



UNIVERSIDAD TÉCNICA DEL NORTE
FACULTAD DE INGENIERÍA EN CIENCIAS APLICADAS
CARRERA DE INGENIERÍA EN TELECOMUNICACIONES

**INFORME FINAL DEL TRABAJO DE INTEGRACIÓN CURRICULAR,
PROYECTO DE INVESTIGACIÓN**

TEMA:

“DETECTOR DE MELANOMAS EN LA PIEL UTILIZANDO REDES
NEURONALES PARA LAS PERSONAS DE LA ASOCIACIÓN AGROTURÍSTICA
VALLE LA RINCONADA”

Trabajo de titulación previo a la obtención del título de Ingeniero en Telecomunicaciones

Linea de investigación: Desarrollo, aplicación de software y cibersecurity (seguridad cibernética)

AUTOR:

Yacelga Cañarejo Jorge Luis

DIRECTOR:

Ing. Suárez Zambrano Luis Edilberto, Msc

Ibarra, 2024

**UNIVERSIDAD TÉCNICA DEL NORTE
BIBLIOTECA UNIVERSITARIA**

IDENTIFICACIÓN DE LA OBRA

La Universidad Técnica del Norte dentro del proyecto Repositorio Digital Institucional, determinó la necesidad de disponer de textos completos en formato digital con la finalidad de apoyar los procesos de investigación, docencia y extensión de la Universidad.

Por medio del presente documento dejo sentada mi voluntad de participar en este proyecto, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
CÉDULA DE IDENTIDAD:	1720444353		
APELLIDOS Y NOMBRES:	YACELGA CAÑAREJO JORGE LUIS		
DIRECCIÓN:	SAN PABLO DEL LAGO, BARRIO SAN CRISTOBAL, CALLE ASCAZUBI Y CALLE B		
EMAIL:	jorgeyacelgaluis@gmail.com		
TELÉFONO FIJO:	XXXXXXX	TELF. MOVIL	0969909550

DATOS DE LA OBRA	
TÍTULO:	DETECTOR DE MELANOMAS EN LA PIEL UTILIZANDO REDES NEURONALES PARA LAS PERSONAS DE LA ASOCIACIÓN AGROTURÍSTICA VALLE LA RINCONADA
AUTOR (ES):	YACELGA CAÑAREJO JORGE LUIS
FECHA: AAAAMMDD	2024/11/20
SOLO PARA TRABAJOS DE INTEGRACIÓN CURRICULAR	
CARRERA/PROGRAMA:	<input checked="" type="checkbox"/> GRADO <input type="checkbox"/> POSGRADO
TÍTULO POR EL QUE OPTA:	INGENIERO EN TELECOMUNICACIONES
DIRECTOR:	ING. SUÁREZ ZAMBRANO LUIS EDILBERTO, MSC
ASESOR:	ING. MAYA OLALLA EDGAR ALBERTO, MSC

AUTORIZACIÓN DE USO A FAVOR DE LA UNIVERSIDAD

Yo, Yacelga Cañarejo Jorge Luis, con cédula de identidad Nro. 1720444353, en calidad de autor y titular de los derechos patrimoniales de la obra o trabajo de integración curricular descrito anteriormente, hago entrega del ejemplar respectivo en formato digital y autorizo a la Universidad Técnica del Norte, la publicación de la obra en el Repositorio Digital Institucional y uso del archivo digital en la Biblioteca de la Universidad con fines académicos, para ampliar la disponibilidad del material y como apoyo a la educación, investigación y extensión; en concordancia con la Ley de Educación Superior Artículo 144.

Ibarra, a los 21 días del mes de noviembre de 2024

EL AUTOR:



.....
Yacelga Cañarejo Jorge Luis

CONSTANCIAS

El autor manifiesta que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es el titular de los derechos patrimoniales, por lo que asume la responsabilidad sobre el contenido de la misma y saldrá en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 20 días del mes de noviembre de 2024

EL AUTOR:



.....
Yacelga Cañarejo Jorge Luis

CERTIFICACIÓN DEL DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR

Ibarra, 20 de noviembre de 2024

ING. SUÁREZ ZAMBRANO LUIS EDILBERTO, MSC
DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR

CERTIFICA:

Haber revisado el presente informe final del trabajo de Integración Curricular, el mismo que se ajusta a las normas vigentes de la Universidad Técnica del Norte; en consecuencia, autorizo su presentación para los fines legales pertinentes.



