

	GESTIÓN DE SERVICIOS ACADÉMICOS Y BIBLIOTECARIOS		CÓDIGO	FO-GS-15	
			VERSIÓN	02	
	ESQUEMA HOJA DE RESUMEN			FECHA	03/04/2017
				PÁGINA	1 de 1
ELABORÓ		REVISÓ	APROBÓ		
Jefe División de Biblioteca		Equipo Operativo de Calidad	Líder de Calidad		

RESUMEN TRABAJO DE GRADO

AUTOR(ES): NOMBRES Y APELLIDOS COMPLETOS

NOMBRE(S): DIEGO ANDRES APELLIDOS: CASTELLANO CARVAJAL

FACULTAD: INGENIERÍA

PLAN DE ESTUDIOS: INGENIERÍA ELECTRÓNICA

DIRECTOR:

NOMBRE(S): BYRON APELLIDOS: MEDINA DELGADO

NOMBRE(S): SERGIO ALEXANDER APELLIDOS: CASTRO CASADIEGO

TÍTULO DEL TRABAJO (TESIS): HERRAMIENTA DE DIAGNÓSTICO ASISTIDO POR COMPUTADOR PARA IDENTIFICACIÓN Y CLASIFICACIÓN DE LESIONES CUTÁNEAS EN IMÁGENES MÉDICAS

RESUMEN: El melanoma se considera el cáncer de piel más grave en todo el mundo, categorizado como un problema de salud pública debido a su alta incidencia en poblaciones y por las grandes variaciones geográficas en los países y regiones del mundo con relación en la mortalidad desproporcional. Las herramientas asistidas por computador son reconocidas por la capacidad de identificar y clasificar la región de interés de la lesión cutánea con el fin de permitir tratamientos clínicos en función de un diagnóstico remoto y preciso. En esta investigación, se presenta una herramienta de diagnóstico asistido por computador integrada con un algoritmo híbrido denso para la identificación y clasificación de lesiones cutáneas implementada sobre el sistema embebido Raspberry Pi 4B en lenguaje de programación Python. Para entrenamiento y evaluación del algoritmo híbrido se utilizó el conjunto de datos ISIC Challenge versión 2018 y se presentó una exactitud diagnóstica de 98 % para lesiones no malignas, 93.80 % para carcinoma y 94.50 % sobre lesiones de tipo melanoma con valor medio en el uso de CPU de 4.33 %, tasa de uso de memoria temporal promedio de 12.40 % con tiempo de inferencia medio de 12.37 ms.

PALABRAS CLAVES: LESIONES CUTÁNEAS, HERRAMIENTA DE DIAGNÓSTICO ASISTIDO POR COMPUTADOR, ALGORITMO HÍBRIDO DENSO, PYTHON, RASPBERRY PI.

CARACTERÍSTICAS:

PÁGINAS: 140 PLANOS: 0 ILUSTRACIONES: 45 CD ROOM: 1

****Copia No Controlada****

HERRAMIENTA DE DIAGNÓSTICO ASISTIDO POR COMPUTADOR PARA
IDENTIFICACIÓN Y CLASIFICACIÓN DE LESIONES CUTÁNEAS EN IMÁGENES
MÉDICAS

DIEGO ANDRES CASTELLANO CARVAJAL

UNIVERSIDAD FRANCISCO DE PAULA SANTANDER
FACULTAD DE INGENIERÍA
PLAN DE ESTUDIOS DE INGENIERÍA ELECTRÓNICA
SAN JOSÉ DE CÚCUTA
2022

HERRAMIENTA DE DIAGNÓSTICO ASISTIDO POR COMPUTADOR PARA
IDENTIFICACIÓN Y CLASIFICACIÓN DE LESIONES CUTÁNEAS EN IMÁGENES
MÉDICAS

DIEGO ANDRES CASTELLANO CARVAJAL

Trabajo de grado presentado para optar por el título de:
Ingeniero Electrónico

Director
PhD. BYRON MEDINA DELGADO
Ingeniero Electrónico

Codirector
Msc. SERGIO ALEXANDER CASTRO CASADIEGO
Ingeniero Electrónico

UNIVERSIDAD FRANCISCO DE PAULA SANTANDER
FACULTAD DE INGENIERÍA
PLAN DE ESTUDIOS DE INGENIERÍA ELECTRÓNICA
SAN JOSÉ DE CÚCUTA
2022

ACTA DE SUSTENTACIÓN DE UN TRABAJO DE GRADO

Fecha: CÚCUTA, 24 DE JUNIO DE 2022

Hora: 15:00 PM

Lugar: AUDITORIO VICERECTORIA ASISTENTE DE INVESTIGACION Y EXTENSION

Plan de Estudios: INGENIERÍA ELECTRÓNICA

Título de la Tesis: "HERRAMIENTA DE DIAGNÓSTICO ASISTIDO POR COMPUTADOR PARA IDENTIFICACIÓN Y CLASIFICACIÓN DE LESIONES CUTÁNEAS EN IMÁGENES MÉDICAS"

Jurados: DARWIN ORLANDO CARDOZO SARMIENTO IE.MSc
SERGIO IVÁN QUINTERO AYALA IE.ESp

Director: BYRON MEDINA DELGADO, IE PhD

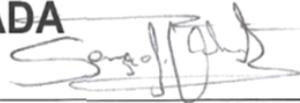
Codirector: SERGIO CASTRO CASADIEGO, IE MSc

Nombre del Estudiante:	Código:	Calificación:
DIEGO ANDRES CASTELLANO CARVAJAL	1161559	5,0 (Cinco, Cero)

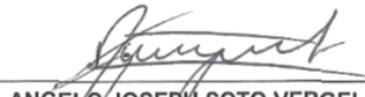
LAUREADA



DARWIN ORLANDO CARDOZO SARMIENTO



SERGIO IVÁN QUINTERO AYALA



ANGELO JOSEPH SOTO VERGEL
Coordinador Comité Curricular
Ingeniería Electrónica

Dedicatorias

Dedico este gran logro a mi madre María Zulay y a mi abuela Flor de María, quienes amo infinitamente con todo mi corazón y son mi motor de vida. A mi tía Myrian Yaneth y mi madrina Ana Milena, quienes me han tratado como a un hijo. A mis primos, Santiago, Valeria y Edwin David, a quienes considero mis hermanos.

Diego Andrés Castellano Carvajal

Agradecimientos

En primer lugar, agradezco infinitamente a Dios y al Espíritu Santo por todas las bendiciones y sabiduría recibida para lograr todos los propósitos y metas. A mi madre María Zulay y mi abuela Flor de María, quienes están en todo momento y me apoyan día a día en cada una de mis metas. A toda mi familia, quienes me han apoyado y deseado lo mejor en cada etapa de mi vida.

Al ingeniero Byron Medina Delgado, director del proyecto de grado, a quien agradezco por todos sus aportes y consejos durante el desarrollo de la propuesta investigativa y por la formación que me brindó como persona integral. Al ingeniero Sergio Alexander Castro Casadiego, codirector del proyecto, quien me orientó en el camino para la culminación del proyecto. Al ingeniero Carlos Vicente Niño Rondón, asesor del proyecto de grado, a quien agradezco infinitamente por su apoyo fundamental y disposición durante el desarrollo del mismo. Al ingeniero Dinael Guevara Ibarra, director del Grupo de Investigación y Desarrollo en Electrónica y Telecomunicaciones, por permitirme pertenecer en el grupo de investigación en donde desarrollé las etapas del proyecto. Al ingeniero Ángel Joseph Soto Vergel, por su apoyo en las etapas de codificación y presentación del proyecto de grado. A mis compañeros, gracias por todo el apoyo y los buenos momentos compartidos. Nunca los olvidaré.

Contenido

	Pág.
Introducción	18
1. Descripción del proyecto	20
1.1 Planteamiento del problema	20
1.2 Justificación del proyecto	21
1.2.1 Beneficios tecnológicos	23
1.2.2 Beneficios sociales	23
1.2.3 Beneficios institucionales	23
1.2.4 Beneficios económicos	24
1.3 Objetivos	24
1.3.1 General	24
1.3.2 Específicos	24
1.4 Limitaciones y delimitaciones	25
1.4.1 Limitaciones	25
1.4.2 Delimitaciones	25
2. Marco referencial	27
2.1 Antecedentes	27
2.2 Marco teórico	33
2.2.1 Cáncer de piel	33
2.2.2 Carcinoma	33
2.2.3 Melanoma	35
2.2.4 Lesiones no malignas	36

2.2.5	Herramienta de diagnóstico asistida por computador	37
2.2.6	Visión artificial	37
2.2.7	Procesamiento digital de imágenes	38
2.2.8	Técnicas para la extracción y reducción de características	39
2.2.9	DenseNet121	39
2.2.10	Matriz de Coocurrencia de Niveles de Gris (GLCM)	40
2.2.11	Análisis de Componentes Principales (PCA)	41
2.2.12	Modelos de aprendizaje y clasificación	41
2.2.13	Máquinas de vectores de soporte (SVM)	41
2.2.14	Redes Neuronales Convolucionales (CNN)	43
2.2.15	LightGBM	44
2.2.16	XGBoost	45
2.2.17	Python	46
2.2.18	OpenCV	46
2.2.19	TensorFlow	46
2.2.20	Sistemas embebidos	47
2.2.21	Raspberry Pi 4B	47
2.2.22	Interfaz gráfica de usuario	48
2.3	Marco legal	48
3.	Metodología	52
3.1	Documentar el estado del arte con respecto a técnicas de diagnóstico y clasificación de cáncer de piel	52
3.2	Aplicación de técnicas de procesamiento digital de imágenes y visión artificial para la extracción y mejora de características de interés de la lesión cutánea	52

3.2.1	Procesamiento digital de imágenes médicas y visión artificial	53
3.2.2	Validación del método de supresión del vello corporal y segmentación	59
3.3	Desarrollo de algoritmos de inteligencia artificial para clasificación de lesiones y evaluar el desempeño de los clasificadores mediante pruebas de funcionamiento	60
3.3.1	DenseNet121	60
3.3.2	Análisis de componentes principales (PCA)	61
3.3.3	XGBoost	63
3.3.4	Evaluación de los métodos de aprendizaje	64
3.3.5	Definición del conjunto de datos de lesiones cutáneas utilizado	66
3.4	Implementación de una interfaz gráfica de usuario como herramienta de apoyo para el diagnóstico asistido por computador	67
4.	Resultados	70
4.1	Documentación de literatura y selección de herramientas	70
4.2	Técnicas de tratamiento digital de imágenes y validación	77
4.2.1	Algoritmo para supresión de vello corporal y segmentación	77
4.2.2	Conversión a escala de grises	78
4.2.3	Detección de vello corporal mediante el algoritmo Canny	79
4.2.4	Aplicación de dilatación morfológica y binarización del vello corporal	79
4.2.5	Trazado para atenuación del vello corporal en las imágenes para diagnóstico	79
4.2.6	Filtro de suavizado medio	80
4.2.7	Segmentación de la lesión	80
4.2.8	Validación de la eliminación del vello corporal y segmentación de la lesión	81
4.3	Diseño del algoritmo híbrido propuesto y pruebas de rendimiento	82
4.3.1	Metodología del algoritmo híbrido denso	83

4.3.2	Algoritmo híbrido propuesto para extracción de características, reducción de componentes y clasificación de la lesión	84
4.3.3	Extracción de características	84
4.3.4	Reducción de componentes	85
4.3.5	Clasificación de las imágenes	86
4.3.6	Validación de los modelos mediante parámetros de software y hardware	87
4.4	Implementación de la herramienta de diagnóstico asistido por computador	94
4.4.1	Diseño e implementación de la herramienta de diagnóstico asistido por computador	94
4.4.2	Diagrama de casos de uso de la herramienta de diagnóstico asistido por computador	95
4.4.3	Arquitectura del sistema	97
4.4.4	Algoritmo propuesto para el diagnóstico de lesiones cutáneas	98
4.4.5	Validación del algoritmo híbrido denso y la herramienta de diagnóstico bajo criterios de usabilidad	99
4.4.6	Divulgación de resultados a la comunidad académica y científica	100
5.	Conclusiones	103
6.	Recomendaciones	105
7.	Trabajos futuros	106
8.	Bibliografía	107
9.	Anexos	118

Lista de figuras

	Pág.
Figura 1. Tasa de mortalidad estandarizada de cáncer de piel melanoma por regiones	22
Figura 2. Imágenes de lesiones cutáneas producidas por BCC	34
Figura 3. Imágenes de lesiones cutáneas producidas por CCE	35
Figura 4. Imágenes biomédicas representativas de lesiones cutáneas	36
Figura 5. Lesiones cutáneas no malignas	36
Figura 6. Diagrama de bloques de una CAD	37
Figura 7. Diagrama de un sistema de visión artificial	38
Figura 8. Diagrama de un sistema de procesamiento digital de imágenes	39
Figura 9. Ilustraciones relacionadas con la matriz de coocurrencia de niveles de gris	40
Figura 10. División de los datos por los hiperplanos	42
Figura 11. Arquitectura de una red neuronal convolucional	44
Figura 12. Algoritmo del clasificador LightGBM	45
Figura 13. Descripción gráfica del sistema embebido Raspberry Pi 4B	48
Figura 14. Componentes de una interfaz gráfica de usuario	48
Figura 15. Ilustración de la técnica de supresión no máxima	56
Figura 16. Arquitectura de la red convolucional profunda DenseNet121	61
Figura 17. Ilustración de la extracción de los pares de componentes principales	62
Figura 18. Representación gráfica del algoritmo de aprendizaje y clasificación XGBoost	64
Figura 19. Elementos que integran la estructura de la herramienta de diagnóstico asistido por computador	69
Figura 20. Transformación a escala de grises a las imágenes de muestra	78
Figura 21. Detección de ruido producido por vello corporal mediante el algoritmo Canny	79
Figura 22. Dilatación morfológica y binarización del vello corporal detectado	79

Figura 23. Imágenes de lesiones cutáneas reconstruidas por FMM para supresión del vello corporal	80
Figura 24. Filtrado de suavizado medio sobre las imágenes reconstruidas	80
Figura 25. Segmentación de la región de interés de la imagen cutánea	81
Figura 26. Superposición entre las imágenes mejoradas y las máscaras de la región de interés	81
Figura 27. Relación de eliminación de vello corporal en imágenes de lesiones cutáneas	82
Figura 28. Metodología del algoritmo híbrido denso	83
Figura 29. Mapas de características extraídos por DenseNet121	85
Figura 30. Relación entre la proporción de varianza explicada y el número de componentes	85
Figura 31. Ilustración de las componentes por cada clase de lesión cutánea	86
Figura 32. Matriz de confusión obtenidas para el modelo híbrido denso propuesto y las técnicas de comparación	87
Figura 33. Curva ROC con valor AUC para el algoritmo híbrido denso propuesto y las técnicas de comparación	88
Figura 34. Requerimientos en la Unidad Central de Procesos para aprendizaje y entrenamiento	91
Figura 35. Requerimientos de memoria RAM para aprendizaje y entrenamiento	92
Figura 36. Requerimiento en la Unidad Central de Procesos en la clasificación	93
Figura 37. Requerimiento de memoria RAM en la clasificación	93
Figura 38. Tiempo de respuesta en la clasificación.	94
Figura 39. Etapas de la herramienta de diagnóstico asistido por computador	95
Figura 40. Ilustración de la herramienta de dibujo de la región de interés	95
Figura 41. Diagrama de casos de uso para la validación de credenciales	96
Figura 42. Diagrama de casos de uso para caracterización del paciente	96

Figura 43. Diagrama de casos de uso para diagnóstico asistido	97
Figura 44. Arquitectura de algoritmo híbrido propuesto	98
Figura 45. Algoritmo híbrido denso propuesto para el diagnóstico asistido por computador	99

Lista de tablas

	Pág.
Tabla 1. Variables relacionadas con la Matriz de Coocurrencia de Niveles de Gris	40
Tabla 2. Parámetros de comparación para herramientas de hardware	53
Tabla 3. Parámetros de comparación para herramientas de software	53
Tabla 4. Documentación del estado del arte relacionado al tema de investigación	71
Tabla 5. Peso de los parámetros a comparar para la selección de software	72
Tabla 6. Comparación de herramientas de software respecto al tipo de licencia	72
Tabla 7. Comparación de herramientas de software respecto a la capacidad de integración con entornos de desarrollo	73
Tabla 8. Comparación de herramientas de software respecto a la disponibilidad de paquetes y librerías	73
Tabla 9. Comparación de herramientas de software respecto a la conectividad con ofimática	73
Tabla 10. Comparación de herramientas de software respecto a la especialidad para inteligencia artificial	73
Tabla 11. Matriz de decisión para la elección de la herramienta de software	74
Tabla 12. Peso de los parámetros a comparar para la selección de hardware	74
Tabla 13. Comparación de herramientas de hardware respecto a la velocidad de procesamiento	75
Tabla 14. Comparación de herramientas de hardware respecto a la cantidad de memoria RAM	75
Tabla 15. Comparación de herramientas de hardware según los lenguajes de programación soportados	75

Tabla 16. Comparación de herramientas de hardware respecto a la velocidad de procesamiento gráfico	76
Tabla 17. Comparación de herramientas de hardware respecto el precio y la disponibilidad del mercado	76
Tabla 18. Peso de los parámetros a comparar para la selección de hardware	77
Tabla 19. Algoritmo propuesto para supresión de vello corporal y segmentación de la lesión	77
Tabla 20. Validación de los métodos de segmentación de la región de interés	82
Tabla 21. Pasos secuenciales del algoritmo híbrido propuesto para extracción de características, reducción de componentes y clasificación de la lesión cutánea	84
Tabla 22. Rendimiento del método propuesto en términos de parámetros de software	88
Tabla 23. Tasas de verdaderos positivos y falsos positivos para el algoritmo híbrido propuesto y las técnicas de comparación	89
Tabla 24. Comparación del algoritmo híbrido denso propuesto con la literatura científica	90

Lista de anexos

	Pág.
Anexo 1. Instrumento de evaluación del algoritmo híbrido denso y la herramienta de diagnóstico asistido por computador	118
Anexo 2. Acuerdo de cooperación investigación entre la Universidad Francisco de Paula Santander y la empresa VHM INGENIERÍA SAS	120
Anexo 3. Evidencia de la sustentación preparatoria del proyecto en las asignaturas “Fibra Óptica”, “Medios de Transmisión” y “Procesamiento Digital de Señales” a la comunidad académica	124
Anexo 4. Certificación de ponencia en el 2° Congreso Internacional de Ingeniería Biomédica y Bioingeniería (CI-IB&BI)	125
Anexo 5. Certificación de ponencia en el Congreso Anual de Ingeniería Biomédica (CAIB 2021)	126
Anexo 6. Participación en el 8° Congreso Internacional de Innovación y Apropiación de las Tecnologías de la Información y las Comunicaciones	127
Anexo 7. Certificado de ponencia en la 7° Conferencia Internacional para la Convergencia en Tecnología IEEE	128
Anexo 8. Publicación del artículo científico por parte de la revista Ingeniería y Competitividad de la Universidad del Valle	129
Anexo 9. Publicación del artículo científico por parte de la revista Eco matemático relacionado con el área de aplicación del proyecto	130
Anexo 10. Notificación de aceptación para la publicación del artículo científico por parte de la Revista Científica Ingeniería y Desarrollo de la Fundación Universidad del Norte	131
Anexo 11. Notificación en plataforma de evaluación del artículo científico enviado a la revista especializada IEEE Embedded System Letters publicada por IEEE CEDA	132

Anexo 12. Notificación de aceptación para publicación del artículo científico enviado a la revista científica Eco matemático de la Universidad Francisco de Paula Santander	133
Anexo 13. Publicación en IEEE Xplore del artículo presentado en el 2° Congreso Internacional de Ingeniería Biomédica y Bioingeniería (CI-IB&BI)	134
Anexo 14. Resumen de la ponencia con publicación en IEEE Xplore del artículo presentado en la 7° Conferencia Internacional para la Convergencia en Tecnología	135
Anexo 15. Solicitud de registro del software ROI SkinLesionEnhancement (software para el realce de características de regiones de interés de lesiones cutáneas en imágenes dermatoscópicas) ante la Dirección Nacional de Derechos de Autor	136
Anexo 16. Solicitud de registro del software BHNS SkinLesion (software para la eliminación del ruido por vello corporal en lesiones cutáneas de imágenes dermoscópicas) ante la Dirección Nacional de Derechos de Autor	137
Anexo 17. Solicitud de registro del software PatientCPy (software con interfaz gráfica de usuario para la caracterización de pacientes con uso potencial en herramienta de diagnóstico asistido por computador) ante la Dirección Nacional de Derechos de Autor	138
Anexo 18. Manual de usuario del Software SCCHA	139
Anexo 19. Manual técnico del Software SCCHA	140

Introducción

La visión artificial hace referencia a las fases orientadas en el tratamiento de la imagen mediante procesos de reconocimiento, descripción, interpretación y compresión de imágenes que se combinan con la inteligencia artificial involucrando el uso de algoritmos que facilitan la detección y el registro de regiones con posibles irregularidades dentro o fuera de la frontera de la lesión cutánea, siendo una etapa clave para determinar si la lesión es cancerosa [1].

Las tecnologías asistenciales médicas integradas que utilizan imágenes biomédicas han dado inicio a la integración de métodos basados en el procesamiento digital de imágenes con fines de investigación y diagnóstico como apoyo en el sector salud, con el objetivo de extraer información de características resultado de la enfermedad en las imágenes por medio de la segmentación automática [2].

La inteligencia artificial ha presentado resultados prometedores en el diagnóstico de cáncer de piel en numerosos estudios experimentales y están ingresando al campo de la medicina a ritmos con gran escalabilidad, en donde los modelos matemáticos orientados en capas tienen la capacidad de procesar grandes conjuntos de datos para realizar tareas específicas, como son el reconocimiento de patrones, el análisis de imágenes, y en entornos experimentales para discriminar los melanomas en etapas oportunas, con referencia a mejorar en gran medida el pronóstico la distinción entre cáncer de piel y lesiones benignas [3].

El diagnóstico de lesiones cutáneas en imágenes biomédicas a través de herramientas asistidas por computador ha recibido interés por parte de la comunidad investigativa, siendo reconocidas por la capacidad de identificar y clasificar la región de interés que induce a la zona probablemente cancerosa, permitiendo así tratamientos clínicos oportunos en fases iniciales [4]. Además, proporcionan diagnóstico eficiente, remoto, estándar y preciso en diversas enfermedades cutáneas con estado avanzado, ofreciendo la posibilidad de realizar seguimientos efectivos y a bajo costo [5].

En el presente libro se detalla una herramienta de diagnóstico asistido por computador integrada bajo un algoritmo híbrido para la identificación y clasificación de lesiones cutáneas en imágenes médicas mediante técnicas en procesamiento digital de imágenes e inteligencia artificial que integra interfaces gráficas enfocadas en etapas de validación de credenciales, caracterización del paciente, visualización y diagnóstico de la lesión. La herramienta de apoyo fue implementada sobre el sistema de desarrollo embebido Raspberry Pi 4B en lenguaje de programación Python mediante las librerías OpenCV de visión por computador, TensorFlow para modelos de aprendizaje profundo, Pandas para marco de datos, NumPy para operador de matrices y Sklearn para métricas de evaluación, en conjunto con el software para la elaboración de interfaces gráficas para Python QT Designer integrada con la librería gráfica PyQt5. El modelo de clasificación fue entrenado y evaluado por el conjunto de datos de lesiones cutáneas de libre acceso de cáncer de piel ISIC Challenge versión 2018. La herramienta propuesta presenta una exactitud de diagnóstico de 98 % para lesiones no malignas, 93.8 % para carcinoma y 94.5 % sobre lesiones de tipo melanoma.

1. Descripción del proyecto

1.1 Planteamiento del problema

El cáncer de piel se considera una de las enfermedades que predominan en el mundo asociado con el 10 % de los reportes de cáncer aproximadamente. Según estadísticas de la Organización Mundial de la Salud, se registran en el mundo cada año de dos a tres millones de casos de cáncer de piel no melanoma y 132.000 casos de melanoma, en donde este último representa el 4 % de las formaciones anormales de tejidos en la piel y es asociado con el 80 % de las muertes por cáncer de piel. En consecuencia, es el más maligno, frecuente y agresivo [6].

Las lesiones cutáneas, por lo general, presentan variación en cuanto a forma, tamaño y color a causa de la apariencia de los tipos de cáncer de piel. Algunas presentan límites borrosos, bordes irregulares y reducido constante. Asimismo, suelen contener rasgos intrínsecos de la piel como vello corporal hasta elementos externos como marcadores de aire, regla y variantes de color, lo cual dificulta el diagnóstico y no permite segmentar de forma adecuada las regiones de baja dimensión, lo cual influye que la precisión de la segmentación con base en la optimización de canales de color y métodos de niveles de conjuntos sean totalmente reducidas [7]. Por otro lado, los modelos recientes basados en aprendizaje profundo requieren alto volumen de datos multimedia para entrenamiento a gran escala, tiempo y recursos computacionales elevados para obtener una buena precisión en los modelos de aprendizaje supervisado [8].

Los avances tecnológicos han dado lugar al desarrollo de aplicaciones para teléfonos inteligentes con novedades de brindar accesibilidad generalizada, rentabilidad y mayor detección temprana en pacientes. Sin embargo, varios estudios demuestran que las aplicaciones a menudo no son precisas, ya que 3 de cada 4 aplicaciones clasificaron erróneamente más del 30 % de los melanomas como lesiones de no consideración médica [9]. Los expertos en el área

advierten que depender de estas aplicaciones móviles sin supervisión normativa producen falsa sensación de seguridad, cuyo resultado será el diagnóstico equívoco y tardío [10].

En consecuencia, se plantea una alternativa que consiste en el desarrollo de una herramienta de diagnóstico asistida por computador en código abierto que integre un algoritmo híbrido basado en técnicas en procesamiento digital de imágenes médicas e inteligencia artificial para eliminación de rasgos irrelevantes, extracción, mejora de características y diagnóstico de cáncer de piel, dedicada para dar la autonomía al especialista en adaptar, segmentar y dibujar la región de interés de la imagen dermatoscópica. Por lo anterior, es válido plantear el siguiente interrogante:

¿Cómo implementar una herramienta de diagnóstico asistido por computador que elimine rangos extrínsecos, mejore la imagen biomédica para extracción de características y apoye en el diagnóstico de la lesión cutánea?

1.2 Justificación del proyecto

En Colombia, la tasa de cáncer de piel estimada para 2003 fue 23 casos por cada 100.000 habitantes. Para 2007 pasó de 41 casos por cada 100.000 habitantes y en 2020 se estimaron 102 casos por cada 100.000 habitantes aproximadamente. El distrito capital Bogotá y los departamentos de Antioquia, Cundinamarca y Boyacá fueron las zonas con mayor incidencia [11].

En la figura 1, se presenta la tasa de mortalidad por cáncer de piel melanoma y anual estandarizada por 100.000 habitantes hombres y mujeres comprendida entre los años 1997 y 2019 para las regiones de Colombia según las estadísticas del Instituto Nacional de Cancerología (INS) y el Departamento Administrativo Nacional de Estadística (DANE).

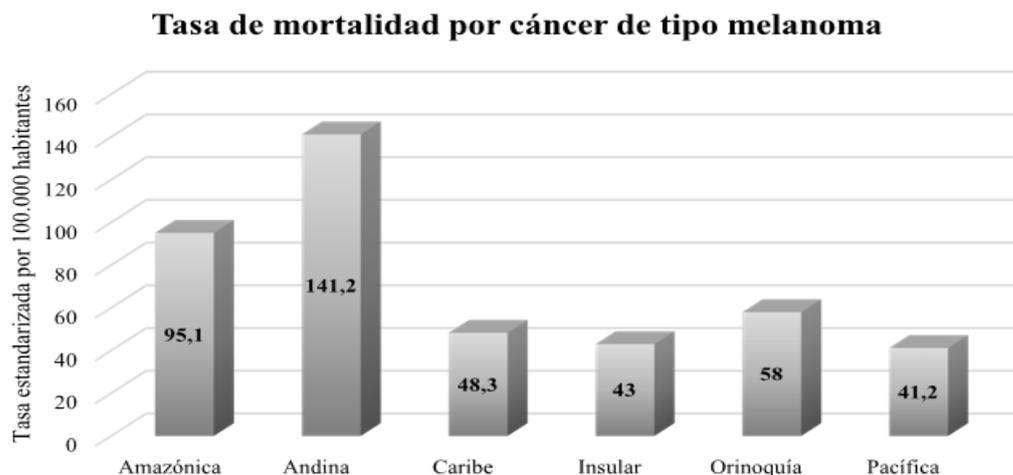


Figura 1. Tasa de mortalidad estandarizada de cáncer de piel melanoma por regiones

Esteva et al., introducen un algoritmo basado en inteligencia artificial sobre un conjunto de datos que contiene 129450 imágenes clínicas y dermatoscópicas que representan 2032 enfermedades de lesiones cutáneas. El rendimiento de algoritmo fue comparado con 21 dermatólogos certificados en la clasificación y diferenciación de enfermedades y demostraron que la inteligencia artificial tiene potencial y está a la par con la evaluación de los dermatólogos [12].

Así mismo, Tschandl, et al., exponen una comparativa de la precisión diagnóstica y reconocimiento de cáncer de piel entre representaciones de inteligencia artificial y médicos especialistas evaluadores sobre un conjunto de datos de lesiones pigmentadas que incluyen siete categorías de diagnóstico. En el estudio, participaron un total de 302 evaluadores de 41 países: 169 dermatólogos certificados por el Consejo Americano de Dermatología, 77 especialistas en dermatología y 38 médicos generales. El objetivo fue diagnosticar las imágenes primero sin y luego con la herramienta de apoyo recolectando 512 pruebas y 13.428 calificaciones, cuyos resultados reflejan que el apoyo a la decisión con probabilidades basadas en inteligencia artificial mejora la precisión de los calificadores médicos del 63.6 % a 77 %, con factor de confianza del 95 % [13].

Dicho esto, surge la necesidad de desarrollar una herramienta computacional asistida que se muestre como apoyo para el especialista en el diagnóstico supervisado y dermatoscópico de cáncer de piel sobre lesiones cutáneas, que eleve las tasas efectivas en precisión diagnóstica con la posibilidad de reducir los procedimientos clínicos invasivos garantizando la reproducibilidad, lo que traerá consigo beneficios tecnológicos, sociales, institucionales y económicos, que serán descritos a continuación.

1.2.1 Beneficios tecnológicos

La aplicación de técnicas en procesamiento digital de imágenes e inteligencia computacional bajo librerías de libre acceso y código abierto permiten la mejora y eliminación de ruido de las imágenes dermatoscópicas [14]. En adición, el desarrollo de una herramienta computacional de apoyo para el diagnóstico y la evaluación en imágenes médicas de lesiones cutáneas mediante un algoritmo híbrido que apoye los procesos de diagnóstico asistido.

1.2.2 Beneficios sociales

El desarrollo de investigaciones enfocadas al apoyo biomédico ofrecerá beneficios en la sociedad mediante el tratamiento a aquellos grupos de personas potenciales pacientes diagnosticados con cáncer de piel, con miras a mejorar la calidad de vida ofreciéndoles herramientas eficaces a bajo costo. Del mismo modo, se pretende exponer el impacto y los beneficios que ofrece la inteligencia artificial en las aplicaciones médicas y dermatológicas, con el objetivo de reducir las pérdidas humanas por enfermedades cutáneas y aumentar la supervivencia por medio de diagnósticos certeros, incidiendo directamente en los tratamientos oportunos por parte del especialista.

1.2.3 Beneficios institucionales

Con la implementación de una herramienta de diagnóstico asistido por computador para la identificación y clasificación de cáncer de piel se pretende impulsar proyectos de índole tecnológica en las instituciones educativas de la región mediante la sistematización de

conocimientos para dar solución a los problemas actuales. En adición, el desarrollo e implementación del sistema de diagnóstico propuesto permitirá obtener la tasa en eficiencia, lo cual centra un punto de partida para la elaboración de futuros proyectos orientados en la aplicación del procesamiento digital de señales que integren diversas áreas del conocimiento y que apoye los procesos de diagnóstico de cáncer, con el fin de brindar los servicios adecuados bajo desarrollo en sistemas de inteligencia artificial que brinden seguridad al paciente mediante diagnósticos certeros de cáncer.

1.2.4 Beneficios económicos

La codificación bajo herramientas de software libre involucra la reducción de costos de implementación, debido a que es el valor de las licencias donde se invierte gran parte del presupuesto de los proyectos de investigación y desarrollo. Además, la ejecución e implementación de herramientas a bajo costo a gran escala disminuirá los costos en los tratamientos en el que incurren los pacientes potenciales de cáncer.

1.3 Objetivos

1.3.1 General

Diseñar e implementar una herramienta de diagnóstico asistido por computador para identificación y clasificación de lesiones cutáneas en imágenes médicas.

1.3.2 Específicos

- Documentar el estado del arte con respecto a técnicas de diagnóstico y clasificación de cáncer de piel.
- Aplicar técnicas de procesamiento digital de imágenes y visión computacional para la extracción y mejora de características de interés de la lesión cutánea.
- Desarrollar algoritmos de inteligencia artificial para clasificación de lesiones y evaluar el desempeño de los clasificadores mediante pruebas de funcionamiento.

- Implementar una interfaz gráfica de usuario como herramienta de apoyo para el diagnóstico asistido por computador.

1.4 Limitaciones y delimitaciones

A continuación, se muestran las limitaciones y delimitaciones a las que se rigió la implementación de la propuesta investigativa.

1.4.1 Limitaciones

Las técnicas de procesamiento digital de imágenes biomédicas, extracción de información, el modelado, entrenamiento y evaluación de los algoritmos de inteligencia artificial para identificación de la región de interés y diagnóstico de lesiones en la piel cáncer de piel se aplicaron sobre el conjunto de imágenes de libre acceso International Skin Imaging Collaboration (ISIC) versión 2018, tomadas por dispositivos especializados en dermatología con anotaciones de especialistas en cáncer de piel, el cual se incluye un archivo metadatos clínico asociado al tipo de la lesión.

La implementación de la herramienta asistida por ordenador no pretende sustituir las actividades y la atención prestada por un dermatólogo en el diagnóstico de enfermedades. Por el contrario, se presenta como un medio de apoyo bajo código abierto y a bajo costo para que los especialistas perfeccionen sus dictámenes en la detección de cánceres de piel.

1.4.2 Delimitaciones

El proyecto se desarrolló bajo los lineamientos académicos establecidos y la implementación de cada una de las etapas de la herramienta asistida por computador para el diagnóstico de cáncer de piel involucró la evaluación y comparación de algoritmos y técnicas utilizadas ampliamente para la clasificar lesiones cutáneas, segmentar la lesión, extraer y seleccionar características de las componentes de la imagen. El análisis comparativo tanto de los resultados obtenidos de los clasificadores como de la eficiencia en diagnósticos de cáncer

se realizó respecto a los antecedentes de las investigaciones que hacen parte del marco referencial del presente proyecto.

2. Marco referencial

2.1 Antecedentes

En esta sección, se muestran los trabajos que evidencian enfoques similares a la propuesta investigativa, así como los aportes de cada uno de las investigaciones.

Detección precoz de cáncer de piel en imágenes basado en redes convolucionales [15]

El trabajo investigativo aporta una visión amplia comparativa y experimental de la implementación de un sistema basado en el uso de redes neuronales convolucionales en el diagnóstico prematuro de diferentes tipos de cáncer de piel representados por un conjunto de datos que consta de 10.000 imágenes dermatoscópicas, aplicando la metodología de transferencia de aprendizaje para el entrenamiento de las redes AlexNet, VGG16 y ResNet. Para el entrenamiento y validación de los modelos se utilizó el conjunto de datos ISIC 2018 (HAM10000) distribuido entre los siete tipos de lesiones cutáneas tanto benignas como malignas aplicado con la técnica de aumentado de datos y corrimientos verticales y horizontales entre las imágenes. Los resultados reflejan la efectividad de los modelos profundos. La red AlexNet presentó una exactitud de 74 % con una proporción de los datos entre 55 % para entrenamiento y 45 % para validación. Para la red VGG16 presentó una precisión media de 69.36 % con la misma proporción de imágenes, y la red convolucional ResNet demostró una precisión de 72 % con proporción de imágenes 55 % para entrenamiento y 45 % para validación.

En adición, resaltan el uso de la plataforma Pytorch de código abierto en aprendizaje profundo que proporciona una interfaz en donde las operaciones computacionales son realizadas conforme el programa es ejecutado, utilizado para la creación de redes neuronales y diseñado para integración con Python.

