

Método para Parametrización del Color en Neoplasias de la Piel

¹Cesar Abdiel Payan Chávez, ¹Juan Martín Carpio Valadez, ¹Raúl Santiago Montero, ²Juan Humberto Sossa Azuela, ¹Luis Ernesto Mancilla Espinoza, ¹Juan Adolfo Montesino Guerra, ¹Lucero de Montserrat Ortiz-Aguilar.

¹Departamento de Posgrado, Instituto Tecnológico de León

²Centro de Investigación en Computación, Instituto Politécnico Nacional
juanmartin.carpio@itleon.edu.mx

Recibido: 28 de octubre, 2017

Aceptado: 13 de diciembre, 2017

RESUMEN

Una de las manifestaciones más visibles del cáncer de piel son las neoplasias conocidas como melanomas. El melanoma es curable si es detectado a tiempo, sin embargo, no existe un método no invasivo establecido para su detección. La evaluación del cáncer de piel por métodos no invasivos se realiza por medio de la regla *ABCDE* en el cual se evalúa la asimetría (*A*), irregularidad del borde (*B*), color (*C*), diámetro (*D*) y evolución de la misma (*E*). En este artículo se presentan dos propuestas metodológicas para la parametrización de color de lesiones cutáneas, nuestra propuesta P_1 considera el contraste entre la coloración de piel del individuo y la coloración de la neoplasia y la propuesta del estado del arte P_2 que solamente considera la coloración de la neoplasia. Las propuestas son evaluadas por medio de un proceso estadístico donde se pondera su desempeño al realizar una discriminación entre melanomas y no melanomas, para lo cual se utilizan tres procesos de clasificación. Además, se analiza la aportación del color aunada a las características de borde y asimetría utilizadas en la parametrización de melanomas. Como resultado se encontró que la Propuesta P_1 tuvo un mejor desempeño con respecto a la Propuesta P_2 . También se valoró si la influencia de la característica *C* de color, aunada con las características *A*, *B*, de borde y asimetría respectivamente, aumentan el porcentaje de clasificación discriminante entre neoplasias benignas y malignas.

Palabras clave: Melanoma, regla *ABCDE*, parametrización de color.

ABSTRACT

One of the most visible manifestations of skin cancer is the neoplasms commonly known as melanomas. This is curable if it is detected in early stages, however, there is no non-invasive method established for its detection. Evaluation of skin cancer by non-invasive methods is performed by the *ABCDE* rule, in which the asymmetry (*A*), border irregularity (*B*), color (*C*), diameter (*D*), and evolution (*E*) are evaluated. In this article we present two methodological proposals for the parameterization color of skin lesions, our proposal P_1 considers the contrast between the skin coloring of the individual and the coloration of the neoplasm and the proposed state of the art P_2 , only considers the coloration of the neoplasia. The proposals are evaluated by means in statistical test where their performance is weighed when performing discrimination between melanomas and non-melanomas, for which three classification processes are used. In addition, the contribution of color to edge and asymmetry in the parameterization of melanomas is analyzed. As a result, it was found that Proposition P_1 has a better performance than Proposition P_2 . Also we consider the influence of the characteristic *C* of color, combined with the characteristics *A*, *B*, of edge and asymmetry respectively, increases the percentage of discriminant classification between benign and malignant neoplasms.

Keywords: Melanoma, *ABCDE* rule, color parameterization.

1 INTRODUCCION

Se le conoce como melanoma cutáneo a la neoplasia con un índice de malignidad de la piel mayor, la cual produce una neo-formación cutánea pigmentada, plana o exofítica, curable durante la etapa inicial pero que sin tratamiento es de rápido avance, pudiendo provocar metástasis linfáticas y hematógenas que provocan alta mortalidad (De La Fuente-García et.al., 2010).

Es debido a lo anterior que surge la necesidad de realizar diagnósticos oportunos en etapas iniciales de la enfermedad. Existen diferentes métodos para la detección de melanoma como:

- *Total/partial Body photograph*: se hacen tomas fotográficas de cuerpo completo o parcial en 2-D y 3-D, para después analizar las lesiones de forma individual (Nehal K. S. et.al., 2002).
- *Dermoscopy ELM (oil/slide mode and polarizing mode)*. En esta se identifican los focos del melanoma para ayudar al oncólogo, en decir donde se debe seccionar la muestra para minimizar los resultados de falsos negativos, como error del muestreo (Stauffer F., 2001).
- *Multispectral imaging*. Entre estas se encuentran: *Melafind*, *Solar Scan*, *Spectrophotometric*, análisis intracutáneo entre otros. El objetivo de estos es ayudar en el diagnóstico de lesiones de un tamaño máximo de 2 milímetros (Carrara M., et.al., 2007).
- *Laser-based enhanced diagnosis*. Algunos de ellos son: microscopia de laser con barrido confocal (en inglés *cofocal*), microscopia reflectante confocal y microscopia confocal con codificación espectral (Lober A., et.al., 2009). Un microscopio confocal, emplea una técnica óptica de imagen con el fin de incrementar el contraste y/o reconstruir imágenes tridimensionales, utilizando un colimador de orificio delimitante espacial (en inglés *pinhole*), para eliminar la luz desenfocada o destellos de la lente sobre especímenes bajo estudio que son más gruesos que el plano focal, es decir del orden de μm (micrómetros).
- *Optical coherence tomography*: Tomografía de coherencia óptica (TCO) es una técnica de imagen no invasiva, que utiliza ondas de luz para tomar fotografías de la sección transversal del tejido. Mediante una TCO, cada una de las capas características del tejido pueden observarse, permitiendo mapear y medir su espesor. (Mongensen M. et.al., 2009).
- Imagen ultrasónica (Blum A et.al., 2006).
- Imagen de resonancia magnética (El Gammal S. et.al., 1996).

Un tipo de diagnóstico (*total body Photograph*) de cáncer en piel se realiza mediante el *test* de imagen que consta de una medición cualitativa de las características de asimetría, borde, color, diámetro y evolución, por sus siglas en ingles representado como *ABCDE* (Maglogiannis et.al., 2009).

El Test previamente mencionado es realizado comúnmente por un médico de manera personal y no existen reglas o escalas valorativas para cada uno de los aspectos que el análisis comprende. Sin embargo, dentro del estado del arte existen diversos estudios enfocados en la parametrización de las características *A*, *B* de las neoplasias utilizando métodos distintos de extracción de características de las imágenes (Maglogiannis et.al, 2009) (Sboner et al., 2003).

En cuanto a la característica *C* existen múltiples estudios que abordan diversos métodos para la extracción de esta característica, en uno de ellos hacen uso del modelo de color *HSV* evaluando la presencia de colores específicos para obtener un índice de coloración (Jaiswar Kadri et. al., 2014), en otros casos hacen uso del espacio de color *LAB* para obtener un color que represente a la lesión alcanzando porcentajes de clasificación cercanos al 80% (Ercal Chawla et.al, 1994), no obstante en estos estudios se hace la representación del color *C*, tomando en cuenta solamente la región de interés de la lesión, dejando fuera el tono de piel del individuo.

En el estado del arte de inteligencia artificial, este problema ha sido abordado mediante técnicas de reconocimiento de patrones: enfoque supervisado y sin supervisar (técnicas de clúster o agrupamiento) (Massod A. et.al. 2013). Dentro de las técnicas supervisadas se encuentran las siguientes:

- ✓ *K-NN (k-nearest neighborhood)* (Elgamal M., 2013).

- ✓ SVM (Support Vector Machine) (Gilmore S., et. al. 2010).
- ✓ Naive Bayes (Ruiz D., et. al. 2011).
- ✓ ANN (Artificial Neural Networks) (Orgorzalek M., et.al. 2011).
- ✓ Decision Trees (Di Leo G. et.al. 2008).
- ✓ Fuzzy Logic (Massod A. et.al. 2013b).
- ✓ Logistic Regression (Fikrle T. et.al. 2007).
- ✓ Extreme Learning Machine (Vennila G. S. et.al. 2012).

Partiendo de la regla *ABCDE*, dado que el color es una de las tres principales características utilizadas para el diagnóstico de melanomas, en este artículo se presentan dos propuestas metodológicas para la parametrización de color de lesiones cutáneas, nuestra propuesta P_1 que considera el contraste entre la coloración de piel del individuo y la coloración de la neoplasia y la propuesta del estado del arte P_2 que solamente considera la coloración de la neoplasia.

La aportación principal de este artículo la planteamos en forma de conjetura, estableciendo la siguiente Hipótesis de Trabajo (*HT*): *Si* la parametrización de color de lesiones cutáneas se realiza con la propuesta P_1 , *entonces* es posible mejorar el porcentaje de clasificación discriminante entre neoplasias benignas y malignas obtenida con la propuesta P_2 del estado del arte.

Además, se valora si la influencia de la característica *C* de color, aunada con las características *A*, *B*, de borde y asimetría respectivamente, coadyuvan en la mejora del porcentaje de clasificación discriminante entre neoplasias benignas y malignas.

2 MARCO TEÓRICO

2.1.1 ASIMETRÍA

Para el cálculo de la asimetría, primero se determinan los ejes principales o de inercia de la imagen de la lesión, y luego se traslapan las mitades de la lesión a lo largo de los ejes principales; el área fuera de la región de traslape corresponde al valor *A* de asimetría (Maglogiannis et. al., 2009).