.....
Ing. Suárez Zambrano Luis Edilberto, Msc
C.C.: 1002304291

APROBACIÓN DEL COMITÉ CALIFICADOR

El Comité Calificado del trabajo de Integración Curricular “Detector de melanomas en la piel utilizando redes neuronales para las personas de la Asociación Agroturística Valle La Rinconada” elaborado por Yacelga Cañarejo Jorge Luis, previo a la obtención del título de Ingeniero en Telecomunicaciones, aprueba el presente informe de investigación en nombre de la Universidad Técnica del Norte:



.....
Ing. Suárez Zambrano Luis Edilberto, Msc
C.C.: 1002304291



.....
Ing. Maya Olalla Edgar Alberto, Msc
C.C.: 1002702197

DEDICATORIA

La culminación de mi carrera universitaria ha presentado un sinnúmero de inconvenientes, uno más difícil que otro, pero gracias al apoyo constante de mis padres he podido salir adelante, debido a eso estoy eternamente agradecido con ustedes y desde lo más profundo de mis sentimientos se los dedico, Jorge y Patricia. Han sido el soporte día a día de mis alegrías y tristezas, no han permitido que me dé por vencido y gracias a su responsabilidad como buenos padres y educadores de la vida, he podido cumplir este sueño.

De igual manera dedico este logro a mi hermana Evelyn, que con su sabiduría me ha guiado a tomar las mejores decisiones durante todo este trayecto, siendo mi consejera en todo momento y finalmente a mi hermana pequeña Almudena, a la cual quiero mucho por su cariño demostrado en los momentos difíciles que he pasado.

Este es un escalón muy importante en mi vida, que marca un antes y un después en la persona que soy. Es el comienzo de los grandes sueños que tengo por delante y anhelo cumplir junto con las personas que más quiero.

Yacelga Cañarejo Jorge Luis

AGRADECIMIENTO

Agradezco profundamente a Dios, al Niño Jesús y a la Virgen del Quinche por brindarme la salud y fuerza para afrontar todos los desafíos, ya que cada paso que he dado a sido gracias a que me han guiado por el camino correcto.

Asimismo, agradezco a mis ratones, David, Erick, Ana y Anahí, mis grandes amigos. Sin su apoyo desde el primer día, esto no habría sido posible. Han demostrado resiliencia y perseverancia durante todo este tiempo, lo que nos ha permitido avanzar. No encuentro mejores palabras para expresar mi gratitud; solo puedo decirles: Muchas gracias, ratones, los llevaré siempre en mi corazón.

De igual manera quiero agradecer a mi primo Luis Felipe, el cual ha sido como un hermano desde mucho antes que empezara mi carrera universitaria, el me ha apoyado emocionalmente durante todo este proceso y ha sido un soporte para mi en todo momento, este aspecto emocional ha sido demasiado importante para no desistir.

Me permito agradecer al MSc, Luis Suárez, MSc. Edgar Maya y MSc. Jaime Michilena quienes me han guiado durante el desarrollo del trabajo de titulación con sus recomendaciones y puntos de vista, además que me han formado de la mejor manera en las aulas, indicándome el camino correcto para ser un buen profesional y haciendo de mí, una persona de bien.

Por último, agradezco a mi ahora alma mater, la Universidad Técnica del Norte por permitirme estudiar y brindarme los mejores docentes para mi formación académica.

