

Recognition of Skin Lesions in Dermoscopic Images using Local Binary Patterns and Multinomial Logistic Regression

Washington D. Quero-Caiza, and Miguel Altuve, *Senior Member, IEEE*

Abstract—Skin cancer, such as melanoma, affects more than 13 million people annually and causes more than 65,000 deaths. As with almost all types of cancer, it can be treated effectively if it is diagnosed in its early stages. The development of computer-aided diagnostic tools is, therefore, a valuable and urgent need to support the decision of dermatologists, minimize human error, and accelerate the time to diagnosis and the prognosis of patients. The present work proposes the automatic recognition of three skin lesions, namely Common Nevus, Atypical Nevus, and Melanoma, from dermoscopic images. First, a feature vector representing texture is extracted from the dermoscopic images using the local binary pattern operator (LBP). Then, a multinomial logistic regression (MLR) model is used to exploit the feature vector to perform the multiclass classification. The hyperparameters of the LBP operator, namely the radius and the pixel neighborhoods, were modified to provide the feature set to the MLR model that maximizes the classification performance. Moreover, to assure the generalizability of the model and the reproducibility of the results, a 10-iteration Monte Carlo cross-validation (MCCV) was employed, by dividing the dataset into 70% for training and 30% for testing, with different random seeds in each iteration. The optimal LBP-MLR classification model was finally embedded in a graphical user interface (GUI) to facilitate the interaction between the user and the classification system. An Average accuracy of 90%, average recall of 89.23%, 84.75%, and 100%, and average precision of 85.95% 88.12%, and 100% were obtained, to identify Common Nevus, Atypical Nevus, and Melanoma, respectively, in the MCCV strategy. It should be highlighted that the proposed classification system can perfectly differentiate melanoma from the other two skin lesions.

Index Terms—Melanoma, Cancer, Local Binary Patterns, Logistic Regression, Classification.

I. INTRODUCCIÓN

El cáncer es una de las principales causas de muerte en el mundo (aprox. 10 millones de fallecimiento por año), donde 1,2 millones de personas fallecieron por cáncer de piel en el año 2020 [1]. Uno de cada tres diagnósticos de cáncer es un cáncer de piel y más de trece millones de nuevos casos son diagnosticados cada año. El tipo de cáncer de piel más común es el melanoma, aunque conforma solo el 1% de los casos diagnosticados, es el causante de la gran mayoría de muertes en este tipo de cáncer [2]. En Ecuador, el cáncer de piel es un problema prevalente dada la gran radiación ultravioleta debido

a su posición geográfica [3]. Como en casi todos los tipos de cáncer, el melanoma se puede tratar de manera eficaz si es detectado en sus etapas iniciales.

El diagnóstico de cáncer de piel inicia con una evaluación visual a fin de hallar irregularidades en la piel, luego se realiza un examen dermatoscópico utilizando instrumentos especializados para obtener imágenes con una resolución detallada para visualizar la lesión y, en caso de ser necesario, se realiza una biopsia para realizar un análisis histopatológico que determine la presencia o ausencia de la patología [4], [5]. Este proceso requiere un elevado nivel de experticia por parte del especialista ya que la piel puede presentar características similares en condiciones patológicas diferentes. Lamentablemente, y debido a varios factores, esta patología es detectada cuando la condición ya es maligna, entre ellos: *i*) la realización de un trabajo manual (autoexploración de la piel), *ii*) la existencia de cambios imperceptibles difíciles de diferenciar y de realizar un seguimiento de forma manual, y *iii*) los altos costos de los equipos médicos para diagnosticar esta enfermedad, y de los procedimientos quirúrgicos y terapias para tratarla, siendo inalcanzable en muchos países de bajos recursos económicos. Por lo antes expuesto, se hace necesario el desarrollo de herramientas de diagnóstico automático que ayuden en el proceso de decisión médica, principalmente en lugares con acceso limitado a centros de salud. Es por ello por lo que en la actualidad existe un auge en el desarrollo de soluciones basadas en inteligencia artificial para el diagnóstico asistido por computadora enfocados al cáncer, y en particular al cáncer de piel debido al crecimiento poblacional y a la falta de experiencia y de servicios médicos adecuados [6], [7].

En la literatura se pueden encontrar numerosos enfoques de detección de lesiones cutáneas (ver sección II), sin embargo, la gran mayoría de las publicaciones se han dedicado a detectar el melanoma en imágenes dermatoscópicas (clasificación binaria) [8], [9], [10], [11], [12], y pocos se han concentrado en diferenciar varias lesiones cutáneas (clasificación multiclase) [13], [14], [15], [16], pues esta última tiende a ser más complicada dado que se aumenta las clases a diferenciar y por consiguiente es más propensa a errores, por lo que los desempeños reportados suelen ser inferiores a los del caso binario. En la cadena de detección de la patología, en general suelen aplicarse técnicas de reducción de ruido (filtrado, eliminación del vello), mejoramiento de contraste, segmentación de la lesión, extracción y/o selección de características, y uso de un modelo clasificador. La gran mayoría de los trabajos reportados en la literatura suelen hacer

W.D. Quero-Caiza is with Valencian International University, Valencia, Spain (e-mail: wdquero@espe.edu.ec)

M. Altuve is with Valencian International University, Valencia, Spain, and with the Applied Biophysics and Bioengineering Group, Simon Bolívar University, Caracas, Venezuela. E-mail: miguel.altuve@ieec.org.

un proceso de extracción manual de características, seguido muchas veces de un proceso de selección (reducción) de características, siendo las características de forma las más utilizadas [15], [16]. Entre las técnicas de clasificación, la regla ABCD y las máquinas de vectores de soporte han sido las más utilizadas [14], [10], [8], aunque también se pueden destacar los k vecinos próximos y las funciones de base radial [16], [11].