2.1.2 BORDE

El borde es considerado una característica crítica en todo el proceso de identificación e involucra la extracción de la región de interés (Maglogiannis et. al., 2009), y es referido a la sección que circunfiere a esta. En este trabajo se utiliza la relación entre el perímetro y área de la lesión contra el cuadrado con el mismo perímetro y área para representar la irregularidad del borde, esto se calcula con el factor de elasticidad normalizada o *FEN* por sus siglas que esta modelado por la Ecuación (1), donde *P* es el perímetro y *a* el área de la lesión respectivamente.

$$FEN = \frac{P}{4\sqrt{a}} \quad (1)$$

2.1.3 COLOR

Para parametrizar el color se hace uso de la metodología propuesta en (García-Lamont Cervantes et.al., 2012) en la cual presentan la idea de identificar el papel moneda mexicano por medio de un sistema de visión haciendo uso del color distintivo de cada uno de ellos, usando eso como base se pretende determinar un color que represente la imagen en cuestión, es decir, se obtiene el color promedio de la imagen el cual se representa por la Ecuación (2):

$$C_s = \sum_{i=1}^N \sum_{j=1}^M C(i, j) \quad (2)$$

Donde $C(i, j)$ es el color de cada pixel, además se calcula su representación como un mapeo no lineal del mismo. Para ello es necesario realizar una normalización del color (C_s) obteniendo u_s , el cual se define a continuación en la Ecuación (3):

$$u_s = \frac{C_s}{\|C_s\|} \quad (3)$$

Entonces los cosenos directores pueden ser representados como Ecuación (4), donde b_s es la representación en arcosenos de u_s . Donde α es el canal R de color, β el canal G y θ el canal B trasladados. RGB (por sus siglas en inglés de *red, green, blue*, y en español «rojo, verde y azul»)

$$b_s = \alpha_s + \beta_s + \theta_s \quad (4)$$

2.1.4 BASE DE DATOS

Para este proyecto se hace uso de la base de datos obtenida por el Hospital Pedro Hispano (ver figura 1) la cual contiene un total de 200 imágenes en formato *bmp*, divididas en tres clases, 80 para lunares comunes, 80 para lunares atípicos y 40 melanomas. Este artículo se enfoca en la separación de los melanomas de las otras dos clases, para lo cual, las primeras dos se consideran como una sola (Mendonca Ferreira et. al., 2013).

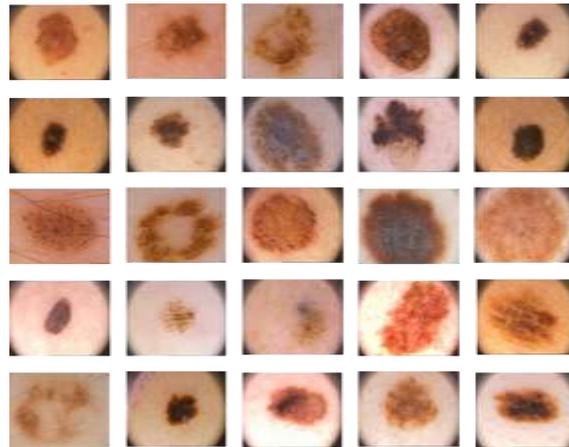


Figura 1 Muestra de la Base de Datos del Hospital Pedro Hispano

3 METODOLOGÍA

La metodología que se siguió en esta investigación se aborda a continuación.

3.1 DISEÑO EXPERIMENTAL

Para el desarrollo experimental se propusieron dos metodologías a seguir para la parametrización de color de lesiones cutáneas, nuestra propuesta P_1 que considera el contraste entre la coloración de piel del individuo y la coloración de la neoplasia y la propuesta del estado del arte P_2 que solamente considera la coloración de la neoplasia. Estas propuestas metodológicas P_1 (figura 2) y P_2 (figura 3) son:

P_1 : Imagen Completa

- 1) Obtención de la imagen.- En este paso se seleccionan las imágenes a utilizar para el cálculo del vector de características, siendo estas las 200 imágenes propuestas en la base de datos.
- 2) Cálculo del color promedio.- Se calcula el color promedio de cada una de las imágenes, haciendo uso de la ecuación (2).

- 3) Representación lineal.- Una vez obtenido el color promedio de cada imagen se realiza la representación lineal de cada una de ellas, es decir, se normaliza el color promedio utilizando la ecuación (3) y se transforma en ángulos, utilizando la ecuación (4).
- 4) Clasificación.- Una vez obtenido el vector de características se procede a la clasificación de los vectores.



