

Proyecto Fin de Carrera

Ingeniería de Telecomunicación

Desarrollo de un Modelo de Inteligencia Artificial para la Clasificación de Hemangiomas Infantiles Mediante Aprendizaje Máquina

Autor: Jorge Gonzalo Linares Serrano

Tutores:

Carmen Serrano Gotarredona

Begoña Acha Piñero

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

Sevilla, 2024



Proyecto Fin de Carrera
Ingeniería de Telecomunicación

Desarrollo de un Modelo de Inteligencia Artificial para la Clasificación de Hemangiomas Infantiles Mediante Aprendizaje Máquina

Autor:

Jorge Gonzalo Linares Serrano

Tutores:

Carmen Serrano Gotarredona

Begoña Acha Piñero

Profesoras titulares

Dpto. de Teoría de la Señal y Comunicaciones

Escuela Técnica Superior de Ingeniería

Universidad de Sevilla

Sevilla, 2024

Proyecto Fin de Carrera: Desarrollo de un Modelo de Inteligencia Artificial para la Clasificación de Hemangiomas Infantiles Mediante Aprendizaje Máquina

Autor: Jorge Gonzalo Linares Serrano

Tutores: Carmen Serrano Gotarredona

Begoña Acha Piñero

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

Presidente:

Vocales:

Secretario:

Acuerdan otorgarle la calificación de:

Sevilla, 2024

El Secretario del Tribunal

A mi familia

A mis maestros

Agradecimientos

En primer lugar querría agradecer a mis tutoras por todo su trabajo y paciencia ya que gracias a ellas este trabajo ha sido posible. También quiero agradecer a todas las personas que me han acompañado a lo largo de este viaje por las telecomunicaciones, a mi familia que siempre ha estado ahí para apoyarme incondicionalmente, a mis amigos que han sido un gran apoyo durante todos estos años, a mis profesores que me han formado tanto profesionalmente como humanamente, y a todo el resto de personas que han hecho posible que hoy esté donde estoy.

Jorge Gonzalo Linares Serrano

Sevilla, 2024

Los Hemangiomas Infantiles son tumores vasculares no cancerígenos muy comunes entre los bebés, aproximadamente 1 de cada 20 bebés tienen un hemangioma. Con este trabajo de fin de grado se pretende desarrollar un modelo de inteligencia artificial que asista al personal médico en el diagnóstico de estos hemangiomas.

El sistema consistirá en extraer características que representen propiedades de los colores y la textura presentes en las lesiones, y entrenar con esas características un modelo SVM (Máquina de vectores de soporte). Estas características servirán para diferenciar los distintos tipos de hemangiomas, y se realizará un estudio de las más discriminatorias y útiles para este propósito. Con estas características seleccionadas se entrenará un modelo de aprendizaje máquina que sea capaz de clasificar las imágenes de los HI según su profundidad.

Actualmente el personal médico diagnostica los HI principalmente mediante simple inspección visual, aunque se pueden apoyar en otras técnicas como la ecografía Doppler o la resonancia magnética, pero estas técnicas no están siempre disponibles y su costo es elevado. El objetivo de este proyecto es elaborar una herramienta que ayude al personal médico a diagnosticar HI de forma rápida. Para ello aplicaremos el uso de técnicas de aprendizaje máquina para cumplir este cometido. De esta manera se podrán diagnosticar los HI de forma más rápida y a menor coste.

Para la elaboración de este proyecto se han extraído características de un conjunto de imágenes fotográficas convencionales de HI y se ha entrenado un modelo SVM (*support-vector machines*) que ha obtenido una precisión de hasta el 100%.

Abstract

Infantile hemangiomas are very common non-cancerous vascular tumors among infants, approximately 1 in 20 infants have a hemangioma. The aim of this final degree project is to develop an artificial intelligence model that assists medical personnel in the diagnosis of these hemangiomas.

The system will consist of extracting features representing color and texture properties present in the lesions, and training a SVM (Support Vector Machine) model with these features. These features will be used to differentiate the different types of hemangiomas, and a study will be made of the most discriminating and useful ones for this purpose. With these selected features, a machine learning model will be trained to classify the images of IHs according to their depth.

Currently, medical personnel diagnose IH mainly by simple visual inspection, although they can rely on other techniques such as Doppler ultrasound or magnetic resonance imaging, but these techniques are not always available and their cost is high. The aim of this project is to develop a tool that will help medical personnel to diagnose IH quickly. To this end, we will apply the use of machine learning techniques to develop an artificial intelligence that fulfills this task. In this way, IH can be diagnosed more quickly and at a lower cost.

For the development of this project, features have been extracted from a set of conventional photographic images of HI and a SVM (support-vector machines) model has been trained to obtain an accuracy of up to 100%.

Agradecimientos	ix
Resumen	xi
Abstract	xiii
Índice	xiv
ÍNDICE DE TABLAS	xvi
ÍNDICE DE FIGURAS	xviii
Notación	xx
1 Introducción	1
1.1 ¿Qué es un hemangioma?	1
1.2 Protocolo clínico de actuación en el tratamiento de un hemangioma	2
1.3 Inteligencia artificial	3
1.4 Métodos de IA actuales para el diagnóstico automático de HI en la literatura	3
2 Material y Metodología	5
2.1 Material	5
2.2 Metodología	5
2.2.1 Preprocesamiento de las imágenes	5
2.2.2 Cuantificación de las imágenes	6
2.2.3 Cálculo de las matrices coocurrencia	8
2.2.4 Extracción de características	9
2.2.5 Selección de características	10
2.3 Entrenamiento del clasificador	10
3 Resultados	11
4 Conclusiones y Futuras Mejoras	19
4.1 Conclusiones	19
4.2 Futuras mejoras	19
Referencias	21

