANOPAS” (que se muestra en 6.3.3.1). Finalmente, hay que añadir los indicadores comunes que se muestran en la presentación de 6.2.

Hay que destacar que el desarrollo de esta herramienta software representa un añadido, un “plus” al trabajo de investigación propiamente dicho. Se ha dado un paso adelante y se ha desarrollado un prototipo de CAD para el diagnóstico de melanoma –llamado MELANOPAS– que implementa el algoritmo médico llamado “Regla del ABCD” (el más popular entre los expertos dermatólogos) y que ha dado muy buenos resultados, habiendo sido testado por los médicos dermatólogos Jesús Gardeazabal y Jose Luis Díaz –de la Unidad de Dermatología del Hospital de Cruces y el IMQ, que participaron en la investigación, tal y como se explica en 1.4.1– que pudieron validar su buen funcionamiento.

6.3 Impacto científico

A continuación, se muestra el impacto científico realizado en el transcurso de la presente investigación. Se muestran las aportaciones directamente relacionadas con el tema de la investigación –el diagnóstico automatizado de melanoma a partir de imágenes dermatoscópicas–: artículos y capítulos de libros, congresos, patentes y registros software y otros méritos de investigación.

Además, también se muestra el impacto científico que no está directamente relacionado con el tema de la presente investigación –aunque sí que tiene bastante relación, ya que están englobados en las categorías de “procesamiento digital de

imagen” y “reconocimiento de patrones”–.

6.3.1 Artículos y capítulos de libros

6.3.1.1 Artículo: “Detection of pigment network in dermoscopy images using supervised machine learning and structural analysis”

Título: Detection of pigment network in dermoscopy images using supervised machine learning and structural analysis.

Autores (por orden de firma): Jose Luis García Arroyo and Begoña García Zapirain.

Revista/Libro: *Computers in Biology and Medicine*.

Tipo de publicación: Artículo.

Año: 2014.

Volumen: 44.

Páginas: 144-157.

Editorial: Elsevier.

Indicios de calidad: JCR= 1.521 (2015) Q2, 27/56 (MATHEMATICAL & COMPUTATIONAL BIOLOGY).

6.3.1.2 Capítulo de libro: “Automated detection of melanoma in dermoscopic images”

Título: Automated detection of melanoma in dermoscopic images.

Autores (por orden de firma): Jose Luis García Arroyo and Begoña García Zapirain.

Revista/Libro: *Computer Vision Techniques for the Diagnosis of Skin Cancer*.

Tipo de publicación: Capítulo de libro.

Año: 2014.

Páginas: 139-192.

Editorial: Springer.

Indicios de calidad: Es una editorial de gran prestigio en el campo de las disciplinas STEM (Science, Technology, Engineering, and Mathematics). El resto de los autores de los capítulos del libro son investigadores relevantes en el campo de la detección automatizada de melanoma, autores de artículos del estado del arte.

6. CONCLUSIONES

6.3.1.3 Capítulo de libro: “Comparison of image processing techniques for reticular pattern recognition in melanoma detection”

Título: Comparison of image processing techniques for reticular pattern recognition in melanoma detection. **Autores (por orden de firma):** Jose Luis García Arroyo and Begoña García Zapirain.

Revista/Libro: *Dermoscopy Image Analysis*.

Tipo de publicación: Capítulo de libro.

Año: 2015.

Páginas: 131-181.

Editorial: CRC Press/Taylor & Francis.

Indicios de calidad: Es una editorial de gran prestigio en el campo de las disciplinas STEM (Science, Technology, Engineering, and Mathematics). El resto de los autores de los capítulos del libro son investigadores relevantes en el campo de la detección automatizada de melanoma, autores de artículos del estado del arte. De hecho, el libro ha sido citado, como revisión de libro, en:

M Emre Celebi, Teresa Mendonca, and Jorge S Marques. Dermoscopy image analysis [book review]. *IEEE Transactions on Medical Imaging*, 35(4):1147–1148, 2016.

6.3.1.4 Artículo: “Hypopigmentation pattern recognition in dermoscopy images for melanoma detection”

Título: Hypopigmentation pattern recognition in dermoscopy images for melanoma detection.

Autores (por orden de firma): Jose Luis García Arroyo and Begoña García Zapirain.

Revista/Libro: *Journal of Medical Imaging and Health Informatics*.

Tipo de publicación: Artículo.

Año: 2015.

Volumen: Vol. 5, N^a 8.

Páginas: 1875-1879.

Editorial: American Scientific Publishers.

Indicios de calidad: JCR= 0.877 (2015) Q4, 43/56 (MATHEMATICAL & COMPUTATIONAL BIOLOGY).

6.3.1.5 Artículo: “Recognition of pigment network pattern in dermoscopy images based on fuzzy classification of pixels”

Título: Recognition of pigment network pattern in dermoscopy images based on fuzzy classification of pixels.

Autores (por orden de firma): Jose Luis García Arroyo and Begoña García Zapirain.

Revista/Libro: *Computer Methods and Programs in Biomedicine*.

Tipo de publicación: Artículo.

Año: 2017.

Estado: Pendiente de revisión.

Editorial: Elsevier.

Indicios de calidad: JCR= 1.862 (2015) Q1, 16/105 (COMPUTER SCIENCE, THEORY & METHODS).

6.3.1.6 Artículo: “Segmentation of skin lesions based on fuzzy classification of pixels and histogram thresholding”

Título: Segmentation of skin lesions based on fuzzy classification of pixels and histogram thresholding.

Autores (por orden de firma): Jose Luis García Arroyo and Begoña García Zapirain.

Revista/Libro: *IEEE Journal of Biomedical and Health Informatics*.

Tipo de publicación: Artículo.

Año: 2017.

Estado: Aceptado. Al haber participado en el Reto del ISIC 2017 para la segmentación de la lesión en una imagen dermatoscópica (que se explica en 6.3.4.5) –en el que participaron los principales equipos de investigación de todo el mundo en este área– contribuyendo con un método innovador, se nos ha invitado a publicar este artículo. Está pendiente de envío la versión final y posterior publicación. Hay una versión *abstract* publicada en: <https://arxiv.org/abs/1703.03888> (J. L. Garcia-Arroyo, B. Garcia-Zapirain, “Segmentation of skin lesions based on fuzzy classification of pixels and histogram thresholding”, arXiv preprint arXiv:1703.03888.)

Editorial: IEEE.

Indicios de calidad: JCR= 2.093 (2015) Q1, 29/144 (COMPUTER SCIENCE, IN-

6. CONCLUSIONES

FORMATION SYSTEMS).

6.3.2 Congresos

6.3.2.1 “Blue-white veil and dark-red patch of pigment pattern recognition in dermoscopic images using machine-learning techniques”

Título: Blue-white veil and dark-red patch of pigment pattern recognition in dermoscopic images using machine-learning techniques.

Autores (por orden de firma): Jose Luis García Arroyo, Begoña García Zapirain and Amaia Méndez Zorrilla.

Tipo de participación: Comunicación escrita y ponencia.

Nombre del congreso: *011 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*.

Páginas: 196-201.

Carácter: Internacional.

Lugar y año de realización: Bilbao, 2011.

6.3.2.2 “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas”

Título: MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas.

Autores (por orden de firma): Jose Luis García Arroyo and Begoña García Zapirain.

Tipo de participación: Comunicación escrita.

Nombre del congreso: *XII Congreso Internacional en Innovación Tecnológica Informática*.

Carácter: Internacional.

Lugar y año de realización: Buenos Aires (Argentina), 2014.

En este congreso le dieron el Primer Premio en el Certamen de Trabajos Estudiantiles del CIITI 2014 (en la categoría de postgrado) al trabajo correspondiente a la tesis doctoral y al sistema de detección de melanoma MELANOPAS (que se muestra en 6.3.3.1), tal y como se muestra en 6.3.4.2.

6.3.3 Patentes y registros software

6.3.3.1 Herramienta software “MELANOPAS”

Título: MELANOPAS.

Autores (por orden de firma): Jose Luis García Arroyo and Begoña García Zapirain.

Número de registro: 349971.

Fecha: 2-10-2014.

Carácter: Nacional (registrado en el Registro de la Propiedad Intelectual del Gobierno Vasco).

Descripción: Aplicación software de ayuda al diagnóstico, que implementa algoritmos avanzados de procesamiento digital de imagen para la detección automatizada de melanoma.

6.3.4 Otros méritos de investigación

6.3.4.1 Artículo del periódico Cinco Días

Mérito: Artículo en el periódico. 9-7-2014.

Descripción: Artículo del periódico Cinco Días, del 9-7-2014, en el que Begoña García Zapirain, la directora de la tesis, explica a un periodista el trabajo que se está realizando en el ámbito de la detección automatizada de melanoma.

(<http://dkh.deusto.es/VisualizarDocumento.aspx?doc=b30bf4ad-6b63-438b-8d41-991ca19ee68a&ext=.pdf&archivoAdjuntoSem=001DQMUT%23%23idgoogle%23%230B21w8ATkOYQ5V1FoRWhEZXQtcUE&ontologiaAdjuntoSem=6a216217-c2e1-4472-8b19-293b7a61986f&ID=ffffff-ffff-ffff-ffff-ffffff&proy=bfcf20e1-b1f6-4646-8fab-63defbe005f9>)

6.3.4.2 Primer Premio en el Certamen de Trabajos Estudiantiles del CIITI 2014

Mérito: Primer Premio a la tesis doctoral en el Certamen de Trabajos Estudiantiles del CIITI 2014. 2-10-2014

Descripción: Primer Premio en el Certamen de Trabajos Estudiantiles del CIITI 2014 (en la categoría de postgrado) que se celebró en el congreso XII Congreso Internacional en Innovación Tecnológica Informática, en Buenos Aires (Argentina),

6. CONCLUSIONES

el 2 de octubre de 2014. En este certamen se presentó el trabajo correspondiente a la tesis doctoral y al sistema de detección de melanoma MELANOPAS (mostrado en 6.3.3.1), descrito en el artículo “MELANOPAS: un sistema innovador para la detección automatizada de melanoma sobre imágenes dermatoscópicas” mostrado en 6.3.2.2.

6.3.4.3 **Áccesit (Segundo Premio) en la XI Edición del Premio UD-GRUPO SANTANDER de Investigación (Convocatoria 2015)**

Mérito: Áccesit (Segundo Premio) en la XI Edición del Premio UD-GRUPO SANTANDER (Convocatoria 2015) de Investigación. 3-2-2016

Descripción: Áccesit (Segundo Premio) en la XI Edición del Premio UD-GRUPO SANTANDER (Convocatoria 2015) de Investigación al trabajo “TICs como ayuda a diagnósticos de lesiones dermatológicas con riesgo de melanoma”, concedido al grupo de investigación eVida, formado por Begoña García-Zapirain, Amaia Méndez, Ibon Oleagordia, José Luis García y Andrés Gola. El impacto de este premio ha sido grande por su aportación a la detección automatizada de melanoma, y ha aparecido reflejado en numerosos medios de comunicación.