Figura 2 Diagrama General de P_1

P_2 : Imagen Parcial

- 1) Obtención de la imagen.- De igual manera que en la P_1 , se seleccionan las imágenes a utilizar tomando en cuenta las mismas 200 imágenes.
- 2) Obtención de región de interés.- En esta parte se aplica una máscara propuesta en la base de datos para eliminar el fondo de la imagen dejando solamente la imagen de la neoplasia.
- 3) Cálculo del color promedio.- Se calcula el color promedio de cada una de las imágenes resultantes del paso anterior, haciendo uso de la Ecuación **¡Error! No se encuentra el origen de la referencia..**
- 4) Representación lineal.- De igual manera que en la Propuesta P_1 se realiza la representación lineal de cada una de ellas, es decir, se normaliza el color promedio utilizando la Ecuación (3) y se transforma en ángulos, utilizando la ecuación (4).
- 5) Clasificación.- Una vez obtenido el vector de características se procede a la clasificación de los vectores.

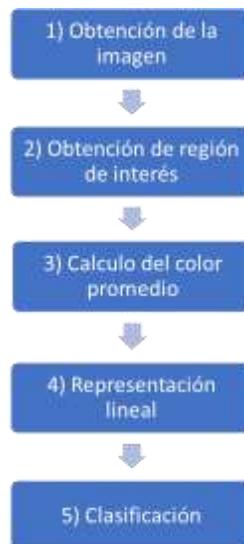


Figura 3 Diagrama General de P_2

Nota: Cabe destacar que las metodologías propuestas tienen la misma base, siendo la segunda una variante de la primera.

3.2 VALORES COMPLEMENTARIOS

Se añade la característica C a una parametrización de características A y B . Para la característica de B se hizo uso de una medida de compacidad la cual se describe con la Ecuación **¡Error! No se encuentra el origen de la referencia.** (Sossa López-Morales et.al, 2014).

Mientras que para la característica A se realizó una división de la imagen en 8 secciones partiendo del centroide de la imagen; posteriormente se calculó la medida de compacidad para cada sección, y se obtuvo la diferencia de las secciones opuestas de la imagen con lo que se obtuvo el valor de la descripción A . Finalmente se utilizaron diversos clasificadores para probar la eficacia del método propuesto.

4 RESULTADOS

Para contrastar estadísticamente las propuestas P_1 y P_2 , se realizó una serie de clasificaciones utilizando una Red Neuronal Artificial (*Artificial Neural Network, ANN* por sus siglas en inglés), entrenada con *Retro-Propagación* considerando la configuración mostrada en la Tabla 1, donde n es la cantidad de neuronas en la capa de entrada. Se realizaron nueve corridas para cada propuesta P_1 y P_2 , utilizando en ejecución 2, 3, 4, 5, 6, 7, 8, 9 y 10 *folds* respectivamente.

Tabla 1 Configuración de Red Neuronal Artificial, entrenada con Retro-Propagación

ANN	
Neuronas capa Intermedia	$2n-1$
Tasa de Aprendizaje	0.3
Épocas	500

Se empleó la prueba estadística de suma de rangos con signos de *Wilcoxon* con el fin de comprobar la hipótesis nula H_0 : *Las distribuciones del porcentaje de clasificación correcta obtenidos por P_1 y P_2 son idénticas (coinciden en posición)*. Se estableció un valor de significancia $\alpha = 0.05$. Los porcentajes de clasificación y valores de jerarquía se muestran en la Tabla 2. Los valores del estimador y crítico fueron $W = 1.5$, $W_0 = 3$ respectivamente, además el $P_valor = 0.1336$. Dado que $W < W_0$ y $P_valor < \alpha$, entonces existe evidencia estadística significativa para rechazar H_0 , y aceptar la hipótesis alternativa H_a : *Las distribuciones del porcentaje de clasificación correcta obtenidos por P_1 y P_2 no son idénticas (no coinciden en posición)*, es decir, la distribución de resultados de la propuesta P_1 , se encuentra a la derecha y P_2 .

Tabla 2 Prueba de suma de Rangos con signo de Wilcoxon para P_1 y P_2

<i>Folds</i>	P_1	P_2	$ P_1 - P_2 $	jerarquía	-	+
2	81.5	81.5	0	0		
3	81	80	1	4.5		3.5
4	84	81	3	8		7
5	81.5	79.5	2	6.5		5.5
6	84	79.5	4.5	9		8
7	82.5	82	0.5	2.5		1.5
8	82.5	83	0.5	2.5	1.5	
9	82	80	2	6.5		5.5
10	82	81	1	4.5		3.5

Una vez establecido el rechazo de H_0 , y aceptación de H_a , se calculó el promedio de clasificación correcta de P_1 y P_2 , lo cual se muestra en la **¡Error! No se encuentra el origen de la referencia.**, en la cual se pudo comprobar que P_1 tiene un mayor promedio de clasificación y una ligeramente menor dispersión que P_2 . Por lo cual se puede concluir que en promedio, la propuesta P_1 tiene un mejor desempeño que la propuesta P_2 , en relación a la característica C para la discriminación de las neoplasias.