ÍNDICE DE TABLAS

Tabla 2–1. Matrices CCM	9
Tabla 3–1. P-value de las características de las imágenes CIECAM16	11
Tabla 3–2. P-value de las características de las imágenes CCM	11
Tabla 3–3. Correlación entre las características seleccionadas de las imágenes CIECAM16	12
Tabla 3–4. Correlación entre las características seleccionadas de las CCM	14
Tabla 3–5. Características seleccionadas de las imágenes CIECAM16 y las CCM	14
Tabla 3–6. Correlación entre las características seleccionadas de las imágenes CIECAM16 y las CCM	15
Tabla 3–7. P-value de las características seleccionadas de las imágenes CIECAM16 y las CCM	15
Tabla 3–8. Características seleccionadas para el entrenamiento	15
Tabla 3–9. Resultados con características de las CCM	16
Tabla 3–10. Resultados con características de las imágenes CIECAM16	16
Tabla 3–11. Resultados con características teóricamente óptimas	16
Tabla 3–12. Resultados con todas las características	16
Tabla 3–13. Resultados comparativo de los cuatro conjuntos de características	17
Tabla 3–14. Resultados con características de las CCM	17
Tabla 3–15. Resultados con características de las imágenes CIECAM16	17
Tabla 3–16. Resultados con características teóricamente óptimas	18
Tabla 3–17. Resultados con todas las características	18
Tabla 3–18. Resultados comparativo de los cuatro conjuntos de características	18

ÍNDICE DE FIGURAS

Figura 1-1. Imagen de HI superficial	1
Figura 1-2. Imagen de HI profundo	2
Figura 1-3. Imagen de HI mixto	2
Figura 2-1. Diagrama de flujo del proyecto	5
Figura 2-2. Imagen original	7
Figura 2-3. Imagen cuantificada a 21 centroides	8

Notación

A^*	Conjugado
c.t.p.	En casi todos los puntos
c.q.d.	Como queríamos demostrar
■	Como queríamos demostrar
e.o.c.	En cualquier otro caso
e	número e
IRe	Parte real
IIm	Parte imaginaria
sen	Función seno
tg	Función tangente
arctg	Función arco tangente
sen	Función seno
$\sin^x y$	Función seno de x elevado a y
$\cos^x y$	Función coseno de x elevado a y
Sa	Función sampling
sgn	Función signo
rect	Función rectángulo
Sinc	Función sinc
$\partial y \partial x$	Derivada parcial de y respecto
x°	Notación de grado, x grados.
$\Pr(A)$	Probabilidad del suceso A
SNR	Signal-to-noise ratio
MSE	Minimum square error
:	Tal que
<	Menor o igual
>	Mayor o igual
\	Backslash
$\Leftrightarrow$	Si y sólo si

1 INTRODUCCIÓN

El objetivo de este trabajo es elaborar un modelo de Inteligencia Artificial (IA) que sea capaz de diagnosticar el tipo de un hemangioma infantil (HI) para ayudar al personal médico a diagnosticarlo con eficacia y mayor rapidez. La rapidez a la hora de diagnosticar los HI es de vital importancia dado el rápido crecimiento de los HI entre 1 y 3 meses de edad, esto hace que sólo haya una pequeña ventana de oportunidad para tratar las lesiones de alto riesgo y prevenir complicaciones como la desfiguración permanente.

1.1 ¿Qué es un hemangioma?

Los hemangiomas infantiles (HI) son los tumores benignos más frecuentes en la infancia. Se estima que afectan al 1-3% de todos los recién nacidos, mientras que alcanzan el 10% en lactantes menores de 1 año [1]. Los HI se consideran clásicamente marcas de nacimiento. Pero, a diferencia de la mayoría de las marcas de nacimiento, los HI son dinámicos. Al nacer están ausentes o apenas son evidentes, pero proliferan en las primeras semanas y meses de vida, llegando a una fase de involución que puede durar varios meses o años. La mayoría de los HI no presentan complicaciones, pero una minoría significativa conlleva complicaciones como ulceración, amenaza para la visión, obstrucción de las vías respiratorias e insuficiencia cardíaca congestiva. Los hemangiomas también pueden dejar cicatrices residuales y/o distorsión permanente de rasgos faciales, lo que puede alterar realmente la vida.

Los HI se pueden clasificar en tres tipos distintos en función de su profundidad en la piel: superficial, profundo y mixto.

Cuando la lesión está cerca de la piel se llama hemangioma superficial. Estos HI tienen una apariencia rojo brillante, con relieve o parches planos sobre la piel. Estas lesiones pueden sobresalir de la piel con forma de bultos (figura 1-1).




Figura 1-1. Imagen de HI superficial

Cuando crece debajo de la piel se llaman hemangiomas profundos. Los hemangiomas profundos

tienen la apariencia de una masa o “bulto” con una coloración azulada o violácea. De estas salen unos vasos sanguíneos que también pueden ser visibles sobre la piel o debajo de ella. Como los hemangiomas profundos están debajo de la piel, podrían no notarse hasta varias semanas o meses después del nacimiento (figura 1-2).



Figura 1-2. Imagen de HI profundo

Cuando en la lesión hay componentes superficiales y profundos, se clasifican como hemangioma mixto. Las lesiones mixtas pueden tener una mezcla de capas, con color rojo arriba y azul más abajo. El color de los hemangiomas no desaparece por completo cuando se presiona el área (figura 1-3).




Figura 1-3. Imagen de HI mixto

1.2 Protocolo clínico de actuación en el tratamiento de un hemangioma

La evaluación de la extensión y el volumen de los HI no es sencilla. Los hemangiomas pueden presentar patrones irregulares o estar cubiertos por pelo, o pueden no ser accesibles para la inspección visual. Kilcline et al. [2] realizaron un seguimiento de la evolución de los HI mediante fotografías estandarizadas evaluadas por diferentes expertos. En situaciones clínicas prácticas, los médicos controlan la evolución de los HI inspeccionando visualmente fotografías anteriores que pueden no mostrar los límites reales del tumor.

Cuando la visualización directa del HI no es suficiente, se usan técnicas basadas en otro tipo de imagen para ayudar a los médicos a determinar la extensión y la localización de la HI. Estas técnicas de diagnóstico convencionales son la ecografía Doppler y la resonancia magnética. Estos métodos de diagnósticos son caros por lo que no siempre están disponibles en la primera consulta.

Leñero-Barbadillo et al. [3] estudian, como alternativa a las técnicas auxiliares de diagnóstico, el uso de imágenes termográficas para el estudio y clasificación de HI. Esto es debido a que los HI producen alteraciones locales de la temperatura corporal detectables por las cámaras de infrarrojos. Siguiendo la misma línea de investigación, en [4] estudian el uso de estas cámaras para la detección de HI específicamente.