(<http://www.elmundo.es/f5/campus/2016/02/09/56ba38bee2704e77278b461d.html>)

6.3.4.4 **Reto del ISIC 2016 para la segmentación de la lesión en una imagen dermatoscópica**

Mérito: 9º puesto en el reto (challenge) del ISIC 2016 para la segmentación de una lesión en una imagen dermatoscópica, computado de acuerdo al indicador de Jaccard.

Descripción: La International Society for Digital Imaging of the Skin (ISDIS) ha creado el proyecto International Skin Imaging Collaboration (ISIC) para el avance colaborativo en el desarrollo de métodos de imagen para la detección de problemas de piel (y en particular la detección de melanoma). En el año 2016 ha organizado un reto entre equipos de investigación de todo el mundo correspondiente a la segmentación de una lesión en una imagen dermatoscópica, quedando el equipo compuesto por Jose Luis García Arroyo y Begoña García Zapirain en el puesto 9º, computado de acuerdo al indicador de Jaccard, de un total de 28 participantes

<https://challenge.kitware.com/#phase/566744dccad3a56fac786787>.

6.3.4.5 Reto del ISIC 2017 para la segmentación de la lesión en una imagen dermatoscópica

Mérito: 15° puesto en el reto (challenge) del ISIC 2017 para la segmentación de una lesión en una imagen dermatoscópica, computado de acuerdo al indicador de Jaccard, 1° puesto computado de acuerdo al indicador de sensibilidad.

Descripción: La International Society for Digital Imaging of the Skin (ISDIS) ha creado el proyecto International Skin Imaging Collaboration (ISIC) para el avance colaborativo en el desarrollo de métodos de imagen para la detección de problemas de piel (y en particular la detección de melanoma). En el año 2017 ha organizado un reto entre equipos de investigación de todo el mundo correspondiente a la segmentación de una lesión en una imagen dermatoscópica, quedando el equipo compuesto por Jose Luis García Arroyo y Begoña García Zapirain en el puesto 15°, computado de acuerdo al indicador de Jaccard, de un total de 23 participantes; si se computa de acuerdo al indicador de sensibilidad, alcanza el 1° puesto, lo que permite suponer que este algoritmo puede ser en cierta manera más robusto frente a imágenes de otras fuentes que otros, que era el principal objetivo de los autores en el diseño del algoritmo. Al haber participado en este Reto contribuyendo con un método innovador, se nos ha invitado a publicarlo en la revista *IEEE Journal of Biomedical and Health Informatics*, existiendo ya un resumen publicado en arXiv, tal y como se muestra en 6.3.1.6

(<https://challenge.kitware.com/#phase/566744dccad3a56fac786787>).

6.3.5 Impacto científico no directamente relacionado con la presente investigación

A continuación se muestra el impacto científico que no está directamente relacionado con el tema de la presente investigación, aunque sí que tiene bastante relación, ya que están englobados en las categorías de “procesamiento digital de imagen” y “reconocimiento de patrones”.

6. CONCLUSIONES

6.3.5.1 Artículos y capítulos de libros relacionados

Artículo: “Marco de trabajo tecnológico para la realización de estudios de caracterización articulatória sobre imágenes MRI”

Título: Marco de trabajo tecnológico para la realización de estudios de caracterización articulatória sobre imágenes MRI.

Autores (por orden de firma): Jose Luis García Arroyo, Begoña García Zapirain, Ibón Oleagordia Ruiz y Amaia Méndez Zorrilla.

Revista/Libro: *Estudios de Fonética Experimental*.

Tipo de publicación: Artículo.

Año: 2013.

Volumen: XXII.

Páginas: 367-404.

Editorial: Laboratori de Fonetica, Universitat de Barcelona.

Indicios de calidad: SJIF Scientific Journal Impact Factor: SJIF 2012= 3.319. Scopus: SJR (2012) = 0.103. IN-RECH. Primer cuartil (1 de 51).

6.3.5.2 Congresos

Artículo: “Quantitative Study and Monitoring of the Growth of Lung Cancer Nodule Using an X-Ray Computed Tomography Image Processing Tool”

Título: Quantitative Study and Monitoring of the Growth of Lung Cancer Nodule Using an X-Ray Computed Tomography Image Processing Tool.

Autores (por orden de firma): Jose Luis García Arroyo, Begoña García Zapirain y Amaia Méndez Zorrilla.

Tipo de participación: Comunicación escrita y ponencia.

Nombre del congreso: *IWANN'11 Proceedings of the 11th international conference on Artificial neural networks conference on Advances in computational intelligence*.

Páginas: 74-82.

Carácter: Internacional..

Lugar y año de realización: Torremolinos (Málaga, España), 2011.

Artículo: “Computed Tomography CAD system for monitoring and modeling the evolution of lung cancer nodule”

Título: Computed Tomography CAD system for monitoring and modeling the evolution of lung cancer nodule.

Autores (por orden de firma): Iván Ornes Uriondo, Jose Luis García Arroyo, Begoña García Zapirain y Amaia Méndez Zorrilla.

Tipo de participación: Comunicación escrita y ponencia.

Nombre del congreso: *2011 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*.

Páginas: 484-489.

Carácter: Internacional.

Lugar y año de realización: Bilbao, 2011.

6.3.5.3 Patentes y registros software

Herramienta software “DICOMPAS”

Título: DICOMPAS.

Autores (por orden de firma): Jose Luis García Arroyo, Begoña García Zapirain, Ibón Oleagordia Ruiz y Amaia Méndez Zorrilla.

Número de registro: A registrar.

Carácter: Nacional (a registrar en el Registro de la Propiedad Intelectual del Gobierno Vasco).

Descripción: Aplicación software para la caracterización articular sobre imágenes DICOM de cine-MRI.

Herramienta software “NODULEPAS”

Título: NODULEPAS.

Autores (por orden de firma): Jose Luis García Arroyo, Begoña García Zapirain e Ibón Oleagordia Ruiz.

Número de registro: 349972.

Fecha: 2-10-2014.

6. CONCLUSIONES

Carácter: Nacional (registrado en el Registro de la Propiedad Intelectual del Gobierno Vasco).

Descripción: Aplicación software de ayuda al diagnóstico, que implementa algoritmos avanzados de procesamiento digital de imagen para la monitorización de los pacientes de cáncer de pulmón.

6.4 Líneas futuras

En 6.2 se han descrito las principales contribuciones realizadas en la presente investigación. A continuación se muestran las posibles líneas de mejora de cara al futuro.

En primer lugar, tal y como se ha explicado, la principal contribución de la investigación ha sido el algoritmo de reconocimiento del patrón reticular, un método muy innovador que puede ser utilizado además en otros problemas de reconocimiento de patrones de naturaleza similar. Este sería precisamente el primer paso a adoptar, realizar un escalado de los algoritmos de reconocimiento de patrones parecidos –especialmente globular, puntos y ramificaciones lineales/pseudópodos– adoptando las innovaciones realizadas en dicho algoritmo de cara a integrar dichas mejoras en la herramienta software, ya que, aunque actualmente los algoritmos de reconocimiento de estos patrones funcionan bien, no son tan buenos como el correspondiente al patrón reticular. De hecho, en el algoritmo de segmentación de la lesión, contribución mostrada en 6.2.5, se han adoptado muchas de las innovaciones –aunque es cierto que este problema no es similar, sí que guarda puntos en común–, con unos excelentes resultados.

En segundo lugar, también sería interesante realizar el desarrollo de un algoritmo para el diagnóstico de melanoma no basado en un algoritmo médico –es decir, del segundo enfoque explicado en 2.2.1.2–, con el fin de complementar el diagnóstico realizado por la herramienta software desarrollada.

En tercer lugar, sería importante que los algoritmos de la herramienta software desarrollada fueran testados y refinados contra un número elevado de imágenes, tanto de la base de datos utilizada en la presente investigación como de otras bases de datos como el recientemente creado Archivo ISIC [Int16].

En cuarto lugar, debería acometerse un proyecto en colaboración con alguna institución médica –con el fin de probar los algoritmos desarrollados, asegurando

la bondad del sistema– con pacientes reales en un entorno médico, realizando un estudio médico planteado de manera rigurosa, de tipo retrospectivo, prospectivo o “ambispectivo” o mixto.

Finalmente, en quinto lugar, de cara a optimizar la eficiencia del sistema en el entorno de producción habría que migrar los algoritmos a una arquitectura paralela.

En resumen, actualmente se tiene una investigación muy avanzada y unas líneas claras de mejora de cara al futuro, para la utilización del sistema automatizado en la detección de melanoma con pacientes reales. Para ello sería necesario encontrar fuentes de financiación, pero ese ya es otro tema.

Bibliografía

- [ACF12] Q Abbas, M E Celebi, and I Fondón. Computer-aided pattern classification system for dermoscopy images. *Skin Research and Technology*, 18(3):278–289, 2012. 49, 52, 54, 55, 67, 68, 77, 80, 81, 84, 85
- [ACFA13] Q Abbas, M E Celebi, I Fondón, and W Ahmad. Melanoma recognition framework based on expert definition of ABCD for dermoscopic images. *Skin Research and Technology*, 19(1):e93–e102, 2013. 45, 49, 51, 54, 55, 68, 77, 80, 81, 84, 85
- [ACS⁺13] Q Abbas, M E Celebi, C Serrano, I Fondón, and G Ma. Pattern classification of dermoscopy images: A perceptually uniform model. *Pattern Recognition*, 46(1):86–97, 2013. 49, 52, 54, 55, 68, 69, 77, 80, 81, 84, 85
- [AEC12a] AECC (Asociación Española Contra el Cáncer). Incidencia del melanoma. <https://www.aecc.es/SOBREELCANCER/CANCERPORLOCALIZACION/MELANOMA/Paginas/incidencia.aspx>, 2012. Accessed: 2016-11-09. 1, 22, 25, 26
- [AEC12b] AECC (Asociación Española Contra el Cáncer). Síntomas del melanoma. <https://www.aecc.es/sobreelcancer/cancerporlocalizacion/melanoma/paginas/sintomas.aspx>, 2012. Accessed: 2016-11-09. 35
- [AFC⁺98] G Argenziano, G Fabbrocini, P Carli, V De Giorgi, E Sammarco, and M Delfino. Epiluminescence microscopy for the diagnosis of doubtful melanocytic skin lesions. Comparison of the