Tabla 3 Promedio de Clasificación correcta de P_1 y P_2

	P_1	P_2
Promedio	82.33	80.83
Desviación estándar	1.061	1.20

Para indagar sobre el desempeño en conjunto de las características conjuntas ABC , se diseñaron dos nuevas propuestas experimentales, P_3 y P_4 , las cuales tomaron como base las propuestas P_1 y P_2 respectivamente, añadiéndole a cada una de ellas las características A y B . Para la clasificación se utilizó una Red Neuronal Artificial (*Artificial Neural Network, ANN* por sus siglas en inglés), entrenada con *Retro-Propagación*, donde la configuración es la mostrada en la Tabla 1. Se realizaron nueve corridas para cada propuesta P_3 y P_4 , utilizando en ejecución 2, 3, 4, 5, 6, 7, 8, 9 y 10 *folds* respectivamente.

Se empleó la prueba estadística de suma de rangos con signos de *Wilcoxon* con el fin de comprobar la hipótesis nula H_0 : *Las distribuciones del porcentaje de clasificación correcta obtenidos por P_3 y P_4 son idénticas (coinciden en posición)*. Se estableció un valor de significancia $\alpha = 0.05$. Los porcentajes de clasificación y valores de jerarquía se muestran en la Tabla 2. Los valores del estimador y crítico fueron $W = 14$, $W_0 = 5$ respectivamente, además el $P_valor = 0.0027$. Dado que $W > W_0$ y $P_valor < \alpha$, entonces no existe evidencia estadística significativa para rechazar H_0 , es decir *Las distribuciones del porcentaje de clasificación correcta obtenidos por P_3 y P_4 son idénticas (coinciden en posición)*.

Se calculó también el promedio y desviación estándar de clasificación correcta de P_3 y P_4 , lo cual se muestra en la **¡Error! No se encuentra el origen de la referencia.**, donde se puede corroborar que no hay una diferencia significativa entre los promedios de clasificación correcta, pero si en la dispersión entre las propuestas P_3 y P_4 , lo que nos arroja una variabilidad menor con la propuesta P_3 con respecto a la propuesta P_4 . Aun cuando no se pudo establecer quién de las propuestas P_3 y P_4 obtuvo mejor desempeño de clasificación discriminante de neoplasias, al comparar los resultados de las tablas 3 y 5 respectivamente, se puede observar que ambas propuestas P_3 y P_4 , obtuvieron mejor porcentaje de clasificación correcta que las propuestas P_1 y P_2 . Por lo tanto, esto pudiera indicar que la influencia de la característica C , en forma conjunta con las características A y B , abona en la discriminación de las neoplasias.

Con el fin de robustecer los resultados, se aplican dos enfoques más de clasificación. Se propuso el último diseño experimental P_5 , tomando como base la propuesta P_1 y se añadieron los clasificadores *Naive Bayes* y *KNN con $K=3$* . Para la Red Neuronal Artificial (*ANN* por sus siglas en inglés), entrenada con *Retro-Propagación*, se utilizó la configuración mostrada en la Tabla 1. Se realizaron nueve corridas, para cada propuesta P_1 , utilizando en ejecución 2, 3, 4, 5, 6, 7, 8, 9 y 10 *folds* respectivamente.

Se empleó la prueba estadística no paramétrica de *Friedman* para probar la hipótesis nula H_0 : *No existe diferencia entre las distribuciones de clasificación correcta de los clasificadores*. Se estableció un valor de significancia $\alpha = 0.05$. Los porcentajes de clasificación y valores de jerarquía se muestran en las Tabla 26 y 7 respectivamente. Se obtuvo un $P_valor = 0.005$. Dado que $P_valor < \alpha$, entonces existe evidencia estadística significativa para rechazar H_0 , y aceptar la hipótesis alternativa H_a : *existe diferencia entre las distribuciones de clasificación correcta de los clasificadores*.

Tabla 4 Prueba de suma de Rangos con signo de Wilcoxon para P_3 y P_4

<i>Folds</i>	P_1	P_2	$ P_1 - P_2 $	jerarquía	-	+
2	82	83	1	3.5	3.5	
3	84	81	3	7		7
4	82.5	82	0.5	1.5		1.5
5	84	82.5	1.5	5		5
6	85.5	82	3.5	8		8
7	86	86.5	0.5	1.5	1.5	
8	87	86	1	3.5		3.5
9	86	83.5	2.5	6		6
10	82.5	88	5.5	9	9	