RESUMEN

El presente trabajo de integración curricular se centra en la problemática que existe en la salud de las personas al estar expuestas por largos periodos a la radiación solar, derivando de ello enfermedades malignas como los melanomas que son altamente cancerígenos. El objetivo general fue desarrollar un sistema de detección de melanomas en la piel de las personas a través de inteligencia artificial para la Asociación Agroturística Valle La Rinconada. El funcionamiento del sistema se basa en la dermatoscopia, que realiza el análisis manual de imágenes de lesiones en la piel para la detección de enfermedades. El sistema desarrollado automatiza el procedimiento de análisis de las imágenes dermatoscópicas, a través del uso de redes neuronales que permiten aprender a diferenciar imágenes con lesiones benignas de las malignas (melanomas). El detector de melanomas es una aplicación de escritorio, que funciona por medio del ingreso de imágenes capturadas por un dermatoscopio digital, en el que se ingresan los datos del usuario a prediagnosticar, se indican los resultados del prediagnóstico y se genera un documento con toda la información respectiva. A su vez se evalúa métricas de entrenamiento y procesamiento del desarrollo del modelo de inteligencia artificial en diferentes entornos de infraestructura computacional. El modelo de red neuronal utilizado es Data Efficient Image Transformer (DeiT) que ha obtenido un nivel de precisión en la predicción de 88.10% y una pérdida de 0.3585. El sistema desarrollado es una herramienta útil para la detección temprana de enfermedades, que provee beneficios tanto socioeconómicos como de salud.

Palabras clave: Piel, Melanoma, Red Neuronal, Imágenes, DeiT e Infraestructura computacional.

ABSTRACT

This curricular integration work focuses on the problems that exist in people's health when they are exposed for long periods to solar radiation, resulting in malignant diseases such as melanomas, which are highly carcinogenic. The general objective was to develop a system for detecting melanomas on people's skin through artificial intelligence for the Valle La Rinconada Agrotourism Association. The operation of the system is based on dermatoscopy, which performs the manual analysis of images of skin lesions for the detection of diseases. The developed system automates the dermoscopic image analysis procedure through the use of neural networks that learn to differentiate images with benign lesions from malignant ones (melanomas). The melanoma detector is a desktop application that works by income images captured by a digital dermatoscope, in which the data of the user to be pre-diagnosed is entered, the results of the pre-diagnosis are indicated, and a document is generated with all the respective information. At the same time, training and processing metrics of the development of the artificial intelligence model are evaluated in different computational infrastructure environments. The neural network model used is Data Efficient Image Transformer (DeiT) which has obtained a prediction accuracy level of 88.10% and a loss of 0.3585. The developed system is a useful tool for early disease detection, providing both socio-economic and health benefits.

Keywords: Skin, Melanoma, Neural Network, Images, DeiT and Computational Infrastructure.

LISTA DE SIGLAS

ARCOTEL. Agencia de Regulación y Control de las Telecomunicaciones.

CDC. Centros para el Control y Prevención de Enfermedades.

CIELAB. Sistema de color de la Comisión Internacional de Iluminación.

CNN. Red Neuronal Convolutiva.

CPU. Unidad Central de Procesamiento.

DC. Corriente Continua.

DeiT. Data Efficient Image Transformer

EEPROM. Memoria de Solo Lectura Programable y Borrable Eléctricamente.

EPROM. Memoria de Solo Lectura Programable y Borrable.

FFN. Red Neuronal Feed-Forward.

GAN. Red Generativa Antagónica.

GUI. Interfaz Gráfica de Usuario.

GPU. Unidad de Procesamiento Gráfico.

HDD. Unidad de Disco Duro.

IA. Inteligencia Artificial.

IEEE. Instituto de Ingenieros Eléctricos y Electrónicos.

INEC. Instituto Nacional de Estadísticas y Censo.

INAMHI. Instituto Nacional de Meteorología e Hidrología – Ecuador.

JPEG. Joint Photographic Experts Group.

LED. Diodo Emisor de Luz.

MRKF. Software propietario del dermatoscopio TIANUYE M39.

MSP. Ministerio de Salud Pública.

ML. Machine Learning.

NCI. Instituto Nacional del Cáncer.

ONU. Organización de las Naciones Unidas.

PIC. Plan de Integración Curricular.