Siguiendo los esfuerzos de la literatura, y motivados por el incremento de casos de melanomas y por la necesidad existente de diagnosticarlo oportunamente y de manera automática, en este trabajo se propone el reconocimiento automático de tres lesiones cutáneas (melanoma, nevo atípico, y nevo común) en imágenes dermatoscópicas. Para ello se usó, en primer lugar, el operador de patrones locales binarios (LBP, por sus siglas en inglés *Local Binary Pattern*) [17] para obtener características con información de textura local de las imágenes dermatoscópicas, y en segundo lugar, un modelo de regresión logística multinomial (MLR, por sus siglas en inglés *Multinomial Logistic Regression*) para explotar esas características y emitir un diagnóstico basado en probabilidades. Por un lado, el operador LBP tiene un alto poder discriminativo, es fácil de implementar, presenta invarianza a cambios monótonos y un bajo costo computacional, por lo que resulta muy adecuado en el reconocimiento de texturas en imágenes dermatoscópicas y en la generación de un vector de características que pueda ser explotado por un modelo clasificador. Además, ha sido empleado con éxito en numerosos campos, incluidos el reconocimiento facial [18] y la detección de COVID-19 [19]. Por otro lado, el modelo MLR, una extensión de la regresión logística binaria, permite estimar las probabilidades de M categorías de una variable cualitativa Y a partir de un conjunto de variables explicativas X . Comparado con otros enfoques de aprendizaje automático, la MLR tiene un bajo costo computacional, es sencilla de implementar, y es fácil de interpretar al ofrecer una vista probabilística de las predicciones de cada clase. Además, el modelo MLR ha sido aplicado con éxito en numerosos campos, incluidos la clasificación de imágenes hiperespectrales [20] y la detección de errores financieros con intención de fraude [21]. En este trabajo, varios experimentos fueron llevados a cabo para la selección del vector de características apropiado que produce el mejor desempeño de clasificación, al variar los hiperparámetros del operador LBP (radio y número de píxeles vecinos). Adicionalmente, se desarrolló una interfaz gráfica para facilitar el uso del clasificador por parte del usuario.

A diferencia de otros enfoques, y como principales contribuciones de este trabajo, resaltamos que *i*) nuestra propuesta de clasificación no involucra un proceso de eliminación del vello en las imágenes, *ii*) la etapa de preprocesamiento solo involucra el recorte de la imagen, *iii*) no realizamos un proceso de extracción de características basadas en descriptores estadísticos (ver por ejemplo [12]) y una posterior selección de estas pues el vector de característica explotado por el MLR es automáticamente generado por el operador LBP (no se reduce ni se redimensiona), *iv*) los hiperparámetros del operador LBP (radio y número de píxeles vecinos) son ajustados para generar un vector de características único con información de la textura

de la imagen, y *v*) el modelo clasificador seleccionado es uno de los más sencillos existente y con bajo costo computacional. La concepción y el desarrollo de un clasificador automático de lesiones cutáneas en imágenes dermatoscópicas servirán como soporte clínico para proporcionar un diagnóstico eficaz y económico, impactando positivamente en la detección, prevención y tratamiento de estos pacientes, mejorando su calidad de vida. El resto del documento se encuentra estructurado de la siguiente manera. En la siguiente sección se presentan la metodología de clasificación llevada a cabo y la base de datos de imágenes dermatoscópicas utilizada. Posteriormente se presentan y analizan los resultados de clasificación y se muestra la interfaz gráfica. Finalmente, en la última sección, se exponen las conclusiones de la investigación realizada.

II. TRABAJOS RELACIONADOS

En la literatura se pueden encontrar varios enfoques para detectar el cáncer de piel y otras lesiones cutáneas. Entre estos podemos encontrar dos tipos de enfoques: un enfoque de clasificación binaria, en donde existen dos clases a diferenciar, como la presencia o ausencia del cáncer de piel, y un enfoque de clasificación multiclase, en donde existen varias clases a detectar, como la clasificación de la lesión cutánea en nevo común, nevo atípico, y melanoma, el cual es el caso de estudio del presente trabajo. Dependiendo de la tarea de clasificación (multiclase o binaria), diferentes métricas de desempeño suelen emplearse, siendo la más común y utilizada la exactitud en ambas tareas de clasificación, mientras que la sensibilidad y la especificidad suelen emplearse en el caso binario, y la exhaustividad, la precisión y el valor F1 suelen emplearse para evaluar una clasificación multiclase.

Entre los enfoques de clasificación binaria, podemos encontrar el trabajo de Alquran y colaboradores, quienes obtuvieron una exactitud de 92,1% para diferenciar la lesión de piel maligna de benigna en imágenes dermatoscópicas segmentadas mediante umbralización, y extrajeron características (matriz de co-ocurrencia de nivel de gris, asimetría, borde, color, diámetro, etc.) que fueron seleccionadas mediante un análisis de componentes principales y explotadas por una máquina de vectores de soporte [8]; el trabajo de Hu y colaboradores quienes obtuvieron una sensibilidad de 92,5% y una especificidad de 91,3% para detectar el melanoma en imágenes dermatoscópicas con una máquina de vectores de soporte que explota características extraídas de los histogramas de color RGB y transformación de características invariantes en escala [9]; el trabajo de Saravanan y colaboradores quienes desarrollaron un sistema en LabVIEW con una exactitud de 100% para detectar el melanoma usando la regla ABCD en imágenes dermatoscópicas que fueron preprocesadas (filtro de mediana y estiramiento del contraste) y segmentadas y caracterizadas (asimetría, borde, color y diámetro) [10]; el trabajo de Cheong y colaboradores quienes obtuvieron una exactitud de 97,5% para detectar el melanoma en imágenes dermatoscópicas usando una descomposición de modo empírico bidimensional, mejoramiento de textura, entropía y una combinación de máquinas de vectores de soporte y funciones de base radial [11]; y el trabajo de Luna-Benso y colaboradores quienes obtuvieron una exactitud de 97,8% para detectar

el melanoma usando autómatas celulares en imágenes dermatoscópicas que fueron segmentadas y caracterizadas (once características estadísticas) [12].

Concernientes a los enfoques de clasificación multiclase, podemos destacar el trabajo de Salido y Ruiz quienes obtuvieron una exactitud de 87,5% para clasificar la lesión en melanoma, nevo común o nevo atípico, a partir de imágenes dermatoscópicas a las que se les había removido el vello, usando un enfoque de clasificación basado en una red neuronal convolucional [13]; el trabajo de Zaqout quien obtuvo una exactitud de 90% para para clasificar la lesión en benigna, sospechosa o maligna usando la regla ABCD en imágenes dermatoscópicas que fueron preprocesadas (eliminación de ruido y mejoramiento del contraste), segmentadas y caracterizadas [14]; el trabajo de Ghalejoogh y colaboradores quienes obtuvieron una exactitud de 96% para clasificar las lesiones cutáneas en melanoma, displásica o benigna en imágenes dermatoscópica a las que le aplicaron la transformación de sombrero de copa para eliminar el vello, segmentaron el área de la lesión con el método de Otsu, extrajeron características de forma, color y textura, y combinaron clasificadores [15]; y el trabajo de Paramkusham y Kumar quienes obtuvieron una exactitud de 90% para clasificar la lesión en melanoma, nevo común o nevo atípico, a partir de imágenes dermatoscópicas a las que se les extrajeron características basadas en la forma (excentricidad, perímetro, área convexa, orientación) que fueron explotadas por diferentes clasificadores, como máquinas de vectores de soporte y k vecinos próximos [16].