BIBLIOGRAFÍA

ABCD rule of dermatoscopy and a new 7-point checklist based on pattern analysis. *Archives of Dermatology*, 134(12):1563–1570, December 1998. 3, 36, 94, 95

[Ale12] Alegre, Víctor. Clases de dermatología. <http://www.uv.es/derma/>, 2012. Accessed: 2016-11-09. 16, 17, 18, 19, 20, 22

[ALL04] Richard Ashton, Barbara Leppard, and Nicholas J Lowe. *Differential diagnosis in dermatology*. Ed. McGraw-Hill Interamericana, 2004. 16, 17, 18, 20, 22, 23

[Ame16a] American Cancer Society. Cancer Facts and Figures 2016. <http://www.cancer.org/acs/groups/content/@research/documents/document/acspc-047079.pdf>, 2016. Accessed: 2016-11-09. 25

[Ame16b] American Joint Committee on Cancer). Melanoma of the Skin Staging, 7th edition. <https://cancerstaging.org/references-tools/quickreferences/Documents/MelanomaSmall.pdf>, 2016. Accessed: 2016-11-09. 24

[AMS04] Murali Anantha, Randy H Moss, and William V Stoecker. Detection of pigment network in dermatoscopy images using texture analysis. *Computerized Medical Imaging and Graphics*, 28(5):225–234, July 2004. 48, 51, 53, 55, 58, 62, 74, 80, 83, 85

[Ana15] Anatomy Body Gallery. Imagen de las células de la epidermis. <http://anatomybodygallery.com/human-anatomy-integumentary-system/2746/integumentary-system-model-3>, 2015. Accessed: 2015-06-12. xxi, 15

[Apa16a] Apache Software Foundation. Apache Hadoop. <http://hadoop.apache.org/>, 2016. Accessed: 2016-12-20. 163

[Apa16b] Apache Software Foundation. Apache Projects. <https://www.apache.org/>, 2016. Accessed: 2016-12-20. 167

- [Apa16c] Apache Software Foundation. Apache Spark. <https://spark.apache.org/>, 2016. Accessed: 2016-12-20. 163
- [Apa16d] Apache Software Foundation. The Apache Commons Mathematics Library. <http://commons.apache.org/proper/commons-math/>, 2016. Accessed: 2016-12-20. 163, 166
- [ASCA03] Giuseppe Argenziano, H. Peter Soyer, Sergio Chimenti, and Et Al. Dermoscopy of pigmented skin lesions: Results of a consensus meeting via the internet. *Journal of the American Academy of Dermatology*, 48(5):693–679, 2003. 3, 4, 41, 94, 96, 102
- [ASP+00] Giuseppe Argenziano, H. Peter Soyer, Vincenzo De Giorgio Domenico Piccolo, Paolo Carli, Mario Delfino, Angela Ferrari, Rainer Hofmann-Wellenhof, Daniela Massi, Giampiero Mazzochetti, Massimiliano Scalvenzi, and Ingrid H. Wolf. *Interactive atlas of dermoscopy*. EDRA-Medical Publishing and New Media, Milan, Italy, 2000. xxi, 3, 21, 39, 94, 95, 183
- [Bar11] Catalina Barata. *Detection of Pigment Network in Dermoscopy Images*. PhD thesis, Universidade Técnica de Lisboa, 2011. 54, 55
- [BB14] W Barhoumi and A Baâzaoui. Pigment network detection in dermoscopic images for melanoma diagnosis. *IRBM*, 35(3):128–138, 2014. 50, 51, 54, 71, 78, 80, 81, 84, 85, 86
- [BBS+01] Charles M Balch, Antonio C Buzaid, Seng-Jaw Soong, Michael B Atkins, Natale Cascinelli, Daniel G Coit, Irvin D Fleming, Jeffrey E Gershenwald, Alan Houghton, John M Kirkwood, et al. Final version of the american joint committee on cancer staging system for cutaneous melanoma. *Journal of Clinical Oncology*, 19(16):3635–3648, 2001. 24
- [BDF+06] G. Betta, G. Di Leo, G. Fabbrocini, A. Paolillo, and P. Sommeilla. Dermoscopic image-analysis system: estimation of atypical

BIBLIOGRAFÍA

- pigment network and atypical vascular pattern. In *IEEE International Workshop on Medical Measurement and Applications*, pages 63–67, Benevento, Italy, 2006. IEEE. 48, 51, 53, 54, 55
- [BDLF⁺05] G Betta, G Di Leo, G Fabbrocini, A Paolillo, and M Scalvenzi. Automated application of the “7-point checklist” diagnosis method for skin lesions: Estimation of chromatic and shape parameters. In *Proceedings of the IEEE Instrumentation and Measurement Technology Conference (IMTC 2005)*, volume 3, pages 1818–1822, Ottawa, Canada, 2005. IEEE. 48, 51, 53, 54, 55
- [BGS⁺09] Charles M Balch, Jeffrey E Gershenwald, Seng-jaw Soong, John F Thompson, Michael B Atkins, David R Byrd, Antonio C Buzaid, Alistair J Cochran, Daniel G Coit, Shouluan Ding, et al. Final version of 2009 ajcc melanoma staging and classification. *Journal of Clinical Oncology*, 27(36):6199–6206, 2009. 24
- [Bio15] Biomips. DBDermo-Mips/DDAX. <http://www.ddax.com>, 2015. Accessed: 2015-06-25. 32, 42
- [Bis06] Christopher M Bishop. Pattern recognition. *Machine Learning*, 128:1–58, 2006. 45, 61, 69, 127, 128, 175
- [BL04] Bruce Lawrence Berg and Howard Lune. *Qualitative research methods for the social sciences*, volume 5. Pearson Boston, 2004. 9
- [BMR11] Catarina Barata, Jorge S Marques, and Jorge Rozeira. Detecting the pigment network in dermoscopy images: a directional approach. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 5120–5123, Boston, Massachusetts, United States, 2011. IEEE. 54, 55
- [BMR12a] Catarina Barata, Jorge S Marques, and Jorge Rozeira. A system for the automatic detection of pigment network. In *2012 9th IEEE International Symposium on Biomedical Imaging (ISBI)*, pages 1651–1654, Barcelona, Spain, 2012. IEEE. 54, 55

- [BMR12b] Catarina Barata, Jorge S Marques, and Jorge Rozeira. A system for the detection of pigment network in dermoscopy images using directional filters. *IEEE Transactions on Biomedical Engineering*, 59(10):2744–2754, October 2012. xxii, 49, 51, 54, 55, 66, 67, 72, 77, 80, 81, 84, 85, 86, 87, 94, 221
- [Bre01] Leo Breiman. Random forests. *Machine Learning*, 45(1):5–32, 2001. 128, 170, 171, 173
- [BRO⁺05] Ralph Peter Braun, Harold S Rabinovitz, Margaret Oliviero, Alfred W Kopf, and Jean-Hilaire Saurat. Dermoscopy of pigmented skin lesions. *Journal of the American Academy of Dermatology*, 52(1):109–121, 2005. 33
- [Can86] John Canny. A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(6):679–698, 1986. 65, 76
- [Can16] Canfield. Canfield VECTRA. <http://www.canfieldsci.com/newsletter/stories/vectra-wb360-3d-whole-body-imaging-system/>, 2016. Accessed: 2016-11-09. xxi, 27, 31
- [CDDY06] Emmanuel Candes, Laurent Demanet, David Donoho, and Leixing Ying. Fast discrete curvelet transforms. *Multiscale Modeling & Simulation*, 5(3):861–899, 2006. 72, 79
- [CIE17] CIE (Commission Internationale de l’Éclairage). Comisión Internacional de la Iluminación (CIE: Commission Internationale de l’Éclairage). <http://www.cie.co.at>, 2017. Accessed: 2017-01-16. 116, 118
- [CIS⁺08] 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. *Computerized Medical Imaging and Graphics*, 32(8):670–677, December 2008. 49, 51, 53, 55

BIBLIOGRAFÍA

- [CKAS06] M Emre Celebi, Hassan A Kingravi, Y Alp Aslandogan, and William V Stoecker. Detection of blue-white veil areas in dermoscopy images using machine learning techniques. In *Medical Imaging*, pages 61445T–61445T. International Society for Optics and Photonics, 2006. 53, 55
- [CKU⁺07] M Emre Celebi, Hassan A. Kingravi, Bakhtiyar Uddin, Hitoshi Iyatomi, Y. Alp Aslandogan, William V. Stoecker, and Randy H. Moss. A methodological approach to the classification of dermoscopy images. *Computerized Medical Imaging and Graphics*, 31(6):362–373, September 2007. 45
- [Cor16] Cortex Technology. DermaScan. <http://www.cortex.dk/skin-analysis-products/dermascan-ultrasound.html>, 2016. Accessed: 2016-11-09. 29
- [CPG02] B Caputo, V Panichelli, and G E Gigante. Toward a quantitative analysis of skin lesion images. *Studies in Health Technology and Informatics*, 90:509–513, 2002. 48, 51, 53, 57, 74, 80, 81, 83, 85
- [Der15a] Derma Medical Systems. MoleMax. <http://www.dermamedicalsystems.com>, 2015. Accessed: 2015-06-25. 32
- [Der15b] DermLite. DermLite. <http://www.dermlite.com>, 2015. Accessed: 2015-06-25. 32
- [Der15c] DermoScan. DermoGenius. <http://www.dermoscan.de>, 2015. Accessed: 2015-06-25. 32, 42
- [Der15d] Dermoscopix. Dermoscopix. <http://www.dermoscopix.com>, 2015. Accessed: 2015-06-25. 32, 42
- [Der16] Derma Medical Systems. MoleMax HD. http://www.dermamedicalsystems.com/index.php?menu_id=182&locale=es, 2016. Accessed: 2016-11-09. xxi, 28, 31