PROM. Memoria de Solo Lectura Programable

RAM. Memoria de Acceso Aleatorio.

RGB. Modelo de Color - Rojo, Verde, Azul.

RNN. Red Neuronal Recurrente.

ROM. Memoria solo de lectura.

SOLCA. Sociedad de Lucha Contra el Cáncer.

SrSH. Requerimientos de Arquitectura.

SSD. Unidad de Estado Sólido.

SSID. Identificador de Conjunto de Servicios.

StSR. Requerimientos de Stakeholders.

SySR. Requerimientos del Sistema.

SiSF. Requerimientos de Infraestructura.

TIC. Trabajo de Integración Curricular.

TPU. Unidad de Procesamiento Tensorial.

USB. Bus Universal en Serie.

UV. Radiación Ultravioleta.

ViT. Vision Transformer.

Wi-Fi. Wireless Fidelity.

ÍNDICE DE CONTENIDOS

	Pág.
CAPÍTULO I: ANTECEDENTES	26
1.1 Tema	26
1.2 Problema de investigación.	26
1.3 Justificación	29
1.4 Objetivos	33
1.4.1 Objetivo General	33
1.4.2 Objetivos Específicos	33
CAPÍTULO II: FUNDAMENTACIÓN TEÓRICA.....	34
2.1 Melanoma	34
2.1.1 Melanoma léntigo maligno.....	35
2.1.2 Melanoma diseminación superficial	35
2.1.3 Melanoma nodular	36
2.1.4 Melanoma acral	37
2.2 Técnicas de detección	38
2.3 Dataset de imágenes ISIC	41
2.4 Inteligencia artificial	43
2.4.1 Redes neuronales.....	44
2.4.2 Redes neuronales basadas en Transformers	45
2.4.2.1 Modelo Data Efficient Image Transformer	46
2.5 Infraestructura computacional	51
2.6 Entornos de entrenamiento	58

CAPÍTULO III: DISEÑO Y DESARROLLO	61
3.1 Metodología de desarrollo	61
3.1.1 Fases del Modelo en Cascada.....	62
3.1.1.1 Fase 1: Requisitos	62
3.1.1.2 Fase 2: Diseño	62
3.1.1.3 Fase 3: Implementación.....	62
3.1.1.4 Fase 4: Verificación.....	62
3.1.1.5 Fase 5: Mantenimiento	63
3.2 Análisis de la situación actual.....	63
3.3 Propósito del sistema	66
3.4 Ámbito del sistema	66
3.5 Requisitos y requerimientos del sistema.....	67
3.5.1 Nomenclatura de los requerimientos.....	67
3.5.2 Prioridades de los requerimientos	67
3.5.3 Determinación de Stakeholders.....	68
3.5.4 Requerimientos de Stakeholders	69
3.5.5 Requerimientos del Sistema	71
3.5.6 Requerimientos de la Arquitectura.....	73
3.5.7 Requerimientos de Infraestructura	75
3.6 Diseño y descripción general del sistema	78
3.6.1 Selección de hardware y software.....	80
3.6.1.1 Elección de infraestructura	80
3.6.1.1.1 Elección de Unidad Central de Proceso (CPU)	81
3.6.1.1.2 Elección de Unidad de Procesamiento Gráfico (GPU).....	82

3.6.1.1.3 Elección de Memoria RAM.....	83
3.6.1.1.4 Elección de Almacenamiento	84
3.6.1.1.5 Elección de Unidad de Procesamiento Tensorial (TPU)	85
3.6.1.2 Elección de Hardware.....	86
3.6.1.2.1 Elección del dermatoscopio digital.....	86
3.6.1.3 Elección de Software	89
3.6.1.3.1 Elección del entorno de desarrollo.....	89
3.6.1.3.2 Elección del dataset de imágenes.....	90
3.6.1.3.3 Elección de la red preentrenada	91
3.6.2 Diagramas del sistema.....	92
3.6.2.1 Diagrama de bloques del sistema	93
3.6.2.1.1 Bloque de obtención de datos	93
3.6.2.1.2 Bloque de procesamiento y análisis.....	94
3.6.2.1.3 Bloque de visualización	94
3.6.2.2 Diagrama de flujo del funcionamiento del sistema	95
3.6.2.3 Diagrama de flujo del entrenamiento y clasificación del sistema	96
3.7 Desarrollo del sistema.....	96
3.7.1 Bloque de obtención de datos	97
3.7.1.1 Localización de zonas afectadas.....	97
3.7.1.2 Consideraciones en la toma de muestras	98
3.7.1.3 Configuración del dermatoscopio digital	99
3.7.1.4 Obtención de imágenes dermatoscópicas	101
3.7.2 Bloque de procesamiento y análisis	103
3.7.2.1 Obtención del dataset de imágenes.....	104
3.7.2.2 Procesamiento de las imágenes	105