Reconocimiento de Patrones en imágenes no dermatoscopias para la Detección de Enfermedades Malignas en la Piel, utilizando Redes Neuronales Convolutivas y Autocodificadores [16]

El autor presenta un método orientado al reconocimiento de lesiones cutáneas para identificación de tumores malignos en imágenes biomédicas utilizando redes neuronales convolucionales con adición de autocodificadores como técnica de clasificación. Se recolectaron imágenes con anomalías de la piel con la correspondiente etiqueta y desarrollaron un conjunto de datos para evaluar el método propuesto utilizando las bases de datos DermNet, Dermis, DermatoWeb y el ISBI 2016, conformado por 2360 imágenes divididas en clases benigna, premaligna y maligna. Para la evaluación del modelo realizaron una selección aleatoria de 1554 imágenes divididas en 75 % para entrenamiento y 25 % para validación, cuyas imágenes fueron aumentadas mediante rotaciones y reflejos. La clasificación se realizó con la arquitectura de red VGG19 con autocodificadores definidos mediante una adaptación de 5 capas con 4096, 2048, 1024, 2048 y 4096 neuronas con una distribución nominal nula y desviación estándar 0.001. Los resultados experimentales indican que con el modelo de red neuronal convolucional con 11 autocodificadores se obtiene una exactitud del 85.71 % y precisión de 91.41 % en detectar tumores malignos, benignos y pre-malignos.

Feature extraction from dermoscopy images for melanoma diagnosis [17]

Los autores proponen la extracción de características relacionadas con la forma, las propiedades de color y el tamaño de las lesiones mediante la regla ABCD en imágenes dermatoscópicas del conjunto de datos PH2, en donde incluyeron 160 imágenes de lesiones benignas y 40 lesiones tipo melanoma para el aprendizaje del clasificador implementado con la herramienta computacional MATLAB. La segmentación se realizó por medio de los algoritmos Otsu y Chan-Vese, y el vello corporal se eliminó con el algoritmo Dull-Razor que consiste en operación de cierre morfológico, interpolación bilineal y filtrado medio. Para la

clasificación utilizaron el modelo basado en red neuronal para identificar lesiones benignas y malignas con base a las características extraídas. Los resultados de clasificación con 12 imágenes benignas y 10 lesiones malignas de fuentes de internet indican que el método alcanza una precisión de 98.2 %, sensibilidad de 98 % y especificidad de 98.2 %.

Computer-Aided Diagnosis of Micro-Malignant Melanoma Lesions applying Support Vector Machines [18]

En la investigación, se presentan un algoritmo basado en máquinas de vectores de soporte SVM para clasificación de cáncer de piel tipo melanoma en fases tempranas sobre lesiones con diámetro inferior a 5 mm. La metodología consiste en la mejora de imagen mediante operaciones morfológicas y componentes de color HSL, segmentación de la lesión mediante el algoritmo de fusión de regiones, extracción de características por valores geométricos y variables GLCM, y finalmente la clasificación por SVM.

El algoritmo SVM fue evaluado con 200 imágenes, incluidas 70 melanomas y 130 lesiones benignas del atlas interactivo de dermatoscopia con acceso restringido, el cual arrojó una sensibilidad del 90 % con especificidad del 96 %, detectó la mayoría de los casos malignos y podrá proporcionar información fiable para un examen eficaz de lunares en la piel.

Artificial Intelligence-Based Image Classification Methods for Diagnosis of Skin Cancer: Challenges and Opportunities [19]

El artículo expone una revisión de los últimos avances en soluciones aplicativas de inteligencia artificial para el diagnóstico del cáncer de piel representado por imágenes digitales, exponiendo algunos desafíos y oportunidades que proponen mejorar estos sistemas aliados a las actividades de los dermatólogos.

La revisión expone el rendimiento de los algoritmos de inteligencia artificial InceptionV4 y ResNet50 utilizados para el diagnóstico en distintos conjuntos de datos de fotografías clínicas, imágenes de dermatoscopia y escáneres en patologías representativas de lesiones cutáneas,

obteniendo sensibilidades del 95 % y 84.2 %, permitiendo considerar las soluciones en inteligencia artificial como una herramienta mejorada en eficiencia para apoyo médico en el diagnóstico. Codella et al. desarrollaron un conjunto de modelos basados en aprendizaje automático que combina redes profundas residuales, redes neuronales convolucionales y la red convolucional U-Net para segmentación y clasificación, entrenados con 900 imágenes y evaluados con 379 imágenes del conjunto de datos ISIC versión 2016. El rendimiento de los modelos se comparó con los diagnósticos de 8 dermatólogos en la clasificación de 100 lesiones cutáneas determinando entre benignas o malignas. El rendimiento promedio de los dermatólogos en términos de precisión fue de 70,5 % con una especificidad de 59 %, mientras que para el modelo la precisión obtenida fue de 76 % y una especificidad de 62 %, evaluados con una sensibilidad de 82 % del modelo [20].

Expert-Level Diagnosis of Nonpigmented Skin Cancer by Combined Convolutional Neural Networks [21]

La investigación abordó una comparativa entre la precisión de un clasificador basado en Redes Neuronales Convolucionales con médicos expertos con diferentes niveles de experticia. El entrenamiento del modelo de clasificación mediante redes convolucionales se realizó mediante 7895 muestras de imágenes dermatoscópicas y con 5829 imágenes de lesiones extirpadas en una clínica especializada en cáncer de piel en Queensland, Australia entre el 2008 y 2017, combinando ambos métodos de obtención de imágenes. La CNN fue evaluada con 2072 casos de imágenes desconocidas y sus resultados fueron comparados con 95 evaluadores médicos, incluidos 62 dermatólogos con diferente experiencia en dermatoscopia.

En la detección del cáncer de piel, el valor medio del análisis estadístico mediante el área bajo la curva para los evaluadores médicos fue de 0.695, menor que la media del área bajo la curva para las CNN de 0.742. Sin embargo, la CNN presentó una tasa de área bajo la curva inferior frente a los evaluadores expertos, siendo de 0,733 frente a 0,741. Por otro lado, la

sensibilidad de la evaluación de los dermatólogos en la detección de cáncer fue de 77.6 % con especificidad de 51.3 %, mientras que, para las CNN se obtuvo 80.5 % en sensibilidad y 53.5 % en especificidad sobre evaluaciones de cáncer de piel.

Diseño de una aplicación para el tratamiento de imágenes dermatoscópicas [22]

El autor presenta el diseño de una aplicación computacional realizada en MATLAB utilizando la librería OpenCV para la clasificación de imágenes dermatoscópicas para la detección del nevus benignos y melanomas. En primer lugar, realizaron una revisión previa conceptual de la enfermedad con enfoques hacia el análisis de técnicas de detección y diagnóstico mediante sistemas asistidos por computador. Posteriormente, se implementó un algoritmo de preprocesamiento y segmentación que obtiene las representaciones de la lesión y parametriza para dar origen a un clasificador binario de imagen para detectar malignidad por medio del método demoscópico de puntuación ABCD. La evaluación de la aplicación se realizó mediante la aplicación de los conjuntos de datos PH2 con 200 imágenes, 40 correspondientes a lesiones de melanoma y 160 lesiones de nevus con una sensibilidad del 97.5 % y una especificidad del 62.5 %.

Dermatologist-level classification of skin cancer with deep neural networks [12]

La investigación presenta la clasificación de anomalías de la piel utilizando una técnica convolucional profunda entrenada con un conjunto de datos con 129.450 imágenes clínicas que contienen 2.032 muestras diversas de lesiones benignas, malignas (melanoma y carcinomas) y lesiones no neoplásicas contenidas por el repositorio demoscópico ISIC y datos del hospital de Stanford. El rendimiento del modelo fue comparado con 21 dermatólogos certificados para evaluación de imágenes de biopsia para clasificar las lesiones benignas e identificar cáncer de piel tipo melanoma. Se utilizó la arquitectura convolucional InceptionV3 entrenada con retro propagación utilizando la novena parte de conjunto de datos para validación y el resto para el entrenamiento. En términos de precisión de la clasificación, los dermatólogos examinaron 180

imágenes aleatorias de la validación (60 por clase) y se evaluó la CNN, lo cual se refleja que la precisión para los dermatólogos es de 66 % y para la CNN se presentó un valor de 72.1 ± 0.9 % en términos de media y de desviación estándar. Además, el modelo alcanzó un valor de área bajo la curva superior al 91 % para cada uno de los casos.

Uso de algoritmos de machine learning para el diagnóstico de melanomas [23]

La investigación abordó el desarrollo de una herramienta para diagnosticar mediante la identificación de lunares piel la presencia de un posible melanoma a través de la comparación de algoritmos para clasificación random forest probados con la técnica de análisis de componentes principales con transformaciones L y P, y redes convolucionales con arquitecturas DenseNet121 y 161, y ResNet 34 y 50, orientados para crear herramientas en la detección de melanoma con fines de diagnósticos y tratamientos oportunos.

La evaluación de los clasificadores se realizó con imágenes propuestas por la Society for Imaging in Medicine y la International Skin Imaging Collaboration con 1087 imágenes de melanoma y 1029 de lunares benignos aumentadas mediante la técnica de Data Augmentation, en donde se utilizó el 80 % para el entrenamiento y 20 % para validación. En adición, se utilizó el método de morfología *blackhat* combinado con reconstrucción de color y umbralización para eliminar el vello corporal. Las métricas de eficiencia obtenidas indican que el modelo ResNet34 presentó mejores resultados en términos de exactitud de 92.1 %, precisión de 92.3 %, sensibilidad de 92 % y especificidad de 92.3 %. Para el modelo basado en árboles de decisión se presentó una exactitud de 85.6 %, precisión de 83.2 %, sensibilidad de 88.5 % y especificidad de 83.2 %.

Diseño de una herramienta para la clasificación de imágenes de cáncer de piel utilizando Redes Neuronales Profundas (DNN) [24]

El trabajo presentó la utilidad de las redes neuronales convolucionales profundas implementadas en lenguaje de codificación Python y entrenadas con 2.200 muestras para cada

clase (benignas y malignas), validadas con 264 imágenes de lesiones benignas y 263 imágenes características de tumores malignos de los conjuntos de datos de código abierto ISIC y HAM10000 para la clasificación de lesiones en la piel, cuyas muestras fueron procesadas por aumento de datos y técnica de clasificación MobileNetV1 se desarrolló en el sistema embebido Raspberry Pi 3 B +, permitiendo alcanzar una exactitud alrededor del 91 % sobre puntuaciones de valor F de sensibilidad del 91.98 %, precisión de 90.1 % y especificidad de 90.3 %.

2.2 Marco teórico

2.2.1 Cáncer de piel

El cáncer de piel se refiere a la formación desproporcional de células con anomalía sobre la región de la epidermis, la capa externa de la piel, cuya reproducción es causada por daños provocados en el ácido desoxirribonucleico no reparados que desencadenan mutaciones, las cuales hacen que las células afectadas se multipliquen de forma acelerada y formen tumores malignos. La causante principal para contraer cáncer de piel son los rayos ultravioletas (UV) producidos por la radiación solar. A corto plazo, la exposición excesiva a este tipo de rayos ultravioleta puede causar quemaduras que con el tiempo provocarían cambios en la textura de la piel, envejecimiento prematuro en la piel y finalmente cáncer de piel. Los carcinomas son los tipos más comunes de cáncer de piel que se originan en las capas basales y escamosas de la piel. El melanoma es el tercer tipo más común de cáncer de piel que incide en la mayor cantidad de muertes a causa de la tendencia en propagarse a otras partes de cuerpo y en los órganos vitales [25].

2.2.2 Carcinoma

El carcinoma de células basales (BCC) se presenta como el tipo más común y frecuente de todos los cánceres que surge del crecimiento lento anormal e incontrolado de las células basales, correspondientes a las principales células presentes en la capa superior de la piel. El

BCC es provocado frecuentemente por el daño en el ADN por la exposición intensa a la radiación ultravioleta (UV) del sol o por bronceado artificial, los cuales provocan cambios sobre las células basales en la epidermis, resultando un crecimiento desproporcional. En la figura 2 se presentan algunas lesiones cutáneas producidas por BCC. En (a) se tienen un aspecto de llagas abiertas, bultos brillantes (b), parches rojos con crecimientos rosados, cicatrices con bordes enrollados ligeramente superficiales (c), que pueden supurar, sangrar, formar costras o picar. En pacientes con tonalidad de piel oscura, la mayoría de las lesiones están pigmentadas de color marrón [26]. Por lo general, los carcinomas basales no se propagan fuera del origen del tumor. Sin embargo, si se les permite la formación sin supervisión y tratamiento podrían exponer peligrosidad al volverse invasivos, con crecimiento amplio, profundo y destructivo sobre la piel, tejidos y huesos, convirtiéndose así en una amenaza para la vida del individuo. La mayoría de los BCC son curables y causan afectaciones mínimas cuando son detectados y tratados a tiempo [27].

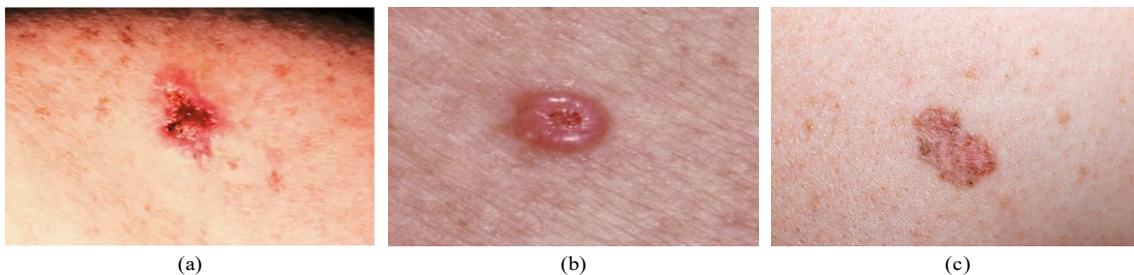


Figura 2. Imágenes de lesiones cutáneas producidas por BCC

El carcinoma de células escamosas (CCE) es el segundo tipo más común de cáncer de piel asociado aproximadamente con 1,8 millones de casos cada año, lo que indica en unos 205 casos diagnosticados cada hora, caracterizado por el crecimiento desproporcional y anormal de las células escamosas localizadas en la capa superior de la piel que se desprenden continuamente respecto a la formación de células nuevas. El CCE ocurre debido al daño sobre el ADN en la exposición intensa a la radiación ultravioleta u otros agentes que desencadenan cambios con anomalías sobre las células escamosas [28]. Como se presenta en la figura 3, los CCE aparecen con lesiones de manchas rojas escamosas (a), piel áspera y llagas abiertas (b), engrosadas y con

crecimientos prolongados que pueden formar costras, sangrar o picar (c). Si bien, la mayoría de casos de CCE pueden tratarse exitosamente, si se les permite crecer, las lesiones podrían ser peligrosas con riesgos de mortalidad.

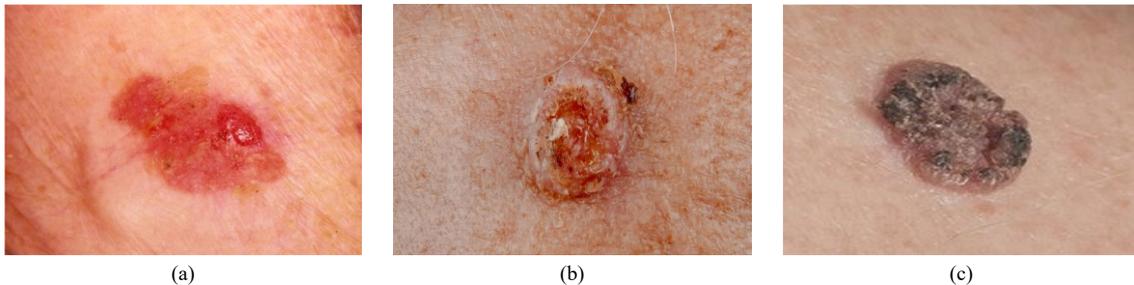


Figura 3. Imágenes de lesiones cutáneas producidas por CCE

2.2.3 Melanoma

El melanoma es el tipo de cáncer de piel más peligroso debido a la capacidad de diseminarse hacia otros órganos más rápidamente si no se trata en fases tempranas. De hecho, se estima que se diagnosticarán más de 197 mil casos de melanoma en los Estados Unidos en 2022. Los melanocitos son las células cutáneas que se encuentran en la capa superior de la piel que producen un pigmento llamado melanina, componente que da color a la piel. Cuando la piel se expone a la radiación UV del sol o camas de bronceado de manera intensiva, se producen daños que provocan que los melanocitos generen más melanina y el pigmento de eumelanina (un tipo de melanina) intentará proteger la región cutánea haciendo que se oscurezca o se broncee. El melanoma ocurre mediante la alteración al ADN por quemaduras a causa de la radiación UV que desprenden cambios o mutaciones sobre los melanocitos, resultando del proceso un crecimiento celular descontrolado. Los melanomas presentan variedad de tamaños, formas y tonalidades como se presenta en la figura 4, y suele ser curable cuando es detectado y tratado a tiempo [29]. El melanoma de extensión superficial (a) se reconoce por su aspecto asimétrico plano y descolorido con bordes irregulares con tonalidades bronceadas, marrones, negras, rosadas, blancas o azules. Algunas lesiones carecen de pigmento y aparecen como una lesión rosada o similar al tono de la piel. Por otro lado, el melanoma lentiginoso acral (b) es la forma

más general de encontrar en personas de color que aparece en lugares difíciles de detectar con un área tonalidad negra o marrón. El melanoma nodular (c) es el tipo de melanoma más agresivo, con crecimiento más rápido y profundo en la piel. Por lo general, es invasivo al momento que se diagnostica por primera vez. El melanoma nodular es identificado como un bulto en la piel de color azul-negro, que también puede originarse como un bulto de color rosa a rojo.

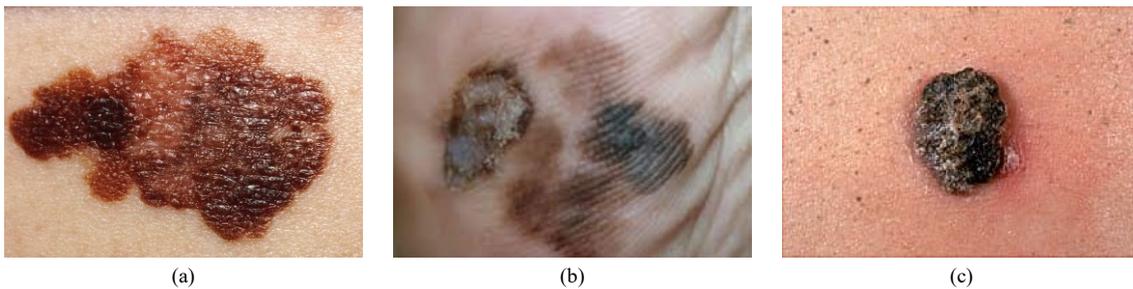


Figura 4. Imágenes biomédicas representativas de lesiones cutáneas

2.2.4 Lesiones no malignas

Las lesiones cutáneas benignas se relacionan con el crecimiento de anomalías cutáneas superficiales no cancerosas que se pueden manifestar de diferentes formas de acuerdo a la causa y tejido de origen. Las lesiones cutáneas benignas comunes incluyen la mayoría de los nevos (figura 5a), que se relacionan con la pigmentación sobre la piel con manifestaciones planas o elevada en forma de lunar que presentan proliferaciones melanocíticas. Además, los dermatofibromas (figuras 5b) se originan por la proliferación de fibroblastos que generan un crecimiento dérmico fibroso con nódulos de color de la piel con lento crecimiento. Así mismo, la queratosis seborreica (figura 5c) se refiere al crecimiento de tumores cutáneos benignos de queratinocitos inmaduros con apariencia grasosa [30].

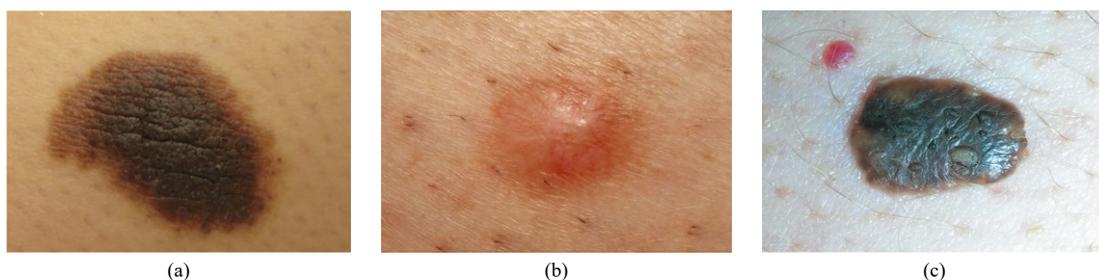


Figura 5. Lesiones cutáneas no malignas

2.2.5 Herramienta de diagnóstico asistida por computador

La interfaz orientada al diagnóstico asistida por computador (*Computer-aided diagnosis*, CAD) integra las técnicas basadas en procesamiento digital de señales e inteligencia artificial utilizadas para el análisis de imágenes que apoya a los médicos en determinar el riesgo de malignidad por medio de los pasos ilustrados en la figura 6 [31]. En el preprocesamiento, se realiza la eliminación de ruido y se armoniza en caso de someterse a niveles de exposición variantes. La etapa de segmentación involucra la detección de las regiones importantes de la imagen que se analizarán a profundidad sin pasar por alto el mínimo detalle. En la extracción de características se analiza cada región de interés para obtener información en cuanto a la forma, tamaño, tonalidad de la región y dispersión de la misma. Finalmente, en la etapa de clasificación con algoritmos entrenados se analizan las regiones identificadas y se determina el diagnóstico mediante el reconocimiento de patrones para dar un apoyo a los especialistas en la interpretación de las imágenes médicas.



Figura 6. Diagrama de bloques de una CAD

2.2.6 Visión artificial

La visión artificial se define como una técnica para el procesamiento y análisis de información específica la cual es proveniente de imágenes digitales, reconocida por ser una rama de la inteligencia artificial que trata de emular la visión que tiene los seres humanos de observar, analizar y actuar respecto a una imagen vista. Esta técnica se compone de un grupo de procesos destinados a realizar un análisis a la imagen captada, en donde estos sistemas adquieren la información del entorno por medio de imágenes en el cual posteriormente realizan un proceso para que sea analizado por el algoritmo realizado [32].

Los procesos que hacen parte de la visión artificial se pueden observar en el diagrama de bloques de la figura 7, comenzando con la adquisición o captación de la imagen mediante dispositivos como lo son las cámaras 2D y 3D, sensores y cámaras hiperespectrales. Seguidamente, se procede con el proceso de digitalización que convierte la imagen captada a información digital que se almacena en memoria y posteriormente se realizará tratamiento de la imagen mediante las instrucciones que se programaron. La imagen procesada llega al módulo de reconocimiento e interpretación que la convierte en forma analógica. Finalmente, llega a un bloque de actuación que realizará alguna acción programada según el análisis obtenido.

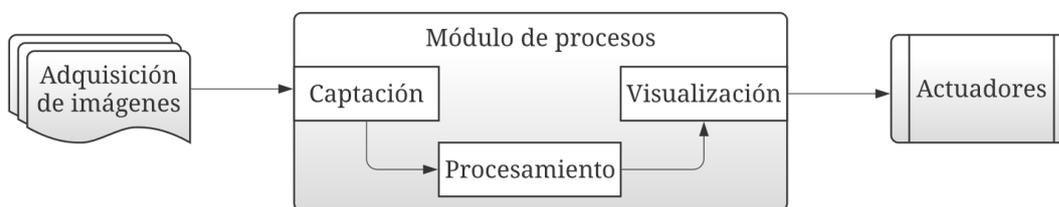


Figura 7. Diagrama de un sistema de visión artificial

2.2.7 Procesamiento digital de imágenes

Se refiere al conjunto de técnicas que se aplican para mejorar el aspecto de las imágenes con el fin de resaltar ciertos detalles que se desean destacar y facilitar la búsqueda de información de la forma presentada en la figura 8. El tratamiento de las imágenes comienza con la división de la imagen y representación en un arreglo rectangular de elementos, en donde cada elemento hace referencia a un pixel. Posteriormente, se realiza la asignación numérica de luminosidad media para cada pixel y la representación de las coordenadas de los mismos para la imagen. El paso siguiente es variar la luminosidad en los valores de los pixeles por medio de transformaciones o modelos matemáticos con el objetivo de resaltar los detalles más relevantes de la imagen. Finalmente, los pixeles alterados por los tratamientos digitales se representan en un visor de imagen con la intención de visualizar la imagen procesada [33].

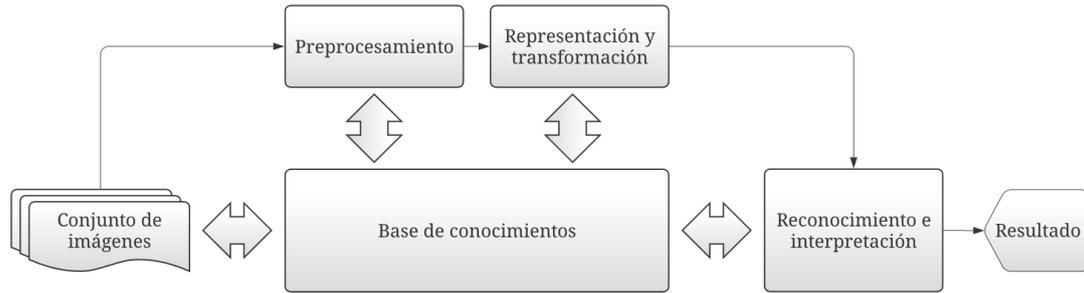


Figura 8. Diagrama de un sistema de procesamiento digital de imágenes

2.2.8 Técnicas para la extracción y reducción de características

La extracción de características se relaciona con la reducción en la dimensionalidad con el propósito de generar un nuevo vector que contengan información relevante relacionada (características) e informativa sin redundancia de los datos de entrada y con representación reducida para las etapas siguientes de aprendizaje y predicción, en lugar de datos completos. A continuación, se presentan las técnicas de Redes Neuronales Densamente Conectadas (DenseNet121), la Matriz de Coocurrencia de Niveles de Gris (GLCM) y Análisis de Componentes Principales (PCA),

2.2.9 DenseNet121

Se refiere a una arquitectura convolucional que integra capas profundas y conexiones más cortas, en donde cada capa se conecta con todas las demás capas situadas en la zona más profunda de la red [34]. La primera capa se conecta con la segunda, tercera y cuarta, así de forma sucesiva, la segunda capa se conecta con la tercera, cuarta y quinta, y así sucesivamente. Lo anterior se realiza para permitir el flujo máximo de información entre cada una de las capas, en donde cada una obtiene entradas de todas las capas anteriores y los mapas de características se pasan a todas las capas sucesivas combinando funciones concatenadas. Así, se requerirán menos parámetros en comparación con las redes neuronales convolucionales debido a que no será necesario aprender mapas de características de representación insignificante.

2.2.10 Matriz de Coocurrencia de Niveles de Gris (GLCM)

La evaluación de las características enfocadas en la textura de la imagen es realizable mediante la técnica estadística de segundo orden GLCM que se calcula con base a métricas cuya relación es angular y distancias entre pixeles. La solución de la matriz se obtiene mediante la reducción en el número de valores de gris y la combinación entre pixeles [35]. En adición, se debe definir la dirección de los pares de pixeles y la distancia entre ellos debido a que la matriz almacena la cantidad de veces que se encuentran el par en la imagen, y a la vez, analiza la relación entre pares no consecutivos. La distancia entre los pixeles debe definirse de forma previa. La figura 9 describe en (A) la matriz con el número de ocurrencias entre pixeles adyacentes, mientras que en (B) se ilustran las direcciones de desplazamientos en GLCM.

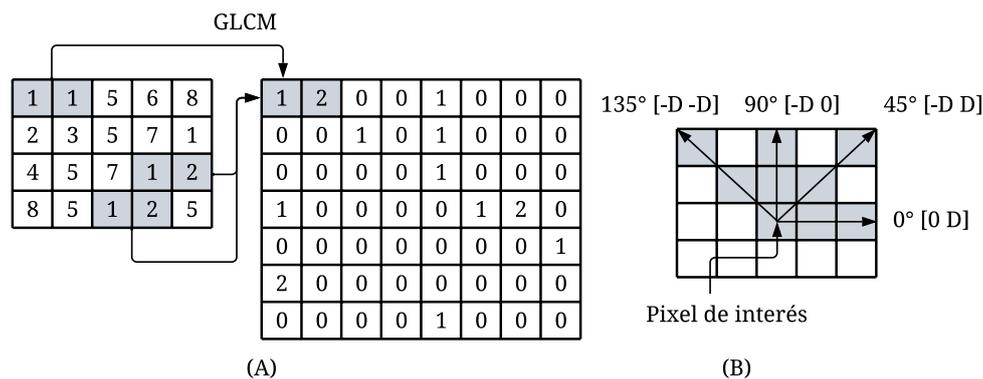


Figura 9. Ilustraciones relacionadas con la matriz de coocurrencia de niveles de gris

La matriz de ocurrencia de niveles de gris involucra el cálculo de variables texturales de segundo orden a través del análisis de pixeles sobre una distancia y unas orientaciones angulares determinadas. Por ello, la tabla 1 presenta las variables basadas en la textura con la respectiva descripción y modelo matemático.

Tabla 1. Variables relacionadas con la Matriz de Coocurrencia de Niveles de Gris

Característica GLCM	Explicación	Modelo
Energía	Mide la uniformidad en relación con la textura de la imagen.	$\sqrt{\sum_{i,j=0}^{N-1} C_{i,j}^2}$

Correlación	Mide la dependencia de las amplitudes lineales de las amplitudes vecinas. Las variables σ_i y σ_j son las desviaciones estándar, mientras que μ_i y μ_j son las medias de GLCM.	$\sum_{i,j=0}^{N-1} \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i^2 * \sigma_j^2}}$
Disimilitud	Los pesos de las probabilidades aumentan linealmente y se alejan de la diagonal donde los valores vecinos son idénticos.	$\sum_{i,j=0}^{N-1} C_{i,j} * i - j $
Homogeneidad	Se encarga de ponderar los valores por la inversa del peso del contraste. La homogeneidad aumenta a medida que disminuye el contraste entre los píxeles.	$\sum_{i,j=0}^{N-1} \frac{C_{i,j}}{1 + i + j }$
Contraste	Presenta las variaciones sobre los tonos de gris de la imagen. Si la variación de los tonos de gris es mayor, el contraste será alto. El contraste es nulo si los niveles de gris son constantes.	$\sum_{i,j=0}^N (i - j)^2 * C_{i,j}$

2.2.11 Análisis de Componentes Principales (PCA)

El análisis de componentes principales se presenta como un método estadístico con la finalidad de simplificar la complejidad de valores muestrales que presentan redundancias significativas en cuanto a las dimensiones, y a la vez preservar la información de las mismas mediante la búsqueda de factores subyacentes que representan idénticamente las muestras.

2.2.12 Modelos de aprendizaje y clasificación

El aprendizaje hace parte de los pilares fundamentados en soluciones bajo inteligencia artificial que conlleva a procesos de optimización para mejorar el conocimiento de los algoritmos y predecir en función de la representación de los datos destinados como entrada y salida. Seguidamente, se detallan los modelos de máquinas de vectores de soporte, redes neuronales convolucionales, LightGBM y XGBoost.

2.2.13 Máquinas de vectores de soporte (SVM)

Las máquinas de vectores de soporte (SVM) tienen como fin encontrar un hiperplano definido en un espacio de dimensión en función del número de características para clasificar los puntos correspondientes a los datos. La separación de dos clases de datos genera varios hiperplanos que podrían seleccionarse, indicando la necesidad de encontrar un plano que

presente el margen máximo o la distancia máxima entre puntos de datos de las clases, con el fin de clasificar con mayor efectividad. El entrenamiento del clasificador requiere de un conjunto de muestras con representación del vector de entrada x_i y la etiqueta asociada y_i , tal y como se presenta en la ecuación 1, donde $x_i \in R^d$ y $y_i \in (+1, -1)$ [36].

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) \quad (1)$$

La dimensión del hiperplano está relacionada con el número de características y los vectores de soporte son aquellos puntos que están más cerca del hiperplano que influyen en la orientación y ubicación del hiperplano, y a la vez maximizan el margen del clasificador. La figura 10 presenta varios hiperplanos de decisión que dividen el conjunto de datos de entrada, en donde es evidente la infinidad de hiperplanos que podrían clasificar los datos [37].

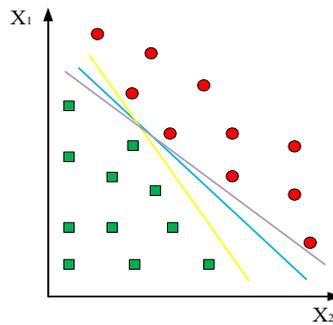


Figura 10. División de los datos por los hiperplanos

El nivel de decisión o hiperplano que separa las clases de espacio de entrada está definido por la ecuación 2.

$$w^T x_i + b = 0 \quad (2)$$

El margen geométrico en el rango de X^+ y X^- se presenta en la ecuación 3, donde w define al hiperplano de óptima separación y b es la inclinación. La optimización del margen geométrico reduce la norma del vector de pesos.

$$\gamma_i = \frac{1}{2} \left(\left\langle \frac{w}{\|w\|} * x^+ \right\rangle - \left\langle \frac{w}{\|w\|} * x^- \right\rangle \right) \quad (3)$$

2.2.14 Redes Neuronales Convolucionales (CNN)

Las Redes Neuronales Convolucionales (CNN) se presentan como un modelo artificial con aplicación en la clasificación de texturas, reconocimiento de objetos y otras aplicaciones de visión computacional [38]. En efecto, hacen referencia a una red neuronal ampliamente utilizada en el procesamiento de datos que introduce capas de agrupación, activación y convolución por medio de una serie de filtros que extraen las características, mientras que, la capa de agrupación se encarga de la reducción de dimensionalidad de la imagen producida por las capas de convolución mediante muestreo reducido, utilizando estrategias como agrupación media o agrupación máxima para sintetizar los parámetros y la complejidad de red [39].

La capa Dropout tiene como función reducir el sobreajuste posiblemente generado durante el entrenamiento, suprimiendo neuronas que hacen parte de capas ocultas o visibles al azar. Sin embargo, es posible modificar la probabilidad de que una neurona sea eliminada mediante la proporción de Dropout.

Finalmente, las capas adicionales en el modelo totalmente conectadas con las funciones de activación extraen las características de alto nivel de los datos y clasifican las imágenes dadas en la clasificación binaria, en donde, la función SoftMax es una de las funciones de activación muy utilizada en estas capas, enfocada en el cálculo de distribución probabilística de un vector de valor real que produce una salida en el rango entre 0 y 1 debido a que la suma de probabilidad es 1 [40]. La ecuación 4 presenta la base matemática de la función.

$$f(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \text{ para } j = 1, 2, \dots, k \quad (4)$$

Los núcleos de capas convolucionales y los pesos de las conexiones de las redes se optimizan en el entrenamiento mediante retro propagación [41]. La figura 11 describe la arquitectura del método presentado de aprendizaje profundo en la clasificación de imágenes con base a la predicción.

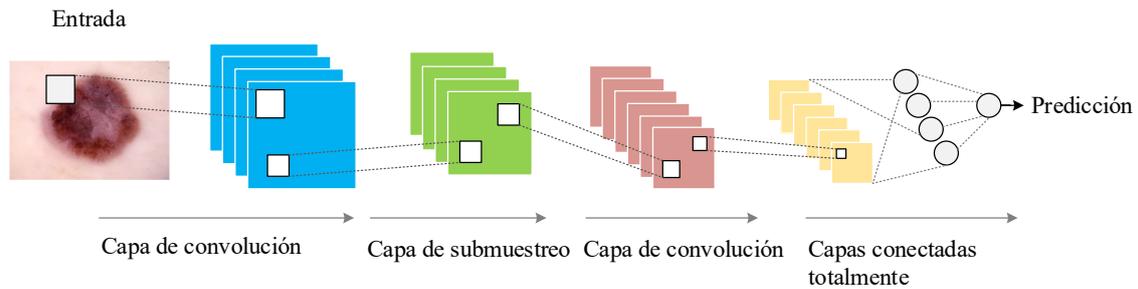


Figura 11. Arquitectura de una red neuronal convolucional

El modelamiento matemático del proceso de convolución se presenta en la ecuación 5, en donde X_{ij} es la i -ésima y la j -ésima matriz con dirección de la fila y la columna correspondientes a núcleos de convolución de la matriz de entrada por medio de desplazamientos uniformes, K es el núcleo de convolución, y γ es la matriz de la salida.

$$\gamma_{(i,j)} = X_{ij} * K \quad (5)$$

El principio matemático de la estructura de capa totalmente conectada se expresa como se muestra en la ecuación 6, donde o es el vector compuesto por valores de salida, x es el vector compuesto por variables de entrada, w es el vector compuesto en valores de peso, b es el vector compuesto por valores de umbral, y f es la función de activación.

$$o = f(w_f^T x + b) \quad (6)$$

La salida del vector convolución produce un rango en una dimensión por medio de expansión de aplanamiento. Posteriormente, los vectores se conectan a la capa densa para obtener la salida en una dimensión [42].

2.2.15 LightGBM

LightGBM hace referencia a una técnica de clasificación de aprendizaje automático con enfoque en aprendizaje mejorado de refuerzo de gradiente en arboles de decisión con el objetivo de aumentar la eficiencia del modelo y reducir la tasa de memoria utilizada. El algoritmo utiliza la técnica de muestreo unilateral basado en gradiente (GOSS) y la agrupación excluyente de características (EFB) que complementan el histograma que utiliza los marcos GBDT (Gradient Boosting Decision Tree) para agrupar los valores de las características o

atributos en secciones discretas que permiten acelerar el entrenamiento [43]. Por lo general, la mayoría de las técnicas orientadas en el aprendizaje por la técnica arboles de decisión hacen crecer el árbol de forma horizontal o profunda, por el contrario, LightGBM hace crecer el árbol en forma de hoja, permitiendo así elegir la hoja con la máxima pérdida para crecer y mantener fijo el algoritmo por hojas, consiguiendo menores pérdidas comparadas con otros algoritmos de conjuntos de niveles [44]. La figura 12 muestra el proceso del crecimiento de las hojas del árbol del LightGBM.