- [DFP⁺09] Giuseppe Di Leo, Gabriella Fabbrocini, Alfredo Paolillo, Orsola Rescigno, and Paolo Sommella. Towards an automatic diagnosis system for skin lesions: Estimation of blue-whitish veil and regression structures. In *2009 6th International Multi-Conference on Systems, Signals and Devices*, pages 1–6, Djerba, Tunisia, March 2009. IEEE. 49, 51, 52, 53, 54, 55
- [DLFL⁺04] G Di Leo, G Fabbrocini, C Liguori, A Pietrosanto, and M Sclavenzi. Elm image processing for melanocytic skin lesion diagnosis based on 7-point checklist: a preliminary discussion. In *Proc. 13th Int. Symp. Measurements for Research and Industry Applications, IMEKO, Budapest, Hungary*, pages 474–479, 2004. 53, 54, 55
- [DLPS08] G. Di Leo, C. Liguori, A. Paolillo, and P. Sommella. An improved procedure for the automatic detection of dermoscopic structures in digital ELM images of skin lesions. In *2008 IEEE Conference on Virtual Environments, Human-Computer Interfaces and Measurement Systems*, pages 190–194, Istanbul, Turkey, July 2008. IEEE. xxii, 48, 51, 53, 54, 55, 60, 75, 80, 81, 83, 87, 94
- [DLPS⁺10] G Di Leo, A Paolillo, P Sommella, G Fabbrocini, and O Rescigno. A software tool for the diagnosis of melanomas. In *2010 IEEE Instrumentation and Measurement Technology Conference (I2MTC)*, pages 886–891, Austin, Texas, United States, 2010. IEEE. 53, 54, 55
- [DMS⁺11] Ankur Dalal, Randy H. Moss, R. Joe Stanley, William V. Stoecker, Kapil Gupta, David A. Calcara, Jin Xu, Bijaya Shrestha, Rhett Drugge, Joseph M. Malters, and Lindall A. Perry. Concentric decile segmentation of white and hypopigmented areas in dermoscopy images of skin lesions allows discrimination of malignant melanoma. *Computerized Medical Imaging and Graphics*, 35(2):148–154, March 2011. 49, 51, 52, 54

BIBLIOGRAFÍA

- [DPSF10] G. Di Leo, A. Paolillo, P. Sommella, and G. Fabbrocini. Automatic Diagnosis of Melanoma: A Software System Based on the 7-Point Check-List. In *2010 43rd Hawaii International Conference on System Sciences*, pages 1–10, Honolulu, Hawaii, United States, 2010. IEEE. 45, 49, 51, 53, 54, 55, 60
- [Ecl16] Eclipse. Eclipse Project. <http://www.eclipse.org/>, 2016. Accessed: 2016-12-20. 163
- [FA91] William T Freeman and Edward H Adelson. The design and use of steerable filters. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(9):891–906, 1991. 68, 78
- [FB73] Wendell L French and Cecil H Bell. *Organization development: Behavioral science interventions for organization improvement*. Prentice-Hall Englewood Cliffs, NJ, 1973. 9
- [FBDL⁺10] Gabriella Fabbrocini, Giovanni Betta, Giuseppe Di Leo, Consolatina Liguori, Alfredo Paolillo, Antonio Pietrosanto, Paolo Sommella, Orsola Rescigno, Sara Cacciapuoti, Francesco Pastore, et al. Epiluminescence image processing for melanocytic skin lesion diagnosis based on 7-point check-list: a preliminary discussion on three parameters. *The Open Dermatology Journal*, 4(110-115):57, 2010. 53, 54, 55
- [FBH⁺97] Hugh S Fairman, Michael H Brill, Henry Hemmendinger, et al. How the cie 1931 color-matching functions were derived from wright-guild data. *Color Research & Application*, 22(1):11–23, 1997. 113
- [FCT⁺09] Jose Fernandez Alcon, Calina Ciuhu, Warner Ten Kate, Adrienne Heinrich, Natallia Uzunbajakava, Gertruud Krekels, Denny Siem, and Gerard De Haan. Automatic Imaging System With Decision Support for Inspection of Pigmented Skin Lesions and Melanoma Diagnosis. *IEEE Journal of Selected Topics in Signal Processing*, 3(1):14–25, February 2009. 44, 45

- [FHT⁺00] Jerome Friedman, Trevor Hastie, Robert Tibshirani, et al. Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors). *The annals of statistics*, 28(2):337–407, 2000. 64, 76
- [Fij16a] Fiji. Fiji FeatureJ. <http://imagej.net/FeatureJ>, 2016. Accessed: 2016-02-04. 119, 121, 123, 124, 125
- [Fij16b] Fiji. Fiji image processing software. <http://fiji.sc/Fiji>, 2016. Accessed: 2016-02-04. 91, 119, 121, 123, 124, 125, 163, 166
- [Fij16c] Fiji. Fiji ImageScience library. <http://imagej.net/ImageScience>, 2016. Accessed: 2016-02-04. 119, 121, 123, 124, 125
- [Fij16d] Fiji. Fiji Trainable Weka Segmentation. http://imagej.net/Trainable_Weka_Segmentation, 2016. Accessed: 2016-02-04. 119, 121, 123, 124, 125
- [Fit88] Thomas B Fitzpatrick. The validity and practicality of sun-reactive skin types i through vi. *Archives of dermatology*, 124(6):869–871, 1988. 22
- [Fot15] FotoFinder Systems. FotoFinder. <http://www.fotofinder.de>, 2015. Accessed: 2015-06-25. 32
- [Fre14] Fredrik Lundh and Contributors. Python Imaging Library. <http://www.pythonware.com/products/pil/>, 2014. Accessed: 2014-11-14. 89
- [FS95] Yoav Freund and Robert E Schapire. A decision-theoretic generalization of on-line learning and an application to boosting. In *European conference on computational learning theory*, pages 23–37. Springer, 1995. 66, 72, 77, 79
- [FSCZ99] Matthew G Fleming, Carsten Steger, Armand B Coggnetta, and Jun Zhang. Analysis of the network pattern in dermatoscopic images. *Skin Research and Technology*, 5(1):42–48, 1999. 48, 51, 52, 53, 55, 56, 58, 74, 80, 81, 83, 85

BIBLIOGRAFÍA

- [FSG96] Stefan Fischer, Philippe Schmid, and Joël Guillod. Analysis of skin lesions with pigmented networks. In *1996 International Conference on Image Processing*, volume 1, pages 323–326, Lausanne, Switzerland, 1996. IEEE. 48, 51, 53, 56, 74, 80, 83, 85
- [FSZ⁺98] Matthew G. Fleming, Carsten Steger, Jun Zhang, Jianbo Gao, Armand B. Coggnetta, Llya Pollak, and Charles R. Dyer. Techniques for a structural analysis of dermatoscopic imagery. *Computerized Medical Imaging and Graphics*, 22(5):375–389, September 1998. 48, 51, 53, 55
- [FVC⁺14] Gabriella Fabbrocini, Valerio De Vita, Sara Cacciapuoti, Giuseppe Di Leo, Consolatina Liguori, Alfredo Paolillo, Antonio Pietrosanto, and Paolo Sommella. Automatic Diagnosis of Melanoma Based on the 7-Point Checklist. In J Scharcanski and M E Celebi, editors, *Computer Vision Techniques for the Diagnosis of Skin Cancer*, pages 71–107. Springer, 2014. 45, 53, 54, 55
- [Gab46] Dennis Gabor. Theory of communication. part 1: The analysis of information. *Journal of the Institution of Electrical Engineers-Part III: Radio and Communication Engineering*, 93(26):429–441, 1946. 125
- [GAGZ14] Jose Luis García Arroyo and Begoña García Zapirain. Detection of pigment network in dermoscopy images using supervised machine learning and structural analysis. *Computers in Biology and Medicine*, 44:144–157, 2014. xxii, 50, 51, 54, 70, 71, 78, 80, 81, 84, 85, 86, 94, 221
- [GAGZ15] Jose Luis Garcia-Arroyo and Begonya Garcia-Zapirain. Hypopigmentation pattern recognition in dermoscopy images for melanoma detection. *Journal of Medical Imaging and Health Informatics*, 5(8):1875–1879, 2015. 50, 51, 54

- [GBS06] Pall Oskar Gislason, Jon Atli Benediktsson, and Johannes R Sveinsson. Random forests for land cover classification. *Pattern Recognition Letters*, 27(4):294–300, 2006. 170, 173
- [GCC⁺16] David Gutman, Noel CF Codella, Emre Celebi, Brian Helba, Michael Marchetti, Nabin Mishra, and Allan Halpern. Skin lesion analysis toward melanoma detection: A challenge at the international symposium on biomedical imaging (isbi) 2016, hosted by the international skin imaging collaboration (isic). *arXiv preprint arXiv:1605.01397*, 2016. 4, 5, 42, 45, 91
- [GCPS06] C. Grana, R. Cucchiara, G. Pellacani, and S. Seidenari. Line Detection and Texture Characterization of Network Patterns. In *18th International Conference on Pattern Recognition (ICPR'06)*, volume 2, pages 275–278, Hong Kong, China, 2006. IEEE. 53, 55
- [GDP⁺07] Costantino Grana, Vanini Daniele, Giovanni Pellacani, Stefania Seidenari, and Rita Cucchiara. Network patterns recognition for automatic dermatologic images classification. In *Medical Imaging*, pages 65124C–65124C, San Diego, California, United States, 2007. 2007 International Society for Optics and Photonics. 48, 51, 53, 55, 58, 74, 80, 81, 83, 85, 86
- [GG09] Agnessa Gadeliya Goodson and Douglas Grossman. Strategies for early melanoma detection: Approaches to the patient with nevi. *Journal of the American Academy of Dermatology*, 60(5):719–738, May 2009. 2, 28, 30
- [GGM11a] Jose Luis García Arroyo, Begoña García Zapirain, and Amaia Mendez Zorrilla. Blue-white veil and dark-red patch of pigment pattern recognition in dermoscopic images using machine-learning techniques. In *2011 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*, pages 196–201, Bilbao, Spain, December 2011. IEEE. 49, 51, 54

BIBLIOGRAFÍA

[GGM11b] Andrés Gola Isasi, Begoña García Zapirain, and Amaia Mendez Zorrilla. Melanomas non-invasive diagnosis application based on the ABCD rule and pattern recognition image processing algorithms. *Computers in Biology and Medicine*, 41(9):742–755, September 2011. 49, 51, 54, 55, 65, 76, 80, 81, 84, 85, 86

[GIGZMZRO10] A Gola Isasi, B García Zapirain, A Mendez Zorrilla, and I Ruiz Oleagordia. Automated diagnosis of melanomas based on globular and reticular pattern recognition algorithms for epiluminiscence images. In *18th European Signal Processing Conference (EUSIPCO-2010)*, pages 264–268, Aalborg, Netherlands, 2010. 54, 55

[GM11] Pascale Guitera and Scott W Menzies. State of the art of diagnostic technology for early-stage melanoma. *Expert review of anticancer therapy*, 11(5):715–723, May 2011. 2, 26, 28, 30

[GPR⁺01] H. Ganster, A. Pinz, R. Röhner, E. Wildling, M. Binder, and H. Kittler. Automated melanoma recognition. *IEEE Transactions on Medical Imaging*, 20(3):233–9, March 2001. 45

[GW08] Rafael C. Gonzalez and Richard E. Woods. *Digital Image Processing, 3rd edition*. Prentice Hall, 2008. 56, 74, 112, 114, 115, 116, 120, 121, 122

[Hei15] Heine. Dermatoscope Delta. <http://www.heine.com>, 2015. Accessed: 2015-06-25. 32