3.7.2.3 Entrenamiento del modelo DeiT.....	112
3.7.2.3.1 Procesamiento digital del dataset.....	112
3.7.2.3.2 Adaptación del modelo de entrenamiento	115
3.7.2.3.3 Parámetros de entrenamiento	119
3.7.2.3.4 Script de Python (Clasificación de imágenes)	121
3.7.3 Bloque de visualización	122
3.7.3.1 Desarrollo de Interfaz Gráfica de Usuario.....	123
3.7.3.2 Obtención de informe de resultados	134
3.7.3.3 Compilación de aplicación de escritorio	135
CAPÍTULO IV: PRUEBAS Y RESULTADOS.....	138
4.1 Evaluación del modelo de entrenamiento en distintas infraestructuras computacionales.....	138
4.1.1 Entrenamiento en infraestructura computacional (Google Colab / A100)...	139
4.1.2 Entrenamiento en infraestructura computacional (Google Colab / L4)	144
4.1.3 Entrenamiento en infraestructura computacional (Google Colab / TPUv2-8)	149
4.1.4 Análisis el entrenamiento en diferente infraestructura.....	153
4.1.5 Tiempos de inferencia del sistema	155
4.2 Pruebas del sistema	156
4.2.1 Pruebas de funcionamiento del sistema	156
4.2.2 Pruebas de campo del sistema	165
4.2.2.1 Identificación de la población.....	165
4.2.2.2 Metodología de selección	166
4.2.2.3 Toma de muestras	167

4.2.2.4 Análisis de los resultados	171
4.2.2.5 Validación de los resultados	172
4.2.2.6 Umbral de confianza.....	173
4.2.3 Pruebas externas.....	174
4.3 Análisis Costo/Beneficio	175
4.3.1 Costo general del sistema.....	176
4.3.2 Cálculo del costo/beneficio	178
CONCLUSIONES	181
RECOMENDACIONES	182
REFERENCIAS BIBLIOGRÁFICAS	183
ANEXOS	193
ANEXO A.- Aceptación de la Asociación Agroturística Valle La Rinconada	193
ANEXO B.- Permiso de toma de pruebas en la Asociación Agroturística Valle La Rinconada	194
ANEXO C.- Validación de los resultados con el médico asesor.....	195
ANEXO D.- Muestras tomadas en las personas de la asociación y pertenecientes al dataset (pruebas)	196
ANEXO E.- Resultados de los prediagnósticos realizados.	211
ANEXO F.- Evidencia de pruebas externas	216