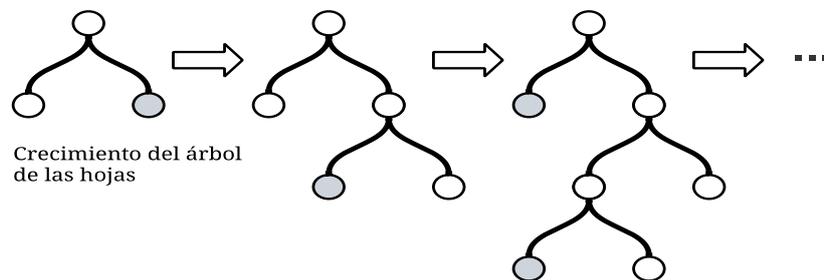


Figura 12. Algoritmo del clasificador LightGBM

2.2.16 XGBoost

XGBoost (Aumento Extremo de Gradiente) es un modelo de aprendizaje automático que implementa máquinas de aumento de gradiente para elevar la eficiencia en el tiempo de cómputo y los recursos de memoria, con el objetivo de optimizar los recursos disponibles para entrenar el modelo. Este algoritmo implementa arboles de decisión con aumento de gradiente, cuyo enfoque es crear nuevos modelos que predicen los errores de los modelos anteriores y minimizan la pérdida al adicionar nuevos modelos, y posteriormente se ponderan para la predicción final [45]. XGBoost adiciona características de soporte para implementación en estructura de bloques para parametrizar la construcción del árbol sobre los núcleos de CPU para entrenamiento y optimización de cache dedicada a estructura de datos que mejoran la aplicación del hardware.

2.2.17 Python

Python es un lenguaje de programación multiparadigma interpretado en la legibilidad de código que combina aspectos imperativos, funcionales y orientados a objetos, permitiendo que la entrada al lenguaje pueda hacerse de forma progresiva. El lenguaje de programación cuenta con un amplio repositorio de herramienta de software con más de 120.000 paquetes en PyPI (Python Package Index), orientados a resolver tareas de utilidad, por ejemplo, la lectura de ficheros, el desarrollo de interfaces gráficas, conexión con bases de datos, entre otras aplicaciones [46].

2.2.18 OpenCV

Es una biblioteca de software orientada a la visión artificial y el aprendizaje autónomo en código abierto que proporciona una infraestructura general en aplicaciones de visión por computador. La biblioteca cuenta con más de 2500 algoritmos optimizados que incluyen un conjunto de algoritmos de aprendizaje automático y profundo que son utilizados para detectar y reconocer rostros, identificación y rastreo de objetos, unir imágenes para producir una de alta resolución, entre otras.

OpenCV tienen interfaces en Python, C ++, MATLAB y Java, compatible con los sistemas operativos Windows, Android, Linux y Mac OS, utilizada por empresas, grupos de investigación y organismos de gobierno [47].

2.2.19 TensorFlow

Tensorflow se considera un proyecto de código abierto desarrollado por programadores de Google para desarrollar y ejecutar modelos de machine learning, Deep learning y otros modelos para análisis predictivo y estadístico. El proyecto tiene como fin de agilizar los procesos de desarrollo y ejecución de los modelos tanto para usuarios como a los científicos de datos y estadísticos. TensorFlow realiza el tratamiento a los conjuntos de datos que se organizan en forma de nodos computaciones, representados como vectores o matrices multidimensionales

llamados tensores, los cuales son usados bajo una arquitectura de flujo de datos que permiten obtener resultados intermedios con cálculos generalizados e integran procesamiento paralelo a gran escala y profundos [48]. Los modelos desarrollados en TensorFlow pueden ejecutarse en la Unidad Central de Procesos del sistema computacional o en Unidades de Procesamiento de Gráficos (GPU) de mayor desempeño, así como en las unidades de procesamiento de tensor (TPU) disponibles de Google.

2.2.20 Sistemas embebidos

Los sistemas embebidos corresponden a un sistema que integra hardware y software para ejecutar una o varias operaciones en tiempo real. Los recursos que ofrecen no son muy amplios, pero si son lo suficiente para considerarse un ordenador a baja escala con la utilidad para la construcción de nuevos productos con enfoque sobre líneas de código modificables y adaptables a las necesidades y requerimientos emergentes de un diseño [49].

2.2.21 Raspberry Pi 4B

Raspberry Pi 4B (figura 13) es una placa de desarrollo embebida de bajo costo teniendo en cuenta sus características. Posee un tamaño compacto con la posibilidad de conexión de múltiples periféricos como teclados, conectores USB, mouse, y conexión a monitores [50]. La placa incluye un procesador Broadcom BCM2711 cortex-A72 de cuatro núcleos con arquitectura de 64 bits a una frecuencia de reloj de 1.5 GHz, memoria RAM de 1 GB, 2GB, 4 GB o 8 GB de acuerdo al modelo, conexión con doble LAN inalámbrica de banda 2.4 a 5.0 GHz con bluetooth 5.0, GPIO de 40 pines, entrada HDMI, 2 puertos USB 2.0 y 3 puertos USB 3.0, salida de audio estéreo y vídeo compuesto mediante dos puertos micro HDMI con resolución máxima 4Kp60, microSD, así como de puertos CSI y DSI para la conexión de cámaras de video y pantallas táctil respectivamente [51]. Es un sistema basado en Linux, por lo cual permite modificar diferentes características de la placa aceptando lenguajes de programación usados en el procesamiento de imágenes como Python y Scratch.

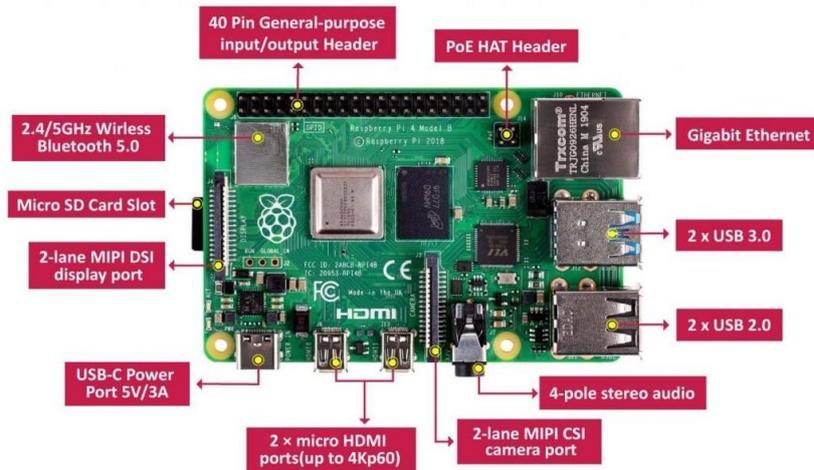


Figura 13. Descripción gráfica del sistema embebido Raspberry Pi 4B

2.2.22 Interfaz gráfica de usuario

La interfaz gráfica de usuario (GUI) hace referencia al conjunto de métodos y formas que permiten la interacción de un sistema codificado con los usuarios a través de imágenes y gráficos, con referencia a iconos, botones, fuentes, ventanas, entre otros, cuyos elementos están asociados con funciones, información y acciones definidas. La función de una GUI se centra en ofrecer un entorno intuitivo para interactuar con las diferentes aplicaciones sin requerir de conceptos especializados de conocimientos informáticos [52]. La figura 14 ilustra los componentes básicos de una GUI.

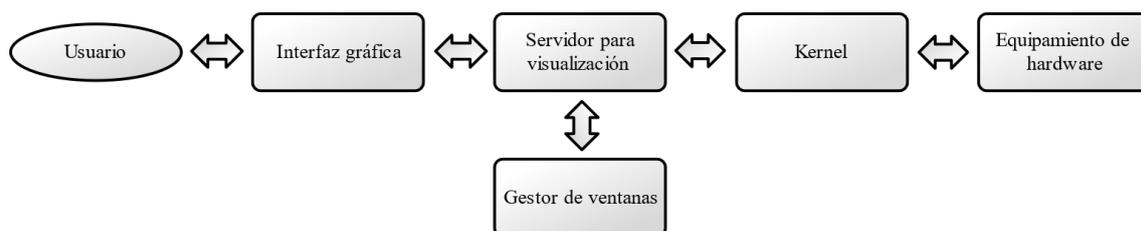


Figura 14. Componentes de una interfaz gráfica de usuario

2.3 Marco legal

A continuación, se presentan las normativas legales correspondientes al manejo de información personal para el tratamiento de las imágenes médicas.

- **Artículo 15 de la Constitución Política de Colombia:** Todas las personas tienen derecho a su intimidad personal y familiar y a su buen nombre, y el Estado debe respetarlos y hacerlos respetar.
- **Ley 1581 de 2012** “por la cual se dictan disposiciones generales para la protección de datos personales”, la cual en el título I correspondiente al objeto, ámbito de aplicación y definiciones manifiesta:

Artículo 1: La presente ley tiene por objeto desarrollar el derecho constitucional que tienen todas las personas a conocer, actualizar y rectificar las informaciones que se hayan recogido sobre ellas en bases de datos o archivos, y los demás derechos, libertades y garantías constitucionales a que se refiere el artículo 15 de la Constitución Política; así como el derecho a la información consagrado en el artículo 20 de la misma.

Artículo 2: Los principios y disposiciones contenidas en la presente ley serán aplicables a los datos personales registrados en cualquier base de datos que los haga susceptibles de tratamiento por entidades de naturaleza pública o privada.

La presente ley aplicará al tratamiento de datos personales efectuado en territorio colombiano o cuando al responsable del tratamiento o encargado del tratamiento no establecido en territorio nacional le sea aplicable la legislación colombiana en virtud de normas y tratados internacionales.

- **Ley 1266 de 2008** “por la cual se dictan las disposiciones generales del hábeas data y se regula el manejo de la información contenida en bases de datos personales en especial la financiera, crediticia, comercial, de servicios y la proveniente de terceros países y se dictan otras disposiciones”.
- **Ley 657 de 2001** “por la cual se reglamenta la especialidad médica de la radiología e imágenes diagnósticas y se dictan otras disposiciones”, la cual, el Congreso de la República decreta:

Artículo 1: La radiología e imágenes diagnósticas es una especialidad de la medicina basada en la obtención de imágenes de utilidad médica para efectos diagnósticos y terapéuticos, mediante la utilización de ondas del espectro electromagnético y de otras fuentes de energía.

Artículo 2: La radiología e imágenes diagnósticas estudia los principios, procedimientos, instrumentos y materiales necesarios para producir diagnósticos y realizar procedimientos terapéuticos óptimos, todo con fundamento en un método científico, académico e investigativo.

Artículo 3: La especialidad médica de la radiología e imágenes diagnósticas participa con las demás especialidades de la medicina en el manejo integral del paciente y por ende pueden prescribir, realizar tratamientos, expedir certificados y conceptos sobre el área de su especialidad e intervenir como auxiliares de la justicia.

- **Ley 1581 de 2012:** “Por la cual se dictan disposiciones generales para la protección de datos personales”, que manifiesta:

Artículo 1. Desarrollar el derecho constitucional que tienen todas las personas a conocer, actualizar y rectificar las informaciones que se hayan recogido sobre ellas en bases de datos o archivos, y los demás derechos, libertades y garantías constitucionales a que se refiere el artículo 15 de la Constitución Política; así como el derecho a la información consagrado en el artículo 20 de la misma.

Artículo 2. Los principios y disposiciones contenidas en la presente ley serán aplicables a los datos personales registrados en cualquier base de datos que los haga susceptibles de tratamiento por entidades de naturaleza pública o privada. La presente ley aplicará al tratamiento de datos personales efectuado en territorio colombiano o cuando el responsable del tratamiento o encargado del tratamiento no establecido en territorio nacional sea aplicable a la legislación colombiana en virtud de normas y tratados internacionales.

- **Sentencia C-038 / 03 de la Corte Constitucional de Colombia:** Por la cual declara exequibles las expresiones “imágenes diagnosticas” contenida en el titulo y en los artículos del 1 al 16 de la ley 557 de 2001, “Ondas del espectro electromagnéticos y de otras” contenida en el artículo primero de la misma ley y “especialistas” contenida en el párrafo del artículo 4 de la misma ley.

3. Metodología

El trabajo de investigación fue realizado de forma secuencial de acuerdo con lo planteado en cada uno de los objetivos.

3.1 Documentar el estado del arte con respecto a técnicas de diagnóstico y clasificación de cáncer de piel

La literatura consultada está asociada con los filtros de búsqueda por palabras clave: Extracción de características, Técnicas de detección de cáncer de piel y Herramientas de diagnóstico asistidas por computador. En la revisión sistemática se incluyeron trabajos de grado y artículos de investigación resultantes de una exploración enfocada en técnicas de procesamiento digital de imágenes, inteligencia artificial y herramientas de diagnóstico asistidas por computador que aportan información significativa sobre los procesos de detección de cáncer de piel a través de herramientas computacionales. Se incluyeron documentos redactados tanto en idioma inglés como en español con año de publicación superior al 2016 y se encuentran disponibles en las bases de datos de alto impacto científico de Elsevier, SpringerLink, Google Scholar, PubMed e IEEE Xplore. En la sección “marco referencial” del capítulo 2, específicamente en el apartado de antecedentes, se muestran los trabajos y artículos relacionados con cada una de las temáticas mencionadas previamente. Del mismo modo, en el apartado de “marco teórico” se presentan los conceptos requeridos para la implementación de la herramienta de diagnóstico asistida.

3.2 Aplicación de técnicas de procesamiento digital de imágenes y visión artificial para la extracción y mejora de características de interés de la lesión cutánea

Una vez consultada la literatura científica a considerar en el desarrollo del proyecto de investigación, se hace necesario en la aplicación de técnicas de procesamiento digital de imágenes la selección de herramientas tanto de hardware como de software a utilizar [53]. La selección consiste en comparar parámetros los cuales se establece un peso específico para

comparar entre los mismos. La matriz de priorización se realiza para comparar parámetros en donde se asignan 10 unidades si la opción es mucho más eficiente respecto a la comparada, 5 si es más eficiente, 1 si es igual, 1/5 si es menos eficiente que la comparada y 1/10 si se considera mucho menos eficiente. Posteriormente, los valores asignados se suman para obtener el peso correspondiente al parámetro en cuestión [54].

Las herramientas de hardware comparadas fueron Raspberry Pi 4B, Jetson Nano, PocketBeagle y Nexys 3 Spartan 6. La tabla 2 presenta los parámetros comparados para la selección del sistema de hardware con la respectiva denotación en la matriz de priorización.

Tabla 2. Parámetros de comparación para herramientas de hardware

Parámetro	Denotación
Velocidad de procesamiento	A
Cantidad de memoria RAM	B
Lenguajes de programación soportados	C
Velocidad de procesamiento gráfico	D
Precio y disponibilidad en el mercado	E

Del mismo modo, las herramientas de software comparadas fueron Python, Lenguaje M, Java y C++. Los parámetros comparados para la selección de la herramienta de software con la denotación en la matriz de priorización se presentan en la tabla 3.

Tabla 3. Parámetros de comparación para herramientas de software

Parámetro	Denotación
Tipo de la licencia	A
Capacidad de integración con entornos de desarrollo	B
Disponibilidad de paquetes y librerías	C
Conectividad con ofimática	D
Especialidad para inteligencia artificial	E

3.2.1 Procesamiento digital de imágenes médicas y visión artificial

Las imágenes de lesiones cutáneas presentan algunas limitantes que impiden el diagnóstico o la realización de procedimientos médicos, ya que las imágenes pueden mostrarse borrosas, con vello corporal, elementos de regla o con ruido que no permiten apreciar claramente la lesión. En consecuencia, se aplican los algoritmos de procesamiento

digital de imágenes médicas para hacer más clara la visualización de dichas imágenes, de modo que, el médico y los modelos de clasificación puedan apreciar con detalle la lesión y determinar con mayor precisión los diagnósticos, y a la vez resaltar las características asociadas con la anatomía de la enfermedad. Las técnicas referentes al procesamiento digital de imágenes se detallan a continuación.

A. Conversión de las imágenes a escala de nivel de gris

Inicialmente, la imagen es sometida a un preprocesamiento para la representación en escala de grises mediante valores de intensidad entre tonalidades de blanco y negro. De modo que, la expresión matemática de las componentes R, G y B respectivamente se representan en la ecuación 7, donde R hace referencia al color rojo, G al color verde y B corresponde al color azul.

$$I = 0.299R + 0.587G + 0.114B \quad (7)$$

B. Detección de vellos corporales mediante el algoritmo de Canny

Se basa en un algoritmo compuesto por varias etapas para detectar los diversos bordes que son representados por los vellos corporales presentes en la imagen. El algoritmo de detección de bordes se compone mediante las etapas de reducción de ruido, operador de gradiente, supresión no máxima y umbralización por histéresis [55]. El filtro de suavizado gaussiano se aplica para eliminar las redundancias en las imágenes con la pérdida mínima de detalles, ya que la detección de bordes es vulnerable al ruido y el pixel referenciado no podrá ser similar a los pixeles vecinos, cuyo resultado será una detección incorrecta de los bordes. El filtro gaussiano realiza dos barridos en una sola dimensión, uno en el eje x y otro en el eje y , evitando las convoluciones bidimensionales [56]. La ecuación 8 muestra la representación del filtro, donde X e Y hacen referencia a los desplazamientos horizontales y verticales, y σ es la desviación estándar de la distribución gaussiana con tamaño de filtro 3×3 .

$$G(x) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (8)$$

Posteriormente, se calcula la magnitud y dirección del gradiente mediante la diferencia finita del tamaño 2×2 con referencia al área entre vecinos para determinar la magnitud $g_{(x,y)}$ y la dirección $\theta_{(i,j)}$ de la imagen. Las derivadas parciales de primer orden correspondientes tanto para la dirección en x como la dirección en y para el pixel $I_{(i,j)}$ se describe en la ecuación 9. Mientras que, la magnitud y dirección del gradiente se presentan en la ecuación 10.

$$\nabla S = \begin{bmatrix} \frac{\partial g}{\partial x} \\ \frac{\partial g}{\partial y} \end{bmatrix} * I_{(i,j)} = \begin{bmatrix} g_x(i,j) \\ g_y(i,j) \end{bmatrix} * I_{(i,j)} \quad (9)$$

$$g_{(i,j)} = \sqrt{g_x(i,j)^2 + g_y(i,j)^2} \quad (10)$$

$$\theta_{(i,j)} = \tan^{-1} \left(\frac{g_y(i,j)}{g_x(i,j)} \right)$$

La representación de los bordes unilaterales es realizable mediante la técnica de supresión no máxima, representado por un área de adyacencia de tamaño 3×3 que consta de 8 direcciones para interpolar la magnitud obtenida del gradiente alrededor de la dirección del mismo. El procedimiento consiste en seleccionar puntos de los bordes considerando si la magnitud del gradiente en cada punto de la dirección del gradiente es la máxima alrededor de las 8 secciones vecinas. Según la figura 15, la supresión no máxima ocurre cuando el pixel q presente una intensidad mayor que p y r , donde los pixeles p y r son los pixeles orientados hacia la dirección del gradiente de q . Si se cumple la condición, el pixel representa un borde. Por el contrario, se convierte en un pixel de intensidad nula.

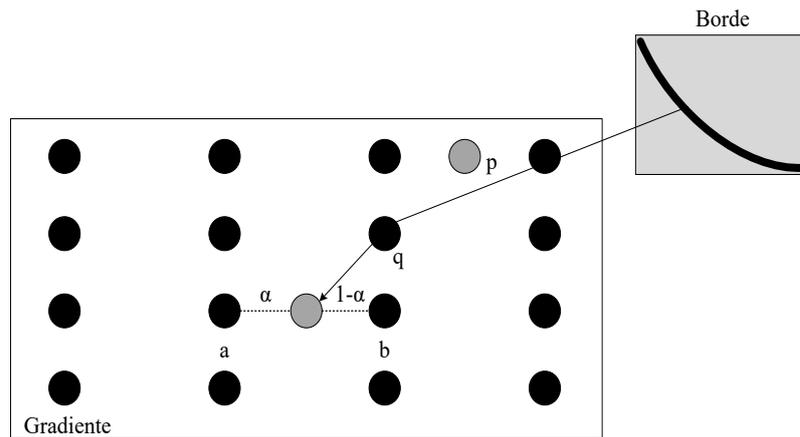


Figura 15. Ilustración de la técnica de supresión no máxima

La ecuación 11 presenta la interpolación de los pixeles para lograr mayor precisión.

$$r = \alpha * b + (1 - \alpha) * a \quad (11)$$

Finalmente, la umbralización por histéresis determina cuales son los bordes mediante la determinación de dos valores de umbral (val_{min} y $val_{máx}$). El borde de magnitud de gradiente mayor a $val_{máx}$ será considerado un borde representativo de la imagen, y los bordes que se sitúen por debajo de val_{min} serán omitidos. Los valores de gradiente que se ubiquen en medio de los dos umbrales se clasificarán como un borde en función de la conectividad entre los pixeles que fueron considerados como bordes.

C. Aplicación del filtro morfológico de dilatación

La dilatación es una operación morfológica de suma invariante y desplazamiento que extiende las estructuras que resaltan sobre la imagen. Por consiguiente, el nuevo valor de intensidad de gris para cada pixel será el máximo entre los valores anteriores de gris para la mayoría de los pixeles ubicados en el elemento estructural con origen en el pixel [57]. El operador dilatador se complementa con un elemento estructural en forma de cruz y tamaño 5×5 . La ecuación 12 muestra la expresión matemática del filtro de dilatación, donde A_b es la translación de A por b .

$$A \oplus B = \bigcup_{b \in B} A_b \quad (12)$$

D. Umbralización del ruido producido por vello corporal

La umbralización se refiere a la técnica que asigna a las imágenes en escala de grises valores en función de un parámetro de umbral predefinido que establece las dos regiones. Cada pixel se compara con el valor de umbral, y si el valor de un pixel es inferior que el umbral se establece en cero, por el contrario, se establece el valor máximo de 255. Con lo anterior, se utiliza el método de umbral binario para representar el vello corporal y separarlo del fondo de la imagen en un primer plano con un umbral $T = 10$.

E. Trazado para decoloración del vello corporal

Se introduce el método *image inpainting* para la tarea de reconstrucción de regiones sobre una imagen. El método consiste en una clase de algoritmos de visión artificial para rellenar secciones dentro de la imagen mediante una máscara binaria. En específico, la máscara se referencia con la obtenida mediante la binarización del vello corporal. La supresión del ruido se realiza propagando la información partiendo desde el límite de la región que se desea reconstruir. La restauración de la imagen consiste en el Método de marcha rápida (FMM) que utiliza la imagen con transformaciones laplacianos con estimadores de suavizado y valor medio en la vecindad del pixel que se desea restaurar [58]. El fundamento de *FFM* se basa en resolver planteamientos de condición de frontera mediante la formulación de la ecuación de *Eikonal* mostrada en la ecuación 13, donde $F(X)$ es la función de velocidad en la dirección perpendicular en un punto sobre la curva límite y $T(X)$ es el tiempo en el que la curva de nivel equidista sobre el punto X . Los valores de degradado de la vecindad son utilizados para estimar el color que se va a pintar sobre el pixel.

$$|\nabla T(x)| * F(X) = 1 \quad (13)$$

F. Aplicación del filtro de suavizado mediano

Se introduce el filtro de suavizado mediano como un método útil en la eliminación de ruido en las imágenes médicas debido a la especificidad del filtro que mantiene las características

representativas de la imagen [59]. La ecuación 14 presenta el modelo matemático del filtro mediano sobre una vecindad $m \times n$ para agruparlas en orden ascendente, seleccionar el valor medio de las vecindades ordenadas y reemplazar el pixel central, en donde C representa la vecindad centrada alrededor de la ubicación (m, n) de la imagen con tamaño de filtro 3×3 . Posteriormente, la imagen suavizada por filtro de mediana se presenta en escala de grises para la segmentación de la región de interés.

$$y_{(m,n)} = \text{median}\{x_{(i,j)}, (i,j) \in C\} \quad (14)$$

G. Segmentación de la región de interés

Del mismo modo, se aplica el método de umbralización binaria para separar la región de la lesión del fondo de la imagen. En adición, se emplea el método de umbralización adaptativa de Otsu para una primera aproximación a la segmentación de la lesión del fondo [60]. La ecuación 15 muestra el cálculo de la probabilidad de ocurrencia de cada clase, en donde la clase 0 representa el fondo de la imagen y la clase 1 se refiere a la lesión con s y t como valores del umbral de refuerzo con valor de 127.

$$\begin{aligned} P_0(s, t) &= \sum_{i=0}^s \sum_{j=0}^t P_{ij} \\ P_1(s, t) &= \sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L-1} P_{ij} \end{aligned} \quad (15)$$

En adición, la interfaz gráfica de usuario para diagnóstico dispondrá de una herramienta para dibujar a mano alzada el contorno de la lesión usando el puntero. Por ello, se diseña un método inspirado en el dibujo de formas regulares usando el puntero para dibujar al azar objetos a mano alzada. Por consiguiente, se realiza un enmascaramiento de color para representar una máscara binaria del objeto trazado en combinando la detección de contornos para rastrear la ubicación del lápiz sobre el objeto. Una vez terminado el proceso, se conectan los puntos usando las coordenadas x, y de la ubicación previa del lápiz con los puntos x, y del nuevo

marco. Por lo tanto, mediante este método se pueden representar los puntos por medio de una interpolación entre ellos mediante la técnica *line* de la librería OpenCV.

Por otra parte, se utiliza el filtrado morfológico de apertura por la facilidad en la separación de los objetos relacionados por la línea finita de píxeles, en donde las regiones sometidas por la operación de erosión serán restauradas por la dilatación en su tamaño original [61]. El filtrado por apertura se complementa con un elemento estructural de circunferencia que proporciona suavidad sobre las esquinas dentro de la vecindad de píxeles, redondea las esquinas, elimina el ruido y compacta la imagen. Según la aplicación y el contenido de la imagen se establece el tamaño y la forma del elemento estructural. La ecuación 16 describe el enfoque matemático del filtrado de apertura, donde A es la imagen a procesar y B es el elemento estructural elíptico de tamaño 5×5 .

$$A \circ B = (A \ominus B) \oplus B \quad (16)$$

La representación de la región binaria de la lesión se complementa con el método de búsqueda de contornos mediante una configuración de búsqueda de contornos sobre el borde de la lesión para detectar la región de interés. En complemento, se aplica el método de aproximación simple para distinguir los contornos y resaltar los puntos finales del contorno, permitiendo que el sistema requiera menor uso de memoria y evita almacenar todos los puntos del contorno, agilizando así el procesamiento de la imagen [62]. El procesamiento para segmentar la lesión finaliza con una superposición de imágenes. La imagen sin vello corporal se opera respecto a la máscara de la lesión segmentada, en donde la imagen sin vello corporal se traslada a un primer plano.

3.2.2 Validación del método de supresión del vello corporal y segmentación

Para la validación del método desarrollado de atenuación de ruido, se propone una inspección manual de las imágenes procesadas, relacionando el número de vellos capilares presentes en la lesión que fueron eliminados por completo. La validación de la segmentación,

ya sea por umbral binario y adaptativo por Otsu o por dibujo de la región de interés, se realiza mediante el coeficiente de similitud de Jaccard que se presenta como una medida ampliamente utilizada en la segmentación de imágenes médicas [63], cuyo modelo se representa por el valor M referenciado por la verdad (*ground truth*) de la segmentación de la región de interés y C representa la máscara generada tanto por la umbralización combinada por Otsu como la dibujada por la herramienta de lápiz. El índice de Jaccard se define como se muestra en la ecuación 17.

$$J(M, C) = \frac{|M \cap C|}{|M| + |C| - |M \cap C|} \quad (17)$$

3.3 Desarrollo de algoritmos de inteligencia artificial para clasificación de lesiones y evaluar el desempeño de los clasificadores mediante pruebas de funcionamiento

La inteligencia artificial ofrece herramientas con la capacidad para analizar información multimedia sobre pruebas médicas relacionadas con el historial clínico del paciente con el fin de brindar diagnósticos certeros junto con las labores que realizan los profesionales especialistas. En este sentido, los procedimientos de los modelos de aprendizaje computacional y de extracción de información propuestos en la investigación se presentan a continuación.

3.3.1 DenseNet121

DenseNet121 (*Red Convolutiva Densa*) es un tipo de red convolutiva utilizada para la extracción de información de las imágenes que incorpora bloques densos y de capas de transición, en donde la mejora del flujo de información entre capas l^{th} se realiza mediante un patrón de conectividad que agrega conexiones directas desde una capa hacia las siguientes como se muestra en la figura 16. Por ello, los mapas de características x_0, \dots, x_{l-1} se consideran como entrada $x_l = H_l([x_0, x_1, \dots, x_{l-1}])$, donde $[x_0, x_1, \dots, x_{l-1}]$ hace referencia a la concatenación de los mapas de características obtenidos de las capas $0, \dots, l - 1$. La función compuesta H_l se define por las operaciones en normalización por lotes (BN), una unidad lineal rectificadora (ReLU) y una red de convolución de dimensión 3x3 [64].

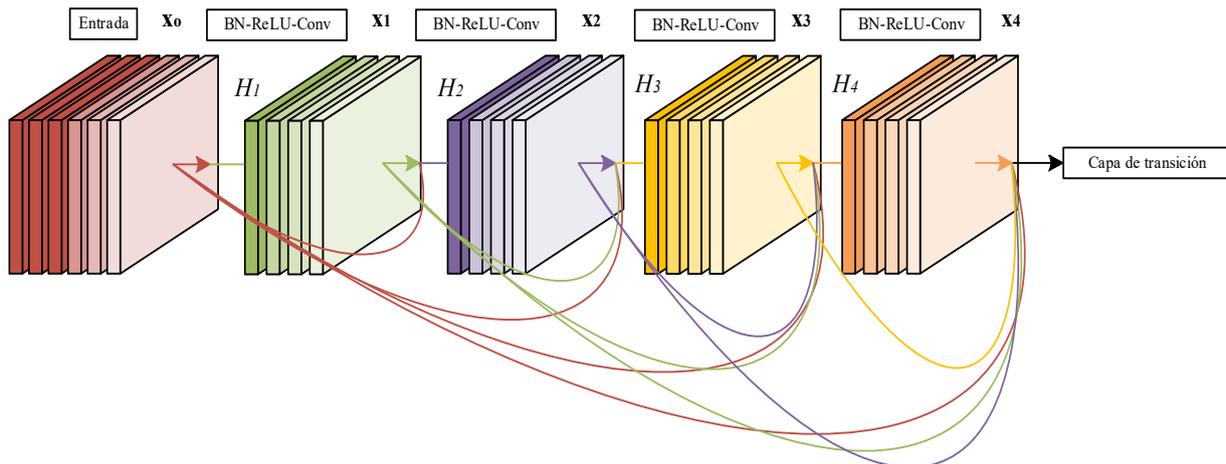


Figura 16. Arquitectura de la red convolucional profunda DenseNet121

Por otra parte, en el muestreo descendiente del tamaño de los mapas de características se divide la red densa en bloques múltiples conectados, específicamente a las capas entre bloques y las capas de transición, las cuales realizan la agrupación y convolución. Las capas de transición constan de una capa de normalización por lotes y una capa convolucional de tamaño 1×1 , seguidas por una capa de agrupación media 2×2 . Por lo general, cada función H_l puede producir k mapas de características, en donde la l -ésima capa contiene $k_0 + k * (l - 1)$ mapas de características provenientes de la entrada. El factor k_0 hace referencia en el número de canales presentes en la capa de entrada y k es el hiperparámetro de la tasa de crecimiento de la red. Las capas añaden k mapas de características propias de cada estado y la tasa de crecimiento determina la cantidad de información que añade cada capa al conjunto global. En adición, es posible mejorar la capacidad del modelo reduciendo el número de características m en la capa densa de transición dejando que la capa siguiente de transición genere $\lceil \theta * m \rceil$ mapas de características a la salida, donde $0 < \theta \leq 1$ se reconoce como el factor de compresión.

3.3.2 Análisis de componentes principales (PCA)

La técnica para Análisis de Componentes Principales (PCA) se aplica para reducir y compactar las dimensiones de las componentes presentes de una imagen a causa de acelerar los procesos siguientes de clasificación y entrenamiento de modelos de aprendizaje [65]. La figura 17 representa la forma iterativa en que se extrae los pares de componentes, en donde la

componente principal n representa la dirección de la máxima varianza, y la componente principal $n + 1$ hace referencia a la dirección perpendicular con respecto a la primera componente.

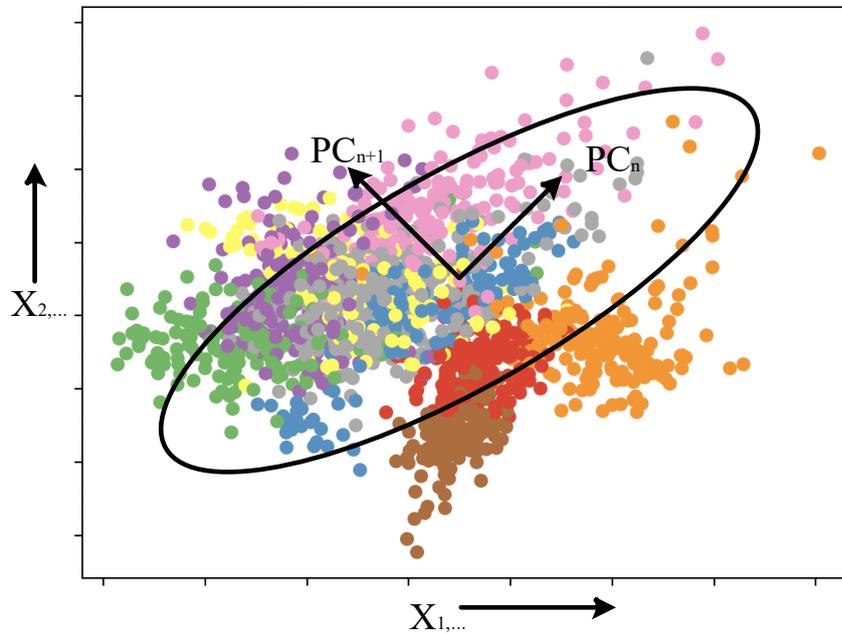


Figura 17. Ilustración de la extracción de los pares de componentes principales

La reducción de componentes comienza con la representación de la imagen en el espacio de color RGB con la separación de cada uno de los canales que integra la imagen [66]. Posterior de la separación de los canales, se genera un datagrama de datos para cada canal y se normaliza entre valores de 0 y 1 como se representa en la ecuación 18.

$$Df_{R,G,B} = \frac{1}{255} \begin{pmatrix} d_{11} & d_{12} & d_{1\dots} & d_{1n} \\ d_{21} & d_{22} & d_{2\dots} & d_{2n} \\ d_{\dots} & d_{\dots} & d_{\dots} & d_{\dots} \\ d_{n1} & d_{n2} & d_{n\dots} & d_{nn} \end{pmatrix} \quad (18)$$

Una vez se tiene la imagen con los canales separados, se representa un vector Y que describe la imagen, y se define por $Y = [Y_1, Y_2, Y_3 \dots Y_n]$, lo cual permite conformar la imagen como se describe en la ecuación 19 y aplicar una transformación a cada datagrama normalizado que pasa de 3 a 2 valores, siendo este último referencia al número de componentes a los que se reduce

la imagen [67]. Finalmente, se devuelve la imagen combinando los canales rojo, verde y azul, y se obtiene la imagen multicanal.

$$\begin{aligned} \text{Image}(Y) = & (Y_1)(\text{Pixel } 1) + (Y_2)(\text{Pixel } 2) + (Y_3)(\text{Pixel } 3) \\ & + \dots (Y_n)(\text{Pixel } n) \end{aligned} \quad (19)$$

Por otra parte, la covarianza entre dos variables se relaciona con la medida de la correlación, en donde todos los valores de covarianza posibles entre m variables y su diagonal contienen todas las varianzas [68]. La ecuación 20 presenta la matriz de covarianza, en la que X es el conjunto de datos y \bar{x} es el vector medio.

$$\begin{aligned} C_Y = & \frac{1}{n-1} \sum_{i=1}^n (X - \bar{x})^T (X - \bar{x}) \\ \bar{x} = & \frac{1}{n} \sum_{i=1}^n x_i \end{aligned} \quad (20)$$

Considerando que $\lambda_1, \dots, \lambda_l$ son los valores representativos de la matriz de covarianza C_Y con $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_l$, Y_i representa la proporción de la variación total explicada por cada uno de los componentes principales que contienen la mayor parte de la información (varianza) y se representa de la forma mostrada en la ecuación 21.

$$Y_i = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \dots + \lambda_l} \quad (21)$$

3.3.3 XGBoost

El algoritmo XGBoost (Refuerzo Extremo del Gradiente) se presenta como una mejora de la técnica de Árbol de Decisión de Gradiente (GBDT) que incorpora clasificadores débiles con el fin de generar un clasificador con robustez mediante el modelo de árbol regresivo de clasificación añadiendo arboles de forma continua que dividen las características para hacer crecer el árbol y aprender una nueva función ajustable según la última predicción [69]. Según la característica que presente la muestra, en cada árbol caerá un nodo de hoja correspondiente

y una puntuación sumada para obtener el valor de predicción de la muestra, tal como se muestra en la figura 18.