III. MATERIALES Y MÉTODOS

A. Conjunto de Imágenes

200 imágenes dermatoscópicas fueron utilizadas en este trabajo [22]. Dichas imágenes fueron obtenidas con el sistema Tubinga Mole Analyzer, con un aumento de 20x. Las imágenes son en color RGB de 8 bits, con una resolución de 768x560 píxeles. Cada imagen fue evaluada por un dermatólogo experto de acuerdo con: la segmentación manual de la lesión cutánea, el diagnóstico clínico e histológico, y criterios dermatoscópicos (asimetría, color, presencia de estructuras diferenciales típicas y atípicas). La base de datos contiene 80 nevos comunes (NeCo), 80 nevos atípicos (NeAt) y 40 melanomas (Me), y está disponible de forma gratuita en el enlace <https://www.fc.up.pt/addi/ph2%20database.html>.

El NeCo es un lunar liso y redondo de un solo color; se puede nacer con este, pero por lo general se desarrolla en la niñez. El NeAt es generalmente benigno a pesar de tener un gran parecido al melanoma, sin embargo, su presencia tiene una mayor incidencia en desarrollar melanoma. El Me, el tipo más grave de cáncer de piel, ocurre cuando los melanocitos empiezan a crecer fuera de control. En la Figura 1 se muestran ejemplos de imágenes dermatoscópicas de estas tres clases de lesiones cutáneas.

B. Obtención de la ROI y Extracción de Características

En primer lugar, las imágenes a color fueron convertidas a escala de grises en el rango 0-255 (0 representa negro

y 255 representa blanco). Debido a que las imágenes dermatoscópicas contienen un contorno oscuro, propio del equipo utilizado en la dermatoscopia digital (ver Figura 1), se realizó un recorte de la imagen para obtener la región de interés (ROI, del inglés *region of interest*). Para ello se recorta la imagen en un 15% de ancho (115 píxeles) y un 2% de alto (11 píxeles). Posteriormente, se extrajeron las características de las ROI de las imágenes dermatoscópicas, las cuales fueron utilizadas como atributos de entrada al modelo MLR.

Las características se extraen usando el operador LBP, un descriptor visual que proporciona una distribución de intensidad alrededor de un píxel central, útil para describir una imagen al ser estas distribuciones de intensidad. El LBP se obtiene dividiendo la imagen en celdas. Cada píxel en la celda se compara con sus ocho píxeles vecinos en una vecindad de 3×3 píxeles: se asigna un 1 si el píxel central es mayor que el píxel vecino, de lo contrario se asigna un 0. De esta forma se obtienen ocho dígitos binarios que se convierten en un número decimal (valor LBP) de acuerdo con la ubicación de los píxeles vecinos ($2^0 = 1$, $2^1 = 2$, $2^2 = 4$, $2^3 = 8$, $2^4 = 16$, $2^5 = 32$, $2^6 = 64$, $2^7 = 128$). Este número decimal se asigna al píxel central de la vecindad, y se repite el procedimiento en todos los píxeles de la celda [17]. Posteriormente se determina el histograma en la celda con los valores LBP de los píxeles de la celda. Este procedimiento se repite para todas las celdas de la imagen. Los histogramas concatenados corresponden al vector de características de la imagen que puede ser usado por una técnica de aprendizaje automático con fines de clasificación.

En el operador LBP se pueden usar vecinos de diferentes tamaños [23], específicamente se puede extender la técnica para procesar P píxeles vecinos en un radio circular R . En este trabajo se hicieron cinco experimentos diferentes al combinar los valores de los hiperparámetros P y R para obtener vectores de características diferentes a ser explotados por los MLR. Específicamente, se obtuvieron características usando las siguientes combinaciones de los hiperparámetros:

- 1) $R = 1$, $P = 4$
- 2) $R = 1$, $P = 8$
- 3) $R = 2$, $P = 8$
- 4) $R = 2$, $P = 12$
- 5) $R = 3$, $P = 12$

Para extraer información de textura de una única y gran porción de la imagen, y así minimizar el costo computacional del enfoque propuesto, se optó por un tamaño de la celda igual al tamaño de la ROI de la imagen dermatoscópica en escala de gris. De esta forma se da mayor preferencia a los detalles globales que a los locales. Además, se ha usado una interpolación lineal para seleccionar los P píxeles vecinos en el radio R , y se ha aplicado una normalización Euclidiana (ℓ_2 -norm) a la celda del histograma LBP.

C. Reconocimiento de la Lesión Cutánea Usando MLR

Con los vectores de características extraídos con el operador LBP, se proceden a entrenar los MLR para que sean capaces de clasificar las imágenes dermatoscópicas en función de las lesiones cutáneas (NeCo, NeAt, y Me). La MLR es una extensión multivariante de la regresión logística binaria



Fig. 1. Ejemplos de imágenes dermatoscópicas del conjunto de datos.

clásica, en la cual los atributos de entrada pasan a través de funciones logísticas o sigmoideas que terminan tratando al resultado como una probabilidad. En este trabajo, dado que la salida puede ser una de tres clases posibles, esto es, $Y = \{\text{NeCo}, \text{NeAt}, \text{Me}\}$, se tienen tres funciones de probabilidad condicional que permiten realizar la clasificación en las categorías definidas [24]:

$$P(Y = \text{NeCo}|X) = \frac{1}{1 + e^{g_1(X)} + e^{g_2(X)}}$$

$$P(Y = \text{NeAt}|X) = \frac{e^{g_1(X)}}{1 + e^{g_1(X)} + e^{g_2(X)}}$$

$$P(Y = \text{Me}|X) = \frac{e^{g_2(X)}}{1 + e^{g_1(X)} + e^{g_2(X)}}$$

donde:

$$g_1(X) = \alpha_{11} + \beta_{11}x_1 + \beta_{12}x_2 + \dots + \beta_{1k}x_k$$

$$g_2(X) = \alpha_{12} + \beta_{21}x_1 + \beta_{22}x_2 + \dots + \beta_{2k}x_k$$

y x_i , $i = 1, \dots, k$, corresponde a la característica (o atributo) i , y α y β son los coeficientes que se optimizan en el proceso de entrenamiento del modelo. Una vez entrenado el modelo MLR, en la etapa de prueba, la clasificación se asigna a la clase más probable cuando los atributos (vector de características LBP) de una nueva imagen dermatoscópica son introducidos al modelo MLR.