Tabla 5 Promedio de Clasificación correcta de P_3 y P_4

	P_3	P_4
<i>Promedio</i>	84.39	83.83
<i>Desviación estándar</i>	1.82	2.41

Tabla 6 Resultados de Clasificación correcta de P_5

<i>Folds</i>	<i>ANN</i>	<i>Naive Bayes</i>	<i>KNN</i>
2	82.5	78.5	81
3	81.5	79	80.5
4	83.5	80	81
5	80.5	80	82
6	82	80.5	79
7	81.5	79.5	81.5
8	82	77.5	77
9	81.5	78.5	76.5
10	80.5	75	79.5

Tabla 7 Jerarquía de Algoritmos Bajo Prueba de Friedman

Algoritmos	Jerarquía
<i>ANN</i>	1.16
<i>Naive Bayes</i>	2.66
<i>KNN</i>	2.16

Una vez establecido que existe una diferencia estadística entre los clasificadores y tomado como algoritmo de control a la Red Neuronal Artificial (*ANN* por sus siglas en inglés), entrenada con *Retro-Propagación*, según su jerarquía mostrada en la Tabla 7, se realizó la prueba a pares con corrección de *Bonferroni*, cuyos resultados se muestran en la **¡Error! La autoreferencia al marcador no es válida.**

Apoyados en los resultados de la Tabla 8, en la comparativa *ANN-Naive Bayes*, dado que *Bonferroni* $< \alpha$, podemos concluir que la Red Neuronal Artificial (*ANN* por sus siglas en inglés), entrenada con *Retro-Propagación*, obtuvo mejor desempeño en clasificación correcta comparado con *Naive Bayes*. Para comparativa *ANN-KNN*, dado que *Bonferroni* $> \alpha$, la prueba falla y no hay evidencia estadística significativa, para conjeturar cuál de los dos algoritmos de clasificación involucrados obtuvo mejor desempeño en clasificación correcta.

Tabla 8 Resultados de Prueba a Pares

	<i>VALOR Z</i>	<i>P-VALOR</i>	<i>BONFERRONI</i>
<i>ANN - Naive Bayes</i>	3.1819	0.0014	0.0029
<i>ANN - KNN</i>	2.121	0.0269	0.0539

5 ANÁLISIS Y DISCUSIÓN DE RESULTADOS

Con base a los resultados de la serie de experimentos realizados, se pudo determinar lo siguiente:

Para las propuestas P_1 y P_2 , existe evidencia estadística significativa entre los resultados de clasificación correcta a favor de P_1 . Este resultado se atribuye al hecho de que la propuesta P_1 considera el contraste entre la coloración de piel del individuo y la coloración de la neoplasia y la propuesta P_2 solamente la coloración de la neoplasia.

Respecto a las propuestas P_3 o P_4 , la prueba no encontró evidencia suficiente con respecto a cuál de ellas, obtuvo mejor desempeño. Se puede observar comparando los resultados de las tablas 3 y 5 que la influencia de C , aunado con las características de A y B , coadyuvan en una mejor discriminación de las neoplasias, a diferencia de usar solamente la característica C .

Para la propuesta P_5 , que se basa en el color de toda la imagen, en la comparativa *ANN-Naive Bayes*, se encontró evidencia estadística significativa entre los resultados de clasificación correcta a favor de la Red Neuronal Artificial (*ANN* por sus siglas en inglés), entrenada con *Retro-Propagación*. Esto se puede deber al hecho de que *Naive Bayes*, parte de la suposición de independencia entre características y como existe una relación natural entre los ejes de inercia o de simetría y la irregularidad del borde de las neoplasias, entonces esta relación contiene una correlación inherente entre las características A y B .

Para la comparativa *ANN-KNN*, la prueba tampoco encontró evidencia estadística significativa, para conjeturar quién de éstos dos algoritmos de clasificación involucrados obtuvo mejor desempeño en clasificación correcta.

En resumen, no se discernió cuál de los tres algoritmos obtuvo mejor porcentaje de clasificación correcta bajo la experimentación propuesta y para la base de datos seleccionada. Esto evidencia el hecho de que los resultados de clasificación correcta, cuando se utiliza toda la imagen para la parametrización del color de neoplasias, son equiparables en calidad, independientemente de cuál de los tres algoritmos de clasificación utilizados *ANN*, *Naive Bayes* y *KNN*, sea seleccionado para efectuar la clasificación discriminante de neoplasias.