ÍNDICE DE TABLAS

	Pág.
Tabla 1 <i>Entornos de desarrollo de redes neuronales artificiales</i>	59
Tabla 2 <i>Nomenclatura de los requerimientos</i>	67
Tabla 3 <i>Categorías de prioridades de los requerimientos</i>	68
Tabla 4 <i>Lista de Stakeholders</i>	69
Tabla 5 <i>Requerimientos de Stakeholders</i>	69
Tabla 6 <i>Requerimientos del sistema</i>	71
Tabla 7 <i>Requerimientos de la arquitectura</i>	73
Tabla 8 <i>Requerimientos de infraestructura</i>	75
Tabla 9 <i>Descripción de valores</i>	80
Tabla 10 <i>Selección del CPU</i>	81
Tabla 11 <i>Selección de GPU</i>	82
Tabla 12 <i>Selección de Memoria RAM</i>	84
Tabla 13 <i>Selección de Almacenamiento</i>	85
Tabla 14 <i>Selección de TPU</i>	86
Tabla 15 <i>Selección de dermatoscopio digital</i>	87
Tabla 16 <i>Características técnicas del dermatoscopio digital Tianyue M39</i>	87
Tabla 17 <i>Selección del entorno de desarrollo</i>	89
Tabla 18 <i>Selección de dataset de imágenes</i>	90
Tabla 19 <i>Selección de red neuronal preentrenada</i>	92
Tabla 20 <i>Especificaciones del cargador</i>	101
Tabla 21 <i>Distribución de dataset para entrenamiento</i>	105
Tabla 22 <i>Especificaciones del computador</i>	112
Tabla 23 <i>Especificaciones de la red neuronal preentrenada</i>	115

Tabla 24 <i>Configuración de entrenamiento red neuronal originales</i>	120
Tabla 25 <i>Configuración de entrenamiento red neuronal segmentadas</i>	120
Tabla 26 <i>Infraestructura computacional para entrenamiento</i>	138
Tabla 27 <i>Parámetros de entrenamiento en infraestructura (Google Colab / A100) – Red neuronal originales</i>	139
Tabla 28 <i>Parámetros de entrenamiento en infraestructura (Google Colab / A100) – Red neuronal segmentadas</i>	140
Tabla 29 <i>Valores del entrenamiento en infraestructura A100</i>	142
Tabla 30 <i>Parámetros de entrenamiento en infraestructura (Google Colab / L4) – Red neuronal originales</i>	144
Tabla 31 <i>Parámetros de entrenamiento en infraestructura (Google Colab / L4) – Red neuronal segmentadas</i>	145
Tabla 32 <i>Valores del entrenamiento en infraestructura L4</i>	146
Tabla 33 <i>Parámetros de entrenamiento en infraestructura (Google Colab / TPUv2-8) – Red neuronal originales</i>	149
Tabla 34 <i>Parámetros de entrenamiento en infraestructura (Google Colab / TPUv2-8) – Red neuronal segmentadas</i>	150
Tabla 35 <i>Valores del entrenamiento en infraestructura TPUv2-8</i>	151
Tabla 36 <i>Resumen de valores de precisión y pérdida del entrenamiento</i>	154
Tabla 37 <i>Tiempos de inferencia del sistema</i>	155
Tabla 38 <i>Características del computador de la implementación</i>	156
Tabla 39 <i>Conjunto de pruebas de campo del sistema</i>	167
Tabla 40 <i>Resumen de las muestras</i>	170
Tabla 41 <i>Resultados de las pruebas de campo del sistema</i>	171
Tabla 42 <i>Umbral de confianza de los resultados</i>	173

Tabla 43 <i>Resultados de pruebas externas realizadas</i>	175
Tabla 44 <i>Descripción de los costos del sistema</i>	176
Tabla 45 <i>Descripción del costo general del sistema</i>	178
Tabla 46 <i>Tabulación de 100 muestras</i>	196
Tabla 47 <i>Resultados de 100 prediagnóstico</i>	211