D. Evaluación del Desempeño de la Clasificación Multiclase

La evaluación del desempeño de la clasificación se realizó utilizando las métricas exactitud (*Acc*), precisión (*Pre*), y exhaustividad (*Rec*), obtenidas de una matriz de confusión [25], tal como se muestra en la tabla I. Además, se determinó el valor *F1* definido como el promedio ponderado entre la precisión y la exhaustividad:

$$F1 = \frac{2 \times Pre \times Rec}{Pre + Rec} \quad (1)$$

Para garantizar la repetibilidad y reproducibilidad de los resultados, se realizó una validación cruzada por Monte Carlo (MCCV, por sus siglas en inglés, *Monte Carlo cross-validation*) de 10 iteraciones, en la que cada iteración se dividió el conjunto de datos de forma aleatoria en 70% para llevar a cabo el entrenamiento y el 30% restante para ejecutar la prueba.

La cadena de procesamiento de imágenes y de clasificación de las imágenes dermatoscópicas fue llevada a cabo en MATLAB® R2020b (The MathWorks, MA, USA), usando las funciones propias de las cajas de herramientas Image Processing, Computer Vision, y Statistics and Machine Learning, en un computador personal portátil Toshiba, modelo Satellite S55-B5155, con procesador Intel i7-5500U de 2.4 GHz y memoria RAM de 8 GB, en el sistema operativo Windows 10 Pro-64 bits.

Para promover el uso de la interfaz gráfica desarrollada y garantizar la transparencia de los resultados obtenidos, se ha creado un repositorio en GitHub, de acceso libre y gratuito, con el código de este trabajo de investigación, en el enlace <https://github.com/DanQC19/Multinomial-Logistic-Regression>.

E. Diseño de la Interfaz Gráfica

Para que exista una mejor interacción entre el usuario y la máquina, se diseñó una interfaz gráfica, desarrollada en GUIDE de MATLAB® R2020b (The MathWorks, MA, USA); de tal manera que el operador pueda realizar las diferentes operaciones de manera fácil e intuitiva. En esta interfaz se incorporó el operador LBP con los hiperparámetros P y R que produjeron el mejor desempeño de clasificación usando el modelo MLR.

La interfaz gráfica consta de dos ventanas. La primera, llamada “Principal”, contiene información de la aplicación e información de contacto, mientras que la segunda, llamada “Sistema”, permite ejecutar las diferentes operaciones del sistema en forma continua para clasificar las lesiones cutáneas. Las operaciones que se realizan en la ventana “Sistema” son:

- Cargar Imagen: Permite al usuario abrir una imagen dermatoscópica la cual se visualizará en el panel de figuras.
- Procesar: Realiza el recorte de la imagen y se visualiza en el panel de figuras.
- Segmentación: Encierra la ROI de la imagen dermatoscópica y, siguiendo el método de OTSU [26], [27], se realiza la segmentación de la imagen que se visualiza en el panel de figuras. Además, extrae las características de la imagen mediante el operador LBP las cuales serán utilizadas en el clasificador. En el panel de figuras se

TABLA I
MATRIZ DE CONFUSIÓN. LAS ECUACIONES DE PRECISIÓN (Pre), EXHAUSTIVIDAD (Rec), $F1$ Y EXACTITUD (Acc) SE MUESTRAN COMO REFERENCIA.

Referencia	Predicción				Rec	$F1$
	$Clase_1$	$Clase_2$...	$Clase_n$		
$Clase_1$	a_{11}	a_{12}	...	a_{1n}	$\frac{a_{11}}{\sum_{j=1}^n a_{1j}}$	$2 \times \frac{Rec_1 \times Pre_1}{Rec_1 + Pre_1}$
$Clase_2$	a_{21}	a_{22}	...	a_{2n}	$\frac{a_{22}}{\sum_{j=1}^n a_{2j}}$	$2 \times \frac{Rec_2 \times Pre_2}{Rec_2 + Pre_2}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
$Clase_n$	a_{n1}	a_{n2}	...	a_{nn}	$\frac{a_{nn}}{\sum_{j=1}^n a_{nj}}$	$2 \times \frac{Rec_n \times Pre_n}{Rec_n + Pre_n}$
Pre	$\frac{a_{11}}{\sum_{i=1}^n a_{i1}}$	$\frac{a_{22}}{\sum_{i=1}^n a_{i2}}$...	$\frac{a_{nn}}{\sum_{i=1}^n a_{in}}$	$Acc = \frac{\sum_{i=1}^n a_{ii}}{\sum_{i=1}^n \sum_{j=1}^n a_{ij}}$	

presentará la imagen recortada con su histograma, la imagen segmentada, y la imagen LBP con su histograma.

- Clasificar: Utiliza el modelo MLR para realizar la clasificación de la imagen abierta y devuelve la clase a la cual pertenece.
- Limpiar: Realiza un reinicio del sistema.
- Salir: Cierra la aplicación.

La Figura 2 muestra el entorno de diseño de estas dos ventanas.

IV. RESULTADOS

A. Extracción de Características

La Figura 3 muestra ejemplos de imágenes LBP y de vectores de características LBP para diferentes combinaciones de P y R para tres tipos de imágenes dermatoscópicas. El tamaño del vector de características obtenido con el operador LBP, de acuerdo a la configuración descrita en la sección III-B, fue:

- 1) 15 características con $R = 1, P = 4$
- 2) 59 características con $R = 1, P = 8$
- 3) 59 características con $R = 2, P = 8$
- 4) 135 características con $R = 2, P = 12$
- 5) 135 características con $R = 3, P = 12$

B. Clasificadores para el Reconocimiento de la Lesión Cutánea

Las tablas II-VI muestran ejemplos de clasificación para un subconjunto de prueba en una iteración de la MCCV, para las diferentes combinaciones de los hiperparámetros P y R . De estas matrices de confusión podemos destacar que los mejores desempeños, en un subconjunto de prueba, se obtuvieron para $R = 1$ y $P = 8$ ($Acc=88,33\%$) y $R = 2$ y $P = 8$ ($Acc=93,34\%$).

La Figura 4 muestra los valores promedios de las métricas Rec , Pre y $F1$, obtenidos de la MCCV, para cada clase y para cada modelo MLR que explota las características del operador LBP obtenidas con diferentes combinaciones de hiperparámetros. Asimismo, la Figura 5 muestra los valores promedio de Acc , obtenidos de la MCCV, para cada combinación de hiperparámetros. De estas figuras podemos observar que el mejor desempeño de clasificación, para las cuatro métricas, fue obtenido con el modelo MLR que explota

TABLA II
DESEMPEÑO DE CLASIFICACIÓN EN UNA ITERACIÓN DE LA MCCV, PARA $R = 1$ Y $P = 4$.

Referencia	Predicción			$Rec(\%)$	$F1(\%)$
	NeCo	NeAt	Me		
NeCo	19	6	3	67,85	69,08
NeAt	7	15	1	65,21	66,66
Me	1	1	7	77,78	69,99
$Pre(\%)$	70,37	68,18	63,63	68,34	

TABLA III
DESEMPEÑO DE CLASIFICACIÓN EN UNA ITERACIÓN DE LA MCCV, PARA $R = 1$ Y $P = 8$.