6 CONCLUSIONES Y/O PROYECTOS FUTUROS.

Haciendo un balance general, tenemos los siguientes resultados: Se probó la hipótesis de trabajo *HT* planteada en la introducción, es decir, nuestra propuesta P_1 que considera el contraste entre la coloración de piel del individuo, *mejoró significativamente el porcentaje de clasificación discriminante correcta entre neoplasias benignas y malignas, comparada con la obtenida con la propuesta P_2 del estado del arte.*

El análisis comparativo de los resultados experimentales de las propuestas (P_3 y P_4), contra los resultados experimentales de las propuestas (P_1 y P_2), permitieron evidenciar claramente que el al utilizar en forma conjunta

las características *ABC*, se consiguieron mejores porcentajes de clasificación discriminante correcta entre melanomas y no melanomas, que las obtenidas al utilizar solamente la característica de color *C*. El experimento *P₅*, nos dejó algunos grandes y robustos aprendizajes:

- A. Cuando utilizamos toda la imagen para la parametrización del color de neoplasias, se obtuvieron porcentajes de clasificación discriminante correcta entre melanomas y no melanomas, equiparables en calidad, independientemente de cuál de los tres algoritmos de clasificación utilizados *ANN*, *Naive Bayes* y *KNN*, sea seleccionado para efectuar la clasificación discriminante de neoplasias.
- B. Como *Naive Bayes*, parte de la suposición de independencia entre características, este supuesto no se cumplió del todo para el problema que abordamos de clasificación discriminante entre melanomas y no melanomas, dado que hay una correlación inherente entre las características *A* y *B*.
- C. El tono de piel y las variaciones de color de las lesiones están fuertemente relacionados, por lo que es conveniente la inclusión de esta relación para obtener una parametrización adecuada.
- D. La conjunción de características *ABC*, bajo la óptica de la Red Neuronal Artificial (*ANN* por sus siglas en inglés), entrenada con *Retro-Propagación*, coadyuvan en una mejor clasificación discriminante de las neoplasias, comparado con el uso de solamente la característica de color *C*.

Algunas dificultades que se presentaron fueron las siguientes:

1. No existen en la literatura (estado del arte), suficientes bases de datos que contengan imágenes de neoplasias ya etiquetadas como malignas y no malignas por expertos médicos, y las reportadas en algunos artículos no están disponibles.
2. La base de datos utilizada, contienen imágenes que fueron tomadas con diferentes ángulos y cámara fotográfica, así como de iluminación y resolución irregulares.
3. La extracción de la región de interés y contorno, la realizó el equipo de investigación, cuando está debería hacerse por un médico experto (patólogo). Este hecho, bien puede contribuir a que los clasificadores no alcancen mayores porcentajes de clasificación discriminante correcta.

Como trabajo futuro se plantea:

- 1) Proponer que los repositorios de bases de datos del estado del arte cumplan con condiciones estandarizadas que respecto a la cámara fotográfica, el ángulo de captura, la iluminación y resolución.
- 2) Que las regiones de interés, contornos y clasificación sean determinadas por un médico experto (patólogo).
- 3) Realizar un estudio con mayor profundidad incluyendo diferentes métodos para la parametrización de color.
- 4) Abundar sobre más técnicas para la extracción de las características *A* de asimetría y de borde *B*.
- 5) La inclusión de un mayor número de elementos a caracterizar tomando la regla *ABCDE*.

Finalmente, queremos aclarar que el uso de las técnicas aquí utilizadas, se presentan como apoyo para que el médico experto, realice un diagnóstico más asertivo y oportuno de melanomas.

7 AGRADECIMIENTOS

Agradecimientos al Consejo Nacional de Ciencia y Tecnología (CONACYT) México por el apoyo brindado en esta investigación con el número de beca 703742 y al Tecnológico Nacional de México, en especial a la División de Estudios de Posgrado e Investigación del Instituto Tecnológico de León.

8 REFERENCIAS

- BLUM, A., Schmid-Wendtner, M. H., Mauss-Kiefer, V., Eberle, J. Y., Kuchelmeister, C., & Dill-Müller, D. (2006). Ultrasound mapping of lymph node and subcutaneous metastases in patients with cutaneous melanoma: results of a prospective multicenter study. *Dermatology*, 212(1), 47-52.
- CARRARA, M., Bono, A., Bartoli, C., Colombo, A., Lualdi, M., Moglia, D., ... & Santinami, M. (2007). Multispectral imaging and artificial neural network: mimicking the management decision of the clinician facing pigmented skin lesions. *Physics in medicine and biology*, 52(9), 2599.
- DE LA FUENTE-GARCÍA, A. & Ocampo-Candiani, J. (2010). Melanoma cutáneo. *Gaceta Medica de Mexico*.