[HL05] Jin Huang and Charles X Ling. Using AUC and accuracy in evaluating learning algorithms. *IEEE Transactions on Knowledge and Data Engineering*, 17(3):299–310, 2005. 174, 184

[HSD73] Robert M. Haralick, K. Shanmugam, and Its' Hak Dinstein. Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6):610–621, November 1973. 59, 62, 64, 70, 72, 75, 76, 78, 79

- [Ima16] ImageJ2. ImageJ2. <https://imagej.net/ImageJ2>, 2016. Accessed: 2016-02-04. 90
- [Ins16] US National Cancer Institute. Estadiaje del melanoma. <http://www.cancer.gov/espanol/pdq/tratamiento/melanoma/Patient/page2>, 2016. Accessed: 2016-11-09. 24
- [Int16] International Skin Imaging Collaboration (ISIC). ISIC Archive. <https://isic-archive.com/>, 2016. Accessed: 2016-07-01. 5, 91, 246
- [Int17] International Skin Imaging Collaboration (ISIC)). 2017 IS-BI Challenge on Skin Lesion Analysis Towards Melanoma Detection. https://challenge.kitware.com/#challenge/n/ISIC-2017%3ASkinLesion_AnalysisTowardsMelanomaDetection, 2017. Accessed: 2017-02-25. 5, 92
- [IOC⁺08] Hitoshi Iyatomi, Hiroshi Oka, M Emre Celebi, Masahiro Hashimoto, Masafumi Hagiwara, Masaru Tanaka, and Koichi Ogawa. An improved Internet-based melanoma screening system with dermatologist-like tumor area extraction algorithm. *Computerized Medical Imaging and Graphics*, 32(7):566–579, October 2008. 45
- [Jai89] Anil K Jain. *Fundamentals of digital image processing*, volume 3. Prentice-Hall Englewood Cliffs, 1989. 57, 74
- [jav16] java.net. JAI. <https://java.net/projects/jai>, 2016. Accessed: 2016-02-04. 90, 113, 114, 115, 116, 117, 118, 163, 166
- [KAL⁺16] Pegah Kharazmi, Mohammed I AlJasser, Harvey Lui, Z Jane Wang, and Tim K Lee. Automated detection and segmentation of vascular structures of skin lesions seen in dermoscopy, with an application to basal cell carcinoma classification. *IEEE Journal of Biomedical and Health Informatics*, 2016. 50, 51, 54

BIBLIOGRAFÍA

- [KC83] R L Kashyap and R Chellappa. Estimation and choice of neighbors in spatial-interaction models of images. *IEEE Transactions on Information Theory*, 29(1):60–72, 1983. 61, 69, 75, 78
- [KG12] Konstantin Korotkov and Rafael Garcia. Computerized analysis of pigmented skin lesions: a review. *Artificial Intelligence in Medicine*, 56(2):69–90, October 2012. 4, 5, 42, 45
- [KGS⁺09] Azmath Khan, Kapil Gupta, R. J. Stanley, William V. Stoecker, Randy H. Moss, Giuseppe Argenziano, H. Peter Soyer, Harold S. Rabinovitz, and Armand B. Cognetta. Fuzzy logic techniques for blotch feature evaluation in dermoscopy images. *Computerized Medical Imaging and Graphics*, 33(1):50–57, January 2009. 49, 51, 52, 53
- [Kir14] Joseph Kirk. Count Loops in a Graph. http://www.mathworks.com/matlabcentral/fileexchange/10722-count-loops-in-a-graph/content/run_loops.m, 2014. Accessed: 2014-06-11. 63, 76
- [Kor14] Konstantin Korotkov. *Automatic change detection in multiple pigmented skin lesions*. PhD thesis, Universitat de Girona, 2014. 27
- [KVRP10] Ritwik Kumar, Amelio Vázquez-Reina, and Hanspeter Pfister. Radon-like features and their application to connectomics. In *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, pages 186–193, San Francisco, California, United States, 2010. IEEE. 68, 77
- [KY95] George Klir and Bo Yuan. *Fuzzy sets and fuzzy logic*, volume 4. Prentice hall New Jersey, 1995. 128, 129
- [Law80] K I Laws. Textured image segmentation. Technical report, DTIC Document, January 1980. <http://www.dtic.mil/cgi-bin/GetTRDoc?Location=U2&doc=GetTRDoc.pdf&AD=ADA083283>. Accessed: 2014-06-11. 58, 72, 74, 79

- [LG01] L.G.Shapiro and G.C.Stockman. *Computer Vision*. Prentice Hall, 2001. 114, 115, 117, 118, 119, 123, 125
- [Li01] S Z Li. *Markov random field modeling in image analysis*. Springer, 2001. 61, 69, 75, 78
- [LNG⁺97] Tim Lee, Vincent Ng, Richard Gallagher, Andrew Coldman, and David McLean. Dullrazor: A software approach to hair removal from images. *Computers in Biology and Medicine*, 27(6):533–543, November 1997. 58, 71
- [LO93] Pablo Lázaro Ochaita. *Dermatología. Texto y atlas*. Ed. Madrid, Graficas Reunidas, 1993. 14, 16, 17, 18, 22
- [LV95] Steven Lobregt and Max A Viergever. A discrete dynamic contour model. *IEEE Transactions on Medical Imaging*, 14(1):12–24, 1995. 57, 74
- [Mat14a] MathWorks. Image Processing Toolbox. <http://es.mathworks.com/products/image/>, 2014. Accessed: 2014-11-14. 89
- [Mat14b] MathWorks. Matlab. <http://es.mathworks.com/products/matlab/>, 2014. Accessed: 2014-11-14. 89
- [MAV16] MAVIG. VivaScope. <http://www.vivascope.de/es/microscopia-confocal.html>, 2016. Accessed: 2016-11-09. xxi, 29, 31
- [MD09] Ilias Maglogiannis and Charalampos N Doukas. Overview of advanced computer vision systems for skin lesions characterization. *IEEE Transactions on Information Technology in Biomedicine*, 13(5):721–733, 2009. 112
- [MDSA13] A Madooei, M S Drew, M Sadeghi, and M S Atkins. Automatic detection of blue-white veil by discrete colour matching in dermoscopy images. In *Proceedings of the 16th International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2013)*, pages 453–460, Nagoya, Japan, 2013. 49, 51, 54

BIBLIOGRAFÍA

- [MEL15] MELA Sciences. Melafind. <http://www.melafind.com>, 2015. Accessed: 2015-06-25. xxi, 28, 31, 32, 42
- [MICM96] S W Menzies, C Ingvar, K A Crotty, and W H McCarthy. Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features. *Archives of Dermatology*, 132(10):1178–1182, October 1996. 3, 36
- [ML09] Vamsi K. Madasu and Brian C. Lovell. Blotch Detection in Pigmented Skin Lesions Using Fuzzy Co-clustering and Texture Segmentation. In *2009 Digital Image Computing: Techniques and Applications*, pages 25–31, Melbourne, Australia, December 2009. IEEE. 49, 51, 53
- [MLH12] Hengameh Mirzaalian, Tim K Lee, and Ghassan Hamarneh. Learning features for streak detection in dermoscopic color images using localized radial flux of principal intensity curvature. In *2012 IEEE Workshop on Mathematical Methods in Biomedical Image Analysis*, pages 97–101, Breckenridge, Colorado, United States, January 2012. IEEE. 49, 51, 54
- [MPA⁺07] Josep Malvehy, Susana Puig, Giuseppe Argenziano, Ashfaq A Marghoob, and H Peter Soyer. Dermoscopy report: proposal for standardization. Results of a consensus meeting of the International Dermoscopy Society. *Journal of the American Academy of Dermatology*, 57(1):84–95, July 2007. 3, 33, 35, 36, 41
- [MPA09] J Malvehy, S Puig, and G Argenziano. *Principios de dermatoscopia*. Cedilp, tercera edición, 2009. xxi, 2, 4, 16, 17, 19, 22, 23, 26, 27, 28, 30, 32, 33, 34, 35, 36, 37, 38, 40
- [MPFP15] Marlene Machado, Jorge Pereira, and Rui Fonseca-Pinto. Classification of reticular pattern and streaks in dermoscopic images based on texture analysis. *Journal of Medical Imaging*, 2(4):044503–044503, 2015. 50, 51, 54, 55, 72, 79, 80, 81, 84, 85

- [MPFP16] Marlene Machado, Jorge Pereira, and Rui Fonseca-Pinto. Reticular pattern detection in dermoscopy: an approach using curvelet transform. *Research on Biomedical Engineering*, 32(2):129–136, 2016. 50, 51, 54, 55, 72, 79, 80, 81, 84, 85, 86
- [MSA09] Carlos S Mendoza, Carmen Serrano, and Begoña Acha. Pattern analysis of dermoscopic images based on fscm color markov random fields. In *Advanced Concepts for Intelligent Vision Systems*, pages 676–685. Springer, 2009. 53, 54, 55
- [MSM00] Anantha Murali, William V Stoecker, and Randy H Moss. Detection of solid pigment in dermatoscopy images using texture analysis. *Skin Research and Technology*, 6(4):193–198, 2000. 48, 51, 53, 55
- [Ope14a] OpenCV Foundation. Open Source Computer Vision Library. <http://sourceforge.net/projects/opencvlibrary/>, 2014. Accessed: 2014-11-14. 88
- [Ope14b] OpenCV Foundation. OpenCV. <http://opencv.org/>, 2014. Accessed: 2014-11-14. 88
- [OPM02] Timo Ojala, Matti Pietikainen, and Topi Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7):971–987, 2002. 67, 68, 77
- [Ora15a] Oracle. Java. <http://java.sun.com>, 2015. Accessed: 2015-07-10. 90, 163
- [Ora15b] Oracle. Java EE (Java Enterprise Edition). <http://www.oracle.com/technetwork/java/javaee/overview/index.html>, 2015. Accessed: 2015-07-20. 166, 167
- [Ora15c] Oracle. Java SE (Java Standard Edition). <http://www.oracle.com/technetwork/java/javase/overview/index.html>, 2015. Accessed: 2015-07-20. 167