1.3 Inteligencia artificial

La Inteligencia Artificial (IA) es una disciplina y un conjunto de capacidades cognitivas e intelectuales expresadas por sistemas informáticos o combinaciones de algoritmos cuyo propósito es la creación de máquinas que imiten la inteligencia humana para realizar tareas, y que pueden mejorar conforme recopilen información.

El aprendizaje máquina es una disciplina del campo de la IA que, a través de algoritmos, dota a los ordenadores de la capacidad de identificar patrones en datos masivos y elaborar predicciones. Este aprendizaje permite a los computadores realizar tareas específicas de forma autónoma, es decir, sin necesidad de ser programados explícitamente para ello.

El aprendizaje profundo es un método de la IA que enseña a las computadoras a procesar datos de una manera que se inspira en el cerebro humano. Los modelos de aprendizaje profundo son capaces de reconocer patrones complejos en imágenes, textos, sonidos y otros datos, a fin de generar información y predicciones precisas. Es posible utilizar métodos de aprendizaje profundo para automatizar tareas que habitualmente requieren inteligencia humana, como la descripción de imágenes o la transcripción a texto de un archivo de sonido.

El aprendizaje máquina y el aprendizaje profundo comparten similitudes, pero también tienen diferencias que hacen que haya casos donde el uso de uno tiene más sentido que el del otro. Tanto el aprendizaje máquina como el aprendizaje profundo aprenden y trabajan de forma autónoma, pero la primera técnica necesita de mayor intervención humana para hacerlo. El aprendizaje máquina necesita datos previamente estructurados para aprender y poder trabajar con ellos. Por el contrario, el aprendizaje profundo puede trabajar con datos sin estructurar (incluso con grandes volúmenes), motivo por el cual es muy útil a la hora de identificar patrones. Otra diferencia es que el aprendizaje profundo requiere una gran cantidad de datos para obtener resultados precisos, mientras que el aprendizaje máquina puede obtener buenos resultados con un tamaño reducido de datos. Actualmente el aprendizaje profundo se está priorizando frente al aprendizaje máquina debido a su demostrado rendimiento superior [5].

En este proyecto se afronta el problema con algoritmos de aprendizaje máquina, a pesar de la demostrada superioridad de los algoritmos basados en aprendizaje profundo, debido a que la base de datos de la que disponemos no es suficientemente grande como para usar de forma efectiva aprendizaje profundo.

1.4 Métodos de IA actuales para el diagnóstico automático de HI en la literatura

Actualmente existen estudios sobre la aplicación de herramientas de inteligencia artificial a la detección de hemangiomas infantiles, pero estos estudios solo se centran en el diagnóstico de si existe o no presencia de hemangioma.

En el caso del estudio reciente [6] realizado por Zhang et al. , se usaron 79.675 imágenes clínicas de pacientes de dermatología pediátrica en Children's Wisconsin desde 2002 hasta 2019 para identificar la presencia o no de HI en pacientes de 0-1 años de edad. Las imágenes fueron pre-etiquetadas con el diagnóstico en el momento de la captura, y todos los diagnósticos fueron confirmados de forma independiente por un dermatólogo a través de la revisión de fotos y gráficos. Se utilizó ResNet-50 de Microsoft, una arquitectura CNN de gran eficacia y precisión disponible públicamente, para entrenar un clasificador binario de HI con el fin de clasificar las imágenes como HI o no HI. El modelo se entrenó en 10 divisiones de conjuntos de datos diferentes que dividían aleatoriamente los datos en grupos de entrenamiento (80%), validación (10%) y prueba (10%). En este estudio se consiguió elaborar un modelo que alcanzó una precisión global del $91,7 \pm 1,8\%$, con una sensibilidad del $93,0 \pm 1,6\%$ y una especificidad del $90,5 \pm 2,1\%$

Oprisescu et al. [7] presentan un algoritmo para el cálculo automático de la superficie de la lesión HI. La escala de la imagen se calcula utilizando la transformada de Hough y la variación total. Como preprocesamiento, se incluye un paso de corrección geométrica que garantiza que las lesiones se vean perpendiculares a la cámara. La segmentación de la imagen se basa en la agrupación de *K-means* aplicada a una imagen de cinco planos; los cinco planos se seleccionan a partir de siete planos con el uso de la transformada de Karhunen-Loeve. El rendimiento de la segmentación se evaluó en 30 imágenes, y se obtuvo un error de borde medio del 9,31%.

2 MATERIAL Y METODOLOGÍA

2.1 Material

Para este proyecto contamos con una base de datos de imágenes de HI tomadas en el Hospital Universitario Virgen del Rocío de Sevilla y clasificadas por el personal médico del hospital. Esta base de datos cuenta con un total de 82 imágenes de HI, de las cuales 43 son superficiales, 27 son mixtos y 12 son profundos. Debido a la poca cantidad de imágenes de HI mixtos y profundos estos dos se combinarán en una clase durante todo el proyecto, de modo que se clasificaran los HI entre superficial y tipos mixtos/profundos.

Estas imágenes fueron tomadas por el personal médico del hospital con una cámara desarrollada por el Departamento de Teoría de la Señal y Comunicaciones junto con el Departamento de Electrónica y Electromagnetismo, ambos de la Universidad de Sevilla. La cámara consta de un doble sensor. Uno adquiere una imagen fotográfica convencional, y el otro adquiere una imagen en el espectro infrarrojo lejano (LWIR). En este proyecto solo se hará uso de la imagen fotográfica. El sensor del espectro visible es un sensor Sony IMX219 de 8 megapíxeles.

2.2 Metodología




Figura 2-1. Diagrama de flujo del proyecto

2.2.1 Preprocesamiento de las imágenes

Para la elaboración de un proyecto de aprendizaje máquina con imágenes es fundamental un correcto preprocesamiento de las imágenes utilizadas para garantizar unos resultados coherentes. El preprocesamiento de las imágenes que se ha realizado en este proyecto consta de las siguientes partes:

1. Recortar las imágenes de los hemangiomas para que en ellas sólo aparezca la propia lesión. Esto previene de que la parte de la imagen que no forma parte de la lesión introduzca ruido en los resultados.
2. Cambio de base de color de las imágenes de RGB a UCS. Un espacio de color UCS (*Uniform*

Color Space) es perceptivamente uniforme, es decir, la distancia entre dos colores se asemeja al parecido entre esos colores percibidos por el ojo humano. Esto hace que, por ejemplo dos tonos de rojos parecidos tengan una distancia entre sí pequeña, lo que nos permite una mejor interpretación de las imágenes que si usáramos el clásico espacio de color RGB.