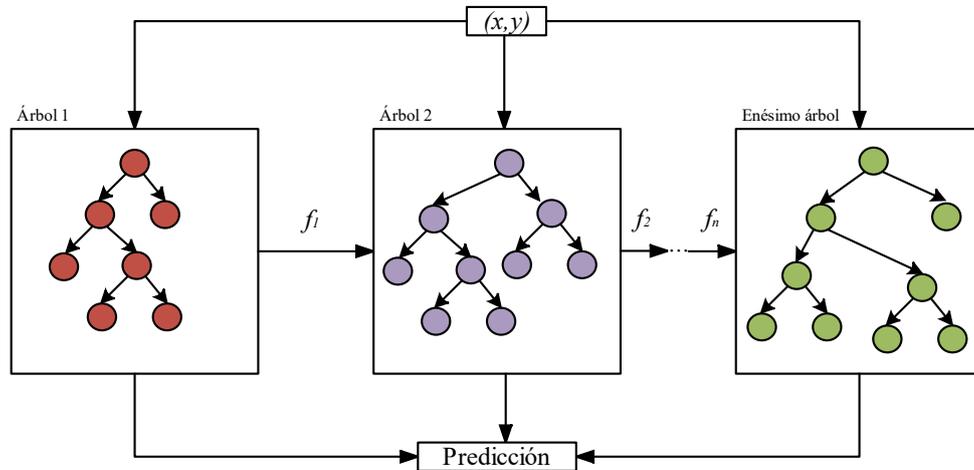


Figura 18. Representación gráfica del algoritmo de aprendizaje y clasificación XGBoost

El modelado que representa el valor de predicción del modelo se presenta en la ecuación 22, donde $f_t(x_i)$ es el valor de predicción del enésimo árbol residual para el enésimo residuo x_i , y_i es el valor de predicción del modelo, f_t es el número de residuos en la enésima iteración y F es el espacio de la función del árbol. En adición, la función objetivo hace relación a los errores de entrenamiento y la dificultad del modelo, definida como se muestra en la ecuación 23, en la que l representa la función de pérdida y Ω es la regularización. Los parámetros de la tasa de aprendizaje, el número de árboles reforzados y el factor gamma se fijaron en 0.1, 1000 y 0.05 respectivamente.

$$\hat{y}_i = \sum_{t=1}^T f_t(x_i), f_t \in F \quad (22)$$

$$obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (23)$$

3.3.4 Evaluación de los métodos de aprendizaje

La validación del algoritmo híbrido en términos de rendimiento se pondera frente a los métodos de inteligencia computacional PCA + SVM, GLCM + LightGBM y CNN. La evaluación de las técnicas se realiza a nivel de hardware y software. Para el análisis de hardware, se

consideran los parámetros basados en tiempo de entrenamiento y ejecución, requerimientos en recursos de CPU y memoria RAM. La comparación del software parte del análisis de la matriz de confusión, referenciada como una herramienta de evaluación ampliamente utilizada en los algoritmos de aprendizaje automático, en donde las columnas de la matriz representan los resultados de la clase de predicción y las filas representan los resultados de la clase propiamente verdadera [70]. En adición, la comparación a nivel software se realiza teniendo en cuenta parámetros basados en la exactitud, precisión y F1-score, cuyas ecuaciones 24, 25 y 26 muestran la forma de obtener estos parámetros respectivamente, en donde TP y TN indican los verdaderos positivos y verdaderos negativos, y FP y FN se refieren a los falsos positivos y falsos negativos de la clasificación.

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} \quad (24)$$

$$Precisión = \frac{TP}{TP + FP} \quad (25)$$

$$F1 - score = \frac{2TP}{2TP + FN + FP} \quad (26)$$

La exactitud hace referencia al porcentaje de muestras totales que son correctas. La precisión indica la proporción de detecciones positivas que realmente fueron correctas. Finalmente, el parámetro F1 – score combina las métricas de precisión y sensibilidad en una única métrica, definida como la media armónica. En adición, se plantea el uso la métrica Curva Operativa del Receptor (ROC) que presenta el rendimiento de las técnicas de aprendizaje sobre todos los umbrales de clasificación basados en la Tasa de Verdaderos Positivos (TPR) y la Tasa de Falsos Positivos (FPR), cuyas representaciones matemáticas se muestran en las ecuaciones 27 y 28.

$$TPR = \frac{TP}{TP + FN} \quad (27)$$

$$FPR = \frac{FP}{FP + TN} \quad (28)$$

El objetivo de la clasificación se centra en obtener una TPR alta y una baja FNR para detectar eficientemente los verdaderos positivos. Asimismo, el Área Bajo la Curva (AUC) se presenta como la medida del espacio bidimensional completo de la curva ROC que indica la probabilidad de que el modelo clasifique una muestra positiva aleatoria más alta que un modelo negativo.

3.3.5 Definición del conjunto de datos de lesiones cutáneas utilizado

Las imágenes utilizadas para la validación tanto del algoritmo híbrido propuesto (DenseNet121 + PCA + XGBoost) como las técnicas PCA + SVM, GLCM + LightGBM y CNN fueron tomadas del conjunto de datos HAM10000 que consta de 10015 imágenes recopiladas por un periodo de 20 años por el Departamento de Dermatología de la Universidad Médica de Viena, Austria, y el Centro de Consulta en Cáncer de piel Cliff Rosendahl en Queensland, Australia. Las imágenes están almacenadas en formato de archivos JPEG, a profundidad de color de 8 bits en calidad 300 DPI, recortadas manualmente y con centro sobre la lesión a resolución de 600x450 px a 72 DPI con correcciones manuales en el histograma para mejora de contraste y reproducción del color. El conjunto de datos incluye categorías de diagnóstico que se encuentran en la práctica clínica en más del 95 % [71].

Las categorías de diagnóstico incluyen las lesiones malignas propuestas por la investigación que son el carcinoma de células escamosas, carcinoma de células basales y melanoma, y como lesiones no malignas contiene imágenes dermatoscópicas de lesiones de tipo dermatofibroma, queratosis seborreica y el nevus melanocito. Según los reportes especificados por el conjunto de muestras más del 50 % de las lesiones cutáneas fueron validadas por histopatología, y las demás fueron sometidas a seguimientos dermatoscópicos durante dos años, a consensos entre dermatólogos expertos o por la evaluación por microscopía confocal in vivo.

3.4 Implementación de una interfaz gráfica de usuario como herramienta de apoyo para el diagnóstico asistido por computador

Para el diseño de las ventanas gráficas orientadas para la verificación de credenciales, caracterización de pacientes y el diagnóstico asistido se hace necesario el entorno Qt Designer, la cual consiste en una herramienta de software basada en el uso de widgets Qt GUI que permite desarrollar interfaces gráficas por medio de la aplicación de múltiples widgets para el control asistido de variables [72]. La codificación se realiza en el lenguaje Python con el paquete PyQt5, y la licencia de la herramienta es bajo código abierto.

Seguidamente, se requiere la identificación de los requisitos del usuario para el diseño e implementación de la interfaz gráfica de usuario. Inicialmente, es necesario proteger la información personal proporcionada a la herramienta. Por ello, se requiere de una etapa de validación de credenciales para ingresar al sistema. Del mismo modo, se hace necesario incluir una etapa de caracterización para individualizar a cada uno de los pacientes, en donde la información proporcionada se debe enviar a un archivo de hoja de cálculo en tiempo real. La interfaz de diagnóstico para la identificación y clasificación de lesiones cutáneas a través de imágenes requiere que el profesional especialista adapte y segmente la imagen mediante objetos deslizadores, y determine el tamaño del kernel del filtro de suavizado a aplica sobre la imagen. Del mismo modo, se dispondrá la posibilidad de que el médico dibuje a mano alzada la región de interés de la lesión que considere y someta a diagnóstico.

La identificación de tareas involucra que el especialista se conecte a la herramienta validando sus credenciales para ingresar a la etapa de caracterización en la que introduce la información allí requerida para individualizar al paciente y la almacena en la hoja de cálculo. Posteriormente, ingresa a la interfaz de diagnóstico la cual le permite introducir la imagen de entrada al sistema y da la autonomía de utilizar los deslizadores para segmentar la imagen a su criterio, aplicar el filtrado de suavizado mediante deslizadores en el caso de que la imagen

contenga vello corporal, y si se hace necesario podrá dibujar la región de interés que considere según su criterio.

Por otra parte, en la figura 19 se muestra la estructura de composición de la herramienta de diagnóstico asistida por computador. En la primera interfaz asociada al control de acceso, se definen tres secciones denominadas *Presentación*, *Entrada de datos* y *Controles*. Para la *Presentación*, se requieren seis elementos etiquetas para descripciones y cuatro etiquetas para representación de logos. Mientras que, para *Entrada de datos*, se requieren dos elementos de cajas de texto. Por último, en la sección de *Controles*, se requieren dos botones: el primero para acceder a la GUI de caracterización y el segundo para salir de la interfaz gráfica.

Del mismo modo, en la GUI de caracterización, se definen tres secciones: *Presentación*, *Entrada de datos* y *Controles*. En *Presentación*, se requieren 16 elementos de etiquetas descriptivas y 4 para representación de logos, en la sección de *Entrada de datos* se requieren 15 elementos en cajas de texto para introducir información. En la sección de *Controles*, se emplean 4 botones utilizados para exportar información, ingresar a la interfaz de diagnóstico, ayuda y créditos.

Finalmente, para la GUI de diagnóstico de lesiones cutáneas, se establecen 5 secciones: *Presentación*, *Visualización*, *Controles*, *Paciente* y *Diagnóstico*. En *Presentación*, se definen 17 elementos en etiquetas para indicaciones y 4 para representar logos. En la sección de *Visualización*, se definen dos elementos etiquetas, donde la primera es para visualizar la lesión de entrada, y la segunda etiqueta se utiliza para visualizar la imagen resultante del procesamiento. En la sección de *Controles*, se emplean cuatro deslizadores utilizados para variar el umbral, el tamaño del filtro, umbral de bordes y la iteración de la dilatación. Los botones restantes se emplean para cargar la imagen, dibujar la región de interés y seleccionar el método de umbral, ya sea por umbralización binaria o adaptativa. Mientras que, en la sección *Paciente*, se utilizan 6 etiquetas para presentar la información básica del paciente. Finalmente,

en la sección *Diagnóstico*, se utilizan 2 etiquetas para presentar el resultado.

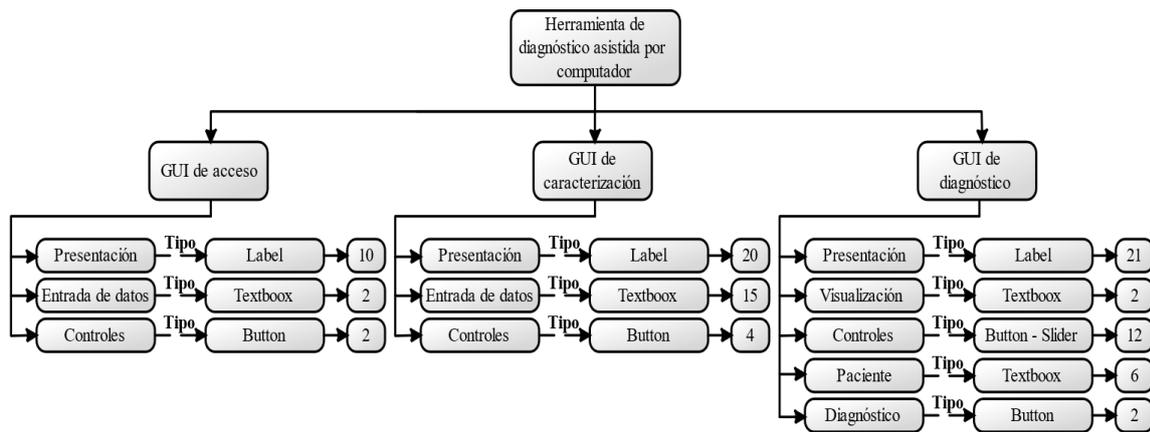


Figura 19. Elementos que integran la estructura de la herramienta de diagnóstico asistido por computador

La validación de la interfaz gráfica de usuario se relaciona con los principios de la usabilidad, referida al grado en que un producto de software pueda ser utilizado por usuarios directos para alcanzar los objetivos específicos con eficiencia, efectividad y satisfacción [73]. La usabilidad involucra la definición de objetivos que se enuncian a continuación. La *facilidad de aprendizaje* hace referencia a la capacidad de operar el sistema a cierto nivel de competencia definido después de un periodo determinado de entrenamiento. *Eficacia*, relacionada con la medición cuantitativa en cómo el usuario alcanza el objetivo de la tarea. El *recuerdo en el tiempo* es el atributo que relaciona el recuerdo acerca de cómo funciona el sistema cuando vuelve a usarlo en un largo periodo de tiempo. La *tasa de errores* indica los errores cometidos por el usuario cuando realizaba una determinada tarea. Finalmente, la *satisfacción* muestra la impresión que el usuario considera del sistema.

4. Resultados

En esta sección, se muestran los resultados obtenidos en la implementación del algoritmo híbrido denso para mejora de características, extracción y reducción de componentes y clasificación de lesiones cutáneas presentados en cuatro etapas: documentación de literatura y selección de herramientas, técnicas de tratamiento digital de imágenes y validación, diseño del algoritmo híbrido propuesto y pruebas de rendimiento e implementación de la herramienta de diagnóstico asistido por computador.

4.1 Documentación de literatura y selección de herramientas

Para la documentación del estado del arte sobre avances en la detección y diagnóstico de cáncer de piel, se presenta en la tabla 4 la búsqueda condensada y delimitada de algoritmos de aprendizaje y herramientas de diagnóstico asistidas por computador, cuyos trabajos fueron realizados después del 2016, obteniendo así la muestra de diez proyectos en trabajos de investigación de repositorios de alto impacto de la literatura científica. Las abreviaturas ACC, PRE, SE, SP y AUC se refieren a la exactitud, precisión, sensibilidad, especificidad y área bajo la curva obtenidos en las investigaciones consultadas respectivamente. Se observa la tendencia hacia la aplicación de algoritmos de aprendizaje profundo en la mayoría de los trabajos de investigación, en donde el aprendizaje profundo presentó resultados en problemas de clasificación con tasas de exactitud superiores al 91 %. Sin embargo, el enfoque del diagnóstico se centró en identificar y clasificar las imágenes de las lesiones a partir de categorías binarias y no se dictó en clasificar la similitud en la apariencia de las lesiones sobre las categorías en específico [74]. De hecho, se consideró únicamente como maligno el cáncer de piel melanoma al utilizar el conjunto de muestras PH2 adquiridas por el servicio dermatológico del Hospital Pedro Hispano, Matosinhos, Portugal, omitiendo las lesiones producidas por el cáncer de piel carcinoma, tal es el caso de [17]. Otro factor influyente es la calidad de los conjuntos de datos para entrenamiento y la validación de los modelos [75]. De ahí que los repositorios ISIC y

HAM1000 se postulan como una fuente de características para los modelos de aprendizaje para los problemas de clasificación al incluir mayores representaciones en el ámbito de lesiones pigmentadas con las respectivas variantes de los mismos [76].

Tabla 4. Documentación del estado del arte relacionado al tema de investigación

Autor	Diagnóstico	Fuente de datos	Modelos	Resultados obtenidos
[15]	Categorías de diagnóstico de la base de datos	HAM10000	AlexNet VGG16 ResNet	ACC: 74 %, 69.36 %, 72 %
[16]	Benigna Premaligna Maligna	DermNet Dermis DermatoWeb ISBI 2016	VGG19	ACC: 85.71 %. PRE: 91.41 %
[17]	Benigno melanoma	PH2 Otras fuentes	ANN	PRE: 98.2 %. SE: 98 %. SP: 98.2 %
[18]	Benigno Maligno	Interactive Atlas of Dermoscopy	SVM	ACC: 94 %. PRE: 92.9 %. SE: 90 %. SP: 96 %
[20]	Benigno Maligno	ISIC 2016	DRN CNN U-Net	PRE: 76 %. SE: 82 %. SP: 62 %
[21]	BCC Queratosis benigna Dermatofibroma Melanoma SCC	Imágenes propias de una clínica especializada de cáncer de piel en Queensland, Australia	CNN	SE: 80.5 %. SP: 53.5 %
[22]	Nevus Melanoma	PH2	Puntuación ABCD	SE: 97.5 %. SP: 62.5 %
[77]	Melanoma Carcinoma Benignas	Repositorio ISIC y datos del hospital de Stanford	InceptionV3	PRE: 72.1 ± 0.9 %. AUC ≥ 91 %
[23]	Benigno Maligno	SIIM-ISIC	ResNet34 Random forest	ACC: 92.1 %, 85.6 %. PRE: 92.3 %, 83.2 %. SE: 92 %, 88.5 %. SP: 92.3 %, 83.2 %
[24]	Benigno Maligno	Repositorio ISIC HAM10000	MobileNet V1	ACC: 91 %. PRE: 90.1 %. SE: 91.98 %. SP: 90.3 %

Para la selección de parámetros comparativos de tecnologías de software se obtuvo el peso de cada uno, los cuales están descritos en la tabla 5.

Tabla 5. Peso de los parámetros a comparar para la selección de software

	A	B	C	D	E	Suma	Factor
A	X	1	1	5	1	8	0.17
B	1	X	5	5	1	12	0.26
C	1	1/5	X	10	1	12.2	0.27
D	1/5	1/5	1/10	X	1/10	0.6	0.01
E	1	1	1	10	X	13	0.29

Según la tabla 5, el parámetro de mayor influencia en la selección fue la especialidad para inteligencia artificial con un 29 %, seguido por 27 % y 26 % tanto para la disponibilidad de paquetes como la capacidad de integración. Con valores inferiores comparados con los anteriores, con 17 % y 1 %, tipo de la licencia y conectividad con ofimática representaron los factores de menor relevancia de la comparación.

Por consiguiente, cada uno de los parámetros comparados se proponen como referencia para la comparación entre las alternativas de software. En la tabla 6, se muestra la comparación respecto a la gratuidad o valor de licencia del software.

Tabla 6. Comparación de herramientas de software respecto al tipo de licencia

	Python	M	Java	C++	Suma	Factor
Python	X	10	5	5	20	0.61
M	1/10	X	1/5	1/5	0.5	0.01
Java	1/5	5	X	1	6.2	0.19
C++	1/5	5	1	X	6.2	0.19

En la tabla 7, se muestra la comparación en la capacidad de integración con entornos de desarrollo.

Tabla 7. Comparación de herramientas de software respecto a la capacidad de integración con entornos de desarrollo

	Python	M	Java	C++	Suma	Factor
Python	X	5	5	1	11	0.44
M	1/5	X	1	1/5	1.4	0.06
Java	1/5	1	X	1/5	1.4	0.05
C++	1	5	5	X	11	0.45

En la tabla 8, se muestra la comparativa respecto a la disponibilidad de paquetes y librerías.

Tabla 8. Comparación de herramientas de software respecto a la disponibilidad de paquetes y librerías

	Python	M	Java	C++	Suma	Factor
Python	X	1	5	5	11	0.60
M	1	X	1	1	3	0.16
Java	1/5	1	X	1	2.2	0.12
C++	1/5	1	1	X	2.2	0.12

Del mismo modo, en la tabla 9 se muestra la comparación respecto a la conectividad con ofimática.

Tabla 9. Comparación de herramientas de software respecto a la conectividad con ofimática

	Python	M	Java	C++	Suma	Factor
Python	X	1	1	1	3	0.25
M	1	X	1	1	3	0.25
Java	1	1	X	1	3	0.25
C++	1	1	1	X	3	0.25

En la tabla 10, se muestra la comparativa de herramientas de software respecto a la especialidad para inteligencia artificial.

Tabla 10. Comparación de herramientas de software respecto a la especialidad para inteligencia artificial

	Python	M	Java	C++	Suma	Factor
Python	X	1	1	5	7	0.32
M	1	X	1	5	7	0.32
Java	1	1	X	5	7	0.32
C++	1/5	1/5	1/5	X	0.6	0.04

Posterior a la comparación de las herramientas de software respecto a cada parámetro, se procedió a la obtención de la matriz final de selección mediante el producto entre el factor obtenido en cada comparación y el peso obtenido por el parámetro en la tabla 5. A continuación, se muestra la matriz de decisión respectiva.

Tabla 11. Matriz de decisión para la elección de la herramienta de software

	A	B	C	D	E	Suma
Python	0.104	0.114	0.162	0.003	0.090	0.473
M	0.002	0.016	0.043	0.003	0.090	0.154
Java	0.032	0.013	0.032	0.003	0.090	0.170
C++	0.032	0.114	0.032	0.003	0.008	0.219

Como se observa en la tabla 11, con el 47.3 %, Python fue seleccionada como la herramienta de software utilizada para la implementación de la investigación. Además, C++ y Java con 21.9 % y 17 % fueron las herramientas que representan el segundo y tercer lugar respectivamente, mientras que con el 15.4 %, lenguaje M se ubicó en la última posición en la selección, según las necesidades de la propuesta.

Para la elección de la herramienta de hardware, se obtuvo el peso de los parámetros a comparar definidos y mostrados en la tabla 12.

Tabla 12. Peso de los parámetros a comparar para la selección de hardware

	A	B	C	D	E	Suma	Factor
A	X	5	5	1	1	12	0.33
B	1/5	X	5	1	1	7.2	0.20
C	1/5	1/5	X	1/5	5	5.6	0.15

D	1	1	5	X	1	8	0.22
E	1	1	1/5	1	X	3.2	0.10

Con el 33 %, la velocidad de procesamiento representó el parámetro de mayor importancia en la selección, seguido por 22 % y 20 % correspondientes a la velocidad de procesamiento gráfico y cantidad de memoria RAM; así mismo, con 15 % los lenguajes de programación soportados es el cuarto parámetro de consideración en la selección. Con valor inferior de 10 %, el precio y disponibilidad fue el aspecto de menor relevancia en la comparación. En la tabla 13, se muestra la comparación según la velocidad de procesamiento.

Tabla 13. Comparación de herramientas de hardware respecto a la velocidad de procesamiento

	Raspberry Pi 4B	Jetson Nano	PocketBeagle	Nexys 3	Suma	Factor
Raspberry Pi 4B	X	1	5	5	11	0.39
Jetson Nano	1	X	5	5	11	0.39
PocketBeagle	1/5	1/5	X	5	5.4	0.19
Nexys 3	1/5	1/5	1/5	X	0.6	0.03

En la tabla 14 se visualiza la comparación realizada en relación a cantidad de memoria RAM.

Tabla 14. Comparación de herramientas de hardware respecto a la cantidad de memoria RAM

	Raspberry Pi 4B	Jetson Nano	PocketBeagle	Nexys 3	Suma	Factor
Raspberry Pi 4B	X	5	5	5	15	0.48
Jetson Nano	1/5	X	5	5	10.2	0.33
PocketBeagle	1/5	1/5	X	1/5	0.6	0.02
Nexys 3	1/5	1/5	5	X	5.4	0.17

Del mismo modo, en la tabla 15 se observa la comparación de las herramientas de hardware, según los lenguajes de programación soportados.

Tabla 15. Comparación de herramientas de hardware según los lenguajes de programación soportados

	Raspberry Pi 4B	Jetson Nano	PocketBeagle	Nexys 3	Suma	Factor
Raspberry Pi 4B	X	1	1	10	12	0.34
Jetson Nano	1	X	1	10	12	0.34
PocketBeagle	1	1/10	X	10	11.1	0.31
Nexys 3	1/10	1/10	1/10	X	0.3	0.01

En la tabla 16, se muestra la comparación realizada entre las herramientas de hardware, según la velocidad de procesamiento gráfico.

Tabla 16. Comparación de herramientas de hardware respecto a la velocidad de procesamiento gráfico

	Raspberry Pi 4B	Jetson Nano	PocketBeagle	Nexys 3	Suma	Factor
Raspberry Pi 4B	X	1/5	10	10	20.2	0.42
Jetson Nano	5	X	10	10	25	0.53
PocketBeagle	1/10	1/10	X	1	1.2	0.025
Nexys 3	1/10	1/10	1	X	1.2	0.025

Finalmente, en la tabla 17 se visualiza la comparación realizada entre las herramientas de hardware, siendo el precio y la disponibilidad en el mercado la variable de referencia.

Tabla 17. Comparación de herramientas de hardware respecto el precio y la disponibilidad del mercado

	Raspberry Pi 4B	Jetson Nano	PocketBeagle	Nexys 3	Suma	Factor
Raspberry Pi 4B	X	10	5	5	20	0.47
Jetson Nano	1/10	X	1/10	1/10	0.3	0.01
PocketBeagle	1/5	10	X	1	11.2	0.26
Nexys 3	1/5	10	1	X	11.2	0.26

Posterior a la comparación de las herramientas de hardware respecto a cada parámetro, se procedió a la obtención de la matriz final de selección mediante el producto entre el factor obtenido en cada comparación y el peso obtenido por el parámetro en la tabla 18.

Tabla 18. Peso de los parámetros a comparar para la selección de hardware

	A	B	C	D	E	Suma
Raspberry Pi 4B	0.129	0.096	0.051	0.092	0.047	0.415
Jetson Nano	0.129	0.066	0.051	0.117	0.001	0.364
PocketBeagle	0.063	0.004	0.047	0.005	0.026	0.145
Nexys 3	0.010	0.034	0.002	0.005	0.026	0.077

Como puede observarse, con un porcentaje de 41.5 %, el sistema embebido Raspberry Pi 4B fue seleccionado como la herramienta de hardware utilizada en la implementación de la investigación. En segundo lugar, con un porcentaje de 36.4 %, la placa Jetson Nano ocupó el segundo lugar. Además, las tarjetas PocketBeagle y Nexys 3 Spartan 6 con 14.5 % y 7.7 %, fueron las herramientas que ocuparon el tercer y cuarto lugar respectivamente, según las necesidades de la propuesta.

4.2 Técnicas de tratamiento digital de imágenes y validación

De acuerdo a la metodología propuesta, se presenta en primer lugar el algoritmo propuesto que integra las técnicas orientadas al tratamiento y mejora de características en las imágenes cutáneas.

4.2.1 Algoritmo para supresión de vello corporal y segmentación

En la tabla 19 se detalla el algoritmo propuesto para la supresión de vello corporal y segmentación de la región de interés de la imagen para observar en detalle la lesión y destacar los rasgos asociados con la anotación de la enfermedad para la etapa siguiente de extracción y reducción de componentes.

Tabla 19. Algoritmo propuesto para supresión de vello corporal y segmentación de la lesión

1	Importar librerías
----------	---------------------------

2	Cargar la imagen de lesión cutánea
3	Redimensionar la imagen en un tamaño de 224x224 pixeles
4	Representar la imagen en formato RGB en escala de grises mediante (7)
5	Aplicar el algoritmo de Canny para detección de vello corporal
6	Definir el elemento estructural en forma de cruz tamaño 5x5
7	Aplicar $A \oplus B$ con elemento estructural
8	Binarizar la imagen dilatada con umbral $T = 10$
9	Reconstruir la imagen RGB mediante FFM (13)
10	Aplicar filtro de suavizado de mediana con (14)
11	Representar la imagen con suavizado de mediana en escala de grises con (7)
12	Segmentar la región de interés, ya sea por umbralización binaria y adaptativa por Otsu o por la herramienta de lápiz
13	Definir elemento estructural elíptico de tamaño 5x5
14	Aplicar $A \circ B$ con elemento estructural elíptico
15	Buscar contornos representativos de la lesión
16	Si los contornos son detectados:
17	Representar la máscara de los contornos sobre la imagen
18	Invertir color de la máscara
19	Aplicar sustracción de fondo entre la imagen mejorada mediante FFM y la máscara
20	Si no: No lesión

4.2.2 Conversión a escala de grises

En las figuras 20a, 20b y 20c se muestran imágenes dermatoscópicas tomadas de la base de datos HAM10000 correspondientes a las lesiones no malignas de tipo nevo, dermatofibroma y queratosis seborreica. Del mismo modo, las figuras 20d y 20e muestran lesiones cutáneas malignas producidas por carcinoma y melanoma. En las figuras 20a, 20b, 20c, 20d y 20e se presenta la conversión a escala de grises de dichas imágenes.

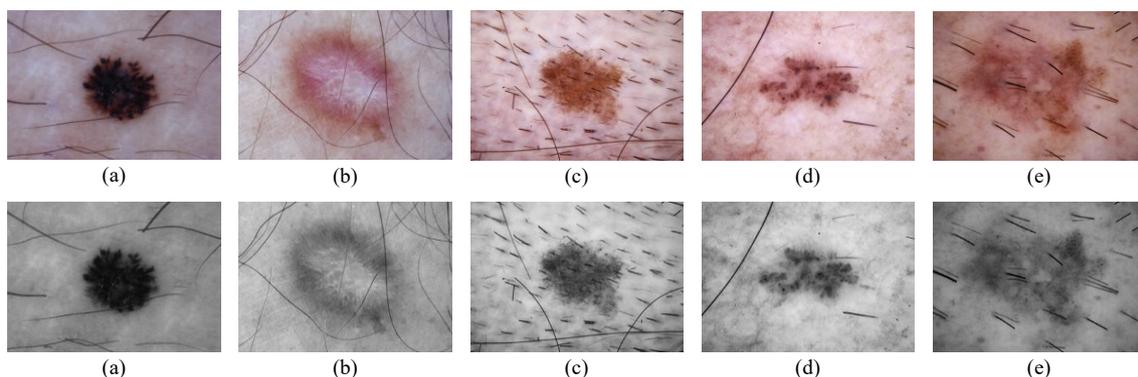


Figura 20. Transformación a escala de grises a las imágenes de muestra

A continuación, se presentan los resultados obtenidos en los procesos de detección de vello corporal mediante el algoritmo Canny, aplicación de filtro morfológico de dilatación y

umbralización del vello corporal de la imagen, reconstrucción de la imagen, aplicación del filtro de mediana y segmentación de la lesión.

4.2.3 Detección de vello corporal mediante el algoritmo Canny

En la figura 21 se observa la detección de bordes representado en ruido por vello corporal mediante el operador Canny que integra etapas de reducción de ruido, operador gradiente, supresión, y umbralización por método de histéresis sobre cada tipo cada lesión cutánea. Con esto, el vello corporal presente fue extraído en la forma de borde de la imagen.

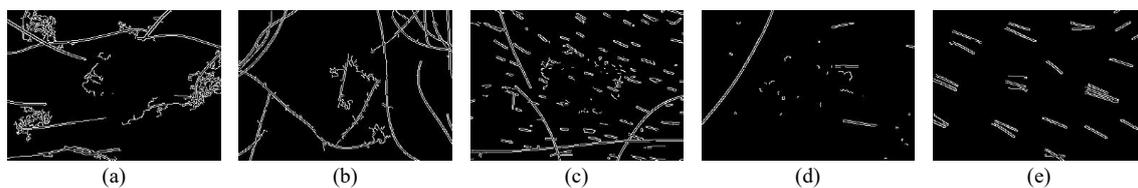


Figura 21. Detección de ruido producido por vello corporal mediante el algoritmo Canny

4.2.4 Aplicación de dilatación morfológica y binarización del vello corporal

Los vellos detectados por el operador Canny se filtraron por la operación de apertura, combinando un elemento estructural en forma de cruz de tamaño 5×5 . En adición, las imágenes filtradas por el operador de apertura se binarizan en función de un umbral de $T = 10$. En la figura 22 se observa la aplicación de los procesos de la morfología de apertura y umbralización del ruido producido por vello corporal.

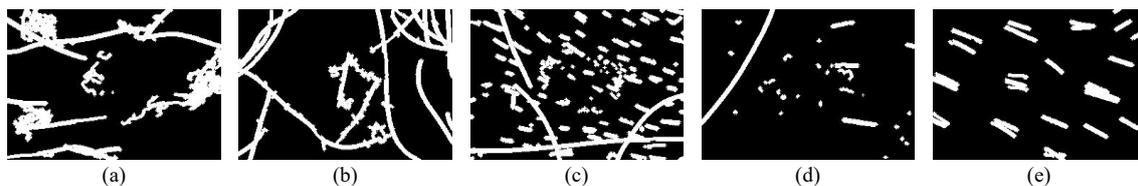


Figura 22. Dilatación morfológica y binarización del vello corporal detectado

4.2.5 Trazado para atenuación del vello corporal en las imágenes para diagnóstico

Se utilizó la técnica de reconstrucción de regiones en imágenes basada en el algoritmo de marcha rápida (FMM) para la mejora de regiones combinando la máscara de los vellos corporales umbralizados en la etapa anterior. La figura 23 se observa las imágenes mejoradas respecto a las clases de lesiones cutáneas.

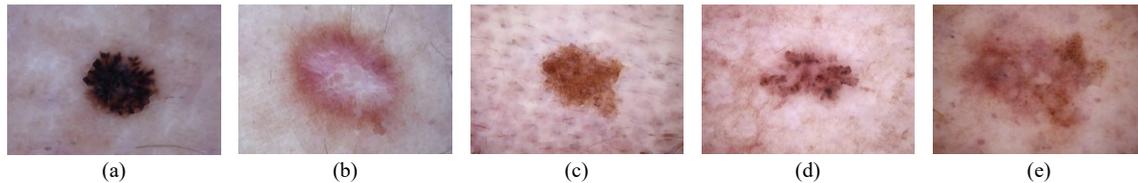


Figura 23. Imágenes de lesiones cutáneas reconstruidas por FMM para supresión del vello corporal

4.2.6 Filtro de suavizado medio

En la figura 24, se observan las imágenes de lesiones cutáneas reconstruidas y filtradas por suavizado de mediana con tamaño de núcleo 3×3 debido al reducido efecto de difuminado sobre la imagen de lesión cutánea. En la figura 24a, 24b y 24c se presentan los resultados sobre las lesiones de tipo nevo, dermatofibroma y queratosis seborreica. Mientras que, en las figuras 24d y 24e se aprecia el efecto sobre las lesiones malignas carcinoma y melanoma.

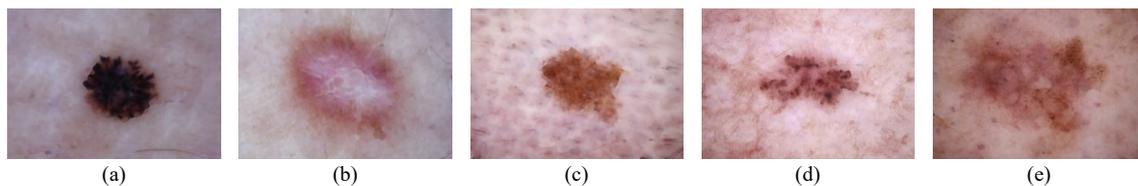


Figura 24. Filtrado de suavizado medio sobre las imágenes reconstruidas

4.2.7 Segmentación de la lesión

La figura 25 presenta el procesamiento para la segmentación de la región de interés de la lesión de la imagen. En la sección a se observa las imágenes filtradas por el filtro de mediana que fueron umbralizadas y procesadas por el filtro morfológico de apertura combinado con elemento estructural en forma elíptica para extraer la lesión del fondo. En adición, la sección b presenta la implementación del método de búsqueda de contornos con aproximación simple para distinción de los bordes. Además, la sección c ilustra la máscara delimitada por la herramienta de dibujo integrada para la segmentación de la región de interés y la sección d presenta la máscara segmentada *ground truth* dada por el conjunto de datos HAM10000.