BIBLIOGRAFÍA

- [Ora16a] Oracle. Fork/Join. <https://docs.oracle.com/javase/tutorial/essential/concurrency/forkjoin.html>, 2016. Accessed: 2016-12-20. 163
- [Ora16b] Oracle. Java DataBase Connectivity (JDBC). <https://docs.oracle.com/javase/8/docs/technotes/guides/jdbc/>, 2016. Accessed: 2016-08-10. 163, 167
- [Ora16c] Oracle. Java Persistence API (JPA). <http://www.oracle.com/technetwork/java/javaee/tech/persistence-jsp-140049.html>, 2016. Accessed: 2016-08-10. 162, 163, 167
- [Ots79] N Otsu. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9(1):62–66, 1979. 60
- [PGCS04] Giovanni Pellacani, Costantino Grana, Rita Cucchiara, and Stefania Seidenari. Automated extraction and description of dark areas in surface microscopy melanocytic lesion images. *Dermatology*, 208(1):21–26, 2004. 48, 51, 52, 53
- [PGS06] Maria Petrou and Pedro García Sevilla. *Image Processing: Dealing With Texture*. John Wiley & Sons, 2006. 112, 120, 121, 122, 123, 124, 125, 126
- [PH09] Estee L Psaty and Allan C Halpern. Current and emerging technologies in melanoma diagnosis: the state of the art. *Clinics in dermatology*, 27(1):35–45, 2009. 2, 27, 28, 29, 30
- [PP10] Maria Petrou and Costas Petrou. *Image Processing: The Fundamentals*. John Wiley & Sons, 2010. 114, 115, 117, 118, 119
- [PSW87] H Pehamberger, A Steiner, and K Wolff. In vivo epiluminescence microscopy of pigmented skin lesions. I. Pattern analysis of pigmented skin lesions. *Journal of the American Academy of Dermatology*, 17(4):571–583, October 1987. 3, 33, 95
- [Pyt14] Python Software Foundation. Python programming language. <https://www.python.org/>, 2014. Accessed: 2014-11-14. 89

- [Qui86] J. Ross Quinlan. Induction of decision trees. *Machine learning*, 1(1):81–106, 1986. 190
- [Qui93] John Ross Quinlan. *C4.5: programs for machine learning*, volume 1. Morgan Kaufmann, San Francisco, CA, 1993. 60, 70, 75, 78, 128, 183, 190
- [Rob77] Alan R Robertson. The cie 1976 color-difference formulae. *Color Research & Application*, 2(1):7–11, 1977. 118
- [RPERM⁺14] José Luis Rodríguez-Peralto, Enrique Espinosa, Juan José Ríos-Martín, Alfonso Berrocal, María Dolores Lozano, Ana Arance, Angel Santos-Briz, José Antonio López-Martín, María Teresa Fernández-Figueras, and Salvador Martín-Algarra. Recomendaciones para la determinación de biomarcadores en el melanoma metastásico. consenso nacional de la sociedad española de anatomía patológica y de la sociedad española de oncología médica. *Revista Española de Patología*, 47(1):9–21, 2014. 27
- [RRF10] Darrell S Rigel, Julie Russak, and Robert Friedman. The evolution of melanoma diagnosis: 25 years beyond the abcds. *CA: a cancer journal for clinicians*, 60(5):301–16, 2010. 2
- [RTL09] Payam Refaeilzadeh, Lei Tang, and Huan Liu. Cross-validation. In *Encyclopedia of database systems*, pages 532–538. Springer, 2009. 175
- [SA09] Carmen Serrano and Begoña Acha. Pattern analysis of dermoscopic images based on markov random fields. *Pattern Recognition*, 42(6):1052–1057, 2009. 49, 52, 53, 54, 55, 61, 68, 69, 75, 80, 81, 83, 85
- [SAC94] W. Stolz, A. Riemann, and A.B. Coggnetta. ABCD rule of dermatoscopy: a new practical method for early recognition of malignant melanoma. *European Journal of Dermatology*, 4:521–527, 1994. 3, 35, 95

BIBLIOGRAFÍA

- [Sad12] Maryam Sadeghi. *Towards prevention and early diagnosis of skin cancer: computer-aided analysis of dermoscopy images*. PhD thesis, Applied Science: School of Computing Science. Simon Fraser University, 2012. 54, 55
- [SAHW07] Hans Peter Soyer, Guiseppe Argenziano, and Rainer Hofmann-Wellenhof. *Color atlas of melanocytic lesions of the skin*. Springer, 2007. 37, 38, 40
- [SAS14] Aurora Saez, Begoña Acha, and Carmen Serrano. Pattern analysis in dermoscopic images. In J Scharcanski and M E Celebi, editors, *Computer Vision Techniques for the Diagnosis of Skin Cancer*, pages 23–48. Springer, 2014. 50, 52, 53, 54, 55
- [SBK⁺10] Bijaya Shrestha, Joseph Bishop, Keong Kam, Xiaohe Chen, Randy H. Moss, William V. Stoecker, Scott Umbaugh, R. Joe Stanley, M Emre Celebi, Ashfaq A. Marghoob, Giuseppe Argenziano, and H. Peter Soyer. Detection of atypical texture features in early malignant melanoma. *Skin Research and Technology*, 16(1):60–65, February 2010. 49, 51, 54, 62, 64, 75, 80, 81, 83, 85, 86
- [Sci14] SciPy.org. SciPy, a Python-based ecosystem of open-source software for mathematics, science and engineering. <http://www.scipy.org/>, 2014. Accessed: 2014-11-14. 89
- [SCLG05] G Sfikas, C Constantinopoulos, A Likas, and N P Galatsanos. An analytic distance metric for gaussian mixture models with application in image retrieval. In *Artificial Neural Networks: Formal Models and Their Applications–ICANN 2005*, pages 835–840. Springer, Warsaw, Poland, 2005. 70
- [SEO16] SEOM (Sociedad Española de Oncología Médica). Las cifras del cáncer en españa. http://www.seom.org/seomcms/images/stories/recursos/LAS_CIFRAS_DEL_CANCER_EN_ESP_2016.pdf, 2016. Accessed: 2016-11-09. 1, 26

- [Ser14] Servicio de Dermatología del Hospital del Mar (Barcelona). Información enfermedades dermatológicas. <http://www.dermatologia.cat/es/index.html>, 2014. Accessed: 2016-11-09. 19, 20, 22
- [SFAH92] Eero P Simoncelli, William T Freeman, Edward H Adelson, and David J Heeger. Shiftable multiscale transforms. *IEEE Transactions on Information Theory*, 38(2):587–607, 1992. 68, 78
- [SGS⁺05] William V. Stoecker, Kapil Gupta, R. Joe Stanley, Randy H. Moss, and Bijaya Shrestha. Detection of asymmetric blotches (asymmetric structureless areas) in dermoscopy images of malignant melanoma using relative color. *Skin Research and Technology*, 11(3):179–184, August 2005. 48, 51, 52, 53
- [SHB⁺08] Milan Sonka, Vaclav Hlavac, Roger Boyle, et al. *Image processing, analysis, and machine vision*, volume 3. Thomson Toronto, 2008. 98, 125, 126
- [SIU14] SIUE (Southern Illinois University Edwardsville). CVIPtools. <http://cviptools.ece.siu.edu/>, 2014. Accessed: 2014-11-14. 88
- [SKCI14] Gerald Schaefer, Bartosz Krawczyk, M Emre Celebi, and Hitoshi Iyatomi. An ensemble classification approach for melanoma diagnosis. *Memetic Computing*, 6(4):233–240, 2014. 45
- [Ski16] Skin Cancer Foundation. Skin cancer facts. <http://www.skin-cancer.org/Skin-Cancer-Facts/>, 2016. Accessed: 2016-11-09. 2, 26
- [SLL⁺11] Maryam Sadeghi, Tim K Lee, H Lui, D Mclean, and MS Atkins. Automated detection and analysis of dermoscopic structures on dermoscopy images. In *22 nd World Congress of Dermatology, Seoul, Korea*, 2011. 54, 55
- [SLL⁺13] M Sadeghi, T Lee, H Lui, D McLean, and S Atkins. Detection and analysis of irregular streaks in dermoscopic images of skin lesions. *IEEE Transactions on Medical Imaging*, 32(5):849–861, January 2013. 50, 51, 54, 55

BIBLIOGRAFÍA

- [SLM⁺12] M Sadeghi, T K Lee, D McLean, H Lui, and M S Atkins. Global pattern analysis and classification of dermoscopic images using textons. In *Proceedings of the SPIE 8314 Medical Imaging*, volume 8314, pages 83144X–83144X, San Diego, California, United States, 2012. International Society for Optics and Photonics. 49, 52, 54, 55
- [SM11] Louise Smith and Sheila Macneil. State of the art in non-invasive imaging of cutaneous melanoma. *Skin Research and Technology*, 17(3):257–269, February 2011. 2, 27, 28, 29
- [Smi78] Alvy Ray Smith. Color gamut transform pairs. *ACM Siggraph Computer Graphics*, 12(3):12–19, 1978. 115
- [SNM⁺09] Margarida Silveira, Jacinto C Nascimento, Jorge S Marques, André RS Marçal, Teresa Mendonça, Syogo Yamauchi, Junji Maeda, and Jorge Rozeira. Comparison of segmentation methods for melanoma diagnosis in dermoscopy images. *IEEE Journal of Selected Topics in Signal Processing*, 3(1):35–45, 2009. 66, 72
- [SRE⁺10] M Sadeghi, M Razmara, M Ester, TK Lee, and MS Atkins. Graph-based pigment network detection in skin images. In *SPIE Medical Imaging*, pages 762312–762312, San Diego, California, United States, 2010. International Society for Optics and Photonics. 54, 55
- [SRLA11] Maryam Sadeghi, Majid Razmara, Tim K. Lee, and M. Stella Atkins. A novel method for detection of pigment network in dermoscopic images using graphs. *Computerized Medical Imaging and Graphics*, 35(2):137–143, March 2011. xxii, 49, 51, 54, 55, 62, 63, 64, 75, 80, 81, 84, 85, 86, 94, 220, 221
- [SRW⁺10] Maryam Sadeghi, Majid Razmara, Paul Wighton, Tim K. Lee, and M. Stella Atkins. Modeling the Dermoscopic Structure Pigment Network Using a Clinically Inspired Feature Set. *Lecture*