En 1976, la Commission Internationale de l'Eclairage (CIE) estandarizó dos espacios de color, $L^*u^*v^*$ y $L^*a^*b^*$, con el objetivo de proporcionar una herramienta para medir las diferencias de color percibidas por los humanos [8].

La definición matemática de la diferencia de color CIELAB entre dos colores, con coordenadas de color (L_1^*, a_1^*, b_1^*) y (L_2^*, a_2^*, b_2^*) , es:

$$\Delta E_{ab}^* = [(L_2^* - L_1^*)^2 + (a_2^* - a_1^*)^2 + (b_2^* - b_1^*)^2]^{1/2} = [\Delta L^{*2} + \Delta a^{*2} + \Delta b^{*2}]^{1/2} \quad (1)$$

Sin embargo, debido a la pobre uniformidad del espacio de color CIE $L^*a^*b^*$ se desarrollaron mejores fórmulas de diferencia de color y nuevos sistemas cromáticos. Por ello, en este proyecto se utiliza el reciente modelo de apariencia del color CIECAM16, recomendado por la CIE para sustituir al CIECAM02 [9].

CIECAM16 toma como entradas las coordenadas X e Y de los estímulos del espacio de color XYZ, las coordenadas de color de luz ambiental y parámetros sobre el entorno de visión y el fondo. A continuación, realiza una adaptación de la iluminación y del color y obtiene los siguientes parámetros de apariencia del color: la luminosidad (J), el croma (C), la composición del tono (H), el ángulo del tono (h), colorido (M), la saturación (s) y el brillo (Q) [9].

A partir de este modelo de apariencia del color se puede definir el espacio de color uniforme CAM16-UCS.

$$J' = \frac{1.7J}{1 + 0.007J} \quad (2)$$

$$M' = \ln \frac{1 + 0.0228 M}{0.0228} \quad (3)$$

$$a' = M' \cos(h) \quad (4)$$

$$b' = M' \sin(h) \quad (5)$$

Donde la diferencia de color entre dos muestras puede calcularse como la distancia euclídea entre ellas,

$$\Delta E' = [\Delta J'^2 + \Delta a'^2 + \Delta b'^2]^{1/2} \quad (6)$$

Se puede encontrar más información sobre CIECAM16 en la referencia [9].

2.2.2 Cuantificación de las imágenes

Una vez hecho el preprocesamiento de las imágenes, procederemos a cuantificar los colores presentes en las mismas. Esta cuantificación consiste en reducir el espacio de color de las imágenes a tan solo 20 colores. Esto es necesario porque luego para el cálculo de las características de textura de las imágenes trabajaremos con matrices de coocurrencia (CCM), que son matrices cuadradas del tamaño del número de colores existentes, por lo que reducimos el número de colores, para que su tamaño sea manejable.

Primero hay que calcular los 20 colores más representativos de todas las imágenes, a los que llamaremos centroides. Esto lo haremos añadiendo a una lista todos los píxeles que no sean negros de todas las imágenes y haciendo uso de la función que implementa el algoritmo de *kmeans* de la librería OpenCV podremos calcular estos 20 centroides.

A estos 20 centroides añadiremos uno más para representar a los píxeles negros, ya que de no hacer esto perderíamos un color representativo.

Una vez calculados los centroides, ya podremos proceder a la cuantificación de las imágenes. Esta cuantificación de las imágenes consiste en calcular por cada píxel el centroide más cercano a dicho píxel, o sea, mapear el color de cada píxel al color más parecido dentro de los 20 más representativos. Cada píxel de las imágenes se sustituirá por el índice del color de dicho píxel codificado. El resultado de la cuantificación de una imagen será una matriz de dos dimensiones del mismo tamaño que la imagen original con un número del 0 al 20 en cada posición.

Aquí podemos ver un ejemplo de la cuantificación de una imagen:



Figura 2-2. Imagen original




Figura 2-3. Imagen cuantificada a 21 centroides

2.2.3 Cálculo de las matrices coocurrencia

La matriz de coocurrencia en escala de grises (GLCM) es una matriz que define la distribución de los valores de los píxeles que coinciden (valores de escala de grises o colores) en un desplazamiento determinado en una imagen. Esta matriz es muy útil como método de análisis de texturas, y la usaremos para obtener características de las imágenes, en concreto trabajaremos con la homogeneidad, varianza, entropía, correlación, y la media de cada una de las tres componentes de los píxeles en el espacio CIECAM16. Estas características serán las que nos servirán para clasificar las imágenes.

Como se aplica el algoritmo de cálculo de las GLCM con índices que representan colores en vez de tono de grises, el resultado será una nueva matriz de coocurrencia de colores (CCM). En esta nueva matriz se analiza la coocurrencia de los principales colores presentes en la imagen. Como se detectan 21 colores principales, se obtiene una matriz de 21×21 . Para cada elemento de la matriz, se estima la probabilidad de coocurrencia del índice de color i y el índice de color j , $P_{i,j}$ en un par concreto de posiciones espaciales relativas. Por ello, cuando se calculan los distintos parámetros extraídos de la matriz de coocurrencia, se tienen en cuenta la información sobre el color y las distancias de color.