Referencia	Predicción			$Rec(\%)$	$F1(\%)$
	NeCo	NeAt	Me		
NeCo	18	4	0	81,81	83,71
NeAt	2	24	0	92,30	88,88
Me	1	0	11	91,66	95,64
$Pre(\%)$	85,71	85,71	100	88,33	

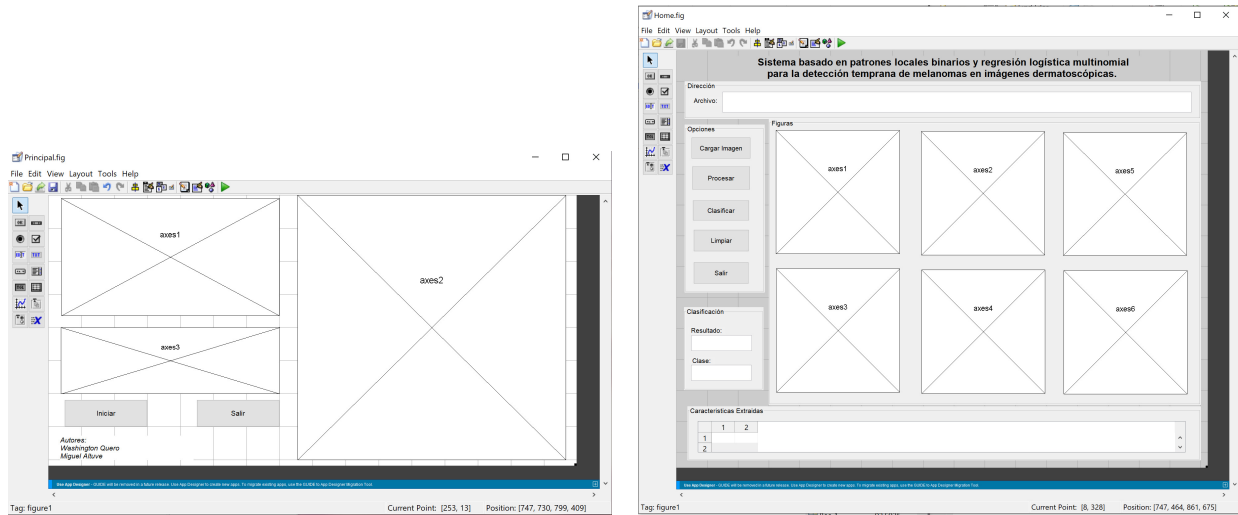
TABLA IV
DESEMPEÑO DE CLASIFICACIÓN EN UNA ITERACIÓN DE LA MCCV, PARA $R = 2$ Y $P = 8$.

Referencia	Predicción			$Rec(\%)$	$F1(\%)$
	NeCo	NeAt	Me		
NeCo	25	2	0	92,59	92,59
NeAt	2	20	0	90,90	90,90
Me	0	0	11	100	100
$Pre(\%)$	92,59	90,90	100	93,34	

TABLA V
DESEMPEÑO DE CLASIFICACIÓN EN UNA ITERACIÓN DE LA MCCV, PARA $R = 2$ Y $P = 12$.

Referencia	Predicción			$Rec(\%)$	$F1(\%)$
	NeCo	NeAt	Me		
NeCo	18	4	1	78,26	79,99
NeAt	3	22	1	84,61	83,01
Me	1	1	9	81,81	81,81
$Pre(\%)$	81,81	81,48	81,81	81,67	

las características LBP con hiperparámetros $R = 2$ y $P = 8$,



(a) Ventana "Principal"

(b) Ventana "Sistema"

Fig. 2. Entorno de diseño de las ventanas de la interfaz gráfica desarrollada.