-
- Notes in Computer Science*, 6326:467–474, 2010. xxii, 49, 51, 54, 55, 63, 64, 76, 80, 81, 82, 84, 85, 86, 87, 94
- [SS00] Robert E Schapire and Yoram Singer. Boostexter: A boosting-based system for text categorization. *Machine learning*, 39(2-3):135–168, 2000. 69, 78
- [SSA14] A Saez, C Serrano, and B Acha. Model-based classification methods of global patterns in dermoscopic images. *IEEE Transactions on Medical Imaging*, 33(5):1137–1147, 2014. 69, 78, 80, 81, 84, 85
- [SST⁺10] Stein Olav Skrovseth, Thomas R. Schopf, Kevin Thon, Maciel Zortea, Marc Geilhufe, Kajsa Mollersen, Herbert M. Kirchesch, and Fred Godtlielsen. A computer aided diagnostic system for malignant melanomas. In *2010 3rd International Symposium on Applied Sciences in Biomedical and Communication Technologies (ISABEL 2010)*, pages 1–5, Roma, Italy, November 2010. IEEE. 49, 51, 53, 61, 75, 81, 83, 85
- [Ste98] Carsten Steger. An unbiased detector of curvilinear structures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(2):113–125, 1998. 56, 57, 58, 74
- [Sun14] Sun Microsystems. Java Advanced Imaging (JAI). <http://java.sun.com/products/java-media/jai/current.html>, 2014. Accessed: 2014-11-14. 90, 163, 166
- [SW83] Chengjun Sun and William G Wee. Neighboring gray level dependence matrix for texture classification. *Computer Vision, Graphics, and Image Processing*, 23(3):341–352, 1983. 58, 74
- [SWC⁺11] William V Stoecker, Mark Wronkiewicz, Raed Chowdhury, R Joe Stanley, Jin Xu, Austin Bangert, Bijaya Shrestha, David A Calcara, Harold S Rabinovitz, Margaret Oliviero, Fatimah Ahmed, Lindall A Perry, and Rhett Drugge. Detection of granularity in dermoscopy images of malignant melanoma using color

BIBLIOGRAFÍA

- and texture features. *Computerized Medical Imaging and Graphics*, 35(2):144–7, March 2011. 49, 52, 54
- [SWL⁺14] Maryam Sadeghi, Paul Wighton, Tim K Lee, David McLean, Harvey Lui, and M Stella Atkins. Pigment network detection and analysis. In J Scharcanski and M E Celebi, editors, *Computer Vision Techniques for the Diagnosis of Skin Cancer*, pages 1–22. Springer, 2014. 54, 55
- [Tan98] Xiaoou Tang. Texture information in run-length matrices. *IEEE transactions on image processing*, 7(11):1602–1609, 1998. 59, 75
- [Ter14] Teresa Winslow. Imagen de los niveles de Clark. <http://www.cancer.gov/diccionario?cdrid=630445>, 2014. Accessed: 2016-11-09. xxi, 24
- [The16a] The University of Waikato. WEKA: Data Mining Software in Java. <http://www.cs.waikato.ac.nz/ml/weka>, 2016. Accessed: 2016-12-05. 62, 75
- [The16b] The University of Waikato. WEKA: Data Mining Software in Java. <http://www.cs.waikato.ac.nz/ml/weka>, 2016. Accessed: 2016-12-20. 163, 166, 170, 183
- [TIO15] TIOBE. TIOBE Index. <http://www.tiobe.com/index.php/content/paperinfo/tpci/index.html>, 2015. Accessed: 2015-07-10. 163
- [TTK⁺04] T Tanaka, S Torii, I Kabuta, K Shimizu, M Tanaka, and H Oka. Pattern classification of nevus with texture analysis. In *2004 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, volume 2, pages 1459–62, San Francisco, California, United States, January 2004. 53, 55
- [TTK⁺08] Toshiyuki Tanaka, Satoru Torii, Iukei Kabuta, Kunio Shimizu, and Masaru Tanaka. Pattern classification of nevus with texture

- analysis. *IEEJ Transactions on Electrical and Electronic Engineering*, 3(1):143–150, 2008. 48, 52, 53, 55, 59, 75, 80, 81, 83, 85
- [Umb10] Scott E Umbaugh. *Digital image processing and analysis: human and computer vision applications with CVIPtools*. CRC press, 2010. 88
- [Uns95] Michael Unser. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*, 4(11):1549–1560, 1995. 67, 77
- [US 14] US National Cancer Institute. Melanoma. <http://www.cancer.gov/espanol/tipos/piel/paciente/tratamiento-melanoma-pdq>, 2014. Accessed: 2016-11-09. 23
- [US 15] US National Library of Medicine. Imagen de las capas de la piel. https://medlineplus.gov/spanish/ency/esp_imagepages/8912.htm, 2015. Accessed: 2015-06-12. xxi, 15
- [US 16] US National Institute of Health. ImageJ. <http://imagej.nih.gov/ij/>, 2016. Accessed: 2016-02-04. 90, 113, 114, 115, 116, 117, 118, 163, 166
- [Vis15] Visiomed AG. MicroDerm. <http://www.visiomedag.com>, 2015. Accessed: 2015-06-25. 32
- [VJ04] Paul Viola and Michael J Jones. Robust real-time face detection. *International journal of computer vision*, 57(2):137–154, 2004. 72, 79
- [WA⁺93] Yoland Wadsworth, Action Research Issues Association, et al. *What is participatory action research?* Action Research Issues Association, 1993. 9
- [Wig11] Paul Wighton. *Towards automated skin lesion diagnosis*. PhD thesis, Applied Science: School of Computing Science. Simon Fraser University, 2011. 54

BIBLIOGRAFÍA

- [Wik05] Wikipedia Commons (no consta el nombre del autor). Imagen del cono del Modelo de Color HSV. https://upload.wikimedia.org/wikipedia/commons/f/f1/HSV_cone.jpg, 2005. Accessed: 2017-01-16. xxiii, 116
- [Wik06] Wikipedia Commons (no consta el nombre del autor). Campaña de Gauss 2D. https://commons.wikimedia.org/wiki/File:Gaussian_2d.png, 2006. Accessed: 2017-01-16. xxiii, 120
- [Wik09] Wikipedia Commons (no consta el nombre del autor). Ejemplo de conjunto nítido y conjunto difuso. https://en.wikipedia.org/wiki/File:Fuzzy_crisp.svg, 2009. Accessed: 2016-01-16. xxiii, 129
- [Wik11] Wikipedia Commons (no consta el nombre del autor). Validación cruzada de k iteraciones (con k=4). https://upload.wikimedia.org/wikipedia/commons/f/f2/K-fold_cross_validation.jpg, 2011. Accessed: 2017-01-16. xxvii, 175
- [Wik14] Wikipedia Commons (no consta el nombre del autor). Curva ROC. https://commons.wikimedia.org/wiki/File:ROC_curve.svg, 2014. Accessed: 2017-01-16. xxvii, 174
- [Wik15] Wikipedia Commons (no consta el nombre del autor). Imagen del tetraedro del Modelo de Color RGB. https://upload.wikimedia.org/wikipedia/commons/d/d6/RGB_color_cube.svg, 2015. Accessed: 2017-01-16. xxiii, 114
- [WLL⁺11] Paul Wighton, Tim K Lee, Harvey Lui, David I McLean, and M Stella Atkins. Generalizing common tasks in automated skin lesion diagnosis. *IEEE Transactions on Information Technology in Biomedicine*, 15(4):622–9, July 2011. 49, 51, 54, 55, 65, 76, 80, 81, 84, 85
- [WLM⁺11] Paul Wighton, Tim K Lee, Greg Mori, Harvey Lui, David I McLean, and M Stella Atkins. Conditional random fields and supervised learning in automated skin lesion diagnosis. *Journal of Biomedical Imaging*, 2011:8, 2011. 54, 55

- [WS82] Gunter Wyszecki and Walter Stanley Stiles. *Color science*, volume 8. Wiley New York, 1982. 116, 118, 119
- [WS10] Elisabeth M Wurm and H Peter Soyer. Scanning for melanoma. *Australian Prescriber*, 33(5):150–155, 2010. 32
- [WSLA09] Paul Wighton, Maryam Sadeghi, Tim K Lee, and M Stella Atkins. A fully automatic random walker segmentation for skin lesions in a supervised setting. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 1108–1115. Springer, 2009. 62
- [WW99] J Weston and C Watkins. Support vector machines for multi-class pattern recognition. In *Proceedings of the European Symposium on Artificial Neural Networks (ESANN 1999)*, pages 219–224, Bruges, Belgium, 1999. 67, 77
- [WZA06] Nigel Williams, Sebastian Zander, and Grenville Armitage. A preliminary performance comparison of five machine learning algorithms for practical ip traffic flow classification. *ACM SIGCOMM Computer Communication Review*, 36(5):5–16, 2006. 183, 190
- [XFZ06] Yong Xia, Dagan Feng, and Rongchun Zhao. Adaptive segmentation of textured images by using the coupled markov random field model. *IEEE Transactions on Image Processing*, 15(11):3559–3566, 2006. 69
- [YTTO04] Sumi Yoshino, Toshiyuki Tanaka, Masaru Tanaka, and Hiroshi Oka. Application of morphology for detection of Dots in tumor. *SICE 2004 Annual Conference*, 1:591–594, 2004. 48, 51, 53
- [Zad65] Lotfi A Zadeh. Fuzzy sets. *Information and control*, 8(3):338–353, 1965. 128
- [Zad78] Lotfi Asker Zadeh. Fuzzy sets as a basis for a theory of possibility. *Fuzzy sets and systems*, 1(1):3–28, 1978. 129

*Las ciencias aplicadas no existen,
sólo las aplicaciones de la ciencia.*

Louis Pasteur

APPENDIX



MELANOPAS: un prototipo para el diagnóstico de melanoma

En este apéndice se muestra el prototipo MELANOPAS, un sistema de detección automatizada de melanoma diseñado y desarrollado por el autor de esta tesis, basado en el algoritmo médico de la “Regla del ABCD”, en el que se han integrado muchos de los algoritmos de procesamiento digital de imagen desarrollados en la presente investigación. En primer lugar se hace una introducción al sistema, en segundo lugar se muestra la arquitectura y en tercer lugar se describe la herramienta software para el diagnóstico automatizado.

A.1 Introducción

En el transcurso de esta investigación se ha diseñado y desarrollado el prototipo MELANOPAS. Es un CAD para el diagnóstico de melanoma basado en el algoritmo médico “Regla del ABCD” –descrito en 2.1.3.6–, muy usado por los médicos debido a su sencillez y los buenos resultados que proporciona. Por tanto, en este sistema software se tienen en cuenta indicadores relativos a la asimetría de la lesión,

A. MELANOPAS: UN PROTOTIPO PARA EL DIAGNÓSTICO DE MELANOMA

tanto en forma como en color, el grado de abrupción de los bordes, la cantidad de colores diferentes que tiene y, finalmente, la presencia o no de las siguientes estructuras o patrones dermatoscópicos: reticular, globular, puntos, áreas homogéneas y desestructuradas y pseudópodos.

A.2 Arquitectura

Tal y como se puede ver en la Fig. A.1, el sistema es multiplataforma y multiacceso, ofreciendo la posibilidad de analizar imágenes macroscópicas y dermatoscópicas clásicas. El médico puede acceder vía la herramienta software al sistema diagnóstico, que está integrado con la base de datos. Los usuarios no médicos, para labores de screening, pueden acceder vía móvil o web a la plataforma de teledermatoscopia, que está integrada con el propio sistema diagnóstico. Las imágenes dermatoscópicas que se analizan pueden ser tomadas desde diferentes fuentes y con diferentes fabricantes, no estando el sistema integrado con ningún hardware concreto.