De estas matrices CCM será de donde calculemos las características homogeneidad, varianza, entropía, correlación, y la media de cada una de las tres componentes de los píxeles en el espacio de color CIECAM16 ($\hat{U}$, $\hat{C}$ y $\hat{M}$). Cada una de estas matriz tendrá un tamaño de 21×21 debido a que teníamos 21 centroides, sin embargo no nos interesa la información sobre los píxeles que son negros por lo que descartaremos la columna y fila correspondiente a los negros quedandonos así con matrices de tamaño 20×20 . De este modo, las características de esta matriz de coocurrencia se calculan del siguiente modo [10]:

Homogeneidad	$H = \sum_{i,j}^{20,20} \frac{P_{i,j}}{1 + (\Delta E(C_i, C_j))^2}$
--------------	---

Media	$\mu = \sum_{i,j}^{20,20} C_i P_{ij}$
Varianza	$\sigma^2 = \sum_{i,j}^{20,20} 1 + (\Delta E(C_i, \mu_i))^2 P_{ij}$
Correlación	$\rho = \sum_{i,j}^{20,20} \frac{\Delta E(C_i, \mu_i) \Delta E(C_j, \mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} P_{ij}$
Entropía	$S = \sum_{i,j}^{20,20} -P_{ij} \ln(P_{ij})$

Una vez ya tenemos las imágenes cuantificadas podemos calcular las matrices CCM. Para ello tenemos que definir las distancias y ángulos que se usarán para el cálculo de estas matrices. Hemos definido 4 ángulos $\{0, \pi/4, \pi/2, -\pi/4\}$, y 5 distancias $\{5, 7, 9, 11, 13\}$, lo que nos va a dar un total de 20 matrices por imagen. Se pueden ver qué distancia y ángulo tiene cada matriz en la tabla 2-1.

Matriz CCM	ángulo	distancia
1	0	5
2	$\pi/4$	5
3	$\pi/2$	5
4	$-\pi/4$	5
5	0	7
6	$\pi/4$	7
7	$\pi/2$	7
8	$-\pi/4$	7
9	0	8
10	$\pi/4$	8
11	$\pi/2$	8
12	$-\pi/4$	8
13	0	11
14	$\pi/4$	11
15	$\pi/2$	11
16	$-\pi/4$	11
17	0	13
18	$\pi/4$	13
19	$\pi/2$	13
20	$-\pi/4$	13

Tabla 2–1. Matrices CCM

2.2.4 Extracción de características

La extracción de características consta de dos partes, la extracción de las características de las imágenes CIECAM16 y la extracción de las características de las matrices CCM.

Las características que extraeremos de las imágenes CIECAM16 son la luminosidad (J), el croma (C), la composición del tono (H), el ángulo del tono (h), colorido (M), la saturación (s) y el brillo (Q). Para calcular sus valores haremos uso de las fórmulas mostradas en el apartado 2.2.1 y el artículo [9].

Tal y como se ha comentado con anterioridad las características que extraeremos de las matrices CCM son la homogeneidad, varianza, entropía, correlación, y la media de cada una de las tres componentes de los píxeles en el espacio CIECAM16. Esto se ha hecho mediante el uso de las fórmulas mostradas en el apartado 2.2.3.

2.2.5 Selección de características

Para poder clasificar correctamente las imágenes es preciso hacer una selección de las características que aporten información útil que nos permita distinguir entre HI superficial y HI mixto/profundo.

Para ello lo primero que hemos de hacer es determinar qué características son las que tienen diferencias sustanciales entre los dos tipos de imágenes que queremos clasificar (HI superficial y HI mixto/profundo). Esto lo haremos mediante el uso de la hipótesis nula de que, dada una característica, su valor no sigue la misma distribución estadística en el caso de HI superficial y HI mixto/profundo. De esta forma calcularemos el *p-value* de las 147 características (140 de las CCM y 7 de las imágenes CIECAM16) que tenemos y tomaremos como válidas aquellas cuyo *p-value* sea inferior a 0.01.

Tras realizar esta selección obtendremos todas las características que sirven para clasificar las imágenes. No obstante, puede ocurrir que estas características estén correlacionadas, lo que implica que haya redundancia entre ellas. Para eliminar esta redundancia es necesario calcular la correlación entre ellas, y por cada grupo de características correlacionadas entre ellas seleccionaremos las que tengan menor *p-value*. Esta correlación entre características la calcularemos obteniendo el coeficiente de correlación de Pearson de cada característica frente a todas las demás.

2.3 Entrenamiento del clasificador

El clasificador que hemos escogido para este proyecto es un clasificador SVM (*support-vector machine*) debido a su simplicidad y efectividad. Los clasificadores SVM son especialmente adecuados para conjuntos de datos pequeños y con pocas características, como es el caso en este proyecto. Esta técnica permite encontrar un hiperplano óptimo que separa las diferentes clases de manera eficiente, incluso con una cantidad limitada de datos, lo que maximiza la precisión del modelo sin requerir una gran cantidad de imágenes de entrenamiento.

Para entrenar este clasificador SVM hemos de dividir el conjunto de imágenes en dos, uno para el entrenamiento y otro para las pruebas. Hemos entrenado el clasificador con tres conjuntos de características: 1º con las características óptimas para la clasificación (escogidas según el apartado anterior); 2º las 3 características no correlacionadas de las CCM; y 3º las 2 características no correlacionadas de las imágenes CIECAM16. Estos dos últimos conjuntos los hemos usado con el fin de ver las diferencias de los resultados respecto al conjunto teóricamente óptimo.

3 RESULTADOS

En la tabla 3-1 se muestra el *p-value* resultante para las 7 características de las imágenes CIECAM16.

J	C	h	s	Q	M	H
1.108e-05	2.319e-07	0.065	1.614e-09	3.098e-05	2.319e-07	0.037

Tabla 3-1. P-value de las características de las imágenes CIECAM16

En la tabla 3-2 se muestra el *p-value* resultante de cada característica de cada matriz CCM. Podemos observar que existen 60 características de las CCM que cumplen la hipótesis nula (su *p-value* es menor que 0.01). Estas son las tres medias de los componentes de los píxeles en el espacio de color CIECAM16 ($\hat{U}$, $\hat{C}$ y $\hat{M}$) para todas las matrices CCM.