ÍNDICE DE FIGURAS

	Pág.
Figura 1 <i>Melanoma "Léntigo maligno"</i>	35
Figura 2 <i>Melanoma "Diseminación superficial"</i>	36
Figura 3 <i>Melanoma "Nodular"</i>	37
Figura 4 <i>Melanoma "Acral" (Léntiginoso acral)</i>	37
Figura 5 <i>Dermoscopio digital</i>	39
Figura 6 <i>Melanoma en imagen dermatoscopica</i>	40
Figura 7 <i>Repositorio de imágenes ISIC</i>	42
Figura 8 <i>Componentes de la Inteligencia Artificial</i>	44
Figura 9 <i>División en parches</i>	48
Figura 10 <i>Representación de parches (tokens) en DeiT</i>	49
Figura 11 <i>Codificador Transformer</i>	50
Figura 12 <i>Bloque de salida y clasificación</i>	50
Figura 13 <i>Vista interna de un CPU o microprocesador</i>	52
Figura 14 <i>Estructura básica de la memoria RAM</i>	53
Figura 15 <i>Estructura básica de una memoria ROM</i>	54
Figura 16 <i>Arquitectura de GPU moderna</i>	56
Figura 17 <i>Arquitectura de TPU</i>	58
Figura 18 <i>Fases del Modelo en Cascada</i>	61
Figura 19 <i>Índice de radiación UV en Ecuador</i>	64
Figura 20 <i>La Rinconada - Parroquia San Pablo del Lago</i>	65
Figura 21 <i>Arquitectura del sistema</i>	79
Figura 22 <i>Representación gráfica del TIANYUE M39</i>	89
Figura 23 <i>Diagrama de bloques del sistema</i>	93

Figura 24 <i>Diagrama de flujo del funcionamiento del sistema</i>	95
Figura 25 <i>Diagrama de flujo de entrenamiento y clasificación del sistema</i>	96
Figura 26 <i>Identificación de lesión en el torso</i>	97
Figura 27 <i>Ejemplo no adecuado en la toma de muestras</i>	98
Figura 28 <i>Ejemplo adecuado en la toma de muestras</i>	99
Figura 29 <i>Archivos del software MRKF</i>	99
Figura 30 <i>Entorno de captura de imágenes MRKF</i>	100
Figura 31 <i>Conexión exitosa del dermatoscopio digital al computador</i>	100
Figura 32 <i>Cargador del dermatoscopio TIANYUE M39</i>	101
Figura 33 <i>Indicadores de interacción del dispositivo</i>	102
Figura 34 <i>Ejemplo de toma de imagen de muestra</i>	102
Figura 35 <i>Directorio de almacenado de imágenes</i>	103
Figura 36 <i>Galería de imágenes del ISIC 2024</i>	104
Figura 37 <i>Representación gráfica del espacio de color CIE L*A*B</i>	106
Figura 38 <i>Aplicación de filtro anisotrópico</i>	107
Figura 39 <i>Segmentación a través de clustering automático k-means</i>	108
Figura 40 <i>Optimización de la segmentación</i>	109
Figura 41 <i>Detección de bordes de la lesión</i>	110
Figura 42 <i>Eliminación de objetos</i>	110
Figura 43 <i>Dilatación de la imagen segmentada</i>	111
Figura 44 <i>Adaptación de dataset para el entrenamiento</i>	113
Figura 45 <i>Porción del código de segmentación de las imágenes del dataset</i>	114
Figura 46 <i>Segmentación del dataset para el entrenamiento</i>	114
Figura 47 <i>Montaje de Google Drive, instalación e importación de librerías</i>	116
Figura 48 <i>Carga de dataset y aumento de datos</i>	116

Figura 49 <i>Carga de modelo DeiT-B Distillation y ajuste de capas.....</i>	117
Figura 50 <i>Técnicas para mejorar el entrenamiento y sobreajuste</i>	117
Figura 51 <i>Código del entrenamiento del modelo DeiT-B Distillation</i>	118
Figura 52 <i>Código de validación del entrenamiento</i>	119
Figura 53 <i>Código de clasificación de imágenes Python.....</i>	122
Figura 54 <i>Ventana de ingreso de credenciales de acceso</i>	124
Figura 55 <i>Ventana del menú de opciones</i>	124
Figura 56 <i>Ventana de ingreso de información del paciente</i>	125
Figura 57 <i>Estructura de control de datos del paciente</i>	126
Figura 58 <i>Carga de imagen al sistema</i>	126
Figura 59 <i>Código de selección de la imagen a ingresar al sistema</i>	127
Figura 60 <i>Procesamiento de la imagen ingresada</i>	128
Figura 61 <i>Código del procesamiento de las imágenes ingresadas al sistema</i>	129
Figura 62 <i>Obtención de los parámetros de la imagen ingresada.....</i>	129
Figura 63 <i>Código para el cálculo de los parámetros de textura de las imágenes</i>	130
Figura 64 <i>Ejemplo de prediagnóstico benigno</i>	131
Figura 65 <i>Ejemplo de prediagnóstico maligno (melanoma)</i>	131
Figura 66 <i>Código del prediagnóstico de las muestras ingresadas.....</i>	132
Figura 67 <i>Ventana de información del desarrollador y salida</i>	133
Figura 68 <i>Código para la generación de informes.....</i>	133
Figura 69 <i>Información del desarrollador</i>	134
Figura 70 <i>Ingreso al directorio con los informes realizados anteriormente</i>	134
Figura 71 <i>Ejemplo de un informe de resultados generado.....</i>	135
Figura 72 <i>Herramienta de compilación de aplicaciones de escritorio</i>	136
Figura 73 <i>Entorno de compilación de aplicaciones</i>	136