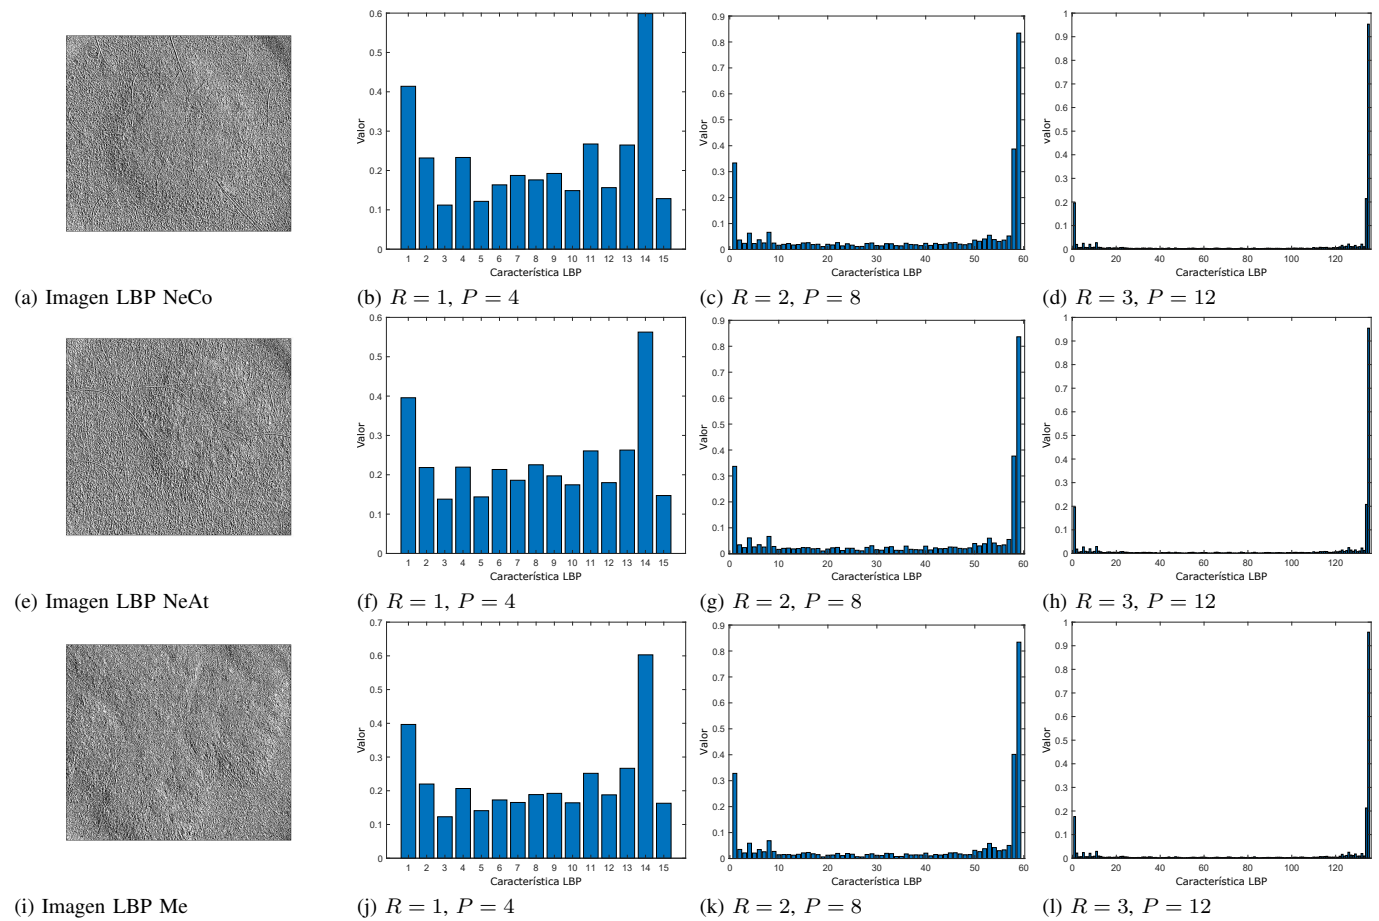


Fig. 3. Imágenes LBP y vectores de características LBP obtenidos para diferentes combinaciones de P y R para las tres clases de imágenes dermatoscópicas. Las imágenes LBP fueron obtenidas con $R = 1$ y $P = 8$.

seguido del modelo MLR que explota las características LBP con hiperparámetros $R = 1$ y $P = 8$. Por lo tanto, el modelo MLR que explota las características LBP con hiperparámetros $R = 2$ y $P = 8$ fue elegido como el mejor y fue utilizado en la interfaz gráfica.

La tabla VII muestra los resultados del desempeño del modelo con hiperparámetros $R = 2$ y $P = 8$ del operador LBP para cada iteración de la MCCV. Se puede observar que el melanoma fue la clase más fácil de detectar (valores de precisión y exhaustividad del 100%). Para este clasificador, los




Fig. 4. Desempeño de clasificación promedio para cada clase y para cada modelo de clasificación con hiperparámetros R y P del operador LBP.

TABLA VI

DESEMPEÑO DE CLASIFICACIÓN EN UNA ITERACIÓN DE LA MCCV, PARA $R = 3$ Y $P = 12$.

Referencia	Predicción			Rec(%)	F1(%)
	NeCo	NeAt	Me		
NeCo	19	2	1	86,36	75,99
NeAt	8	21	1	70,00	77,77
Me	1	1	6	75,00	75,00
Pre(%)	67,85	87,50	75,00	76,67	




Fig. 5. Exactitud promedio para cada modelo de clasificación con hiperparámetros R y P del operador LBP.

valores promedios (valores macro) de exhaustividad, precisión y $F1$ son 91,33%, 91,36% y 91,19%, respectivamente.

C. Interfaz Gráfica

Como indicado, el modelo implementado en la interfaz gráfica corresponde al MLR que explota el vector de características LBP con hiperparámetros $R = 2$ y $P = 8$. En la Figura 6 se muestran las dos ventanas concebidas. En la figura también se observa dos ejemplos de clasificación de imágenes dermatoscópicas en la ventana “Sistema”, uno correspondiente a Nevus Común y otro a Melanoma. Podemos observar las diferentes imágenes desplegadas en la interfaz gráfica, el menú

de opciones (botones en el lado izquierdo), y el vector de características LBP en la parte inferior derecha de la ventana “Sistema” de la interfaz gráfica, entre cosas.

V. DISCUSIÓN

La combinación de los hiperparámetros R y P del operador LBP condujo a diferentes desempeños de clasificación para reconocer los tres tipos de lesiones cutáneas, observándose un pico en las métricas de evaluación del desempeño para $R = 2$ y $P = 8$ (ver Figuras 4 y 5). Estos hiperparámetros R y P producen un vector de características de diferentes longitudes (ver Figura 3) que impactan tanto el desempeño de clasificación como la rapidez del proceso de clasificación. Además, gracias al proceso de validación cruzada por Monte Carlo, garantizamos que estos resultados sean reproducibles y similares (ver Tabla VII), al probar con diferentes particiones aleatorias de los datos.

Para las diferentes combinaciones de los hiperparámetros R y P del operador LBP, tanto en las diferentes matrices de confusión de ejemplos (ver Tablas II-VI) como en el proceso de validación cruzada (ver Tabla VII), el modelo de clasificación se le dificulta diferenciar entre Nevos Común y Nevus Atípico, pero es capaz de reconocer el melanoma, en algunos casos, casi a la perfección. En el caso de los hiperparámetros óptimos del operador LBP, si bien en las diferentes iteraciones de la validación cruzada del modelo de clasificación se obtuvieron resultados perfectos de identificación del melanoma (precisión y exhaustividad del 100%), la diferenciación entre Nevus Común y Nevus Atípico necesita aún ser mejorada (precisión y exhaustividad menor al 90%). Esto es debido a que las imágenes dermatoscópicas de ambas lesiones suelen ser muy similares, y por lo tanto difíciles de reconocer, incluso por un especialista. El trabajo futuro está centrado, por lo tanto, en mejorar esta diferenciación ya sea a partir de un nuevo vector de características o utilizando otro modelo de aprendizaje automático.

Los resultados de clasificación obtenidos en este trabajo (exactitud multiclase de 90%, y precisión y exhaustividad de detección de melanoma de 100%) son comparables con otros reportados en la literatura utilizando otros enfoques.

TABLA VII
DESEMPEÑO DE CLASIFICACIÓN DEL MODELO DE CLASIFICACIÓN CON HIPERPARÁMETROS $R = 2$ Y $P = 8$ DEL OPERADOR LBP PARA CADA ITERACIÓN DE LA MCCV.