Matriz CNN	Homogeneidad	$\hat{U}$	$\hat{C}$	$\hat{M}$	varianza	entropía	correlación
1	0.961	1.14e-05	3.25e-09	0.00736	0.0392	0.53	0.175
2	0.455	1.18e-05	3.49e-09	0.00738	0.0377	0.645	0.205
3	0.585	1.1e-05	3.59e-09	0.00749	0.0402	0.626	0.214
4	0.952	1.06e-05	3.3e-09	0.00767	0.0384	0.618	0.273
5	0.902	1.1e-05	2.87e-09	0.0076	0.0356	0.58	0.141
6	0.354	1.15e-05	3.4e-09	0.00753	0.0357	0.678	0.198
7	0.533	1.02e-05	3.66e-09	0.0076	0.0405	0.639	0.2
8	0.951	1.02e-05	3.05e-09	0.00774	0.0373	0.682	0.27
9	0.843	1.1e-05	2.72e-09	0.00786	0.0325	0.659	0.0799
10	0.279	1.12e-05	3.12e-09	0.00769	0.0338	0.698	0.179
11	0.572	9.52e-06	3.63e-09	0.00776	0.0408	0.611	0.146
12	0.884	9.89e-06	2.78e-09	0.00776	0.0371	0.707	0.218
13	0.838	1.12e-05	3.23e-09	0.00797	0.032	0.705	0.121
14	0.215	1.12e-05	2.83e-09	0.00798	0.0316	0.728	0.121
15	0.545	9.64e-06	3.59e-09	0.00801	0.04	0.616	0.0945
16	0.742	9.95e-06	3.03e-09	0.00827	0.0368	0.789	0.133
17	0.318	1.3e-05	2.74e-08	0.00954	0.0287	0.879	0.27
18	0.186	1.15e-05	2.72e-09	0.00814	0.0301	0.742	0.103
19	0.529	9.84e-06	3.76e-09	0.00831	0.0397	0.657	0.0721
20	0.745	1e-05	3.81e-09	0.00846	0.0372	0.893	0.102

Tabla 3-2. P-value de las características de las CCM

Tras realizar esta selección existen un total de 65 características cuyo *p-value* es inferior a 0.01, de

las cuales 60 son de las CCM y 5 de las imágenes CIECAM16.

Lo siguiente sería comprobar si las las características que cumplen la hipótesis nula están correlacionadas entre sí. Para ello calcularemos el coeficiente de correlación de Pearson de cada características frente a todas ellas.

En la tabla 3-3 se muestra el resultado del coeficiente de correlación de Pearson de las características de las imágenes CIECAM16.

	J	C	s	Q	M
J	1	-0.209	-0.461	0.995	-0.208
C	-0.209	1	0.942	-0.204	1
s	-0.461	0.942	1	-0.468	0.942
Q	0.995	-0.204	-0.468	1	-0.204
M	-0.208	1	0.942	-0.204	1

Tabla 3-3. Correlación entre las características seleccionadas de las imágenes CIECAM16

Estableceremos un límite de coeficiente de correlación de Pearson de 0.5 para determinar si están relacionadas las características entre sí. Al poner este límite evitaremos el ruido que puedan introducir las características que estén muy correlacionadas entre sí. De esta forma, tenemos que la característica J está correlacionada con la característica Q, la característica C está correlacionada con la característica s y la característica M. Por lo que tenemos dos grupos de características independientes de los cuales tendremos que seleccionar solo una característica de cada uno.

En la tabla 3-4 podemos ver el resultado del coeficiente de correlación de Pearson de las características de las CCM.

	$\hat{U}_1$	$\hat{C}_1$	$\hat{M}_1$
$\hat{U}_1$	1	-0.26	0.063
$\hat{C}_1$	-0.26	1	0.756
$\hat{M}_1$	0.063	0.756	1
$\hat{U}_2$	0.999	-0.26	0.065
$\hat{C}_2$	-0.26	0.999	0.755
$\hat{M}_2$	0.061	0.755	0.999
$\hat{U}_3$	0.999	-0.26	0.064
$\hat{C}_3$	-0.26	0.999	0.755
$\hat{M}_3$	0.063	0.756	0.999
$\hat{U}_4$	0.999	-0.26	0.064
$\hat{C}_4$	-0.26	0.999	0.754
$\hat{M}_4$	0.063	0.756	0.999
$\hat{U}_5$	0.999	-0.26	0.064
$\hat{C}_5$	-0.26	0.999	0.755
$\hat{M}_5$	0.064	0.755	0.999
$\hat{U}_6$	0.999	-0.26	0.066
$\hat{C}_6$	-0.26	0.999	0.755
$\hat{M}_6$	0.061	0.755	0.999
$\hat{U}_7$	0.999	-0.26	0.065
$\hat{C}_7$	-0.26	0.999	0.754
$\hat{M}_7$	0.063	0.755	0.999
$\hat{U}_8$	0.999	-0.26	0.065
$\hat{C}_8$	-0.26	0.999	0.754
$\hat{M}_8$	0.064	0.755	0.999
$\hat{U}_9$	0.999	-0.26	0.065
$\hat{C}_9$	-0.26	0.999	0.754
$\hat{M}_9$	0.064	0.755	0.999
$\hat{U}_{10}$	0.999	-0.26	0.066
$\hat{C}_{10}$	-0.26	0.999	0.754
$\hat{M}_{10}$	0.061	0.754	0.999
$\hat{U}_{11}$	0.999	-0.27	0.065
$\hat{C}_{11}$	-0.26	0.999	0.753
$\hat{M}_{11}$	0.064	0.754	0.999
$\hat{U}_{12}$	0.999	-0.27	0.065
$\hat{C}_{12}$	-0.26	0.999	0.753
$\hat{M}_{12}$	0.064	0.754	0.999
$\hat{U}_{13}$	0.998	-0.26	0.066
$\hat{C}_{13}$	-0.26	0.999	0.752
$\hat{M}_{13}$	0.063	0.755	0.999
$\hat{U}_{14}$	0.999	-0.26	0.068
$\hat{C}_{14}$	-0.26	0.999	0.752
$\hat{M}_{14}$	0.062	0.753	0.999
$\hat{U}_{15}$	0.999	-0.27	0.066
$\hat{C}_{15}$	-0.26	0.999	0.753
$\hat{M}_{15}$	0.065	0.752	0.999