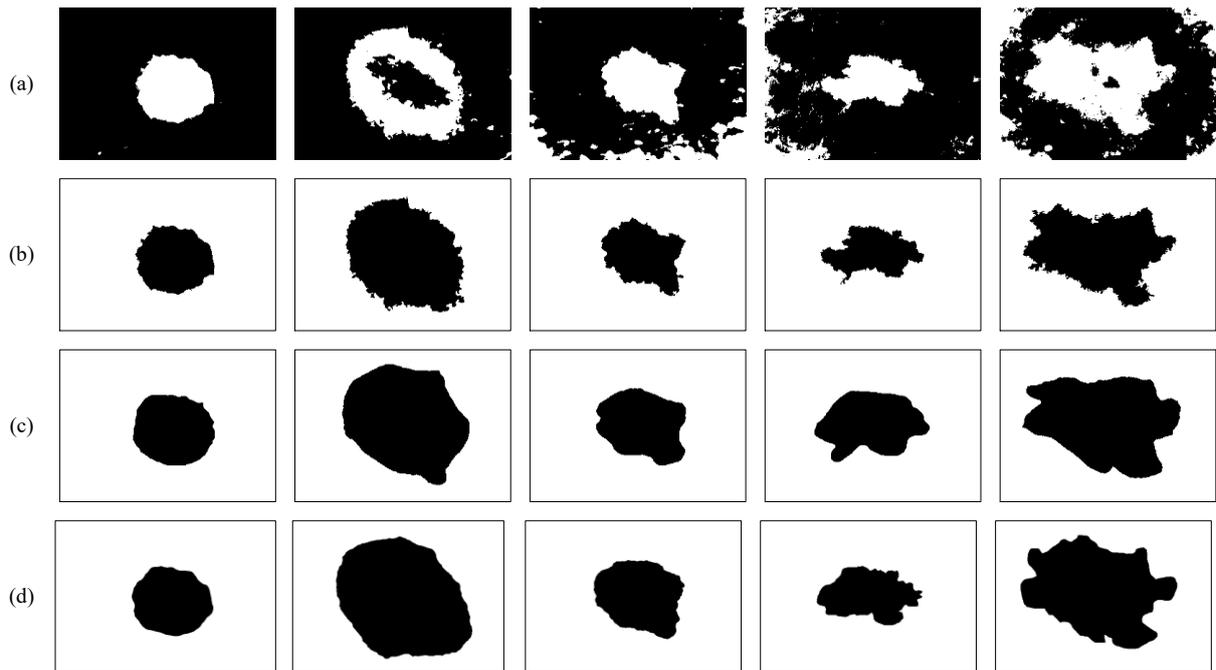


Figura 25. Segmentación de la región de interés de la imagen cutánea

En adición, la sección a y b de la figura 26 presentan la superposición entre la imagen mejorada y las máscaras de la lesión entre la región de interés umbralizada tanto por método de binarización combinado con Otsu como las máscaras obtenidas por la herramienta de lápiz por la herramienta de dibujo.

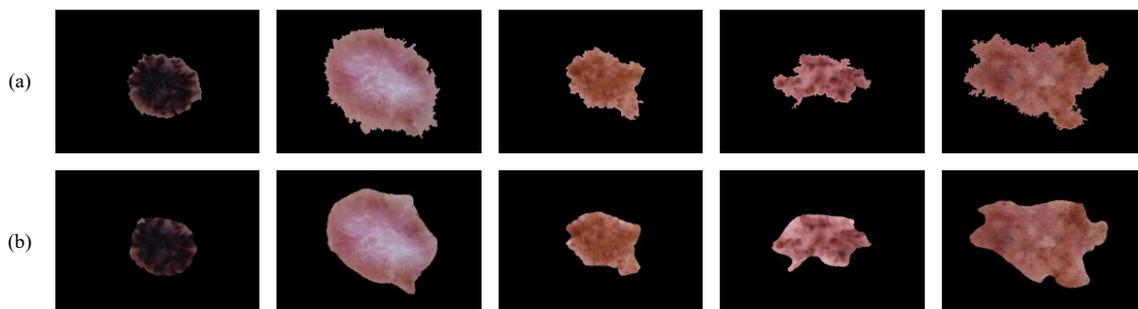


Figura 26. Superposición entre las imágenes mejoradas y las máscaras de la región de interés

4.2.8 Validación de la eliminación del vello corporal y segmentación de la lesión

La figura 27 muestra la proporción de eliminación de vello corporal en las imágenes dermatoscópicas con lesiones cutáneas no malignas y malignas. En el 70 % de las pruebas se alcanzó la eliminación total del vello corporal con una tasa superior al 91.8 %, mientras que en las imágenes procesadas en las que se obtuvo al menos un residuo capilar, la eliminación se logró en una media del 83.183 % del total de vello presente en la imagen.

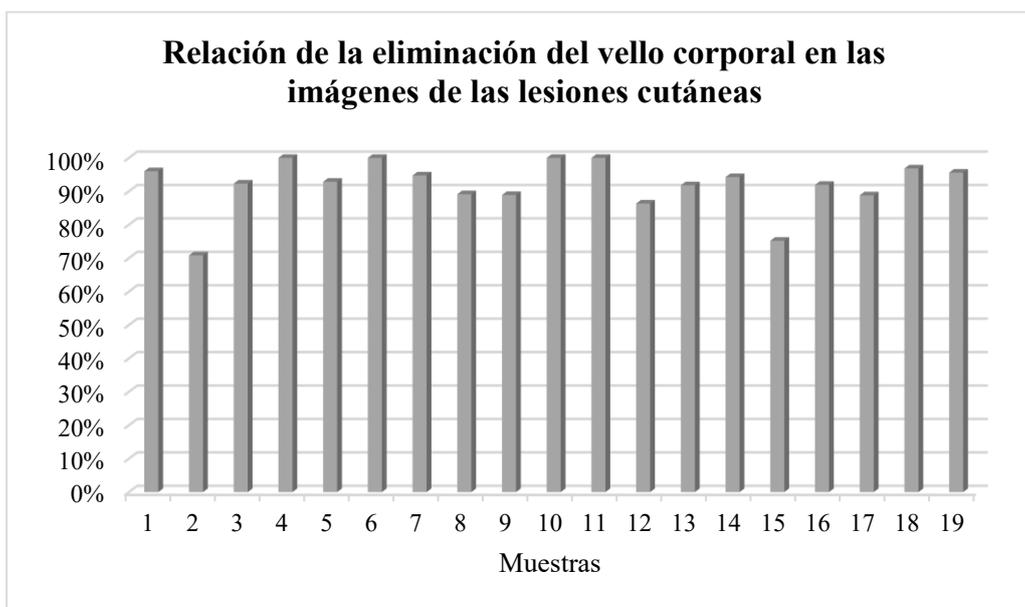


Figura 27. Relación de eliminación de vello corporal en imágenes de lesiones cutáneas

La tabla 20 muestra la comparación en la similitud en la segmentación de la región de interés mediante el índice de Jaccard entre la máscara generada por binarización combinada por Otsu y la obtenida por el dibujo utilizando la herramienta de lápiz integrada. Se presentan los resultados obtenidos con las máscaras binarias procesadas y mostradas en la figura 25, cuyos valores muestran que la efectividad en la segmentación se encuentra entre 0.8428 y 0.9823.

Tabla 20. Validación de los métodos de segmentación de la región de interés

Identificador de imagen de la lesión cutánea		Índice de Jaccard para evaluación de la segmentación de la región de interés	
		Binarización + Otsu	Herramienta integrada de dibujo
No malignas	ISIC 0034295	0.9823	0.9705
	ISIC 0027488	0.8428	0.8578
	ISIC 0024839	0.9328	0.9626
Malignas	ISIC 0024403	0.9508	0.9129
	ISIC 0024323	0.8668	0.8991

4.3 Diseño del algoritmo híbrido propuesto y pruebas de rendimiento

En primer lugar, se presenta la arquitectura del algoritmo híbrido denso para extracción de características y reducción de componentes para la clasificación de la lesión mediante la integración del algoritmo en una herramienta de diagnóstico asistido por computador.

4.3.1 Metodología del algoritmo híbrido denso

La figura 28 presenta la metodología del sistema híbrido denso. El acceso al sistema se representa en primer lugar a través del sistema embebido Raspberry Pi 4B validando las credenciales de acceso, de tal forma, cuando la validación sea correcta, se procede a la caracterización e individualización de los pacientes. Con esto, se accede a la interfaz gráfica de diagnóstico en la que se carga la imagen en el sistema y se somete a los algoritmos orientados en procesamiento de imágenes para mejora de características. Una vez finalizado este proceso, se somete a la extracción de características utilizando el algoritmo DenseNet121 como extractor, siendo previamente organizado el conjunto de datos HAM1000 entre clases de no malignos (1050 imágenes), carcinoma (841 imágenes) y melanoma (1050 imágenes) por el método de retención *Hold-on*, utilizado al presentarse conjuntos de muestras con grandes volúmenes de información. Por consiguiente, se establece la división del 70 % para el entrenamiento y el 30 % para validación y prueba con muestras de datos no vistos por el clasificador. Además, utilizando PCA se reducen las componentes de la imagen para mejorar el rendimiento y se someten al algoritmo de clasificación XGBoost que entrega el diagnóstico de la región de interés de la imagen mediante probabilidades a través de función Softmax, y se envía el informe de diagnóstico final al archivo CSV.

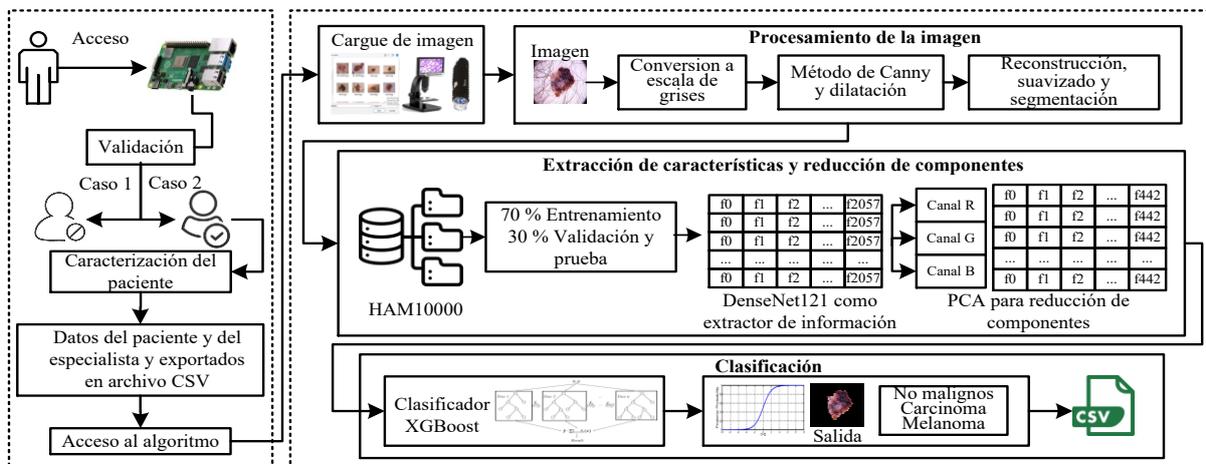


Figura 28. Metodología del algoritmo híbrido denso

4.3.2 Algoritmo híbrido propuesto para extracción de características, reducción de componentes y clasificación de la lesión

En la tabla 21 se presenta el algoritmo híbrido propuesto para extracción de características en las imágenes dermatoscópicas utilizando el modelo DenseNet121 con adición de la reducción a 443 componentes principales mediante la técnica PCA para la clasificación de la lesión cutánea por medio de modelo de aprendizaje XGBoost.

Tabla 21. Pasos secuenciales del algoritmo híbrido propuesto para extracción de características, reducción de componentes y clasificación de la lesión cutánea

1	Importar librerías
2	Cargar la imagen mejorada y segmentada con tamaño de 224x224 pixeles
3	Definir el modelo DenseNet121 como extractor de características
4	Expandir la matriz de la imagen en una tupla de posición en función de las columnas de la imagen
5	Extraer características utilizando DenseNet121
6	Reformar la dimensión de la matriz de una longitud sin alterar sus datos
7	Establecer el número de componentes en función de la proporción de varianza explicada de PCA
8	Reducir las características mediante PCA en la imagen de entrada
9	Cargar el modelo almacenado en un archivo Pickle del clasificador XGBoost previamente entrenado
10	Realizar la predicción sobre el vector de características principales
11	Visualizar el resultado de clasificación

4.3.3 Extracción de características

En la figura 29 se presenta los mapas de características extraídos por el modelo profundo DenseNet121 sobre el conjunto de imágenes HAM1000 que describen las características fundamentales que presentan las imágenes de entrada a partir de la ejecución de procesos basados en convolución y agrupación con la fusión sesgada de un filtro lineal, en donde las capas densas combinadas con las capas de activación representan las características en forma vectorial una dimensión con el fin de acelerar la reducción de componentes y la tarea de clasificación.

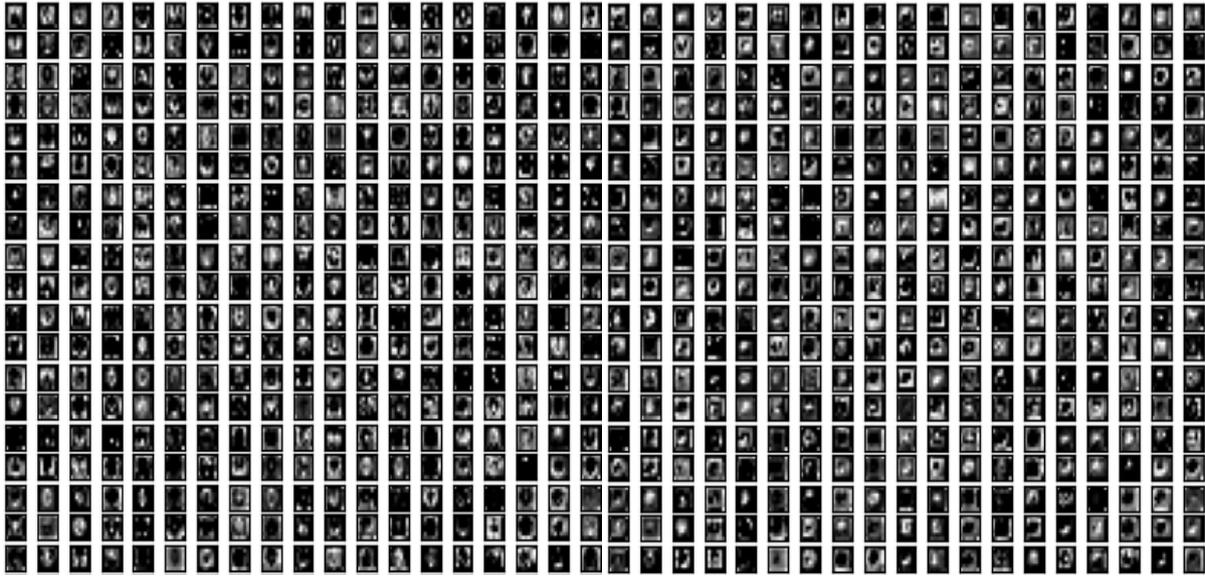


Figura 29. Mapas de características extraídos por DenseNet121

4.3.4 Reducción de componentes

El modelo profundo convolucional DenseNet121 extrajo un máximo de 2058 mapas de características. La figura 30 se presenta la curva de la varianza total explicada en función de las componentes de las imágenes, por la cual se determina el valor de 443 para reducir las 2058 componentes de características originales, debido a que con 443 características reducidas se obtiene el 94.9829 % de la proporción de la variación total explicada.

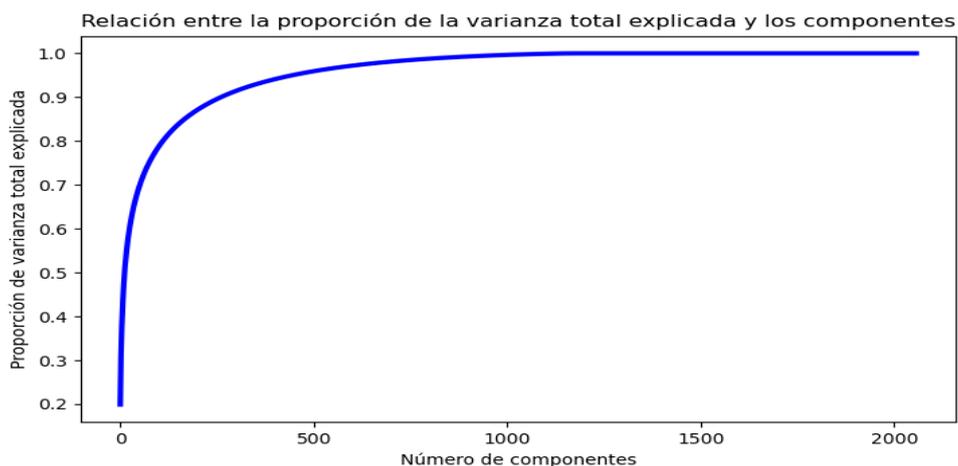


Figura 30. Relación entre la proporción de varianza explicada y el número de componentes

Del mismo modo, la figura 31a presenta la dispersión para el último par de componentes sin reducción, y la figura 31b para el primer y último par de componentes cuando se aplica PCA. Se observa efectivamente la mejora en la distribución al aplicar PCA, ya que, a pesar que en el

último par con 443 componentes se aprecia un solapamiento, este defecto se atenúa con respecto al último par con 2058 componentes, en donde la dispersión se concentra en la región focal con dificultad para identificar las clases.

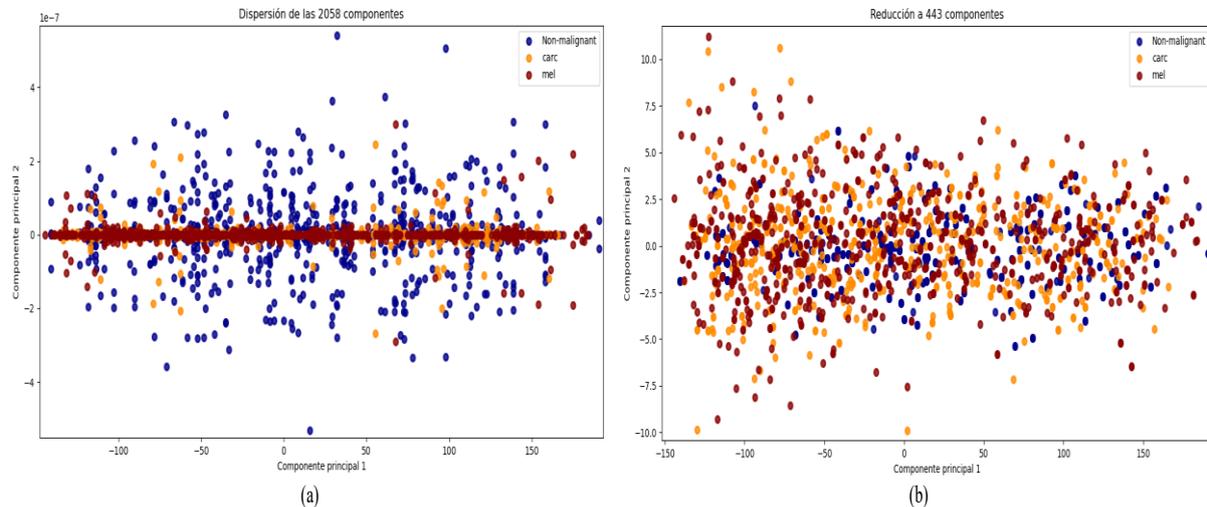


Figura 31. Ilustración de las componentes por cada clase de lesión cutánea

4.3.5 Clasificación de las imágenes

La figura 32 presenta la matriz de confusión obtenida para cada modelo mediante pruebas de clasificación de lesiones cutáneas. De acuerdo con el total de los datos, el 70 % se utilizó para el entrenamiento y el 30 % restante para la validación y prueba. La sección A presenta la matriz resultante al utilizar el modelo híbrido denso propuesto, la sección B presenta la matriz resultante del algoritmo PCA + SVM, mientras que, las secciones C y D presentan las predicciones realizadas por los algoritmos GLCM + LightGBM y CNN. Utilizando el algoritmo híbrido denso sobre cada una de las clases (no malignos, carcinoma y melanoma), el clasificador predijo 317, 215 y 290 imágenes de lesiones de cada clase correctamente como verdaderos positivos. Además, XGBoost clasificó 548, 613 y 544 muestras como valores verdaderos negativos. El clasificador predijo incorrectamente la clase positiva en 17, 23 y 21 imágenes. Finalmente, el modelo híbrido denso predijo incorrectamente la clase negativa en 1, 32 y 28 muestras del conjunto de datos.

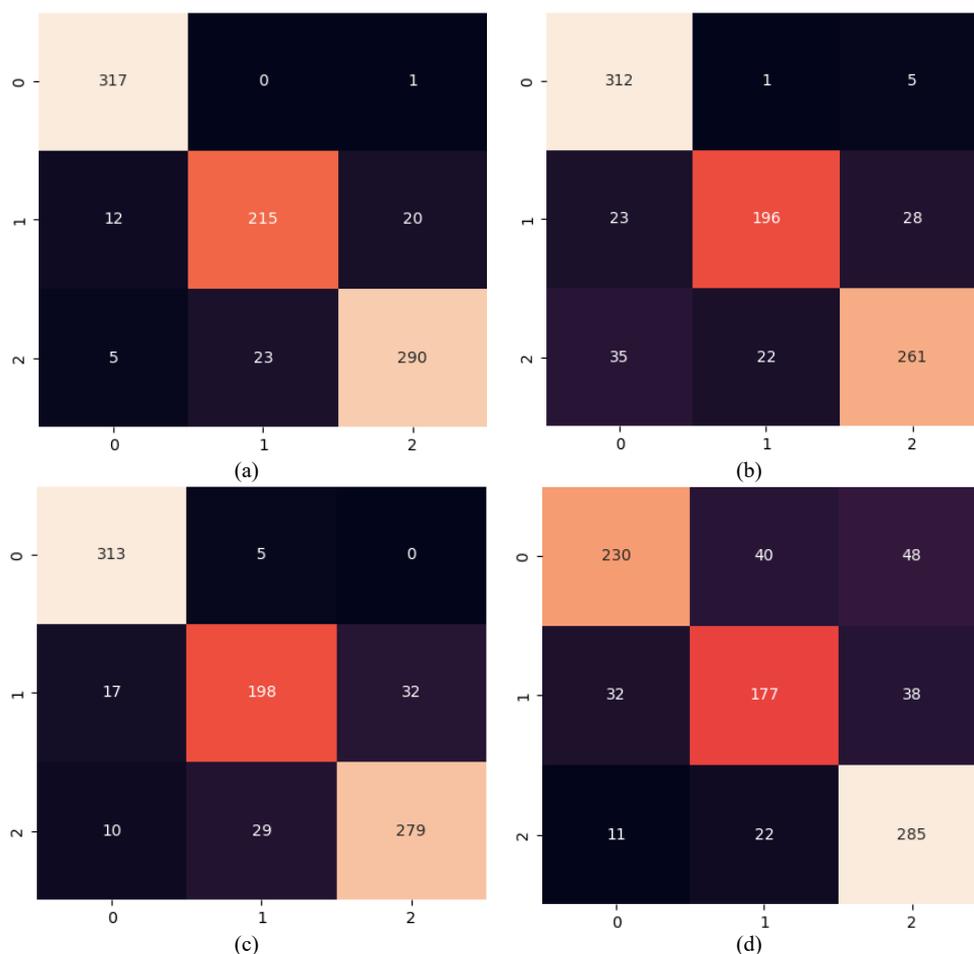


Figura 32. Matriz de confusión obtenidas para el modelo híbrido denso propuesto y las técnicas de comparación

4.3.6 Validación de los modelos mediante parámetros de software y hardware

La tabla 22 presenta los resultados de la comparación en términos de software entre el algoritmo híbrido propuesto y los otros métodos de clasificación, en donde los valores sombreados presentan los mejores resultados obtenidos. Se evidencia que el algoritmo híbrido presentó mejores resultados en precisión, ya que para las clases C1 (no malignos), C2 (carcinoma) y C3 (melanoma) se incrementaron los aciertos en 12.8 %, 8.7 % y 8 % respectivamente. En términos de precisión, el método propuesto presentó robustez al obtenerse mejoras en 10.7 % para C1, 16.2 % sobre la clase C2 y 16.4 % para C3. Así mismo, los valores presentados anteriormente se confirmaron mediante la métrica F1-score que compara y

relaciona las métricas, obteniéndose los valores más altos con un 97.2 %, 88.7 % y 92.2 % para las tres clases.

Tabla 22. Rendimiento del método propuesto en términos de parámetros de software

Método	Exactitud (%)			Precisión (%)			F1-score (%)		
	C1	C2	C3	C1	C2	C3	C1	C2	C3
Algoritmo híbrido denso propuesto	98.0	93.8	94.5	94.9	90.3	93.2	97.2	88.7	92.2
PCA + SVM	92.8	91.6	89.8	84.3	89.5	88.8	90.7	84.1	85.3
GLCM + LightGBM	96.4	90.6	92.0	92.1	85.3	89.7	95.1	82.7	88.7
CNN	85.2	85.1	86.5	84.2	74.1	76.8	77.8	72.8	82.7

La figura 33 presenta las curvas ROC de cada modelo propuesto, en donde (a) se muestran las curvas para el algoritmo híbrido denso, mientras que en (b), (c) y (d) se presentan las curvas ROC obtenidas de PCA + SVM, GLCM + LightGBM y CNN respectivamente.

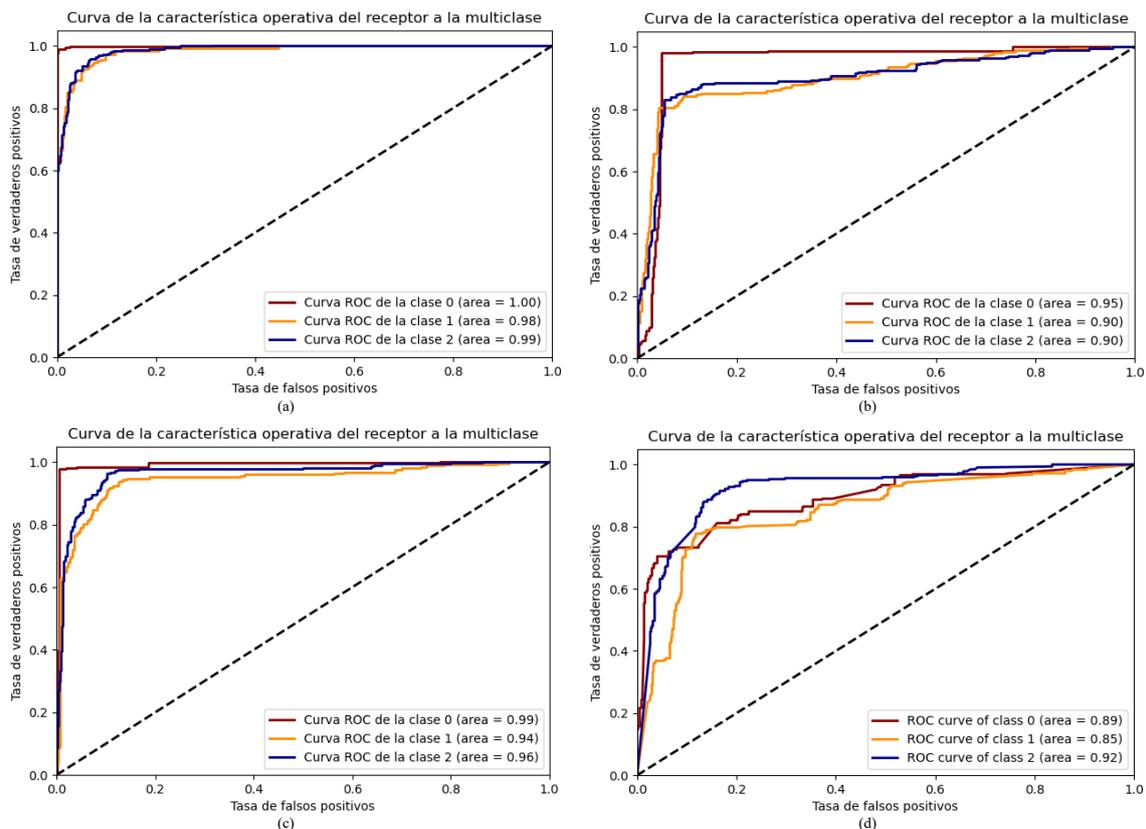


Figura 33. Curva ROC con valor AUC para el algoritmo híbrido denso propuesto y las técnicas de comparación

Del mismo modo, la tabla 23 muestra las tasas de verdaderos positivos y falsos negativos tanto para el algoritmo propuesto y los modelos PCA + SVM, GLCM + LightGBM y CNN respectivamente.

Tabla 23. Tasas de verdaderos positivos y falsos positivos para el algoritmo híbrido propuesto y las técnicas de comparación

Método	Tasa de verdaderos positivos			Tasa de falsos positivos		
	C1	C2	C3	C1	C2	C3
Algoritmo híbrido denso propuesto	0.997	0.870	0.912	0.03	0.036	0.037
PCA + SVM	0.981	0.794	0.821	0.103	0.036	0.058
GLCM + LightGBM	0.984	0.802	0.877	0.048	0.053	0.057
CNN	0.72.3	0.717	0.896	0.076	0.097	0.152

Según los resultados mostrados por las curvas ROC y la tabla 23, el rendimiento del algoritmo híbrido se evidencia por una alta tasa de sensibilidad de 99.7 % para C1, 87 % para C2 y 91.2 % para C3 con valores bajos en las tasas de falsos positivos para cada clase de 0.03, 0.036 y 0.037 para las tres clases, lo que indica que el modelo es estable en determinar de forma eficaz las proporciones positivas de cada una de las clases de lesiones pertenecientes a las clases no malignas, carcinoma y melanoma. En adición, las curvas ROC presentadas en (a) para cada clase se acercan más a la esquina superior izquierda, lo que demuestra la precisión general del modelo híbrido en comparación con los demás algoritmos. Los valores de área bajo la curva medidos y comparados demuestran que el método propuesto presenta mayor desempeño en la identificación de los verdaderos positivos y negativos, reduciendo la incidencia de detecciones de falsos positivos y negativos en la clasificación.

Para comparar el algoritmo híbrido propuesto con otros métodos existentes, se introducen tres trabajos que han reportado sus resultados en la clasificación de lesiones de cáncer de piel, en donde Ahment et al., proponen las arquitecturas ResNet101 y InceptionV3 para

clasificación entre lesiones malignas y benignas contenidas en los repositorios del ISIC-Archive, E. Nasr et al., presentan las redes neuronales convolucionales para la detección de melanoma sobre lesiones del conjunto de datos MED-NODE, y Bonechi et al., exponen la clasificación entre lesiones benignas y malignas (melanoma y carcinomas) del conjunto de datos ISIC utilizando la arquitectura convolucional ResNet50. Los resultados de la evaluación se muestran en la tabla 24, en la cual se aprecia que, con respecto a los métodos utilizados por [78], el algoritmo híbrido denso presenta mejoras de 9.39 % y 15.23 % en la clasificación de lesiones benignas. Sobre las clases malignas, se presenta una exactitud general de 85.66 % y 86 %. Mientras que, con el algoritmo híbrido denso se obtiene 93.8 % y 94.5 % en la clasificación de lesiones malignas (carcinoma y melanoma). Además, se aprecia mejoría del algoritmo híbrido en un 13.5 % en la exactitud respecto a la investigación [79] para la detección de melanoma. Del mismo modo, respecto a [80], el algoritmo híbrido mejoró en 14.56 % la exactitud en la clasificación de benignos y presentó tasas superiores al 93 % de exactitud en clasificar clases malignas por cada clase. La comparativa demuestra que el método propuesto presenta las mayores tasas sobre los parámetros de comparación respecto a los otros métodos del estado del arte, ilustrando la efectividad del algoritmo híbrido denso al integrar métodos de extracción y reducción de características por medio de modelos de aprendizaje y visión computacional.

Tabla 24. Comparación del algoritmo híbrido denso propuesto con la literatura científica

Métodos	Tarea de clasificación	Exactitud en la clasificación
ResNet101-InceptionV3	Malignos y no malignos	ResNet101: 85.66 % y 82.77 % InceptionV3: 86 % y 88.61 %
CNN	Melanoma	81 %
ResNet50	Malignos y no malignos	88.34 % y 83.44 %
Algoritmo híbrido denso propuesto	No malignos, carcinoma y melanoma	98 %, 93.8 % y 94.5 %

En términos de los parámetros de hardware, en la figura 34 se presenta el rendimiento de la Unidad Central de Procesos (CPU) en el entrenamiento tanto del algoritmo híbrido propuesto como los modelos de comparación. Como se muestra, el requerimiento de CPU para el algoritmo híbrido en el equipo ordenador utilizado para el aprendizaje de los modelos fluctúa entre 16.3 % y 76.4 %, lo cual era esperado ya que TensorFlow exige gran cantidad de potencia en el procesamiento y ejecución de operaciones en los núcleos de la Unidad Central de Procesos. Así mismo, dicho requerimiento se encuentra en el rango de 1.9 % y 40.9 % para los modelos PCA + SVM. Para la etapa de aprendizaje y entrenamiento con el conjunto de imágenes ISIC 2018, se requiere entre el 38.5 % y 95.8 % del rendimiento de la CPU usando el algoritmo GLCM + LightGBM. El rendimiento obtenido en demanda CPU usando las CNNs fluctuó entre 64.4 % y 94.3 %.

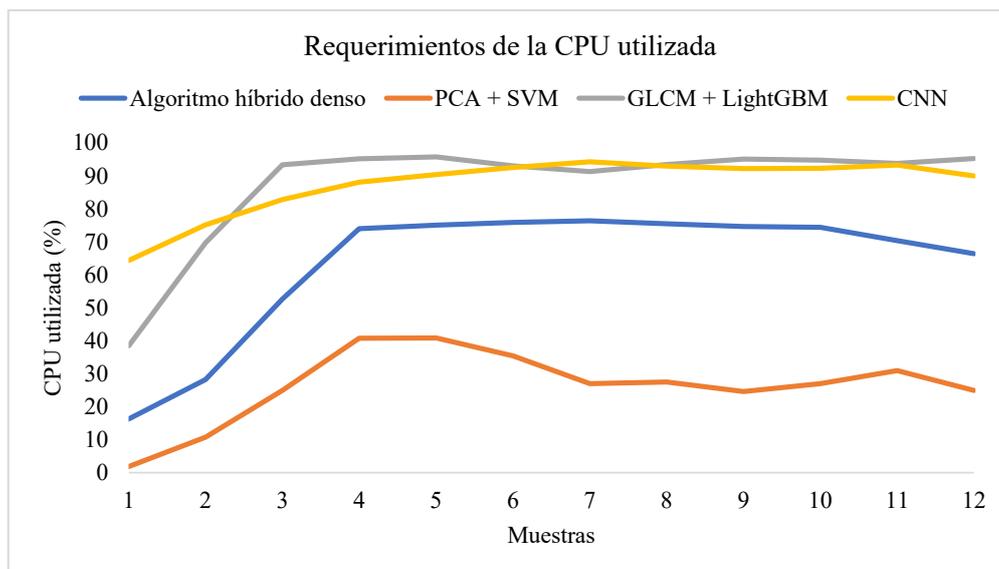


Figura 34. Requerimientos en la Unidad Central de Procesos para aprendizaje y entrenamiento

De igual forma, en la figura 35 se muestra la demanda en memoria RAM en el aprendizaje y entrenamiento con el algoritmo híbrido propuesto y las técnicas computacionales PCA + SVM, GLCM + LightGBM y CNN, en donde se ilustra la demanda reducida con valor promedio de 5.26 % en niveles de almacenamiento temporal de los procesos correspondientes

de la ejecución del algoritmo híbrido, 27.54 % para PCA + SVM, 16.16 % utilizando GLCM + LightGBM y 58.33 % con CNN.

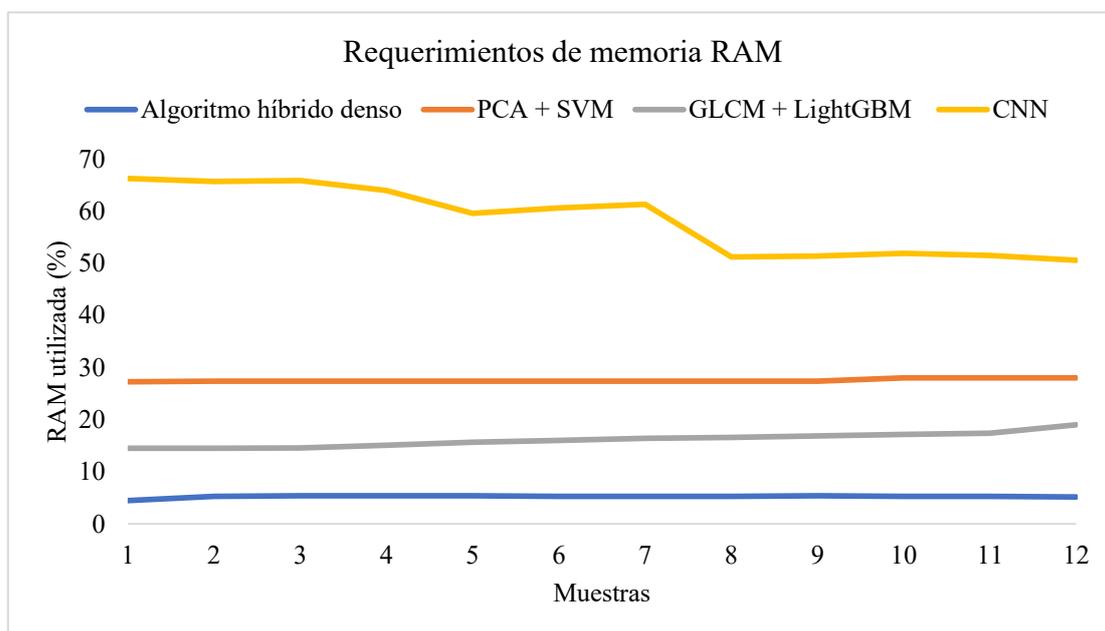


Figura 35. Requerimientos de memoria RAM para aprendizaje y entrenamiento

En términos del tiempo de entrenamiento, el algoritmo híbrido denso requiere un tiempo de entrenamiento de 25.55 segundos en total con las 2058 imágenes. Para PCA + SVM, se requirieron 7.74 segundos para aprendizaje. Mientras que, con GLCM + LightGBM y CNN el entrenamiento con el conjunto de imágenes demoró 35.06 y 665.02 segundos respectivamente. De igual forma, en la figura 36 se presenta el requerimiento sobre la Unidad Central de Procesos en la clasificación de lesiones cutáneas para el algoritmo híbrido denso y los modelos PCA + SVM, GLCM + LightGBM y CNN utilizando el sistema embebido Raspberry Pi 4B. El valor medio obtenido en uso de CPU para el algoritmo híbrido es 4.33 %, utilizando el método PCA + SVM el resultado fue de 6 %. Mientras que, con las técnicas GLCM + LightGBM y CNN, la demanda media obtenida es de 5.92 % y 6.75 % para la clasificación de lesiones no malignas, carcinoma y melanoma.