- DI LEO, G., Liguori, C., Paolillo, A., & Sommella, P. (2008, July). An improved procedure for the automatic detection of dermoscopic structures in digital ELM images of skin lesions. In *Virtual Environments, Human-Computer Interfaces and Measurement Systems, 2008. VECIMS 2008. IEEE Conference on* (pp. 190-194). IEEE.
- ELGAMAL, M. (2013). Automatic skin cancer images classification. *IJACSA) International Journal of Advanced Computer Science and Applications*, 4(3), 287-294.
- EL GAMMAL, S., Hartwig, R., Aygen, S., Bauermann, T., el Gammal, C., & Altmeyer, P. (1996). Improved resolution of magnetic resonance microscopy in examination of skin tumors. *Journal of investigative dermatology*, 106(6), 1287-1292.
- ERCAL, F., Chawla, A., Stoecker, W. V, Lee, H. C., & Moss, R. H. (1994). Neural network diagnosis of malignant melanoma from color images. *IEEE Trans Biomed Eng*, 41(9). <https://doi.org/10.1109/10.312091>
- FIKRLI, T., & Pizinger, K. (2007). Digital computer analysis of dermatoscopical images of 260 melanocytic skin lesions; perimeter/area ratio for the differentiation between malignant melanomas and melanocytic nevi. *Journal of the European Academy of Dermatology and Venereology*, 21(1), 48-55.
- GARCÍA-LAMONT F., Cervantes J., & López, A. (2012). Recognition of Mexican banknotes via their color and texture features. *Expert Systems with Applications*, 39(10), 9651–9660. <https://doi.org/10.1016/j.eswa.2012.02.132>
- GILMORE, S., Hofmann- Wellenhof, R., & Soyer, H. P. (2010). A support vector machine for decision support in melanoma recognition. *Experimental dermatology*, 19(9), 830-835.
- JaISWAR S., Kadri M., & Gatty, V. (2014). www.ijser.in Skin Cancer Detection Using Digital Image Processing. *International Journal of Scientific Engineering and Research (IJSER) ISSN (Online Impact Factor, 3(6), 2347–3878.*
- LORBER, A., Wiltgen, M., Hofmann- Wellenhof, R., Koller, S., Weger, W., Ahlgrimm- Siess, V., ... & Gerger, A. (2009). Correlation of image analysis features and visual morphology in melanocytic skin tumours using in vivo confocal laser scanning microscopy. *Skin Research and Technology*, 15(2), 237-241.
- MAGLOGIANNIS I., & Doukas C. N. (2009). Overview of advanced computer vision systems for skin lesions characterization. *IEEE Transactions on Information Technology in Biomedicine*.
- MASOOD, A., & Ali Al-Jumaily, A. (2013). Computer aided diagnostic support system for skin cancer: a review of techniques and algorithms. *International journal of biomedical imaging*, 2013.
- MASOOD, A., & Al-Jumaily, A. A. (2013). Fuzzy C mean thresholding based level set for automated segmentation of skin lesions. *Journal of Signal and Information Processing*, 4(03), 66.
- MENDONCA T., Ferreira P. M., Marques J. S., Marcal A. R. S., & Rozeira, J. (2013). PH2 - A dermoscopic image database for research and benchmarking. In *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* 5437–5440. <https://doi.org/10.1109/EMBC.2013.6610779>
- MOGENSEN, M., Thrane, L., Jørgensen, T. M., Andersen, P. E., & Jemec, G. B. (2009). OCT imaging of skin cancer and other dermatological diseases. *Journal of biophotonics*, 2(6- 7), 442-451.
- NEHAL, K. S., Oliveria, S. A., Marghoob, A. A., Christos, P. J., Dusza, S., Tromberg, J. S., & Halpern, A. C. (2002). Use of and beliefs about baseline photography in the management of patients with pigmented lesions: a survey of dermatology residency programmes in the United States. *Melanoma Research*, 12(2), 161-167.
- OGORZALEK, M., Nowak, L., Surowka, G., & Alekseenko, A. (2011). Melanoma in the clinic—diagnosis, management and complications of malignancy. *Modern Techniques for Computer-Aided Melanoma Diagnosis*.
- RUIZ, D., Berenguer, V., Soriano, A., & Sánchez, B. (2011). A decision support system for the diagnosis of melanoma: A comparative approach. *Expert Systems with Applications*, 38(12), 15217-15223.

- SBONER A., Eccher, C. Blanzieri, E. Bauer P., Cristofolini M., Zumiani G. & Forti, S. (2003). A multiple classifier system for early melanoma diagnosis. *Artificial Intelligence in Medicine*.
- SOSSA J. H., López-Morales M. a. & Santiago-Montero R. (2014). Digital shape compactness measure by means of perimeter ratios. *Electronics Letters*, 50(3), 171–173. <https://doi.org/10.1049/el.2013.3685>
- STAUFFER, F., Kittler, H., Forstinger, C., & Binder, M. (2001). The dermatoscope: a potential source of nosocomial infection?. *Melanoma research*, 11(2), 153-156.
- VENNILA, G. S., Suresh, L. P., & Shunmuganathan, K. L. (2012, March). Dermoscopic image segmentation and classification using machine learning algorithms. In *Computing, Electronics and Electrical Technologies (ICCEET)*, 2012 International Conference on (pp. 1122-1127). IEEE.