$\hat{U}$ 16	0.998	-0.27	0.067
$\hat{C}$ 16	-0.26	0.999	0.751
$\hat{M}$ 16	0.064	0.753	0.999
$\hat{U}$ 17	0.961	-0.23	0.088
$\hat{C}$ 17	-0.23	0.988	0.749
$\hat{M}$ 17	0.069	0.754	0.998
$\hat{U}$ 18	0.998	-0.26	0.068
$\hat{C}$ 18	-0.26	0.999	0.751
$\hat{M}$ 18	0.063	0.753	0.998
$\hat{U}$ 19	0.998	-0.27	0.066
$\hat{C}$ 19	-0.26	0.998	0.752
$\hat{M}$ 19	0.067	0.751	0.999
$\hat{U}$ 20	0.997	-0.27	0.066
$\hat{C}$ 20	-0.26	0.998	0.749
$\hat{M}$ 20	0.063	0.752	0.998

Tabla 3-4. Correlación entre las características seleccionadas de las CCM

Con el límite de coeficiente de correlación de Pearson de 0.5 podemos ver que todas las características $\hat{U}$, $\hat{C}$ y $\hat{M}$ están correlacionados con sus homónimos, y además las características $\hat{C}$ y $\hat{M}$ están correlacionadas entre sí. Esto nos da a entender que la información que aportan los diferentes ángulos y distancias de las CCM es irrelevante. Debido a esto, de las 60 características sólo nos quedaremos con dos, una de las $\hat{U}$ y una de las $\hat{C}$ y $\hat{M}$.

Para determinar qué característica escogeremos de cada grupo de características correlacionadas simplemente nos guiaremos por su *p-value*, de modo que de cada grupo escogeremos la característica cuyo *p-value* sea menor. En la tabla 3-5 se muestran las características escogidas de cada grupo.

<i>CIECAM16</i>	J	s
<i>CCM</i>	$\hat{U}$ 11	$\hat{C}$ 9

Tabla 3-5. Características seleccionadas de las imágenes CIECAM16 y las CCM

Posteriormente debemos comprobar si las características procedentes de las imágenes CIECAM16 y las de las matrices CCM están relacionadas entre sí, lo haremos de la misma forma que antes. Haciendo esto obtenemos, como podemos observar en la tabla 3-6, que la característica J está correlacionada con la característica $\hat{U}$, y que la característica s está correlaciona con la característica $\hat{C}$.

	J	s	$\hat{U} 10$	$\hat{C} 8$
J	1	-0.460	0.989	-0.304
s	-0.460	1	-0.428	0.924
$\hat{U} 10$	0.989	-0.428	1	-0.267
$\hat{C} 8$	-0.304	0.924	-0.267	1

Tabla 3-6. Correlación entre las características seleccionadas de las imágenes CIECAM16 y las CCM

Para obtener el mejor resultado posible, en el clasificador nos debemos de quedar con la que menor *p-value* tenga entre J y $\hat{U} 10$, y entre s y $\hat{C} 8$.

El *p-value* de estas características muestra en la tabla 3-7.

Característica	P-value
J	1.108e-05
s	1.614e-09
$\hat{U}$	9.517e-06
$\hat{C}$	2.715e-09

Tabla 3-7. P-value de las características seleccionadas de las imágenes CIECAM16 y las CCM

El clasificador SVM se ha entrenado con cuatro conjuntos distintos de características, las características seleccionadas de las CCM, las características seleccionadas de las imágenes CIECAM16, el conjunto teóricamente óptimo y con las características de las CCM y CIECAM16 juntas sin importar que estén correlacionadas. El conjunto de imágenes se ha dividido en dos grupos, uno para el entrenamiento y otro para la validación.

En la tabla 3-8 se muestra qué características forman cada uno de los conjuntos.

<i>CIECAM16</i>	J	s		
<i>CCM</i>	$\hat{U} 10$	$\hat{C} 8$		
<i>ÓPTIMO</i>	$\hat{U} 10$	s		
<i>TODAS</i>	J	s	$\hat{U} 10$	$\hat{C} 8$

Tabla 3-8. Características seleccionadas para el entrenamiento

A continuación en las tablas 3-9, 3-10, 3-11 y 3-12 se muestran los resultados del clasificador para los cuatro conjuntos de características, reservándose la mitad de las imágenes para cada entrenamiento y la otra mitad para validación.

	Aciertos	Fallos
Totales	36	5
Superficiales	22	0
Mixto/Profundo	14	5

Tabla 3–9. Resultados con características de las CCM

	Aciertos	Fallos
Totales	31	10
Superficiales	20	1
Mixto/Profundo	11	9

Tabla 3–10. Resultados con características de las imágenes CIECAM16

	Aciertos	Fallos
Totales	33	8
Superficiales	20	2
Mixto/Profundo	13	6

Tabla 3–11. Resultados con características teóricamente óptimas

	Aciertos	Fallos
Totales	32	9
Superficiales	21	1
Mixto/Profundo	11	8

Tabla 3–12. Resultados con todas las características

En la tabla 3-13 se muestran la comparativa de los resultados de los cuatro conjuntos de características. Para el cálculo de estos resultados se ha tomado como caso positivo que el HI sea mixto/profundo, y por ende como caso negativo que el HI sea superficial.

	<i>Sensibilidad</i>	<i>Valor predictivo positivo</i>	<i>Precisión</i>	<i>Especificidad</i>
<i>CCM</i>	73.68%	100%	87.80%	100%
<i>CIECAM16</i>	55%	91.67%	75.60%	95.24%
<i>Óptimas</i>	68.42%	86.67%	80.49%	90.91%
<i>Todas</i>	57.89%	81.67%	78.04%	95.45%

Tabla 3–13. Resultados comparativo de los cuatro conjuntos de características

A continuación en las tablas 3-14, 3-15, 3-16 y 3-17 se muestran los resultados del clasificador para los cuatro conjuntos de características, esta vez reservándose el 80% de las imágenes para el entrenamiento y el 20% para validación.

	Aciertos	Fallos
Totales	16	0
Superficiales	8	0
Mixto/Profundo	8	0

Tabla 3–14. Resultados con características de las CCM

	Aciertos	Fallos
Totales	14	2
Superficiales	6	2
Mixto/Profundo	8	0

Tabla 3–15. Resultados con características de las imágenes CIECAM16

	Aciertos	Fallos
Totales	12	4
Superficiales	5	3
Mixto/Profundo	7	1

Tabla 3–16. Resultados con características teóricamente óptimas

	Aciertos	Fallos
Totales	14	2
Superficiales	7	1
Mixto/Profundo	7	1

Tabla 3–17. Resultados con todas las características

En la tabla 3-18 se muestran la comparativa de los resultados de los cuatro conjuntos de características. Al igual que antes, se ha tomado como caso positivo que el HI sea mixto/profundo, y como caso negativo que el HI sea superficial.