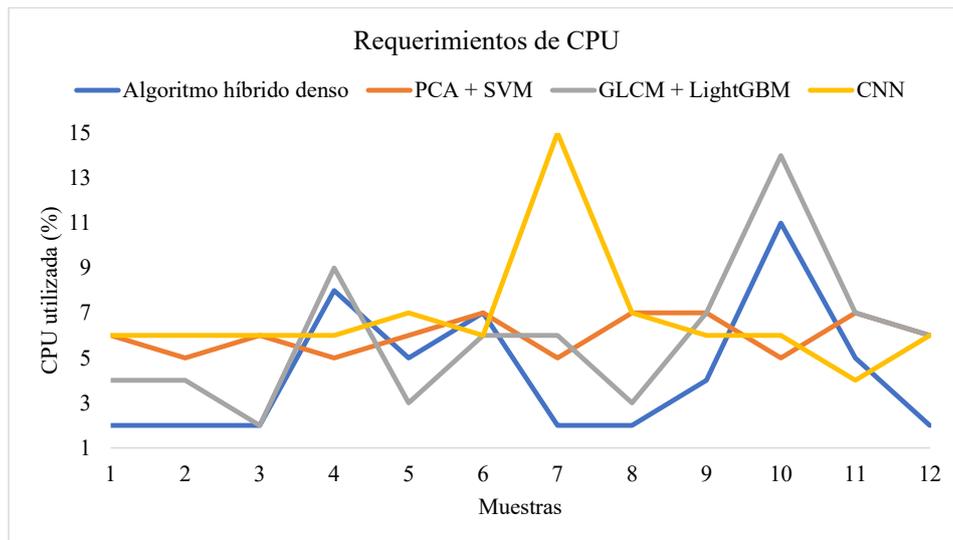


Figura 36. Requerimiento en la Unidad Central de Procesos en la clasificación

Así mismo, en la figura 37 se muestra la tasa de uso de la memoria temporal tanto para el método propuesto y las técnicas propuestas de comparación. Para el algoritmo híbrido, la tasa de utilidad de memoria RAM fluctuó entre 12.39 % y 12.41 %. La técnica PCA + SVM requirió entre 12,27 % y 13,04 %. En consecuencia, la tasa de fluctuación en uso de RAM para clasificación utilizando las técnicas GLCM + LightGBM y CNN presentaron variaciones entre 16.92 % y 26.72 %, y 39.55 % y 41.11 % respectivamente.

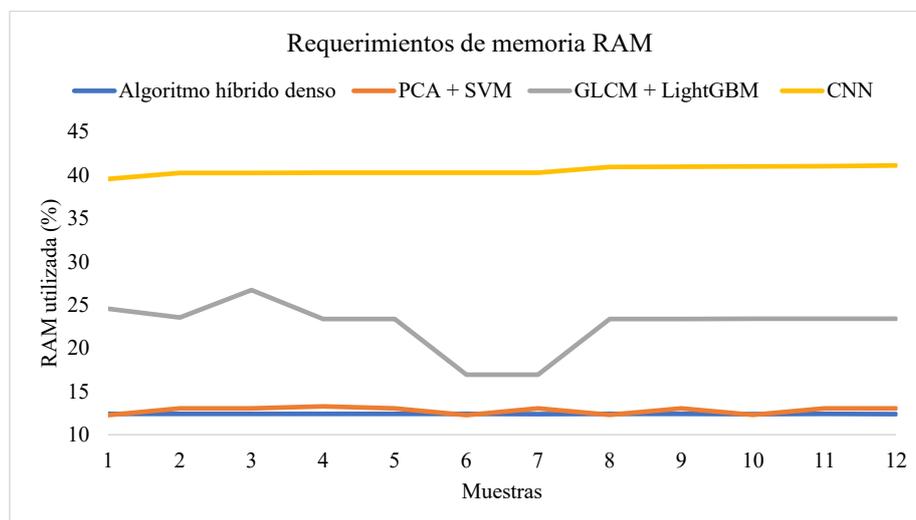


Figura 37. Requerimiento de memoria RAM en la clasificación

Finalmente, la figura 38, presenta el tiempo de respuesta del algoritmo híbrido denso integrado con la metodología propuesta comparado con PCA + SVM, GLCM + LightGBM y CNN para la clasificación de las imágenes mejoradas por las técnicas de procesamiento de

imágenes previamente presentadas. Como se muestra, el tiempo de respuesta del algoritmo híbrido presenta un valor mínimo en 8.46 ms y un máximo en 16,27 ms respectivamente. Para PCA + SVM, los valores presentan un punto mínimo en 22.13 ms y 52.44 ms. Mientras que, GLCM + LightGBM demanda tiempos de ejecución comprendidos entre 141.11 ms y 170.29 ms, y las CNN requieren entre 202.4 ms y 249.55 ms en ejecución para clasificación de imágenes de lesiones cutáneas.

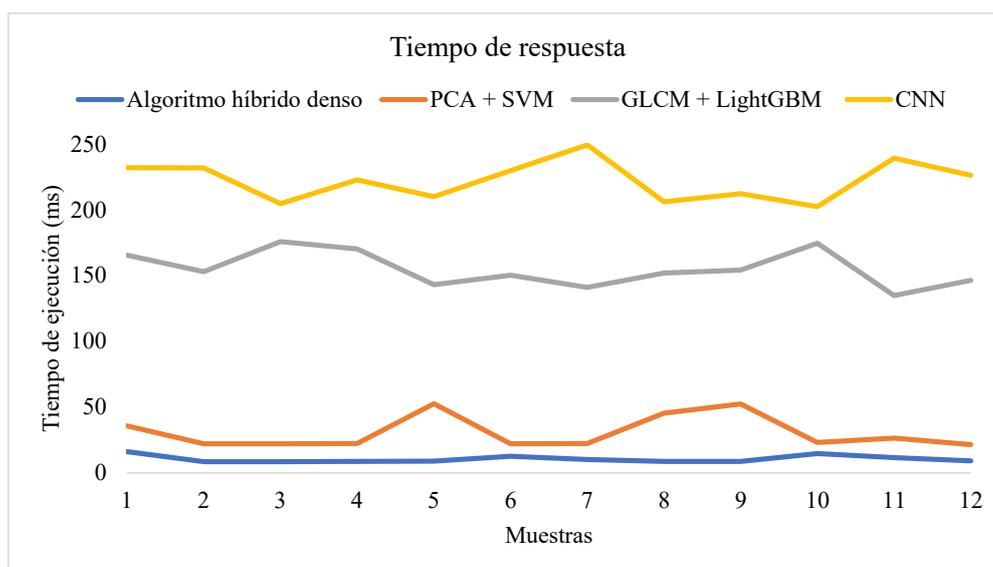


Figura 38. Tiempo de respuesta en la clasificación.

4.4 Implementación de la herramienta de diagnóstico asistido por computador

Una vez evaluado el algoritmo híbrido denso, a continuación, se presenta en diseño e implementación de la herramienta de diagnóstico asistido por computador.

4.4.1 Diseño e implementación de la herramienta de diagnóstico asistido por computador

Posterior a la definición de la lógica de programación de los algoritmos orientados para la mejora de la imagen médica, extracción y reducción de características, y clasificación de la lesión entre no maligna y cancerosa, se utiliza el entorno de diseño de software Qt Designer integrando comandos de PyQt5 orientados a la programación de interfaces gráficas basadas en código abierto para elaborar la aplicación de software bajo la fundamentación de la programación orientada a objetos con propósitos de diseño en forma de una herramienta de

diagnóstico asistido por computador con el objetivo de integrar comandos gráficos con recursos de control programables. Por consiguiente, se presentan las interfaces gráficas mostradas en la figura 39, en donde (a) se incluye la validación de credenciales, en (b) la etapa de caracterización Paciente y en (c) la etapa de diagnóstico asistido.

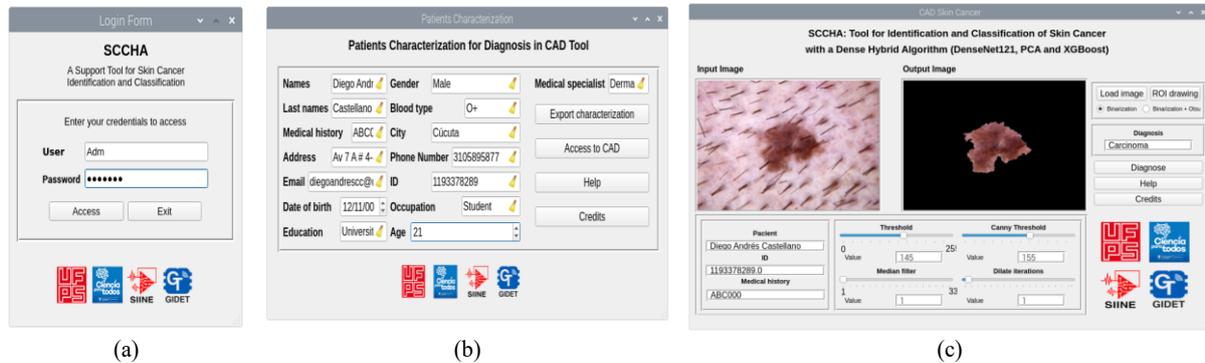


Figura 39. Etapas de la herramienta de diagnóstico asistido por computador

Para la etapa de diagnóstico asistido, se incluye una ventana emergente de manera opcional destinada para dibujar la región de interés en la imagen biomédica cutánea cargada al sistema previamente como se presenta en la figura 40.

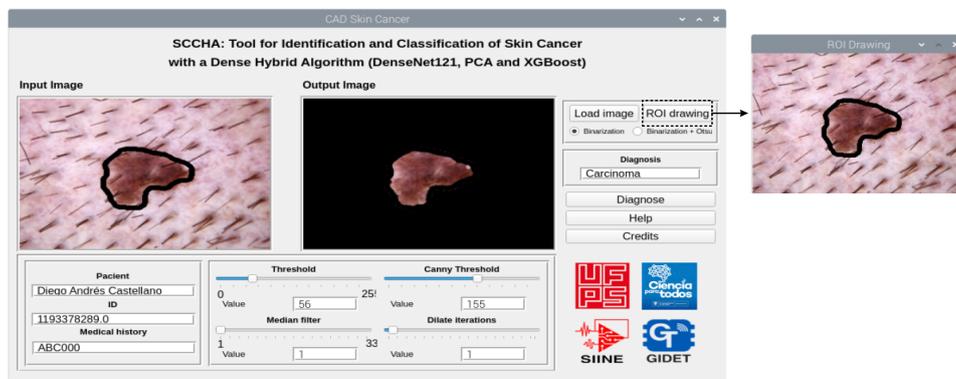


Figura 40. Ilustración de la herramienta de dibujo de la región de interés

4.4.2 Diagrama de casos de uso de la herramienta de diagnóstico asistido por computador

En las figuras siguientes se presentan los diagramas de casos de uso que indican las actividades que pueden realizar los usuarios con la interacción de la GUI. En primer lugar, como se presenta en la figura 41, el operario accede a la aplicación mediante el controlador del

sistema ingresando su usuario y contraseña, en donde se realiza la validación correspondiente de los valores ingresados.

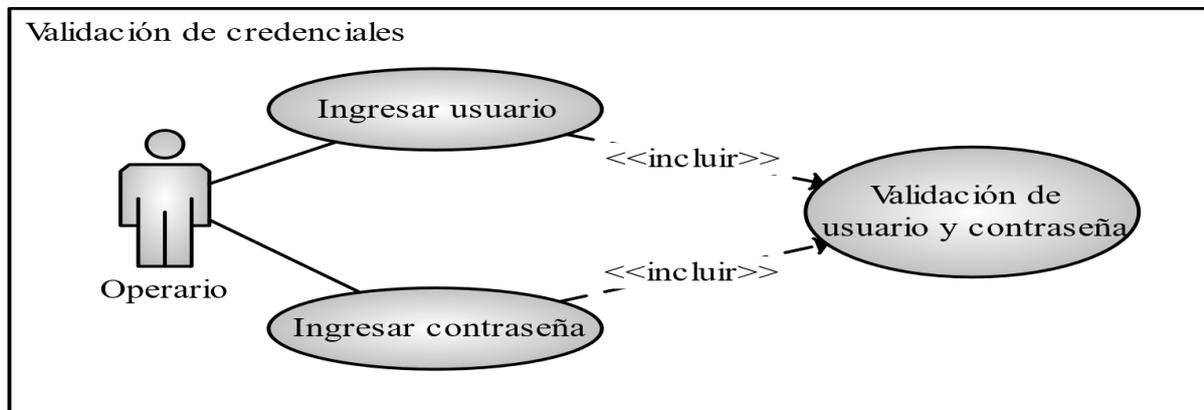


Figura 41. Diagrama de casos de uso para la validación de credenciales

Posterior a la validación de credenciales, se presenta en la figura 42 el diagrama de casos de uso en la etapa de caracterización del paciente. El usuario puede rellenar el formulario de caracterización con la información del paciente potencial relacionando al consolidado el nombre del médico tratante. Una vez realizada la caracterización, el usuario de la herramienta puede exportar la información relacionada del paciente en un archivo CSV y acceder a la interfaz de diagnóstico asistida para la clasificación de la imagen de lesión cutánea. En adición, el usuario dispone de una descripción objetiva de ayuda respecto a la funcionalidad de la interfaz.

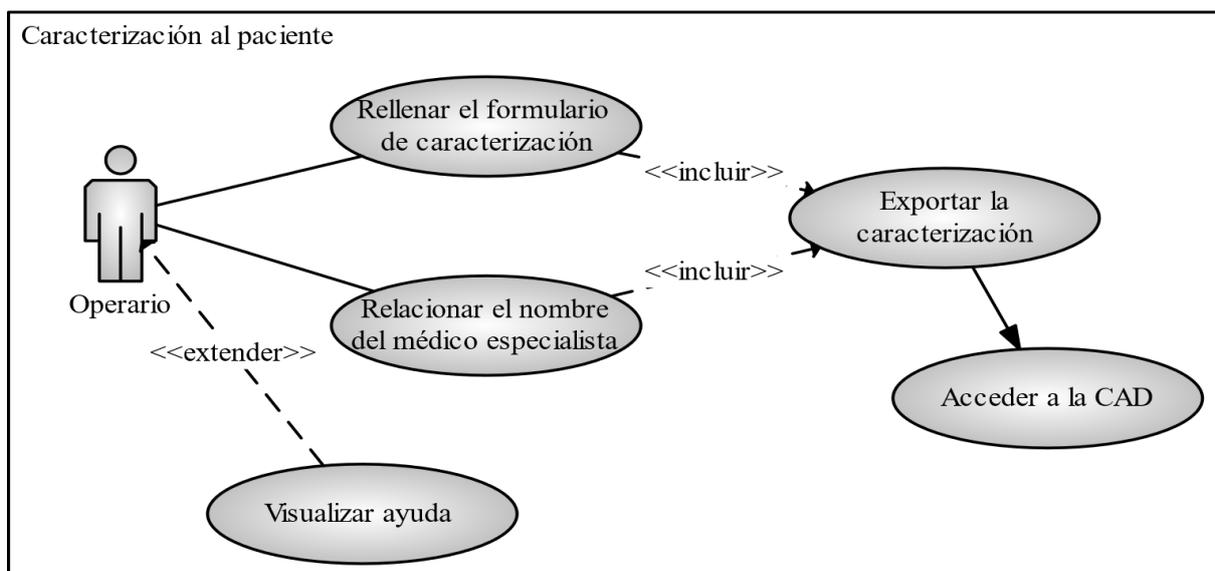


Figura 42. Diagrama de casos de uso para caracterización del paciente

Luego de la etapa de caracterización, se presenta en la figura 43 los casos de uso para la etapa de diagnóstico asistido. El usuario ingresa a la interfaz de diagnóstico y podrá cargar la imagen de lesión cutánea y segmentar la región de interés ya sea por método de umbral o por método combinado por Otsu ajustando por controles el valor de umbral, el tamaño del filtro de suavizado, el umbral de Canny para la detección de vello corporal y las iteraciones del método morfológico de dilatación. Del mismo modo, el usuario, si lo considera, podrá dibujar según su criterio la región de interés en la imagen biomédica cutánea cargada al sistema. La imagen segmentada se somete al algoritmo híbrido propuesto mediante los procesos orientados en la extracción y reducción de características y la clasificación de la lesión cutánea para la visualización por parte del usuario de la herramienta asistida en la predicción del algoritmo. Este mismo, dispone de fuentes textuales descriptivas de ayuda basadas en la funcionalidad de la interfaz dedicada para el diagnóstico.

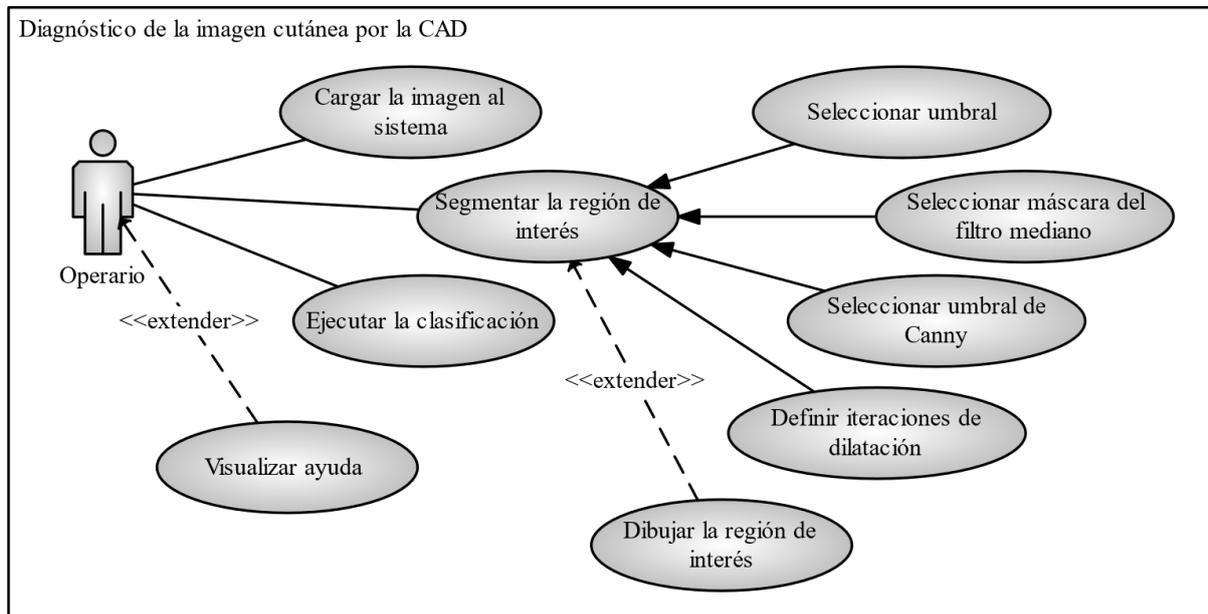


Figura 43. Diagrama de casos de uso para diagnóstico asistido

4.4.3 Arquitectura del sistema

El algoritmo híbrido denso propuesto permite el cargue de la imagen biomédica cutánea y la integración de dispositivos específicos de captura de imágenes dermatoscópicas conectados por puerto USB de la placa embebida Raspberry Pi 4B, la cual se alimenta a un voltaje DC de

5 Voltios. El sistema operativo del sistema embebido es Raspberry Pi OS versión 5.15 programada en lenguaje Python en versión 3.9.7. Las librerías requeridas para el algoritmo son OpenCV versión 4.5.5.62, Numpy versión 1.21.2, TensorFlow versión 2.8.8, Pandas versión 1.3.4, Pickle versión 2.0.0 y Sklearn versión 0.24. Por ello, se realiza la metodología de mejora en procesamiento digital de imágenes, extracción y reducción de características y clasificación de la región de interés a las imágenes cargadas al sistema, visualizando los procesos a través de una pantalla conectada por puerto HDMI de la placa embebida. En la figura 44 se muestra el diagrama que expone la arquitectura del algoritmo propuesto.



Figura 44. Arquitectura de algoritmo híbrido propuesto

4.4.4 Algoritmo propuesto para el diagnóstico de lesiones cutáneas

Se muestra en la figura 45 el algoritmo híbrido denso propuesto integrado en la herramienta de diagnóstico asistido por computador para la mejora de características, atenuación de ruido producido por vello corporal, extracción de características, reducción de componentes y clasificación de la lesión cutánea de la imagen biomédica, integrado en la herramienta de diagnóstico asistido por computador.

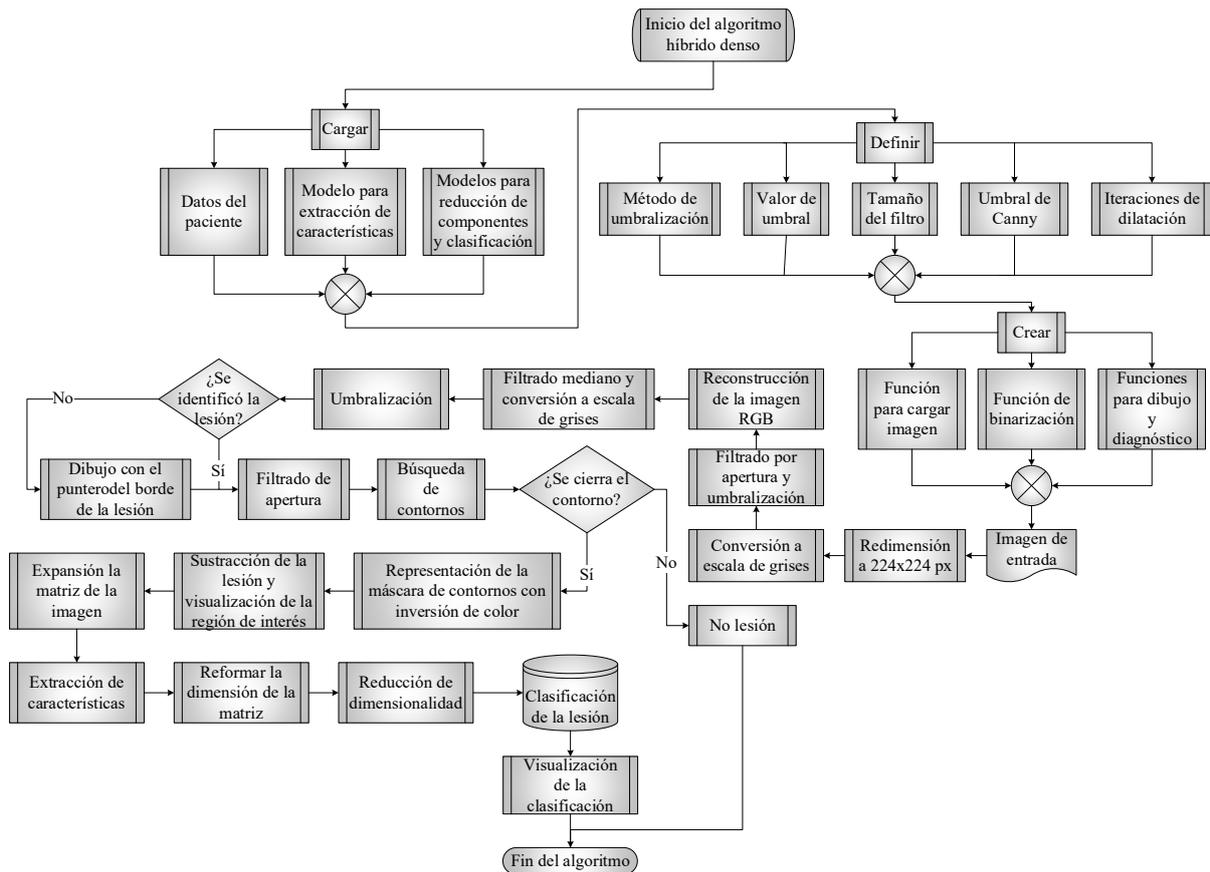


Figura 45. Algoritmo híbrido denso propuesto para el diagnóstico asistido por computador

4.4.5 Validación del algoritmo híbrido denso y la herramienta de diagnóstico bajo criterios de usabilidad

Para la validación del software y la interfaz gráfica de usuario diseñada bajo los criterios de usabilidad, se presenta en el anexo 1 el instrumento de evaluación que consta de 15 preguntas diseñadas en Escala de Likert con el fin de determinar el valor de conformidad, aceptación y concordancia en función de la usabilidad del algoritmo híbrido denso integrado en la interfaz gráfica de usuario. Los potenciales evaluadores y usuarios de la interfaz corresponderán a especialistas del sector médico y biomédico. En consecuencia, se hace necesario el convenio específico de cooperación investigación entre la Universidad Francisco de Paula Santander y VHM INGENIERÍA SAS que tiene como fin establecer los términos y condiciones para cada una de las partes en validar el software de diagnóstico asistido por computador de cáncer de

piel propuesto por el proyecto de investigación. El anexo 2 presenta en detalle el documento de acuerdo.

4.4.6 Divulgación de resultados a la comunidad académica y científica

Los resultados conseguidos de la implementación de la presente propuesta de investigación fueron presentados a la comunidad académica y científica de la siguiente manera:

- Sustentación preparatoria en clase de las asignaturas “Fibra Óptica”, “Medios de Transmisión” y “Procesamiento Digital de Señales” a estudiantes de séptimo, noveno y décimo semestre de Ingeniería Electrónica (Ver anexo 3).
- Ponencia en modalidad oral titulada “Body hair noise suppression in skin lesions by differential operator and maximum variance threshold between classes” en el 2° Congreso Internacional de Ingeniería Biomédica y Bioingeniería (CI-IB&BI). (Ver anexo 4).
- Ponencia en modalidad oral titulada “Edge-Preservation Operator and Elliptical Structural Elements for ROI Identification in Dermoscopic Images” en el Congreso Anual de Ingeniería Biomédica. (Ver anexo 5).
- Ponencia en modalidad oral titulada “Impact of Smoothing Filters on Computer-Aided Diagnostic Tools” en el 8° Congreso Internacional de Innovación y Apropiación de las Tecnologías de la Información y las Comunicaciones. (Ver anexo 6).
- Ponencia en modalidad oral titulada “Component Dimensionality Reduction in Dermoscopic Images using a Machine Learning Technique with Validation By Similarity Metrics” en la 7° Conferencia Internacional para la Convergencia en Tecnología. (Ver anexo 7).
- Publicación en la revista científica “Ingeniería y Competitividad” de la Universidad del Valle del artículo científico titulado “An approach to edge detection in medical imaging through histogram analysis and morphological gradient”. (Ver anexo 8).

- Publicación en la revista científica “Eco matemático” de la Universidad Francisco de Paula Santander del artículo científico titulado “Detección de placas vehiculares mediante modelo de clasificador en cascada basado en lenguaje Python”. (Ver anexo 9).
- Publicación en la revista científica “Ingeniería y Desarrollo” de la Universidad del Norte del artículo científico titulado “Alternative for indoor occupancy estimation based on image processing on embedded system”. (Ver anexo 10).
- Envío del artículo para evaluación en la revista científica “Embedded System Letters” editada por IEEE Council on Electronic Design Automation del artículo científico titulado “HASCC: A Hybrid Algorithm for Skin Cancer Classification”. (Ver anexo 11).
- Notificación de aceptación para publicación en la revista científica “Eco matemático” de la Universidad Francisco de Paula Santander del artículo científico titulado “Preliminary Identification of Skin Lesions using Efficient Computational Learning Techniques”. (Ver anexo 12).
- Publicación del artículo de conferencia en la base de datos del conocimiento “IEEE Xplore” titulado “Body hair noise suppression in skin lesions by differential operator and maximum variance threshold between classes”. (Ver anexo 13).
- Aceptación de publicación del artículo de conferencia en la base de datos del conocimiento “IEEE Xplore” titulado “Component Dimensionality Reduction in Dermoscopic Images using a Machine Learning Technique with Validation By Similarity Metrics”. (Ver anexo 14).
- Envío de documentación para registro de software “ROI SkinLesionEnhancement, software para el realce de características de regiones de interés de lesiones cutáneas en imágenes dermatoscópicas”. (Ver anexo 15).

- Envío de documentación para registro de software “BHNS SkinLesion, software para la eliminación del ruido por vello corporal en lesiones cutáneas de imágenes dermoscópicas”. (Ver anexo 16).
- Envío de documentación para registro de software “PatientCPy, software con interfaz gráfica de usuario para la caracterización de pacientes con uso potencial en herramienta de diagnóstico asistido por computador”. (Ver anexo 17).
- Manual de usuario del Software SCCHA. (Ver anexo 18).
- Manual técnico del Software SCCHA. (Ver anexo 19).

5. Conclusiones

El tratamiento digital de imágenes como etapa inicial del algoritmo híbrido denso propuesto contribuyó en primer lugar en la mejora de las características de la lesión cutánea y en la atenuación de ruido producido por vello corporal, ya que al tomar el vello como un borde de la imagen permitió la distinción de los mismos mediante el algoritmo de Canny, reduciendo así el efecto un factor superior al 91.8 % sobre imágenes con abundante pelo fino sobre la lesión en el 70 % de las muestras.

El procesamiento anterior acompañado con la umbralización combinada entre binaria y adaptativa con la disposición de dibujo de la región de interés demostró la capacidad de replicar lesiones de pigmentación y tamaños diferentes, alcanzando índices de Jaccard cercanos al 0.99 y 0.98 en la preservación y similitud de la región de interés sobre la lesión respecto a su ground truth dado por el conjunto de datos.

El algoritmo propuesto presentó mejoras tanto a nivel de hardware como de software respecto a los métodos evaluados de forma independiente. En términos de hardware sobre el sistema embebido Raspberry Pi 4, se presentaron mejoras del 13 % en requerimientos de CPU, reducción en 3.27 veces en ejecución de procesos en la memoria RAM con tiempos de ejecución inferiores a 10.60 ms. A nivel de software, el algoritmo híbrido denso sobre puntuaciones F1 evidencia una mejora en la clasificación del 19.4 % para la clase de no malignos, 15.9 % en lesiones carcinoma y 9.5 % para clase melanoma, cuyos valores se relacionan con la precisión y la sensibilidad e indican una medida general de exactitud.

En adición, con el algoritmo denso, se presentaron tasas mejoradas en la detección de verdaderos positivos en 4.6 % para los no malignos, 6.1 % sobre imágenes de lesiones por carcinoma y 11.5 % sobre melanomas malignos con AUC superiores al 97 %, desempeñándose así en la detección de clases positivas. Los resultados introducidos demuestran la necesidad del procesamiento digital de imágenes médicas, la extracción de información y la reducción de

dimensionalidad para identificar la similitud entre las clases de lesiones cutáneas para las etapas de aprendizaje y predicciones de los clasificadores. En adición, la integración entre el algoritmo híbrido denso y la interfaz gráfica de usuario proporciona autonomía en la identificación de la región de interés y la eliminación del vello corporal, lo que hace factible la implementación en sistemas asistenciales de apoyo médico tanto en la dermatología como en la medicina general.

6. Recomendaciones

La herramienta de diagnóstico asistido para clasificación de lesiones cutáneas puede implementarse en placas embebidas de bajo costo, como el sistema embebido Google Coral que incluye coprocesador Edge TPU de Google que proporciona herramientas de desarrollo de aprendizaje automático de alto rendimiento a bajo costo de energía. Además, se incluye la plataforma de procesamiento Arm Cortex-A53 a frecuencia de 1.5 GHz con unidad de procesado gráfico Vivante GC7000Lite y con memoria RAM de 4 GB.

Para el tratamiento de la imagen biomédica por el algoritmo híbrido denso propuesto, se recomienda la captura de la imagen mediante un dispositivo dermatoscópico que permite la magnificación para examinar la lesión cutánea en función de la incidencia de la luz del instrumento y disminuye la reflexión de los haces de luz, permitiendo así la representación detallada de las estructuras localizadas en la epidermis, unión dermoepidérmica y la dermis superficial.

El algoritmo híbrido puede ser potenciado mediante otras técnicas de procesamiento de imágenes y aprendizaje automático que involucren la optimización de procesos enfocados en la mejora de imágenes, extracción y reducción de características y clasificación.

7. Trabajos futuros

A corto plazo, se propone la implementación de un dispositivo médico basado en una aplicación móvil para la prestación de servicios médicos regulados que lleve control de la salud de la piel en la detección precisa y oportuna del cáncer de piel, que combine la tecnología de los algoritmos de inteligencia artificial con la experiencia de los profesionales de la salud de la piel y dermatólogos. En adición, se pretende integrar a la solución móvil la interoperabilidad de la historia clínica del Ministerio de Salud para que el personal médico puede consolidar la información del paciente desde cualquier lugar del territorio sin depender del sitio de atención del paciente potencial, ofreciendo la posibilidad de tener a disposición los antecedentes de salud del paciente para la atención y diagnósticos oportunos.

8. Bibliografía

- [1] J. E. Márquez Díaz, “Deep Artificial Vision Applied to the Early Identification of Non-Melanoma Cancer and Actinic Keratosis,” *Comput. y Sist.*, vol. 24, no. 2, pp. 751–766, Jun. 2020, doi: 10.13053/cys-24-2-2901.
- [2] K. Neshatpour *et al.*, “Big biomedical image processing hardware acceleration: A case study for K-means and image filtering,” *Proc. - IEEE Int. Symp. Circuits Syst.*, pp. 1134–1137, Jul. 2016, doi: 10.1109/ISCAS.2016.7527445.
- [3] T. B. Jutzi *et al.*, “Artificial Intelligence in Skin Cancer Diagnostics: The Patients’ Perspective,” *Front. Med.*, vol. 7, no. June, 2020, doi: 10.3389/fmed.2020.00233.
- [4] K. Zafar *et al.*, “Skin Lesion Segmentation from Dermoscopic Images Using Convolutional Neural Network,” *Sensors 2020, Vol. 20, Page 1601*, vol. 20, no. 6, p. 1601, Mar. 2020, doi: 10.3390/S20061601.
- [5] M. N. Bajwa *et al.*, “Computer-Aided Diagnosis of Skin Diseases Using Deep Neural Networks,” *Appl. Sci. 2020, Vol. 10, Page 2488*, vol. 10, no. 7, p. 2488, Apr. 2020, doi: 10.3390/APP10072488.
- [6] M. Salcedo Faytong, I. A. Torres Chávez, and H. E. Romero Urrea, “FACTORES DE RIESGO QUE PREDISPONEN A LA APARICIÓN DEL CANCER DE PIEL UN ESTUDIO DE REVISIÓN,” *Más Vita*, vol. 2, no. 3 Extraord, pp. 97–103, Dec. 2020, doi: 10.47606/ACVEN/MV0045.
- [7] H. Li *et al.*, “Dense Deconvolutional Network for Skin Lesion Segmentation,” *IEEE J. Biomed. Heal. Informatics*, vol. 23, no. 2, pp. 527–537, Mar. 2019, doi: 10.1109/JBHI.2018.2859898.
- [8] D. N. H. Thanh, V. B. S. Prasath, L. M. Hieu, and N. N. Hien, “Melanoma Skin Cancer Detection Method Based on Adaptive Principal Curvature, Colour Normalisation and Feature Extraction with the ABCD Rule,” *J. Digit. Imaging*, vol.