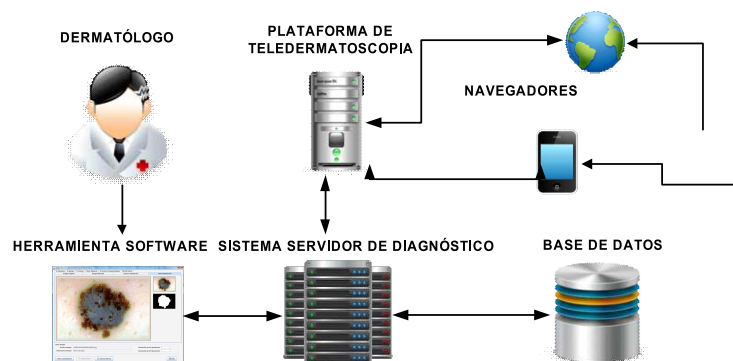


Figura A.1: Arquitectura de MELANOPAS

A continuación se describirá la herramienta software, integrada con el sistema automatizado para el diagnóstico de melanoma, que es el núcleo del sistema.

A.3 Herramienta software para el diagnóstico automatizado

El análisis se realiza en dos etapas. En primer lugar, se realiza el preprocesado (mejora) de la imagen y la segmentación (delimitación) de la lesión. Esta segmentación

A.3 Herramienta software para el diagnóstico automatizado

es posible mejorarla de manera manual por parte del usuario, en caso de que no sea del todo exacta. En segundo lugar, se realiza la detección y caracterización cuantitativa de los indicadores y el posterior diagnóstico a partir de los valores numéricos hallados.

En el sistema se tienen cuatro módulos, correspondientes a las cuatro últimas tareas del ciclo de vida de un sistema automatizado de detección de melanoma, explicadas en 2.2.1.1. Estos módulos se comentan a continuación.

A.3.1 Preprocesado

Se realiza el preprocesado de la imagen. Se detectan y eliminan artefactos de ruido tales como pelos, burbujas, flashes, marcos negros y dispositivos y reglas para medir.

A.3.2 Segmentación

Se realiza la segmentación de la imagen. Además, el sistema proporciona la posibilidad de realizar una segmentación manual para mejorar la obtenida de manera automatizada.

A.3.3 Detección y caracterización de indicadores

A.3.3.1 A: Asimetría

Tras realizar el cálculo de los ejes mayor y menor se computa la asimetría de la imagen con respecto a dichos ejes, en forma y color. En la Fig. A.2 se muestra gráficamente un ejemplo de su ejecución.

A.3.3.2 B: Bordes

Tras realizar el cálculo de los octantes, se calcula el grado de abruptación del borde de la lesión en cada uno de los octantes. En la Fig. A.3 se muestra gráficamente un ejemplo de su ejecución.

A. MELANOPAS: UN PROTOTIPO PARA EL DIAGNÓSTICO DE MELANOMA

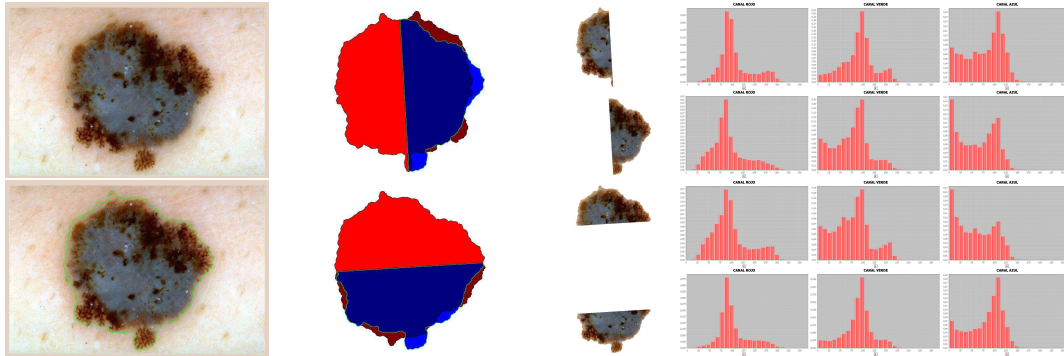


Figura A.2: Computación de la asimetría en una imagen: 1. Preprocesada; 2. Comparación de formas respecto al eje mayor; 3. Comparación de histogramas respecto a eje mayor; 4. Imagen con los ejes; 5. Comparación de formas respecto a eje menor; 6. Comparación de histogramas respecto a eje mayor. La imagen es simétrica en formas con respecto a ambos ejes, y asimétrica en color con respecto a ambos ejes. Por tanto, es asimétrica en ambos ejes. Puntuación: 2.6.




Figura A.3: Computación de los bordes en una imagen: 1. Preprocesada; 2. Imagen con los octantes generados; 3. Corona en el entorno del borde de la lesión donde se examina la abruptción de bordes; 4. Imagen con los límites pintados; 5. Imagen con los radios para el análisis generados; 6. Octante I; 7. Análisis del sector I. La imagen tiene abruptos los sectores: I, II, V, VI y VII. Puntuación: 0,5.

A.3 Herramienta software para el diagnóstico automatizado

A.3.3.3 C: Color

Se genera un mapa correspondientes a los 6 colores (blanco, marrón claro, marrón oscuro, azul-gris, rojo y negro). En la Fig. A.4 se muestran ejemplos.




Figura A.4: Clasificación de los colores en dos imágenes. La primera tiene 3 colores. Puntuación: 1,5. La segunda tiene 2 colores. Puntuación: 1,0.

A.3.3.4 D: Estructuras Dermatoscópicas

Áreas homogéneas y desestructuradas

Se calculan las áreas homogéneas y desestructuradas, a partir del reconocimiento de los patrones homogéneo, homogéneo azulado, manchas de pigmento e hipopigmentación. Si la unión de estas estructuras es superior al 15 % de la lesión, se considera que tiene este patrón. Se muestran ejemplos en la Fig. A.5.




Figura A.5: Computación de estructuras dermatoscópicas (reticular no incluido): primero la imagen, segundo la máscara del patrón (mapa en el caso de áreas homogéneas y desestructuradas). 1. Áreas homogéneas y desestructuradas, puntuación: 0,5; 2. Globular, puntuación: 0,5; 3. Puntos, puntuación: 0,5; 4. Pseudópodos, puntuación: 0,5.

A. MELANOPAS: UN PROTOTIPO PARA EL DIAGNÓSTICO DE MELANOMA

Reticular, glóbulos, puntos y pseudópodos

Se realiza la detección de estos patrones dermatoscópicos, y se considera que tiene el patrón reticular/glóbular/puntos/pseudópodos en caso de tener un número de retículos/glóbulos/puntos/pseudópodos mayor o igual que un valor umbral –uno diferente para cada patrón–. Se puestran ejemplos en la Fig. A.5, salvo en el caso de la estructura reticular, ya que este patrón ha sido comentado con detalle en este documento.

A.3.4 Diagnosis

La herramienta software realiza la diagnosis con la “Regla del ABCD” a partir de los valores calculados de los indicadores. A continuación, en la Fig. A.6, se ven algunas imágenes del proceso completo, usando la herramienta software, con el diagnóstico al final.

A.3 Herramienta software para el diagnóstico automatizado

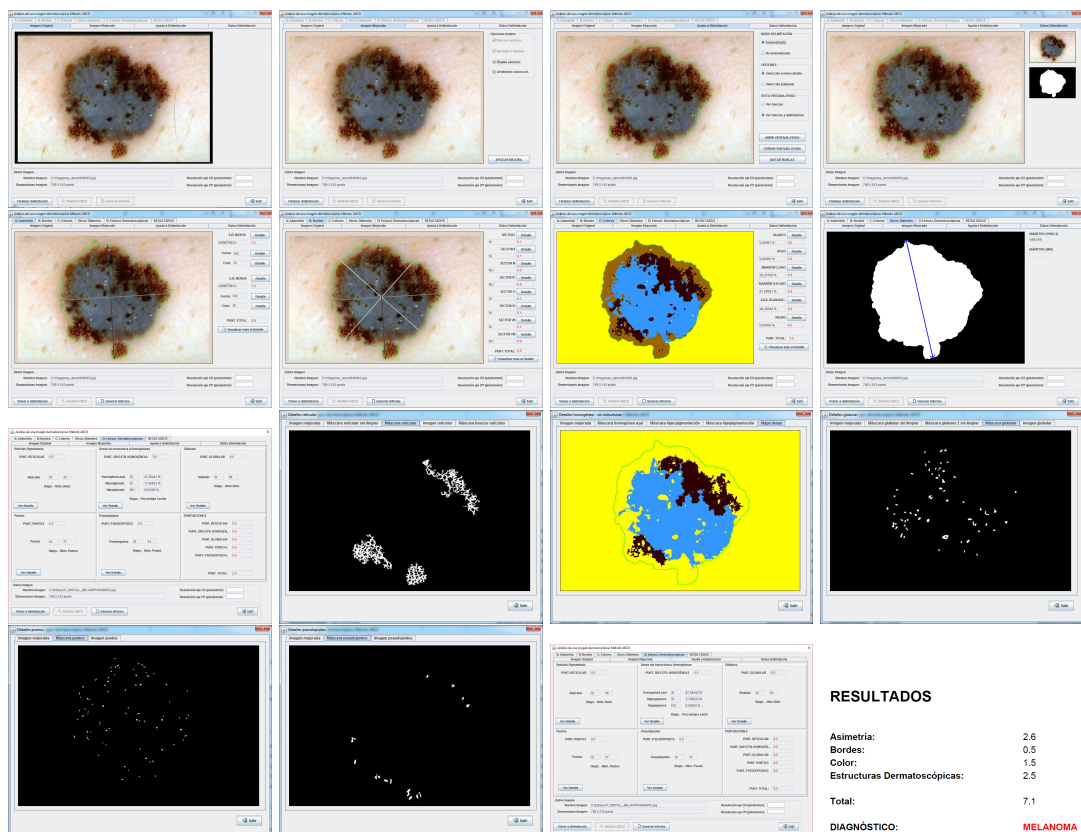


Figura A.6: Algunas ventanas de la herramienta software: 1. Imagen original; 2. Pre-procesada; 3. Segmentación manual por si se requiere; 4. Segmentada; 5. A: Asimetría; 6. B: Bordes; 7. C: Colores; 8. D: Estructuras Dermoscópicas; 9. Resultados; 10. Máscara reticular; 11- Áreas homogéneas y desestructuradas; 12. Máscara globular; 13. Máscara puntos; 14. Máscara pseudópodos; 15. Resultados; 16. Informe generado.