Iteración	Rec (%)			Pre (%)			F1 (%)			Acc (%)
	NeCo	NeAt	Me	NeCo	NeAt	Me	NeCo	NeAt	Me	
1	96,42	85,71	100	90	94,73	100	93,10	90	100	93,33
2	83,33	90	100	90,90	81,81	100	86,95	85,71	100	90
3	72,72	87,50	100	84,21	77,77	100	78,04	82,35	100	85
4	88,46	72,22	100	82,14	81,12	100	85,18	76,47	100	86,67
5	79,16	82,69	100	82,60	79,17	100	80,85	80,85	100	85
6	100	88,89	100	86,36	100	100	92,68	94,11	100	95
7	87,50	78,26	100	80,76	85,71	100	84	81,81	100	86,67
8	100	86,20	100	80,95	100	100	89,47	92,59	100	93,33
9	88,89	85,71	100	88,89	85,71	100	88,89	85,71	100	90
10	95,83	90,90	100	92	95,23	100	93,87	93,02	100	95
Promedio	89,23	84,75	100	85,95	88,12	100	87,30	86,26	100	90

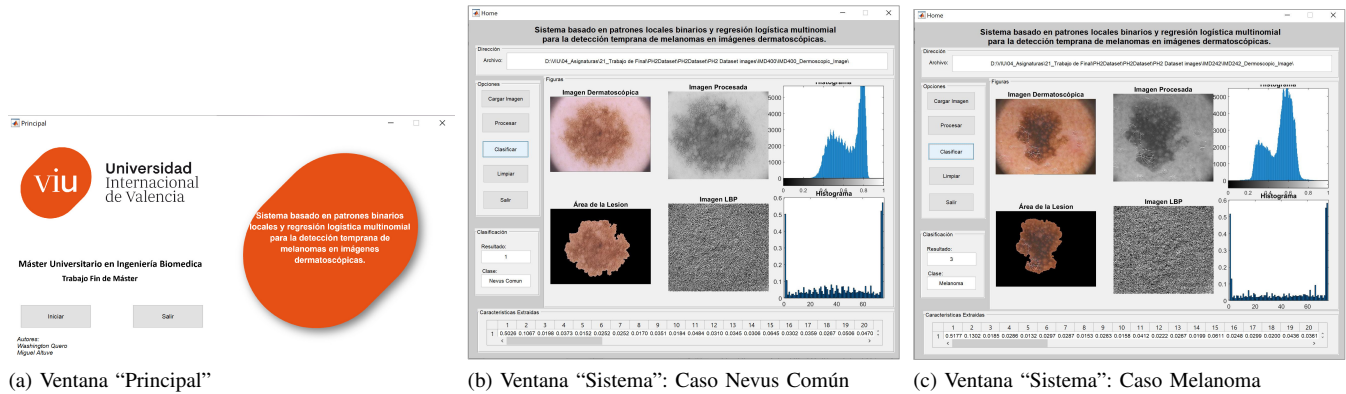


Fig. 6. Ventanas “Principal” y “Sistema” de la interfaz gráfica desarrollada. Se muestran dos ejemplos de clasificación en la ventana “Sistema” de la interfaz gráfica.

Por ejemplo, para el caso de clasificación binaria de lesión de piel (maligna o benigna), utilizando máquinas de vectores de soporte se han reportado exactitudes de 92,1% [8] y 97,5% [11], y una sensibilidad de 92,5% y una especificidad de 91,3% [9], una exactitud de 100% fue obtenida utilizando la regla ABCD [10], y una exactitud de 97,8% fue obtenida usando autómatas celulares [12]. Mientras que para el caso de clasificación multiclase, una exactitud de 90% fue obtenida utilizando la regla ABCD y técnicas de eliminación de ruido, mejoramiento del contraste, segmentación de la lesión, y extracción de características [14], una exactitud de 96% fue obtenida utilizando transformación de sombrero de copa, segmentación usando el método de Otsu, extracción de características, y combinación de clasificadores [15], y una exactitud de 90% fue obtenida utilizando transformación de características invariantes en escala y máquina de vectores de soporte [9], y una exactitud de 90% fue obtenida utilizando características basadas en la forma que fueron explotadas por diferentes clasificadores [16]. No obstante, podemos destacar que la cadena de procesamiento de nuestro trabajo solo involucra el recorte de la imagen y la extracción de características usando el descriptor visual LBP (sencillo de implementar y de bajo costo computacional), y el modelo clasificador implementado es uno de los más sencillos y

de bajo costo computacional existentes. Los enfoques de la literatura suelen incluir técnicas de preprocesamiento (filtrado, mejoramiento de contraste), extracción de una gran cantidad de descriptores estadísticos (media, varianza, asimetría, etc.) y posteriormente su reducción o mapeo (usando análisis en componentes principales, por ejemplo), y el uso de clasificadores complejos y de alto costo computacional (como las máquinas de vectores de soporte).

Finalmente, este trabajo ha sido validado en una base de datos comúnmente usada por la comunidad científica para fines académicos y de investigación. Esta base de datos cuenta con una cantidad apropiada de imágenes por clases para hacer experimentos reproducibles, no obstante, sería interesante probar el sistema propuesto en nuevas imágenes dermatoscópicas. Además, ya que en este trabajo se reconocieron tres tipos de lesiones cutáneas, en un trabajo futuro se desea expandir la capacidad de reconocimiento de otras lesiones cutáneas.

VI. CONCLUSIONES

Las diferentes combinaciones de radio y píxeles vecinos del operador de patrones locales binarios produjeron vectores de características de diferentes longitudes con información de textura útil para la caracterización de las lesiones cutáneas Nevus Común, Nevus Atípico, y Melanoma. Estos vectores

de características fueron explotados por modelos de regresión logística multinomial para el reconocimiento automático de estas lesiones cutáneas, con desempeños de clasificación comparables con la literatura. Utilizando los hiperparámetros óptimos del operador LBP, se obtuvo una exactitud promedio de 90%, exhaustividad promedio de 89,23%, 84,75%, y 100%, y precisión promedio de 85,95%, 88,12%, y 100%, para identificar Nevus Común, Nevus Atípico, y Melanoma, respectivamente, en una estrategia de validación cruzada por Monte Carlo.

La importancia de este trabajo radica en el desarrollo de un sistema de reconocimiento de lesiones cutáneas, de fácil implementación y de bajo costo computacional, en el que los casos de melanoma son detectados a la perfección, mientras que 90 de cada 100 casos de Nevus Atípico son diagnosticados correctamente (10 son diagnosticados erróneamente como Nevus Común), y 80 de cada 100 casos de Nevus Común son diagnosticados correctamente (20 son diagnosticados erróneamente como Nevus Atípico). Además, destacamos la creación de una interfaz gráfica y la disponibilidad del código en un repositorio de libre acceso para reproducir los resultados.