- 33, no. 3, pp. 574–585, Dec. 2020, doi: 10.1007/s10278-019-00316-x.
- [9] Y. Chung *et al.*, “Poor agreement between the automated risk assessment of a smartphone application for skin cancer detection and the rating by dermatologists,” *J. Eur. Acad. Dermatology Venereol.*, vol. 34, no. 2, pp. 274–278, Feb. 2020, doi: 10.1111/JDV.15873.
- [10] D. Lauren E, S. Sara C, and T. Alan J, “Current state of melanoma diagnosis and treatment,” *Cancer Biol. Ther.*, vol. 20, no. 11, pp. 1366–1379, Nov. 2019, doi: 10.1080/15384047.2019.1640032.
- [11] V. C. Restrepo Arias, H. V. Arévalo Riaño, J. D. Ríos Cerón, B. E. Paz Córdoba, and J. C. Caicedo, “Aspectos epidemiológicos del cáncer de piel diagnosticado en el año 2012 en 4 centros de referencia de Popayán, Colombia: un estudio observacional de corte transversal,” *Rev. Colomb. Cirugía Plástica y Reconstr.*, vol. 22, no. 1, pp. 36–43, Jul. 2016, Accessed: Aug. 07, 2021. [Online]. Available: <http://www.ciplastica.com/ojs/index.php/rccp/article/view/7>.
- [12] A. Esteva *et al.*, “Dermatologist-level classification of skin cancer with deep neural networks,” *Nat.*, vol. 542, no. 7639, pp. 115–118, Jan. 2017, doi: 10.1038/nature21056.
- [13] P. Tschandl *et al.*, “Human–computer collaboration for skin cancer recognition,” *Nat. Med.*, vol. 26, no. 8, pp. 1229–1234, Jun. 2020, doi: 10.1038/s41591-020-0942-0.
- [14] V. Dick, C. Sinz, M. Mittlböck, H. Kittler, and P. Tschandl, “Accuracy of Computer-Aided Diagnosis of Melanoma: A Meta-analysis,” *JAMA Dermatology*, vol. 155, no. 11, pp. 1291–1299, Nov. 2019, doi: 10.1001/JAMADERMATOL.2019.1375.
- [15] C. Pérez Lorenzo, “Detección precoz de cáncer de piel en imágenes basado en redes convolucionales,” Universidad Autónoma de Madrid, 2019.
- [16] R. R. Coronado Pérez, “Reconocimiento de Patrones en Imágenes no Dermatoscópicas

- para la detección de Enfermedades Malignas en la Piel, utilizando Redes Neuronales Convolutivas Y Autocodificadores,” Universidad Nacional de San Agustín, 2018.
- [17] S. Majumder and M. A. Ullah, “Feature extraction from dermoscopy images for melanoma diagnosis,” *SN Appl. Sci.*, vol. 1, no. 7, pp. 1–11, 2019, doi: 10.1007/s42452-019-0786-8.
- [18] J. Jaworek-Korjakowska, “Computer-aided diagnosis of micro-malignant melanoma lesions applying support vector machines,” *Biomed Res. Int.*, vol. 2016, pp. 1–8, 2016, doi: 10.1155/2016/4381972.
- [19] M. Goyal, T. Knackstedt, S. Yan, and S. Hassanpour, “Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities,” *Comput. Biol. Med.*, vol. 127, pp. 1–11, Dec. 2020, doi: 10.1016/J.COMPBIOMED.2020.104065.
- [20] N. C. F. Codella *et al.*, “Deep learning ensembles for melanoma recognition in dermoscopy images,” *IBM J. Res. Dev.*, vol. 61, no. 4, Jul. 2017, doi: 10.1147/JRD.2017.2708299.
- [21] P. Tschandl *et al.*, “Expert-Level Diagnosis of Nonpigmented Skin Cancer by Combined Convolutional Neural Networks,” *JAMA dermatology*, vol. 155, no. 1, pp. 58–65, Jan. 2019, doi: 10.1001/JAMADERMATOL.2018.4378.
- [22] A. Matas Crespi, “Diseño de una aplicación para el tratamiento de imágenes dermatoscópicas,” Universitat Politècnica de Catalunya, 2018.
- [23] J. D. Calderon Ortiz, L. F. Morales Ticliahuanca, M. E. Roncal Moscol, and W. G. Solórzano Requejo, “Uso de Algoritmos de Machine Learning para el Diagnóstico de Melanomas,” Universidad de Piura, 2021.
- [24] D. P. Merchán Vargas, H. Navarro Báez, J. G. Barrero Pérez, and J. A. Castillo Bohórquez, “Design of a tool for the classification of skin cancer images using Deep

- Neural Networks (DNN) (Diseño de una herramienta para la clasificación de imágenes de cáncer de piel utilizando Redes Neuronales Profundas (DNN)) Design of a tool for the classificat,” *Cienc. y Tecnol.*, vol. 21, pp. 65–80, 2021.
- [25] Z. Apalla, D. Nashan, R. B. Weller, and X. Castellsagué, “Skin Cancer: Epidemiology, Disease Burden, Pathophysiology, Diagnosis, and Therapeutic Approaches,” *Dermatol. Ther. (Heidelb)*., vol. 7, pp. 5–19, Jan. 2017, doi: 10.1007/S13555-016-0165-Y.
- [26] C. Pellegrini, M. Giovanna Maturo, L. I. Di Nardo, V. Ciciarelli, C. Gutiérrez García-Rodrigo, and M. Concetta Fagnoli, “Understanding the Molecular Genetics of Basal Cell Carcinoma,” *Int. J. Mol. Sci.*, vol. 18, no. 2485, pp. 3–16, 2017, doi: 10.3390/ijms18112485.
- [27] M. C. Cameron *et al.*, “Basal cell carcinoma: Contemporary approaches to diagnosis, treatment, and prevention,” *J. Am. Acad. Dermatol.*, vol. 80, no. 2, pp. 321–339, Feb. 2019, doi: 10.1016/J.JAAD.2018.02.083.
- [28] A. Acosta *et al.*, “Guía de atención integral con evaluación económica para la prevención, el diagnóstico, el tratamiento y el seguimiento del cáncer de piel no melanoma: carcinoma basocelular,” *Rev. la Asoc. Colomb. Dermatología y Cirugía Dermatológica*, vol. 23, no. 4, pp. 258–296, Oct. 2015, doi: 10.29176/2590843X.282.
- [29] F. C. Pozzobon, Á. E. Acosta, and J. S. Castillo, “Cáncer de piel en Colombia: cifras del Instituto Nacional de Cancerología,” *Rev. la Asoc. Colomb. Dermatología y Cirugía Dermatológica*, vol. 26, no. 1, pp. 12–17, Apr. 2018, doi: 10.29176/2590843X.25.
- [30] E. V. Seiverling *et al.*, “Teaching Benign Skin Lesions as a Strategy to Improve the Triage Amalgamated Dermoscopic Algorithm (TADA),” *J. Am. Board Fam. Med.*, vol. 32, no. 1, pp. 96–102, Jan. 2019, doi: 10.3122/JABFM.2019.01.180049.

- [31] I.-A. Grajdeanu *et al.*, “Use of imaging techniques for melanocytic naevi and basal cell carcinoma in integrative analysis (Review),” *Exp. Ther. Med.*, vol. 20, no. 1, Mar. 2020, doi: 10.3892/etm.2020.8620.
- [32] V. M. Arévalo, J. González, and G. Ambrosio, “La Librería de Visión Artificial OpenCV aplicación a la Docencia e Investigación,” *Base Informática*, no. 40, pp. 61–66, 2004, Accessed: Dec. 14, 2021. [Online]. Available: <https://dialnet.unirioja.es/servlet/articulo?codigo=1109583>.
- [33] E. Seeram, “Digital Image Processing Concepts,” in *Digital Radiography*, Springer, Singapore, 2019, pp. 21–39.
- [34] Q. Wang *et al.*, “A Two-Stage Low-Altitude Remote Sensing Papaver Somniferum Image Detection System Based on YOLOv5s+DenseNet121,” *Remote Sens. 2022, Vol. 14, Page 1834*, vol. 14, no. 8, pp. 1–18, Apr. 2022, doi: 10.3390/RS14081834.
- [35] Y. Hao, J. Wang, Y. Liu, Z. Xu, and J. Fan, “Extracting Spatio-Temporal Texture signatures for crowd abnormality detection,” *ICAC 2017 - 2017 23rd IEEE Int. Conf. Autom. Comput. Addressing Glob. Challenges through Autom. Comput.*, Oct. 2017, doi: 10.23919/ICONAC.2017.8082051.
- [36] M. Lingaraj, A. Senthilkumar, and J. Ramkumar, “Prediction of Melanoma Skin Cancer Using Veritable Support Vector Machine,” *Ann. Rom. Soc. Cell Biol.*, vol. 25, pp. 2623 – 2636, Apr. 2021, Accessed: Dec. 14, 2021. [Online]. Available: <https://www.annalsofrscb.ro/index.php/journal/article/view/2800>.
- [37] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, and A. Lopez, “A comprehensive survey on support vector machine classification: Applications, challenges and trends,” *Neurocomputing*, vol. 408, pp. 189–215, Sep. 2020, doi: 10.1016/J.NEUCOM.2019.10.118.
- [38] S. Umer, P. P. Mohanta, R. K. Rout, and H. M. Pandey, “Machine learning method for

- cosmetic product recognition: a visual searching approach,” *Multimed. Tools Appl.*, 2020, doi: 10.1007/s11042-020-09079-y.
- [39] J. Sa, Z. Li, Q. Yang, and X. Chen, “Packaging defect detection system based on machine vision and deep learning,” *2020 5th Int. Conf. Comput. Commun. Syst. ICCCS 2020*, pp. 404–408, 2020, doi: 10.1109/ICCCS49078.2020.9118413.
- [40] P. Nagrath, R. Jain, A. Madan, R. Arora, P. Kataria, and J. Hemanth, “SSDMNV2: A real time DNN-based face mask detection system using single shot multibox detector and MobileNetV2,” *Sustain. Cities Soc.*, vol. 66, no. August 2020, p. 102692, 2021, doi: 10.1016/j.scs.2020.102692.
- [41] F. Milletari *et al.*, “Hough-CNN: Deep learning for segmentation of deep brain regions in MRI and ultrasound,” *Comput. Vis. Image Underst.*, vol. 164, pp. 92–102, 2017, doi: 10.1016/j.cviu.2017.04.002.
- [42] C.-J. Huang, Y.-H. Chen, Y. Ma, and P.-H. Kuo, “Multiple-Input Deep Convolutional Neural Network Model for COVID-19 Forecasting in China,” *medRxiv*, pp. 1–16, Mar. 2020, doi: 10.1101/2020.03.23.20041608.
- [43] J. Zhang, D. Mucs, U. Norinder, and F. Svensson, “LightGBM: An Effective and Scalable Algorithm for Prediction of Chemical Toxicity-Application to the Tox21 and Mutagenicity Data Sets,” *J. Chem. Inf. Model.*, pp. 1–9, 2019, doi: 10.1021/ACS.JCIM.9B00633/SUPPL_FILE/CI9B00633_SI_001.PDF.
- [44] C. Chen, Q. Zhang, Q. Ma, and B. Yu, “LightGBM-PPI: Predicting protein-protein interactions through LightGBM with multi-information fusion,” *Chemom. Intell. Lab. Syst.*, vol. 191, pp. 54–64, Aug. 2019, doi: 10.1016/J.CHEMOLAB.2019.06.003.
- [45] X. Ma, J. Sha, D. Wang, Y. Yu, Q. Yang, and X. Niu, “Study on a prediction of P2P network loan default based on the machine learning LightGBM and XGboost algorithms according to different high dimensional data cleaning,” *Electron. Commer.*

- Res. Appl.*, vol. 31, pp. 24–39, Sep. 2018, doi: 10.1016/J.ELERAP.2018.08.002.
- [46] J. A. Troyano, F. Cruz, M. González, C. G. Vallejo, and M. Toro, “Introducción a la Programación con Python, Computación Interactiva y Aprendizaje Significativo,” *Actas las Jenui*, vol. 3, pp. 223–230, 2018, Accessed: Aug. 20, 2021. [Online]. Available: <https://www.researchgate.net/publication/328928778>.
- [47] OpenCV, “About OpenCV,” 2021. <https://opencv.org/about/> (accessed Aug. 19, 2021).
- [48] B. Pang, E. Nijkamp, and Y. N. Wu, “Deep Learning With TensorFlow: A Review;,” <https://doi.org/10.3102/1076998619872761>, vol. 45, no. 2, pp. 227–248, Sep. 2019, doi: 10.3102/1076998619872761.
- [49] N. G. Barrionuevo, “Sistema Embebido de Control de Acceso y Registro Automático de Asistencia con Tecnología NFC para la Facultad de Tecnología y Ciencias Aplicadas,” Universidad Nacional de Catamarca, 2020.
- [50] E. M. Araujo Mena, “Implementación de un sistema de video vigilancia para los exteriores de la UPS, mediante mini computadores y cámaras Raspberry PI,” Universidad Politécnica Salesiana, 2015.
- [51] Raspberry Pi, “Raspberry Pi 4 Model B specifications.” <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/specifications/> (accessed Jun. 14, 2022).
- [52] M. C. Albornoz, M. Berón, and G. A. Montejano, “Evaluación de interfaces gráfica de usuario,” 2015, Accessed: Apr. 13, 2022. [Online]. Available: <http://sedici.unlp.edu.ar/handle/10915/45770>.
- [53] P. Luppi and M. Basualdo, “Selección óptima de redundancias para el diseño de control tolerante a fallas activo para plantas químicas,” in *V Simposio Argentino de Informática Industrial (SII 2016)*, 2016, pp. 1–12, Accessed: May 08, 2022. [Online]. Available: <http://sedici.unlp.edu.ar/handle/10915/58390>.

- [54] C. V. Niño Rondón, S. A. Castro Casadiego, B. Medina Delgado, and D. Guevara Ibarra, “Análisis de viabilidad y diseño de un sistema electrónico para el seguimiento de la dinámica poblacional en la ciudad de Cúcuta,” *Ing. USBMed*, vol. 11, no. 1, pp. 56–64, Aug. 2020, doi: 10.21500/20275846.4489.
- [55] R. Song, Z. Zhang, and H. Liu, “Edge connection based Canny edge detection algorithm,” *Pattern Recognit. Image Anal. 2017 274*, vol. 27, no. 4, pp. 740–747, Dec. 2017, doi: 10.1134/S1054661817040162.
- [56] P. Singhal, A. Verma, and A. Garg, “A study in finding effectiveness of Gaussian blur filter over bilateral filter in natural scenes for graph based image segmentation,” *4th Int. Conf. Adv. Comput. Commun. Syst. ICACCS 2017*, pp. 4–9, Aug. 2017, doi: 10.1109/ICACCS.2017.8014612.
- [57] A. G. Medeiros *et al.*, “A new fast morphological geodesic active contour method for lung CT image segmentation,” *Measurement*, vol. 148, pp. 1–13, Dec. 2019, doi: 10.1016/J.MEASUREMENT.2019.05.078.
- [58] E. Zereik, F. Gomez-Bravo, C. P. Bechlioulis, S. Garrido, D. Alvarez, and L. E. Moreno, “Marine Applications of the Fast Marching Method,” *Mar. Appl. Fast Marching Method. Front. Robot. AI*, vol. 7, no. 2, 2020, doi: 10.3389/frobt.2020.00002.
- [59] Z. Xu, F. R. Sheykhahmad, N. Ghadimi, and N. Razmjoooy, “Computer-aided diagnosis of skin cancer based on soft computing techniques,” *Open Med.*, vol. 15, no. 1, pp. 860–871, Jan. 2020, doi: 10.1515/MED-2020-0131/MACHINEREADABLECITATION/RIS.
- [60] H. Fan, F. Xie, Y. Li, Z. Jiang, and J. Liu, “Automatic segmentation of dermoscopy images using saliency combined with Otsu threshold,” *Comput. Biol. Med.*, vol. 85, pp. 75–85, Jun. 2017, doi: 10.1016/J.COMPBIOMED.2017.03.025.

- [61] J. H. Kim, J. J. Park, S. H. Ahn, D. G. Lee, D. Moon, and S. K. Kim, "Small target detection using morphology and modified Gaussian distance function," *Secur. Commun. Networks*, vol. 9, no. 6, pp. 555–560, Apr. 2016, doi: 10.1002/SEC.1069.
- [62] Sakshi and V. Kukreja, "Segmentation and Contour Detection for handwritten mathematical expressions using OpenCV," *Int. Conf. Decis. Aid Sci. Appl.*, pp. 305–310, Mar. 2022, doi: 10.1109/DASA54658.2022.9765142.
- [63] Y. Yuan, M. Chao, and Y. C. Lo, "Automatic Skin Lesion Segmentation Using Deep Fully Convolutional Networks with Jaccard Distance," *IEEE Trans. Med. Imaging*, vol. 36, no. 9, pp. 1876–1886, Sep. 2017, doi: 10.1109/TMI.2017.2695227.
- [64] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," *30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, pp. 2261–2269, Aug. 2016, doi: 10.1109/CVPR.2017.243.
- [65] I. Taleb and M. O. Mammari, "Parking access system based on face recognition," *12th Int. Symp. Program. Syst. ISPS 2015*, pp. 176–180, Sep. 2015, doi: 10.1109/ISPS.2015.7244982.
- [66] K. Padmavathi and K. Thangadurai, "Implementation of RGB and Grayscale Images in Plant Leaves Disease Detection-Comparative Study," *Indian J. Sci. Technol.*, vol. 9, no. 6, pp. 1–6, Feb. 2016, doi: 10.17485/ijst/2016/v9i6/77739.
- [67] S. P. Yadav and S. Yadav, "Image fusion using hybrid methods in multimodality medical images," *Med. Biol. Eng. Comput. 2020 584*, vol. 58, no. 4, pp. 669–687, Jan. 2020, doi: 10.1007/S11517-020-02136-6.
- [68] N. Salem and S. Hussein, "Data dimensional reduction and principal components analysis," *Procedia Comput. Sci.*, vol. 163, pp. 292–299, Jan. 2019, doi: 10.1016/J.PROCS.2019.12.111.
- [69] J. Li and R. Zhang, "Dynamic Weighting Multi Factor Stock Selection Strategy Based

- on XGboost Machine Learning Algorithm,” *Proc. 2018 IEEE Int. Conf. Saf. Prod. Informatiz. IICSPI 2018*, pp. 868–872, Apr. 2019, doi: 10.1109/IICSPI.2018.8690416.
- [70] J. Xu, Y. Zhang, and D. Miao, “Three-way confusion matrix for classification: A measure driven view,” *Inf. Sci. (Ny)*, vol. 507, pp. 772–794, Jan. 2020, doi: 10.1016/J.INS.2019.06.064.
- [71] P. Tschandl, C. Rosendahl, and H. Kittler, “The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions,” *Sci. Data 2018 51*, vol. 5, no. 1, pp. 1–9, Aug. 2018, doi: 10.1038/sdata.2018.161.
- [72] J. M. Willman, “Creating GUIs with Qt Designer,” *Begin. PyQt*, pp. 165–203, 2020, doi: 10.1007/978-1-4842-5857-6_7.
- [73] S. Sastoque, C. Narváez, and G. Garnica, “Metodología para la construcción de Interfaces Gráficas Centradas en el Usuario,” *Nuevas Ideas en Informática Educ.*, vol. 12, pp. 314–324, 2016, Accessed: Apr. 24, 2022. [Online]. Available: <http://www.tise.cl/volumen12/TISE2016/314-324.pdf>.
- [74] M. Rastgoo, R. Garcia, O. Morel, and F. Marzani, “Automatic differentiation of melanoma from dysplastic nevi,” *Comput. Med. Imaging Graph.*, vol. 43, pp. 44–52, Jul. 2015, doi: 10.1016/J.COMPMEDIMAG.2015.02.011.
- [75] K. Kourou, T. P. Exarchos, K. P. Exarchos, M. V. Karamouzis, and D. I. Fotiadis, “Machine learning applications in cancer prognosis and prediction,” *Comput. Struct. Biotechnol. J.*, vol. 13, pp. 8–17, Jan. 2015, doi: 10.1016/J.CSBJ.2014.11.005.
- [76] N. C. F. Codella *et al.*, “Skin lesion analysis toward melanoma detection: A challenge at the 2017 International symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC),” *Proc. - Int. Symp. Biomed. Imaging*, vol. 2018-April, pp. 168–172, May 2018, doi: 10.1109/ISBI.2018.8363547.
- [77] A. Esteva *et al.*, “Dermatologist-level classification of skin cancer with deep neural

- networks,” *Nature*, vol. 542, no. 7639, pp. 115–118, Jan. 2017, doi: 10.1038/nature21056.
- [78] A. Demir, F. Yilmaz, and O. Kose, “Early detection of skin cancer using deep learning architectures: Resnet-101 and inception-v3,” *2019 Med. Technol. Congr.*, pp. 1–4, 2019, doi: 10.1109/TIPTEKNO47231.2019.8972045.
- [79] E. Nasr-Esfahani *et al.*, “Melanoma detection by analysis of clinical images using convolutional neural network,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 1373–1376, 2016, doi: 10.1109/EMBC.2016.7590963.
- [80] S. Bonechi *et al.*, “Fusion of Visual and Anamnestic Data for the Classification of Skin Lesions with Deep Learning,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 11808 LNCS, pp. 211–219, 2019, doi: 10.1007/978-3-030-30754-7_21.

9. Anexos

Anexo 1. Instrumento de evaluación del algoritmo híbrido denso y la herramienta de diagnóstico asistido por computador



NIT. 890500622 - 6

Vigilada Mineducación

Señor

Usuario del software SCCHA

A continuación, encontrará las generalidades para las pruebas y validación del software **“SCCHA”, Herramienta de Diagnóstico Asistido por Computador para la Detección y Clasificación de Tipo de Cáncer de Piel.**

1. El software desarrollado es producto de un proyecto de **Jóvenes Investigadores e Innovadores** financiado y desarrollado por el **Ministerio de Ciencia Tecnología e Innovación MinCiencias** y la **Universidad Francisco de Paula Santander Cúcuta**.
2. El objetivo de la herramienta de diagnóstico desarrollada es colocar al alcance de la comunidad médica, empresarial, académica y científica una interfaz gráfica de usuario que apoye al especialista médico en los procesos de diagnóstico de cáncer de piel.
3. La información suministrada será de uso confidencial con fines académicos e investigativos.
4. Los potenciales usuarios de la interfaz corresponden a especialistas en el sector biomédico y médico.
5. Para las pruebas de validación, se requiere que realice tareas de “Almacenamiento de información en archivo de hojas de cálculo”, “diagnóstico inicial sin uso extensivo de la interfaz gráfica” y “prueba de diagnóstico mediante herramientas de soporte de la interfaz”
6. Se requiere validar el software y la interfaz gráfica de usuario mediante el instrumento anexo al presente documento. El instrumento consta de 15 preguntas diseñadas en Escala de Likert para determinar el nivel de conformidad, aceptación y concordancia respecto a la usabilidad del software SCCHA.
7. Se marca mediante una equis (X) en las casillas de 1 a 5, donde 1 indica “totalmente en desacuerdo”, 2 es “en desacuerdo”, 3 es “ni de acuerdo ni en desacuerdo”, 4 es “de acuerdo” y 5 representa la opción “totalmente de acuerdo”.

Agradeciendo su colaboración, atentamente,

Byron Medina Delgado, PhD.

Docente Investigador – Universidad Francisco de Paula Santander
 Director del Proyecto de Jóvenes Investigadores e Innovadores
 Grupo de Investigación y Desarrollo en Electrónica y Telecomunicaciones

Avenida Gran Colombia No. 12E-96 Barrio Colsag
 Teléfono (057)(7) 5776655 - www.ufps.edu.co
 oficinadeprensa@ufps.edu.co San José de Cúcuta - Colombia

Creada mediante decreto 323 de 1970

Instrumento de Validación de Software SCCHA

#	Indicador	Valoración				
		1	2	3	4	5
1	¿Considera que la herramienta de diagnóstico se afianza oportunamente con el usuario?					
2	¿Requirió menos de 20 minutos para afianzarse con los controles ofrecidos por la interfaz?					
3	¿Los datos solicitados por la interfaz de caracterización son acordes para la atención hospitalaria?					
4	¿Considera que la interfaz gráfica de usuario realiza el diagnóstico de la imagen cutánea en un tiempo prudente (menor a 1 minuto)?					
5	¿La mejora mediante procesamiento digital de la imagen es óptima y adecuada para el diagnóstico visual por parte de un especialista?					
6	¿El tiempo general de ejecución de la herramienta es óptimo?					
7	¿La secuencia definida en el sistema de diagnóstico requiere ser aprendida nuevamente desde el inicio?					
8	¿Las técnicas y modelos utilizados involucran baja complejidad de comprensión?					
9	¿La alternativa de control de acceso a la herramienta es apropiada y didáctica?					
10	¿Al probar la herramienta, la interfaz presenta facilidad al ingresar a la misma?					
11	¿Es fiable la forma en cómo se caracteriza el paciente y se almacena la información en el archivo de hoja de cálculo?					
12	¿Las imágenes de muestra fueron procesadas correctamente por los métodos allí propuestos e influyen en el diagnóstico?					
13	¿Considera que la interfaz está preparada como una herramienta de apoyo para la atención en los niveles III y IV?					
14	¿Los modelos de extracción de información y de aprendizaje contribuyen para el diagnóstico oportuno de cáncer de piel?					
15	¿En general, la interfaz gráfica de usuario se presenta como una herramienta intuitiva para el usuario potencial?					

Instrumento completado en la Ciudad de Cúcuta, Colombia a los __ días del mes de __ de 2022 por un profesional en el área de _____.

Anexo 2. Acuerdo de cooperación investigación entre la Universidad Francisco de Paula Santander y la empresa VHM INGENIERÍA SAS

**CONVENIO ESPECÍFICO DE COOPERACIÓN INVESTIGACIÓN ENTRE
LA UNIVERSIDAD FRANCISCO DE PAULA SANTANDER Y VHM
INGENIERÍA SAS**

Entre los suscritos, de una parte, HECTOR MIGUEL PARRA LOPEZ, rector de la UNIVERSIDAD FRANCISCO DE PAULA SANTANDER, identificado con cedula de ciudadanía 13814433 de Bucaramanga, quien en adelante se denominará **ENTIDAD CONVENIANTE** y VICTOR HUGO MURCIA CELIS identificado con cedula de ciudadanía 88217995 de Cúcuta, representante legal de VHM INGENIERÍA SAS NIT 900.254.629-7, hemos acordado celebrar el presente convenio específico, previo las siguientes consideraciones:

Las partes que suscriben este convenio manifiestan bajo la gravedad de juramento que no se encuentran incurso en causal alguna o inhabilidad de que trata los artículos 8 y 9 de la ley 80 de 1993 y demás normas complementarias, por lo tanto, asumen toda responsabilidad por la veracidad de lo indicado.

En virtud de las consideraciones expuestas, las partes:

ACUERDAN

CLÁUSULA PRIMERA: OBJETO. El presente convenio tiene por objeto establecer los términos y condiciones bajo los cuales las partes aunarán esfuerzos para validar el software SCCHA (Algoritmo Híbrido para la Clasificación de Cáncer de Piel), resultado del proyecto de grado modalidad investigación Herramienta de Diagnóstico Asistido por Computador para Identificación y Clasificación de Lesiones Cutáneas en Imágenes Médicas.

PARÁGRAFO: ALCANCE. En desarrollo del anterior objeto, las partes ejecutarán las siguientes actividades: Por parte de la UNIVERSIDAD FRANCISCO DE PAULA SANTANDER, diseñar y desarrollar un instrumento de evaluación y capacitar al médico especialista que evalué el software SCCHA acerca de uso; y por parte de VHM INGENIERÍA SAS, aplicar el instrumento a médicos especialistas en imágenes diagnósticas.

CLÁUSULA SEGUNDA: RÉGIMEN JURÍDICO. El convenio no origina una persona jurídica independiente y el actuar conjunto está regido por las siguientes reglas: 2.1. Cada una de las partes responde exclusivamente por las obligaciones aquí establecidas. 2.2. Los bienes con que contribuya alguna de las partes con fines de ejecución del convenio, no pasarán a ser bienes comunes y, por lo tanto, su propietario continuará con el ejercicio del derecho de dominio sobre los mismos.

CLÁUSULA TERCERA. ADMINISTRACIÓN Y COORDINACIÓN. Para la administración y coordinación de las actividades que se deriven del presente convenio, su desarrollo, orientación y evaluación, las partes acuerdan constituir un Comité Coordinador que estará integrado por Byron Medina Delgado, investigador adscrito al GRUPO DE INVESTIGACIÓN Y DESARROLLO EN ELECTRONICA Y TELECOMUNICACIONES GIDET y Víctor Hugo Murcia, representante legal de VHM INGENIERÍA SAS.

CLÁUSULA CUARTA: FUNCIONES DEL COMITÉ COORDINADOR. Corresponderá al Comité Coordinar las actividades de diseño y desarrollo del instrumento de validación del software SCCHA, así como todas aquellas actividades requeridas para la aplicación e implementación del instrumento, como charlas, capacitaciones, soporte y manuales de uso.

CLÁUSULA QUINTA: OBLIGACIONES DE LA PARTES: Para el cumplimiento del objeto pactado, las partes se obligan a: I. OBLIGACIONES DE LA UNIVERSIDAD: Diseñar y desarrollar un instrumento de validación para el software SCCHA, y apoyar en el proceso de implementación del mismo. II. OBLIGACIONES DE LA ENTIDAD CONVENIENTE: Aplicar el instrumento de validación del software SCCHA a médicos especialistas en imágenes diagnósticas.

CLÁUSULA SEXTA: DURACIÓN DEL CONVENIO: Las partes de común acuerdo fijan como duración del presente convenio un periodo de TRES (3) MESES CALENDARIO, contados a partir de la fecha de la última firma, que podrán ser prorrogados por periodos iguales, previa evaluación de los resultados obtenidos y mediante acuerdo escrito entre las partes, a menos que una de las Instituciones comunique a la otra, por escrito y con QUINCE (15) DÍAS CALENDARIO de anticipación, la fecha en que desee darlo por concluido.

CLÁUSULA SÉPTIMA. CAUSALES DE TERMINACIÓN. Constituyen causales de terminación del presente convenio las siguientes:

- 1 El vencimiento del plazo de duración o cualquiera de sus prórrogas, sin acudir a la prórroga establecida en el presente convenio.
- 2 Por mutuo acuerdo de las partes manifestado por escrito y con causa justificada.
- 3 El incumplimiento parcial o total de alguna de ellas.
- 4 Fuerza Mayor o caso fortuito, que imposibilite llevar a cabo su objeto.

No obstante, e independientemente del motivo de la terminación, los programas, proyectos o actividades que se estén realizando en ese momento, continuarán hasta la fecha programada y sea aprobada su conclusión.

CLÁUSULA OCTAVA: ACTA DE FINALIZACIÓN DE LA COOPERACIÓN: Vencido el plazo estipulado para el desarrollo del presente convenio, se llevará a cabo su evaluación y se decide si se prorroga, en caso contrario, se procederá a suscribir ACTA DE

FINALIZACIÓN DE LA COOPERACIÓN en la que las partes dejarán constancia de las actividades desarrolladas en el marco del presente convenio.

CLÁUSULA NOVENA: CESIÓN. Ninguna de las partes podrá ceder el objeto del presente convenio, en consideración a la especial naturaleza y condición de las partes que lo suscriben.

CLÁUSULA DÉCIMA. SOLUCIÓN DE CONTROVERSIAS. En el evento de presentarse un conflicto en cuanto a la interpretación y/o aplicación de las cláusulas del presente convenio y de los convenios específicos que se deriven, las partes realizarán sus mayores esfuerzos en la búsqueda de una solución consensual.

CLÁUSULA DÉCIMOPRIMERA: NO EXISTENCIA DE RELACIÓN LABORAL. Las personas partícipes de este convenio, incluyendo funcionarios, profesores, investigadores y estudiantes, desarrollarán el objeto del presente convenio con total independencia y autonomía de la institución de la que obtengan la cooperación, entendida esta última como el aporte de instalaciones, equipos, entre otros; por lo cual, el presente convenio no constituye vínculo laboral alguno.

CLÁUSULA DÉCIMOSEGUNDA: NO EXISTENCIA DE RÉGIMEN DE SOLIDARIDAD. No existe régimen de solidaridad entre las partes que suscriben este convenio, en razón a que cada una responde por las obligaciones que se establecen en el mismo. Así mismo, el uso de la imagen corporativa, no implica la asunción de obligaciones solidarias entre las partes

CLÁUSULA DÉCIMOTERCERA: PROPIEDAD INTELECTUAL: Los convenios específicos a que se hace referencia en la cláusula cuarta, contendrán las cláusulas que sean necesarias para regular lo relativo a la propiedad intelectual de los trabajos científicos, intelectuales o creativos que ameriten un reconocimiento de propiedad intelectual, en concordancia con las disposiciones legales vigentes, debiendo otorgarse el reconocimiento a quienes hayan intervenido en la creación de los mismos; salvo el derecho moral de autor el cual pertenecerá a los autores de la(s) obra(s) que llegaren a resultar conforme a las disposiciones nacionales internacionales vigentes sobre la materia. Las partes se comprometen a no usar el nombre, logotipos, emblemas y marcas registradas de la contraparte sin su consentimiento previo y por escrito.

PARÁGRAFO: Lo dispuesto en los convenios específicos no podrá contravenir las disposiciones internas de las partes en materia de propiedad intelectual, ni las normas nacionales e internacionales sobre Derechos de Autor y propiedad industrial.

CLÁUSULA DÉCIMOCUARTA: SUPERVISIÓN: Para efectos de la supervisión del presente convenio, las partes designan como supervisor a: POR LA UNIVERSIDAD: Byron Medina Delgado, y por la ENTIDAD CONVENIANTE: Víctor Hugo Murcia.

CLÁUSULA DÉCIMOQUINTA: DOMICILIO. Para todos los efectos, se entenderá como domicilio del presente convenio, la dirección #0- a Avenida Gran Colombia No. 12E-96, Cúcuta, Norte de Santander.

CLÁUSULA DÉCIMOSEXTA: PERFECCIONAMIENTO Este convenio quedará perfeccionado con las firmas de las partes.