	<i>Sensibilidad</i>	<i>Valor predictivo positivo</i>	<i>Precisión</i>	<i>Especificidad</i>
<i>CCM</i>	100%	100%	100%	100%
<i>CIECAM16</i>	100%	80%	87.5%	75%
<i>Óptimas</i>	87.5%	70%	75%	62.5%
<i>Todas</i>	87.5%	87.5%	87.5%	87.5%

Tabla 3–18. Resultados comparativo de los cuatro conjuntos de características

4 CONCLUSIONES Y FUTURAS MEJORAS

4.1 Conclusiones

Con este proyecto se ha logrado elaborar una herramienta capaz de asistir al personal médico en el diagnóstico de HI. A la vista de los resultados, tomando las características adecuadas, se ha conseguido un 100% de aciertos en la clasificación de HI en los tipos superficial y mixto/profundo, siendo las mejores características para la clasificación la $\hat{U}$ y $\hat{C}$ de las CCM. Sin embargo estos resultados no se pueden tomar como concluyentes, ya que al contar con un número reducido de imágenes, estos resultados no son fiables.

El hecho de que las características seleccionadas sean la media de dos de los tres componentes de los píxeles CIECAM16, la $\hat{U}$ y $\hat{C}$ concuerda con el modo de diagnóstico clínico, que el criterio para distinguir entre superficial y profundo se basa principalmente en color. Pero la textura tiene cierto papel discriminatorio, de ahí que la textura mejore la clasificación.

El análisis de correlación ha sido muy útil para eliminar características redundantes. En concreto, características extraídas de matrices de coocurrencia muy similares. Esto nos ha servido para optimizar los parámetros distancia y ángulo en las matrices de coocurrencia.

La combinación de ambos conjuntos de características, descartando correlaciones, no parece alcanzar mejores resultados. Pero hace falta una validación más amplia para sacar conclusiones.

En medicina la sensibilidad es un parámetro importante, ya que el diagnóstico de falsos negativos puede tener graves consecuencias. Por lo que es importante que sea lo más alta posible para no descartar lesiones que requieran la atención de un especialista. En los resultados se ha visto que las características que mayor sensibilidad ofrecen son la $\hat{U}$ y $\hat{C}$ de las CCM, que a su vez son las que han ofrecido mejores resultado en global.

4.2 Futuras mejoras

Una posible primera mejora futura sería usar la estrategia de validación cruzada para abordar la falta de imágenes. Esto nos permitiría obtener resultados más precisos con la cantidad de imágenes existentes.

Otra posible mejora sería complementar a las imágenes utilizadas (espectro visible) con imágenes termográficas ya que, como se mencionó en el apartado 1.2, estas imágenes también pueden tener información útil para el diagnóstico de HI.

REFERENCIAS

- [1] JUNG, H.L., 2021. Update on infantile hemangioma. *Clinical and experimental pediatrics*, vol. 64, no. 11, ISSN 2713-4148. DOI 10.3345/cep.2020.02061.
- [2] KILCLINE, C. y FRIEDEN, I.J., 2008. Infantile Hemangiomas: How Common Are They? A Systematic Review of the Medical Literature. *Pediatric dermatology*, vol. 25, no. 2, ISSN 0736-8046. DOI 10.1111/j.1525-1470.2008.00626.x.
- [3] LEÑERO-BARDALLO, J.A., SERRANO, C., ACHA, B., PÉREZ-CARRASCO, J.A. y BERNABEU-WITTEL, J., 2021. Thermography for the differential diagnosis of vascular malformations. *Clinical and experimental dermatology*, vol. 46, no. 2, ISSN 0307-6938. DOI 10.1111/ced.14346.
- [4] LEÑERO-BARDALLO, J.A., ACHA, B., SERRANO, C., PÉREZ-CARRASCO, J.A., ORTIZ-ÁLVAREZ, J. y BERNABÉU-WITTEL, J., 2022. Thermography as a Method for Bedside Monitoring of Infantile Hemangiomas. *Cancers*, vol. 14, no. 21, ISSN 2072-6694. DOI 10.3390/cancers14215392.
- [5] RANA, M. y BHUSHAN, M., 2023. Machine learning and deep learning approach for medical image analysis: diagnosis to detection. *Multimedia tools and applications*, vol. 82, no. 17, ISSN 1380-7501. DOI 10.1007/s11042-022-14305-w.
- [6] ZHANG, A.J., LINDBERG, N., CHAMLIN, S.L., HAGGSTROM, A.N., MANCINI, A.J., SIEGEL, D.H. y DROLET, B.A., 2022. Development of an artificial intelligence algorithm for the diagnosis of infantile hemangiomas. *Pediatric dermatology*, vol. 39, no. 6, ISSN 0736-8046. DOI 10.1111/pde.15149.
- [7] OPRISESCU, S., CIUC, M. y SULTANA, A., 2021. Automatic Segmentation and Measurement of Infantile Hemangioma. *Symmetry (Basel)*, vol. 13, no. 1, ISSN 2073-8994. DOI 10.3390/sym13010138.
- [8] Rangayyan, R.M.; Acha, B.; Serrano, C. Color. Image Processing with Biomedical Applications; SPIE Press: Bellingham, WA, USA, 2011.
- [9] Li C, Li Z, Wang Z, et al. Comprehensive color solutions: CAM16, CAT16, and CAM16-UCS. *Color Res Appl*. 2017; 42: 703–718. <https://doi.org/10.1002/col.22131>
- [10] SERRANO GOTARREDONA, M. del C., LAZO MAESTRE, M., SERRANO GOTARREDONDA, A., TOLEDO-PASTRANA, T., BARROS-TORNAY, R. y ACHA PIÑERO, B., 2022. Clinically Inspired Skin Lesion Classification through the Detection of Dermoscopic Criteria for Basal Cell Carcinoma.