REFERENCES

- [1] J. Ferlay, M. Ervik, F. Lam, M. Colombet, L. Mery, M. Piñeros, A. Znaor, I. Soerjomataram, and F. Bray, "Global cancer observatory: cancer today," *Lyon, France: international agency for research on cancer*, pp. 1–6, 2018.
- [2] Instituto Nacional del Cáncer, "https://www.cancer.gov/espanol/tipos/piel," https://www.cancer.gov/espanol/tipos/piel, accessed: 20-09-2021.
- [3] El Telégrafo, "Quito, Loja y Cuenca tienen mayor número de casos de cáncer de piel," https://www.eltelegrafo.com.ec/noticias/sociedad/6/quito-loja-cuenca-casos-cancer-piel, 2019.
- [4] A. Esteva, B. Kuprel, R. A. Novoa, J. Ko, S. M. Swetter, H. M. Blau, and S. Thrun, "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, 2017.
- [5] P. C. Gamerosa and J. E. Téllez, "El cancer de piel, un problema actual," *Revista de la Facultad de Medicina UNAM*, vol. 59, no. 2, pp. 6–14, 2016.
- [6] M. Goyal, T. Knackstedt, S. Yan, and S. Hassanpour, "Artificial intelligence-based image classification for diagnosis of skin cancer: Challenges and opportunities," *Computers in Biology and Medicine*, p. 104065, 2020.
- [7] A. Adegun and S. Viriri, "Deep learning techniques for skin lesion analysis and melanoma cancer detection: a survey of state-of-the-art," *Artificial Intelligence Review*, vol. 54, no. 2, pp. 811–841, 2021.
- [8] H. Alquran, I. A. Qasmieh, A. M. Alqudah, S. Alhammouri, E. Alawneh, A. Abughazaleh, and F. Hasayen, "The melanoma skin cancer detection and classification using support vector machine," in *2017 IEEE Jordan Conference on Applied Electrical Engineering and Computing Technologies (AEECT)*. IEEE, 2017, pp. 1–5.
- [9] K. Hu, X. Niu, S. Liu, Y. Zhang, C. Cao, F. Xiao, W. Yang, and X. Gao, "Classification of melanoma based on feature similarity measurement for codebook learning in the bag-of-features model," *Biomedical Signal Processing and Control*, vol. 51, pp. 200–209, 2019.
- [10] S. Saravanan, B. Heshma, A. A. Shanofer, and R. Vanithamani, "Skin cancer detection using dermoscope images," *Materials Today: Proceedings*, vol. 33, pp. 4823–4827, 2020.
- [11] K. H. Cheong, K. J. W. Tang, X. Zhao, J. E. W. Koh, O. Faust, R. Gururajan, E. J. Ciaccio, V. Rajinikanth, and U. R. Acharya, "An automated skin melanoma detection system with melanoma-index based on entropy features," *Biocybernetics and Biomedical Engineering*, vol. 41, no. 3, pp. 997–1012, 2021.
- [12] B. Luna-Benoso, J. C. Martínez-Perales, J. Cortés-Galicia, R. Flores-Carapia, and V. M. Silva-García, "Melanoma detection in dermoscopic images using a cellular automata classifier," *Computers*, vol. 11, no. 1, p. 8, 2022.
- [13] J. A. A. Salido and C. Ruiz, "Using deep learning to detect melanoma in dermoscopy images," *International Journal of Machine Learning and Computing*, vol. 8, no. 1, pp. 61–68, 2018.

- [14] I. Zaout, "Diagnosis of skin lesions based on dermoscopic images using image processing techniques," *Pattern Recognition-Selected Methods and Applications*, 2019.
- [15] G. S. Ghalejoogh, H. M. Kordy, and F. Ebrahimi, "A hierarchical structure based on stacking approach for skin lesion classification," *Expert Systems with Applications*, vol. 145, p. 113127, 2020.
- [16] S. Paramkusham and G. S. Kumar, "Malignant melanoma and atypical nevus classification using machine learning with shape and asymmetric features," in *2021 2nd Global Conference for Advancement in Technology (GCAT)*. IEEE, 2021, pp. 1–5.
- [17] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern Recognition*, vol. 29, no. 1, pp. 51–59, 1996.
- [18] B. Zhang, Y. Gao, S. Zhao, and J. Liu, "Local derivative pattern versus local binary pattern: face recognition with high-order local pattern descriptor," *IEEE Transactions on Image Processing*, vol. 19, no. 2, pp. 533–544, 2009.
- [19] H. Yasar and M. Ceylan, "A new deep learning pipeline to detect Covid-19 on chest X-ray images using local binary pattern, dual tree complex wavelet transform and convolutional neural networks," *Applied Intelligence*, vol. 51, no. 5, pp. 2740–2763, 2021.
- [20] J. Li, J. M. Bioucas-Dias, and A. Plaza, "Semisupervised hyperspectral image classification using soft sparse multinomial logistic regression," *IEEE Geoscience and Remote Sensing Letters*, vol. 10, no. 2, pp. 318–322, 2012.
- [21] Y. J. Kim, B. Baik, and S. Cho, "Detecting financial misstatements with fraud intention using multi-class cost-sensitive learning," *Expert Systems with Applications*, vol. 62, pp. 32–43, 2016.
- [22] T. Mendonça, P. M. Ferreira, J. S. Marques, A. R. Marcal, and J. Rozeira, "PH 2-A dermoscopic image database for research and benchmarking," in *2013 35th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*. IEEE, 2013, pp. 5437–5440.
- [23] T. Ojala, M. Pietikäinen, and T. Maenpää, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971–987, 2002.
- [24] V. P. Fernández and R. S. M. Fernández, "Regresión logística multinomial," *Cuadernos de la Sociedad Española de Ciencias Forestales*, no. 18, pp. 323–327, 2004.
- [25] M. Altuve, P. Lizarazo, and J. Villamizar, "Human activity recognition using improved complete ensemble EMD with adaptive noise and long short-term memory neural networks," *Biocybernetics and Biomedical Engineering*, vol. 40, no. 3, pp. 901 – 909, 2020.
- [26] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, no. 1, pp. 62–66, 1979.
- [27] P. Pitoy and I. P. Suputra, "Dermoscopy image segmentation in melanoma skin cancer using Otsu thresholding method," *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, vol. 9, no. 3, pp. 397–404, 2021.



Washington D. Quero-Caiza MSc in Biomedical Engineering (2022), Valencian International University, Spain, B.E. in Electronics and Instrumentation Engineering (2019), The Armed Forces University - ESPE, Ecuador. His research interests include digital signal processing and augmented reality.



Miguel Altuve (IEEE S'01-M'12-SM'17) Ph.D. in Signal Processing and Telecommunications (2011), University of Rennes 1, Rennes, France, MSc in Electronic Engineering (2006), Simon Bolivar University, Caracas, Venezuela, and B.E. in Electronic Engineering (2002), National Experimental University of the Armed Forces, Maracay, Venezuela. Visiting Professor (2021-present) and Assistant Professor (2005-2014) at Simon Bolivar University, Caracas, Venezuela, Collaborating Professor (2020-present) at Valencian International University, Spain, and Associate Professor (2015-2019) at Pontifical Bolivarian University, Bucaramanga, Colombia. His research interests include digital signal processing, digital image processing, machine learning, and deep learning.