Para constancia se firma en Cúcuta, a los _____

HECTOR MIGUEL PARRA LOPEZ **VÍCTOR HUGO MURCIA**

Rector
UFPS
Lugar: Cúcuta, Colombia
Fecha: __/__/____

Representante legal
VHM INGENIERÍA SAS
Lugar: Cúcuta, Colombia
Fecha: __/__/____

Anexo 3. Evidencia de la sustentación preparatoria del proyecto en las asignaturas “Fibra Óptica”, “Medios de Transmisión” y “Procesamiento Digital de Señales” a la comunidad académica

GESTIÓN DE TALENTO HUMANO						
LISTADO DE ASISTENCIA						
ELABORÓ		REVISÓ		APROBÓ		
Lider Gestión de Talento Humano		Equipo Operativo de Calidad		Lider de Calidad		
1. INFORMACIÓN DE LA ACTIVIDAD						
NOMBRE DEL EVENTO: Presentación de Avances del Proyecto de Investigación del estudiante Diego Castellano						
TIPO DE ACTIVIDAD: <input checked="" type="checkbox"/> TALLER <input type="checkbox"/> CONFERENCIA <input type="checkbox"/> SEMINARIO <input type="checkbox"/> FORO <input type="checkbox"/> CAPACITACION <input type="checkbox"/> OTRO <input checked="" type="checkbox"/> Presentación						
OBJETIVO DEL EVENTO: Exponer y Presentar un proyecto de Investigación						
FECHA REALIZACIÓN: 05 / 05 / 22						
RESPONSABLE / FACILITADOR: Byron Medina Delgado						
DEPENDENCIA: Dpto. Electricidad y Electrónica						
2. INFORMACIÓN DE LOS PARTICIPANTES						
Nº	NOMBRE Y APELLIDO	IDENTIFICACIÓN O CÓDIGO	DEPENDENCIA	TIPO VINCULACIÓN	E-MAIL	FIRMA
1	Byron Medina D.	04544	Ing. Electrónica	Docente	byronmedina@ups.edu.ec	<i>[Firma]</i>
2	Camilo Estrella O.	1161666	Ing. Electrónica	Estudiante	camilobates0808@ups.edu.ec	<i>[Firma]</i>
3	Harold A. Flores	1161181	Ing. Electrónica	Estudiante	haroldaflores@ups.edu.ec	<i>[Firma]</i>
4	Juan Carlos R.	1161151	Ing. Electrónica	Estudiante	juancarlosr@ups.edu.ec	<i>[Firma]</i>
5	Jonathan D. Pacheco	1161091	Ing. Electrónica	Estudiante	jonathanp@ups.edu.ec	<i>[Firma]</i>
6	Camilo Hernández	1161632	Ing. Electrónica	Estudiante	camilobates0808@ups.edu.ec	<i>[Firma]</i>

GESTIÓN DE TALENTO HUMANO						
LISTADO DE ASISTENCIA						
ELABORÓ		REVISÓ		APROBÓ		
Lider Gestión de Talento Humano		Equipo Operativo de Calidad		Lider de Calidad		
1. INFORMACIÓN DE LA ACTIVIDAD						
NOMBRE DEL EVENTO: Presentación de Avances del Proyecto de Investigación del estudiante Diego Castellano						
TIPO DE ACTIVIDAD: <input checked="" type="checkbox"/> TALLER <input type="checkbox"/> CONFERENCIA <input type="checkbox"/> SEMINARIO <input type="checkbox"/> FORO <input type="checkbox"/> CAPACITACION <input type="checkbox"/> OTRO <input checked="" type="checkbox"/> Presentación						
OBJETIVO DEL EVENTO: Exponer y Presentar un proyecto de Investigación						
FECHA REALIZACIÓN: 05 / 05 / 22						
RESPONSABLE / FACILITADOR: Byron Medina Delgado						
DEPENDENCIA: Dpto. Electricidad y Electrónica						
2. INFORMACIÓN DE LOS PARTICIPANTES						
Nº	NOMBRE Y APELLIDO	IDENTIFICACIÓN O CÓDIGO	DEPENDENCIA	TIPO VINCULACIÓN	E-MAIL	FIRMA
7	Laura Camilo Raygel C.	1161644	Ing. Electrónica	Estudiante	lauracamilor@ups.edu.ec	<i>[Firma]</i>
8	Robinson Cordero R.	1161617	Ing. Electrónica	Estudiante	robinsoncordero@ups.edu.ec	<i>[Firma]</i>
9	David Camilo Ramirez	1161503	Ing. Electrónica	Estudiante	camilodavid@ups.edu.ec	<i>[Firma]</i>
10	Jose Edwin Perez B.	1161618	Ing. Electrónica	Estudiante	edwinperez@ups.edu.ec	<i>[Firma]</i>
11	DIANA INCHA DIAZ C.	1161633	Ing. Electrónica	Estudiante	dianainchadiaz@ups.edu.ec	<i>[Firma]</i>
12	Leonardo Andres Pina	1161650	Ing. Electrónica	Estudiante	leonardopina@ups.edu.ec	<i>[Firma]</i>
13	Leonardo Garcia M.	1161280	Ing. Electrónica	Estudiante	leonardogarcia@ups.edu.ec	<i>[Firma]</i>
14	Daniel E. Valencia	1161615	Ing. Electrónica	Estudiante	danielvalencia@ups.edu.ec	<i>[Firma]</i>
15	Carlos Yvonne Ivan Erazo	1161617	Ing. Electrónica	Estudiante	carlosyvan@ups.edu.ec	<i>[Firma]</i>
16						
17						
18						
19						
20						

GESTIÓN DE TALENTO HUMANO						
LISTADO DE ASISTENCIA						
ELABORÓ		REVISÓ		APROBÓ		
Lider Gestión de Talento Humano		Equipo Operativo de Calidad		Lider de Calidad		
1. INFORMACIÓN DE LA ACTIVIDAD						
NOMBRE DEL EVENTO: Presentación de Avances del Proyecto de Investigación del estudiante Diego Castellano						
TIPO DE ACTIVIDAD: <input checked="" type="checkbox"/> TALLER <input type="checkbox"/> CONFERENCIA <input type="checkbox"/> SEMINARIO <input type="checkbox"/> FORO <input type="checkbox"/> CAPACITACION <input type="checkbox"/> OTRO <input checked="" type="checkbox"/> Presentación						
OBJETIVO DEL EVENTO: Exponer y Presentar un proyecto de Investigación						
FECHA REALIZACIÓN: 05 / 05 / 22						
RESPONSABLE / FACILITADOR: Pedro Pablo Lopez						
DEPENDENCIA: Dpto. Electricidad y Electrónica						
2. INFORMACIÓN DE LOS PARTICIPANTES						
Nº	NOMBRE Y APELLIDO	IDENTIFICACIÓN O CÓDIGO	DEPENDENCIA	TIPO VINCULACIÓN	E-MAIL	FIRMA
1	Camilo Andres Estrella	1161666	Dpto. E y E	Estudiante	camilobates0808@ups.edu.ec	<i>[Firma]</i>
2	Harold A. Flores	1161181	Dpto. E y E	Estudiante	haroldaflores@ups.edu.ec	<i>[Firma]</i>
3	Jose Andres Ramirez	1160993	Dpto. Ing. Electrónica	Estudiante	andreyramirez@ups.edu.ec	<i>[Firma]</i>
4	Juan Carlos Rodríguez	1161293	Dpto. E y E	Estudiante	juancarlosr@ups.edu.ec	<i>[Firma]</i>
5	Jonathan D. Pacheco	1161091	Dpto. E y E	Estudiante	jonathanp@ups.edu.ec	<i>[Firma]</i>
6	Juan Diego Rodriguez R.	1161574	Dpto. E y E	Estudiante	juanrodriguez@ups.edu.ec	<i>[Firma]</i>

GESTIÓN DE TALENTO HUMANO						
LISTADO DE ASISTENCIA						
ELABORÓ		REVISÓ		APROBÓ		
Lider Gestión de Talento Humano		Equipo Operativo de Calidad		Lider de Calidad		
1. INFORMACIÓN DE LA ACTIVIDAD						
NOMBRE DEL EVENTO: Presentación de Avances del Proyecto de Investigación del estudiante Diego Castellano						
TIPO DE ACTIVIDAD: <input checked="" type="checkbox"/> TALLER <input type="checkbox"/> CONFERENCIA <input type="checkbox"/> SEMINARIO <input type="checkbox"/> FORO <input type="checkbox"/> CAPACITACION <input type="checkbox"/> OTRO <input checked="" type="checkbox"/> Presentación						
OBJETIVO DEL EVENTO: Exponer y Presentar un proyecto de Investigación						
FECHA REALIZACIÓN: 05 / 05 / 22						
RESPONSABLE / FACILITADOR: Pedro Pablo Lopez						
DEPENDENCIA: Dpto. Electricidad y Electrónica						
2. INFORMACIÓN DE LOS PARTICIPANTES						
Nº	NOMBRE Y APELLIDO	IDENTIFICACIÓN O CÓDIGO	DEPENDENCIA	TIPO VINCULACIÓN	E-MAIL	FIRMA
7	Harold A. Flores	1161181	Dpto. E y E	Estudiante	haroldaflores@ups.edu.ec	<i>[Firma]</i>
8	Karelis Rojas Lopez	1161637	Dpto. E y E	Estudiante	karelisrojas@ups.edu.ec	<i>[Firma]</i>
9	Carlos Yvonne Ivan Erazo	1161617	Dpto. E y E	Estudiante	carlosyvan@ups.edu.ec	<i>[Firma]</i>
10						
11						
12						
13						
14						
15						
16						
17						
18						
19						
20						

GESTIÓN DE TALENTO HUMANO						
LISTADO DE ASISTENCIA						
ELABORÓ		REVISÓ		APROBÓ		
Lider Gestión de Talento Humano		Equipo Operativo de Calidad		Lider de Calidad		
1. INFORMACIÓN DE LA ACTIVIDAD						
NOMBRE DEL EVENTO: Presentación de Avances del Proyecto de Investigación del estudiante Diego Castellano						
TIPO DE ACTIVIDAD: <input checked="" type="checkbox"/> TALLER <input type="checkbox"/> CONFERENCIA <input type="checkbox"/> SEMINARIO <input type="checkbox"/> FORO <input type="checkbox"/> CAPACITACION <input type="checkbox"/> OTRO <input checked="" type="checkbox"/> Presentación						
OBJETIVO DEL EVENTO: Exponer y Presentar un proyecto de Investigación						
FECHA REALIZACIÓN: 05 / 05 / 22						
RESPONSABLE / FACILITADOR: Ing. Sergio A. Castro Caspedesio						
DEPENDENCIA: Dpto. Electricidad y Electrónica						
2. INFORMACIÓN DE LOS PARTICIPANTES						
Nº	NOMBRE Y APELLIDO	IDENTIFICACIÓN O CÓDIGO	DEPENDENCIA	TIPO VINCULACIÓN	E-MAIL	FIRMA
1	Linnel Suarez	1161512	Ing. Electrónica	Estudiante	linnell@ups.edu.ec	<i>[Firma]</i>
2	Yvonne Ivan Erazo	1161617	Ing. Electrónica	Estudiante	yvan@ups.edu.ec	<i>[Firma]</i>
3	Jose Andres Ramirez	1160993	Ing. Electrónica	Estudiante	andreyramirez@ups.edu.ec	<i>[Firma]</i>
4	Roxinson Agudelo	1161213	Ing. Electrónica	Estudiante	roxinson@ups.edu.ec	<i>[Firma]</i>
5	Harold A. Flores	1161181	Ing. Electrónica	Estudiante	haroldaflores@ups.edu.ec	<i>[Firma]</i>
6	Camilo Andres Estrella	1161666	Ing. Electrónica	Estudiante	camilobates0808@ups.edu.ec	<i>[Firma]</i>

Anexo 4. Certificación de ponencia en el 2° Congreso Internacional de Ingeniería Biomédica y Bioingeniería (CI-IB&BI)



The Organizing Committee of the
IEEE International Congress of Biomedical Engineering and Bioengineering
(CI-IB&BI 2021)
Certifies that

Carlos Vicente Niño Rondón, Diego Andrés Castellano Carvajal, Byron Medina Delgado, Sergio Alexander Castro Casadiego and Dinael Guevara Ibarra

Participated as Authors at the CI-IB&BI 2021,

Virtual Conference – Colombia, October 13th - 15th, 2021

With the oral presentation: *Body hair noise suppression in skin lesions by differential operator and maximum variance threshold between classes in the Bioimaging session*

Mario Andrés Valderrama
General Chair

Andrés Navarro C.
IEEE Colombia Section



Departamento de
Ingeniería Biomédica



Anexo 5. Certificación de ponencia en el Congreso Anual de Ingeniería Biomédica (CAIB 2021)



CERTIFICADO DE PARTICIPACIÓN

CONCEDIDO A

Diego Castellano

Por su participación del Congreso Anual de Ingeniería Biomédica del 6 al 9 de Octubre del 2021

Esteban Pino Quiroga

Profesor Mentor Comité
Organizador CAIB 2021

Paulina Fernández Lagos

Presidenta Comité
Organizador CAIB 2021

Natalia Vidal Barraza

Vicepresidenta Comité
Organizador CAIB 2021



Anexo 6. Participación en el 8° Congreso Internacional de Innovación y Apropiación de las Tecnologías de la Información y las Comunicaciones

The screenshot shows a Microsoft Teams meeting interface. The main content is a presentation slide with the following text and elements:

- Title:** Incidencia de los Filtros de Suavizado en las Herramientas de Diagnóstico Asistido por Computador
- Speakers:** Six individuals are listed with their names and titles:
 - Jl. Diego Andrés Castellano Carvajal
 - Ing. JI. Carlos Vicente Niño Rondón
 - PhD. Byron Medina Delgado
 - MSc. Sergio Alexander Castro Casadiego
 - PhD. Dinael Guevara Ibarra
 - MSc. Miguel Eduardo Posada Haddad
- Contact Information:** [diegoandrescc, carlosvicenteur, byronmedina, sergio.castroc, dinaelgi}@ufps.edu.co, [mposadah]@sena.edu.co
- Logos:** Logos for GIDET, SINE, and the VIII Congreso Internacional de Innovación y Apropiación de las Tecnologías de la Información y las Comunicaciones.

The Teams interface includes a search bar at the top, a sidebar on the left with navigation icons, and a bottom bar with participant avatars and system icons. The system tray at the bottom right shows the date 25/11/2021 and time 15:53.

Anexo 7. Certificado de ponencia en la 7^o Conferencia Internacional para la Convergencia en Tecnología IEEE



Anexo 8. Publicación del artículo científico por parte de la revista Ingeniería y Competitividad de la Universidad del Valle



INGENIERÍA Y
COMPETITIVIDAD
REVISTA CIENTÍFICA Y TECNOLÓGICA

[Portal Revistas Científicas](#)
[Registrarse](#)
[Entrar](#)
Español ▾

[Inicio](#)
[Acerca de ▾](#)
[Para autores](#)
[Actual](#)
[Archivos](#)
[Avisos](#)
[Sello editorial](#)

[INICIO](#) / [ARCHIVOS](#) / VOL. 24 NÚM. 02 (2022): INGENIERÍA Y COMPETITIVIDAD / **ARTÍCULOS DE INVESTIGACIÓN**

Enviar un artículo



Una aproximación a la detección de bordes en imágenes médicas mediante análisis de histograma y gradiente morfológico

Mamografía Tomografía computarizada Detección de bordes Procesamiento de imágenes Diagnóstico asistido por computador

<https://doi.org/10.25100/ijyc.v0i00.11352>

[PDF](#)

Publicado: may 26, 2022
Número: Vol. 24 Núm. 02 (2022):
Ingeniería y Competitividad
Sección: Artículos de investigación

Métricas de publicación

Autores

- Carlos Vicente Niño Rondón Universidad Francisco de Paula Santander
- Diego Andrés Castellano Carvajal Universidad Francisco de Paula Santander
- Sergio Alexander Castro Casadiego Universidad Francisco de Paula Santander
- Byron Medina Delgado Universidad Francisco de Paula Santander
- Dinael Guevara Ibarra Universidad Francisco de Paula Santander

Idioma

Español ▾

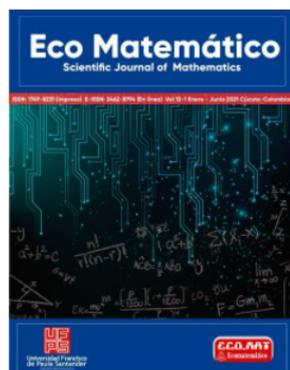
Palabras clave



Anexo 9. Publicación del artículo científico por parte de la revista Eco matemático relacionado con el área de aplicación del proyecto



Detección de placas vehiculares mediante modelo de clasificador en cascada basado en lenguaje Python
Detection of license plates by means of a cascade classifier model based on Python language



Carlos Vicente Niño-Rondón

Servicio nacional de aprendizaje

Diego Andrés Castellano-Carvajal

Universidad Francisco de Paula Santander

Sergio Alexander Castro-Casadiago

Universidad Francisco de Paula Santander

Byron Medina-Delgado

Universidad Francisco de Paula Santander

Dinael Guevara-Ibarra

Universidad Francisco de Paula Santander

RESUMEN

La detección de placas vehiculares empleando técnicas de aprendizaje automático mejora los procesos de rastreo, seguimiento y seguridad. Se presenta el desarrollo de un modelo de clasificador en cascada para la detección de placas vehiculares, utilizando las herramientas de Python, OpenCV y Cascade Trainer GUI, basadas en código abierto. Las imágenes utilizadas para el procesamiento fueron capturadas mediante una cámara para Raspberry Pi conectada a la placa embebida, en diversos puntos de la zona céntrica de la ciudad fronteriza de Cúcuta, Colombia; posteriormente

PDF

FLIP

HTML

Anexo 10. Notificación de aceptación para la publicación del artículo científico por parte de la Revista Científica Ingeniería y Desarrollo de la Fundación Universidad del Norte

Notificaciones



[I y D] Decisión del Editor

2022-04-26 05:17

Estimados autores,

Tenemos el gusto de informarles que su artículo titulado "Alternativa para estimación de ocupación de interiores basada en procesamiento de imágenes sobre sistema embebido" ha sido SELECCIONADO para ser publicado en la revista Ingeniería y Desarrollo correspondiente a nuestra siguiente edición.

En este punto, es importante que todos los autores de nacionalidad colombiana, ajusten su perfil de CvLAC (<https://scienti.minciencias.gov.co/cvlac>) con el fin de actualizar sus datos profesionales, tal como el código orcid y la afiliación institucional hasta finales de este año.

Este detalle es muy importante, ya que es necesario para indexar correctamente su artículo en las bases de datos de revistas científicas más importantes de Colombia, tal como lo es Colciencias - Publindex.

También le recordamos que, en caso de ser necesario, el siguiente paso sería ajustar el artículo en base a las correcciones de estilo sugeridas por el personal de Ediciones Uninorte, para que los artículos se generen en archivo PDF sin ningún problema (Problemas de texto, fórmulas, imágenes, tablas).

Esperamos contar con su perfil de CvLAC actualizado lo más pronto posible, tarea que será verificada antes de la fecha de publicación de su artículo. Y en caso de ser necesario, esperamos contar con su colaboración para finalizar la revisión de estilos.

Si tienen algún comentario no duden en contactarnos.

Saludos cordiales,

Anexo II. Notificación en plataforma de evaluación del artículo científico enviado a la revista especializada IEEE Embedded System Letters publicada por IEEE CEDA

The screenshot displays the 'Author Dashboard' for IEEE Embedded Systems Letters. The user is logged in as Diego Castellano Carvajal. The dashboard shows one manuscript co-authored by the user, titled 'HASCC: A Hybrid Algorithm for Skin Cancer Classification'. The manuscript was created on 11-Mar-2022 and submitted on 11-Mar-2022. The status is 'Revise & Resubmit as New (13-May-2022)'. The due date is 12-Jun-2022. The submitting author is Niño Rondón, Carlos.

STATUS	ID	TITLE	CREATED	SUBMITTED
Revise & Resubmit as New (13-May-2022)	IEEE-ESL-Mar-22-0053	HASCC: A Hybrid Algorithm for Skin Cancer Classification	11-Mar-2022	11-Mar-2022

Submitting Author: Niño Rondón, Carlos

Due on: 12-Jun-2022

[Contact Journal](#)

Anexo 12. Notificación de aceptación para publicación del artículo científico enviado a la revista científica Eco matemático de la Universidad Francisco de Paula Santander

Solicitud de ajustes

×

Participantes

Ingeniero (sergioramonr)

CARLOS VICENTE NIÑO RONDÓN (carlosninoorondon)

Mensajes

Nota	De
<p>Cordial saludo</p> <p>Estimado autor, considerando las recomendaciones de los evaluadores, para continuar con el proceso editorial del artículo es necesario realizar algunos ajustes menores. Estos son señalados en el documento que se adjunta en esta comunicación.</p> <p>Una vez sea enviada la versión ajustada se avanza a la etapa de producción para la posterior publicación del artículo.</p> <p>Agradeciendo su pronta respuesta, y sin otro particular, en nombre del equipo editorial</p> <p> Comentarios.docx</p>	<p>sergioramonr 2022-05-30 11:20 PM</p>

Anexo 13. Publicación en IEEE Xplore del artículo presentado en el 2° Congreso Internacional de Ingeniería Biomédica y Bioingeniería (CI-IB&BI)

The screenshot shows the IEEE Xplore interface for a conference paper. At the top, there is a navigation bar with links to IEEE.org, IEEE Xplore, IEEE SA, IEEE Spectrum, and More Sites. On the right, there are links for SUBSCRIBE, Cart, Create Account, and Personal Sign In. The main header includes the IEEE Xplore logo, navigation menus (Browse, My Settings, Help), an Institutional Sign In button, and a search bar with a dropdown menu set to 'All' and an 'ADVANCED SEARCH' link.

The article title is "Body hair noise suppression in skin lesions by differential operator and maximum variance threshold between classes". The publisher is IEEE, and there are buttons for "Cite This" and "PDF". The authors listed are Carlos Vicente Niño Rondón, Diego Andrés Castellano Carvajal, Byron Medina Delgado, Sergio Alexander Castro Casadiego, and Dinael Guevara I... There is an "All Authors" link.

On the left side, there is a "21 Full Text Views" indicator. Below the title, there is a table of contents under "Document Sections":

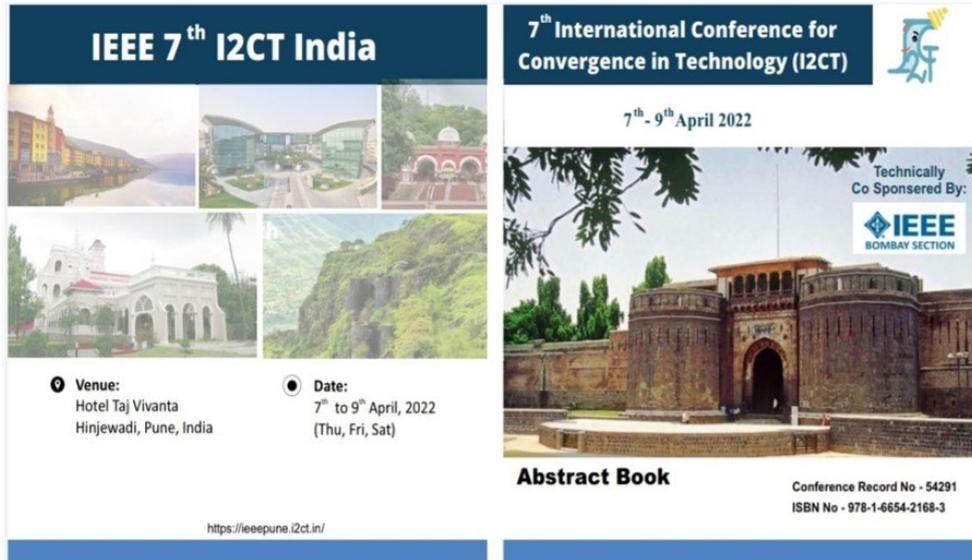
Section	Abstract
I. Introduction	<p>Abstract: Dermoscopic images allow to visualize with emphasis sections of the skin in which lesions are presumed. In these images it is common to find sections of body hair that represent noise in the analysis of the section for the treatment and diagnosis of skin cancer. In this work we present a proposal for the enhancement of the skin lesion of interest in dermoscopic images with abundant body hair over the lesion. The proposal is based on close-up visualization of the lesion of interest, by processing the image using a differential operator for edge detection, accompanied by a maximum variance threshold between classes for skin lesion detection. Tests were performed on images from the ISIC Challenge Dataset, and an average skin lesion size</p>
II. Methodology	
III. Experimental results and	

On the right side, there is a "More Like This" section with two recommendations:

- Nuclear segmentation for skin cancer diagnosis from histopathological images**
 2015 Global Conference on Communication Technologies (GCC1)
 Published: 2015
- Early diagnosis of skin cancer based on segmentation and measurement of vascularization and pigmentation in Nevoscope images**
 The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society
 Published: 2004

A "Feedback" button is located at the bottom right of the "More Like This" section.

Anexo 14. Resumen de la ponencia con publicación en IEEE Xplore del artículo presentado en la 7^o Conferencia Internacional para la Convergencia en Tecnología



IEEE 7th I2CT India

7th International Conference for Convergence in Technology (I2CT)

7th - 9th April 2022

Technically Co Sponsored By: **IEEE BOMBAY SECTION**

Venue: Hotel Taj Vivanta, Hinjewadi, Pune, India

Date: 7th to 9th April, 2022 (Thu, Fri, Sat)

Abstract Book

Conference Record No - 54291
ISBN No - 978-1-6654-2168-3

<https://ieeepune.i2ct.in/>

2022 IEEE 7th International Conference for Convergence in Technology (I2CT)

7th – 9th April, 2022

One of the Most Premium Conference of Asia Pacific

Paper ID: 571

Component Dimensionality Reduction in Dermoscopic Images using a Machine Learning Technique with Validation By Similarity Metrics

Carlos Vicente Niño Rondón (Universidad Francisco de Paula Santander); Diego Andrés Castellano Carvajal (Universidad Francisco de Paula Santander); Byron Medina Delgado (Universidad Francisco de Paula Santander); Sergio Alexander Castro Casadiego (Universidad Francisco de Paula Santander); Dinael Guevara Ibarra (Universidad Francisco de Paula Santander)*

Abstract: Skin cancer is one of the fastest growing diseases globally, where treatments are generally subject to systems with high implementation and development costs. This paper presents the dimensionality reduction of components in dermoscopic images using the Principal Components Analysis technique based on Machine Learning, and complementing the processing by feature enhancement, as an initial stage of a computer-aided diagnosis system. A digital microscope and a Raspberry Pi 3B+ embedded board with Python programming language and open source-based libraries are used. Images reduced to 10, 25, 50, 75 and 100 components are obtained, validated by similarity metrics, as well as by color preservation and execution response time. The best results were obtained with images between 50 and 100 components where the response time does not exceed 3 seconds with a similarity of more than 90 % in images with defined sections, and more than 70 % when the images do not present defined sections. The system is replicable on a large scale due to its high rate of feature preservation and low implementation cost.

Keywords: Bhattacharyya Distance, Computer Aided Diagnosis, Correlation, Principal Component Analysis, Open-Source.

Anexo 15. Solicitud de registro del software ROI SkinLesionEnhancement (software para el realce de características de regiones de interés de lesiones cutáneas en imágenes dermatoscópicas) ante la Dirección Nacional de Derechos de Autor

 REPÚBLICA DE COLOMBIA MINISTERIO DEL INTERIOR Y DE JUSTICIA DIRECCIÓN NACIONAL DE DERECHO DE AUTOR - UAE OFICINA DE REGISTRO		
SOLICITUD INSCRIPCIÓN SOPORTE LÓGICO (SOFTWARE) AHORA TAMBIÉN PUEDE REALIZAR SU TRÁMITE A TRAVÉS DEL <u>REGISTRO EN LÍNEA</u> UBICADO EN NUESTRO SITIO WEB www.derechodeautor.gov.co		
1. DATOS DEL AUTOR O AUTORES		
Nombre: Carlos Vicente Niño Rondón	Doc Ident: 1.090.523.992	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Calle 9N # 2-59 Barrio El Bosque, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Diego Andrés Castellano Carvajal	Doc Ident: 1.193.378.289	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 7 A # 4-45, Barrio San Luis, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Byron Medina Delgado	Doc Ident: 88.240.196	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 11E #7-44 Apto 202, Barrio Colsag, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Sergio Alexander Castro Casadiego	Doc Ident: 88.273.158	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Cr. 15 #6-02 Mz B Int. 18 San Nicolás, Villa del Rosario, Nte de Sder	
Seudónimo:	Fecha de defunción:	
Nombre: Dinael Guevara Ibarra	Doc Ident: 13.467.364	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Calle 9AN #4A-29 Barrio El Bosque, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Oriana Alexandra López Bustamante	Doc Ident: 57.462.449	De: Santa Marta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 11E #7-44 Apto 202, Barrio Colsag, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
2. DATOS DEL PRODUCTOR		
Nombre: Universidad Francisco de Paula Santander		
Correo electrónico: ugad@ufps.edu.co	Sitio web: https://ww2.ufps.edu.co/	Fax: 5776655
Dirección: Avenida Gran Colombia No. 12E-96 Barrio Colsag	Ciudad: Cúcuta	País: Colombia
3. DATOS DE LA OBRA		
Título: ROI SkinLesionEnhancement		
Año de Creación: 2022	<input checked="" type="radio"/> Inédito	
País de Origen: Colombia	<input type="radio"/> Publicado	Año de Publicación:
Carácter de la obra (Ver instrucción 3.1):		
<input type="radio"/> Obra individual <input type="radio"/> Obra colectiva <input checked="" type="radio"/> Obra originaria <input type="radio"/> Obra anónima <input type="radio"/> Obra seudónima <input checked="" type="radio"/> Obra en colaboración <input type="radio"/> Obra por encargo <input type="radio"/> Obra derivada <input type="radio"/> Obra póstuma <input type="radio"/> Otra (Especificar): _____		
4. ELEMENTOS DEL SOPORTE LÓGICO (SOFTWARE) APORTADOS		
<input checked="" type="checkbox"/> Programa de Computador <input checked="" type="checkbox"/> Descripción de Programa <input checked="" type="checkbox"/> Material Auxiliar <input type="checkbox"/>		
Breve Descripción de Funciones: <i>Se agrega el programa de computador, así como la documentación (descripción del programa).</i>		

Anexo 16. Solicitud de registro del software BHNS SkinLesion (software para la eliminación del ruido por vello corporal en lesiones cutáneas de imágenes dermoscópicas) ante la Dirección Nacional de Derechos de Autor

 REPÚBLICA DE COLOMBIA MINISTERIO DEL INTERIOR Y DE JUSTICIA DIRECCIÓN NACIONAL DE DERECHO DE AUTOR - UAE OFICINA DE REGISTRO		
SOLICITUD INSCRIPCIÓN SOPORTE LÓGICO (SOFTWARE) AHORA TAMBIÉN PUEDE REALIZAR SU TRÁMITE A TRAVÉS DEL <u>REGISTRO EN LÍNEA</u> UBICADO EN NUESTRO SITIO WEB www.derechodeautor.gov.co		
1. DATOS DEL AUTOR O AUTORES		
Nombre: Carlos Vicente Niño Rondón	Doc Ident: 1.090.523.992	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Calle 9N # 2-59 Barrio El Bosque, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Diego Andrés Castellano Carvajal	Doc Ident: 1.193.378.289	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 7 A # 4-45, Barrio San Luis, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Byron Medina Delgado	Doc Ident: 88.240.196	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 11E #7-44 Apto 202, Barrio Colsag, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Sergio Alexander Castro Casadiego	Doc Ident: 88.273.158	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Cr. 15 #6-02 Mz B Int. 18, San Nicolás, Villa del Rosario, Nte de Sder	
Seudónimo:	Fecha de defunción:	
Nombre: Dinael Guevara Ibarra	Doc Ident: 13.467.364	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Calle 9AN #4A-29 Barrio El Bosque, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Oriana Alexandra López Bustamante	Doc Ident: 57.462.449	De: Santa Marta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 11E #7-44 Apto 202, Barrio Colsag, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
2. DATOS DEL PRODUCTOR		
Nombre: Universidad Francisco de Paula Santander		
Correo electrónico: ugad@ufps.edu.co	Sitio web: https://ww2.ufps.edu.co/	Fax: 5776655
Dirección: Avenida Gran Colombia No. 12E-96 Barrio Colsag	Ciudad: Cúcuta	País: Colombia
3. DATOS DE LA OBRA		
Título: BHNS SkinLesion		
Año de Creación: 2022	<input checked="" type="checkbox"/> Inédito	
País de Origen: Colombia	<input type="checkbox"/> Publicado	Año de Publicación:
Carácter de la obra (Ver instrucción 3.1):		
<input type="checkbox"/> Obra individual <input type="checkbox"/> Obra colectiva <input checked="" type="checkbox"/> Obra originaria <input type="checkbox"/> Obra anónima <input type="checkbox"/> Obra seudónima <input checked="" type="checkbox"/> Obra en colaboración <input type="checkbox"/> Obra por encargo <input type="checkbox"/> Obra derivada <input type="checkbox"/> Obra póstuma <input type="checkbox"/> Otra (Especificar): _____		
4. ELEMENTOS DEL SOPORTE LÓGICO (SOFTWARE) APORTADOS		
<input checked="" type="checkbox"/> Programa de Computador <input type="checkbox"/> Descripción de Programa <input checked="" type="checkbox"/> Material Auxiliar <input type="checkbox"/>		
Breve Descripción de Funciones: <small>Se agrega el programa de computador, así como la documentación (descripción del programa).</small>		

Anexo 17. Solicitud de registro del software PatientCPy (software con interfaz gráfica de usuario para la caracterización de pacientes con uso potencial en herramienta de diagnóstico asistido por computador) ante la Dirección Nacional de Derechos de Autor

 REPÚBLICA DE COLOMBIA MINISTERIO DEL INTERIOR Y DE JUSTICIA DIRECCIÓN NACIONAL DE DERECHO DE AUTOR - UAE OFICINA DE REGISTRO		
SOLICITUD INSCRIPCIÓN SOPORTE LÓGICO (SOFTWARE) AHORA TAMBIÉN PUEDE REALIZAR SU TRÁMITE A TRAVÉS DEL <u>REGISTRO EN LÍNEA</u> UBICADO EN NUESTRO SITIO WEB www.derechodeautor.gov.co		
1. DATOS DEL AUTOR O AUTORES		
Nombre: Carlos Vicente Niño Rondón	Doc Ident: 1.090.523.992	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Calle 9N # 2-59 Barrio El Bosque, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Diego Andrés Castellano Cervajal	Doc Ident: 1.193.378.289	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 7 A # 4-45, Barrio San Luis, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Byron Medina Delgado	Doc Ident: 88.240.196	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 11E #7-44 Apto 202, Barrio Colsag, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Sergio Alexander Castro Casadiego	Doc Ident: 88.273.158	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Cr. 15 #6-02 Mz B Int. 18 San Nicolás, Villa del Rosario, Nte de Sder	
Seudónimo:	Fecha de defunción:	
Nombre: Dinael Guevara Ibarra	Doc Ident: 13.467.364	De: Cúcuta
Nacionalidad: Colombiana	Dirección completa y ciudad: Calle 9AN #4A-29 Barrio El Bosque, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
Nombre: Oriana Alexandra López Bustamante	Doc Ident: 57.462.449	De: Santa María
Nacionalidad: Colombiana	Dirección completa y ciudad: Av 11E #7-44 Apto 202, Barrio Colsag, Cúcuta, Norte de Santander	
Seudónimo:	Fecha de defunción:	
2. DATOS DEL PRODUCTOR		
Nombre: Universidad Francisco de Paula Santander		
Correo electrónico: ugad@ufps.edu.co	Sitio web: https://ww2.ufps.edu.co/	Fax: 5776655
Dirección: Avenida Gran Colombia No. 12E-96 Barrio Colsag	Ciudad: Cúcuta	País: Colombia
3. DATOS DE LA OBRA		
Título: PatientCPy		
Año de Creación: 2022	<input checked="" type="checkbox"/> Inédito	
País de Origen: Colombia	<input type="checkbox"/> Publicado	Año de Publicación:
Carácter de la obra (Ver instrucción 3.1):		
<input type="checkbox"/> Obra individual <input type="checkbox"/> Obra colectiva <input checked="" type="checkbox"/> Obra originaria <input type="checkbox"/> Obra anónima <input type="checkbox"/> Obra seudónima <input checked="" type="checkbox"/> Obra en colaboración <input type="checkbox"/> Obra por encargo <input type="checkbox"/> Obra derivada <input type="checkbox"/> Obra póstuma <input type="checkbox"/> Otra (Especificar): _____		
4. ELEMENTOS DEL SOPORTE LÓGICO (SOFTWARE) APORTADOS		
<input checked="" type="checkbox"/> Programa de Computador <input checked="" type="checkbox"/> Descripción de Programa <input type="checkbox"/> Material Auxiliar <input type="checkbox"/>		
Breve Descripción de Funciones: <u>Se agrega el programa de computador, así como la documentación (descripción del programa).</u>		

Anexo 18. Manual de usuario del Software SCCHA



Instrucciones y manual de usuario para el Software SCCHA

En esta sección se presentan las instrucciones, requerimientos y procedimientos para la ejecución del software SCCHA, que son presentados a continuación.

1. Acceder al entorno de desarrollo Spyder

En el buscador de aplicaciones de su ordenador, escriba Spyder y haga clic en abrir. De esta forma, podrá acceder al entorno de desarrollo.

2. Cargar el archivo del software SCCHA

Una vez acceda al entorno de desarrollo, proceda a cargar el archivo del software SCCHA. Para esto, debe dar clic en la casilla “File” ubicada en la sección superior izquierda, seguido de clic en “Open”, ubique el archivo “SCCHA.py” y cárguelo.

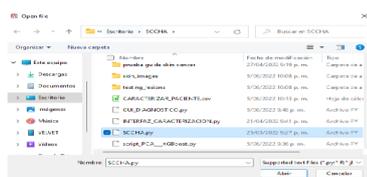


Figura 2. Cargue de archivo del software SCCHA

3. Verificar la existencia de las librerías requeridas por el Software SCCHA

En caso de que desconozca el nombre de algún paquete requerido, diríjase a <https://pypi.org/> y en el buscador, escriba un nombre relacionado con la librería, donde observará los mejores resultados de la búsqueda.

4. Ejecución del software

Una vez realizada toda la configuración descrita en las etapas anteriores, presione F5 para ejecutar el software, o en su defecto, seleccione la opción “Run file” disponible en el panel superior de la interfaz del entorno de desarrollo. Automáticamente se da acceso a la ejecución del software y se presenta la ventana de

caracterización mostrada en la figura 2. Por consiguiente, deberá ingresar los datos de credenciales asignados.



Figura 2. Interfaz gráfica para validación de credenciales

Una vez validados sus datos, ingresará a la ventana de caracterización paciente. En efecto, deberá completar los datos del paciente e indicar su nombre, tal como se muestra en la figura 3.



Figura 3. Interfaz gráfica para caracterización del paciente

Finalmente, ingresará a la ventana de diagnóstico asistido, donde cargará la imagen mediante el botón “Load image” y podrá indicarle al algoritmo híbrido los parámetros para segmentación de lesión, umbral de Canny para detección de vello corporal, tamaño del filtro mediano e iteraciones de dilatación para atenuar la incidencia del vello corporal. El sistema almacenará el diagnóstico en el archivo CSV y se mostrará el mismo como se presenta en la figura 4.

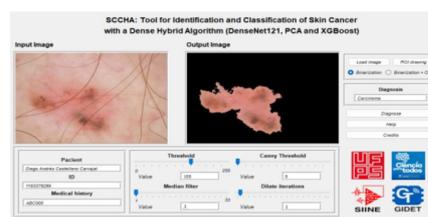


Figura 4. Interfaz gráfica para diagnóstico

Anexo 19. Manual técnico del Software SCCHA



Manual técnico del Software SCCHA

Para la implementación del software SCCHA se requiere la descarga, instalación y configuración del lenguaje de programación Python mediante el entorno de desarrollo Spyder. Del mismo modo, se descargan los programas y paquetes necesarios para el desarrollo del software destinado a la mejora y extracción de características, reducción de componentes y clasificación de imágenes de lesiones cutáneas. Los paquetes con su versión y su descripción se presentan en la tabla 1. En adición, el software SCCHA para su ejecución y carga de modelos computacionales para extracción de información, reducción de características y clasificación requiere 398 MB de espacio en la unidad de almacenamiento disponible en el ordenador.

Tabla 1. Paquetes requeridos para el desarrollo del Software SCCHA

Herramienta / Librería / paquete	Versión	Descripción
Python	3.9.7	Lenguaje de programación interpretado
OpenCV	4.4.0.42	Librería especializada de visión por computador
Spyder	5.1.5	Entorno de desarrollo para Python
ISIC Challenge Dataset	2018	Dataset de libre acceso sobre anomalías de la piel
PyQt5	5.9.2	Librería especializada para desarrollo de interfaces gráficas de usuario
Numpy	1.21.2	Librería para el cálculo matricial
TensorFlow	2.8.0	Librería para el desarrollo de modelos profundos
Pickle	2.0.0	Librería para empaquetado de modelos
Pandas	1.3.4	Librería para generación de archivos de información
Sklearn	0.24	Biblioteca para el desarrollo de modelos de aprendizaje automático