Figura 74 Directorios de distribución de la aplicación	137
Figura 75 Matrices de confusión de red neuronal originales – A100	143
Figura 76 Matrices de confusión de red neuronal segmentadas – A100.....	144
Figura 77 Matrices de confusión de red neuronal originales – L4	148
Figura 78 Matrices de confusión de red neuronal segmentadas – L4.....	148
Figura 79 Matrices de confusión de red neuronal originales – TPUnv2-8.....	152
Figura 80 Matrices de confusión de red neuronal segmentadas – TPUnv2-8	153
Figura 81 Asistente de instalación del programa	157
Figura 82 Instalación de Python.....	157
Figura 83 Instalación de librerías	158
Figura 84 MRKF en ejecución	159
Figura 85 Toma de pruebas a las personas (1)	160
Figura 86 Entorno de toma de muestras con el dermatoscopio	160
Figura 87 Ejecución del software de detección	161
Figura 88 Ingreso de credenciales de administrador	161
Figura 89 Ingreso de datos del paciente	162
Figura 90 Ejemplo de un prediagnóstico de una muestra	163
Figura 91 Informe PDF del resultado de la prueba	164
Figura 92 Toma de pruebas a las personas (2)	168
Figura 93 Toma de pruebas a las personas (3)	168
Figura 94 Bienvenida por parte de los socios hacia el desarrollador	169
Figura 95 Indicaciones iniciales con el representante de la asociación	170
Figura 96 Prueba 1 – Adulto mayor (Mujer 78 años).....	216
Figura 97 Resultado 1 – Adulto mayor (Mujer 78 años).....	216
Figura 98 Prueba 2 – Adulto mayor (Mujer 92 años).....	217

Figura 99 <i>Resultado 2 – Adulto mayor (Mujer 92 años)</i>	217
Figura 100 <i>Resultado 2 – Adulto mayor (Mujer 92 años)</i>	218
Figura 101 <i>Resultado 3 – Adulto mayor (Mujer 83 años)</i>	218
Figura 102 <i>Prueba 4 – Adulto mayor (Hombre 86 años)</i>	219
Figura 103 <i>Resultado 4 – Adulto mayor (Hombre 86 años)</i>	219

CAPÍTULO I

ANTECEDENTES

En el presente capítulo, se da a conocer el tema del Trabajo de Integración Curricular, el problema de investigación, la justificación que respalda al mismo y los objetivos que deberán ser cumplidos a lo largo del desarrollo para la culminación exitosa del trabajo.

1.1 Tema

Detector de melanomas en la piel utilizando redes neuronales para las personas de la Asociación Agroturística Valle La Rinconada.

1.2 Problema de investigación.

La piel, siendo el órgano más grande en el cuerpo humano, desempeña funciones vitales, por lo que mantenerla protegida y bien cuidada es esencial para garantizar un funcionamiento corporal óptimo (Fonseca & Sánchez, 2018). El descuido y maltrato de la piel produce enfermedades que se las puede catalogar como crónicas, infecciosas, tumorales o cancerígenas que producen graves problemas de salud hacia la persona. En Ecuador, según el Instituto Nacional de Estadísticas y Censo, las enfermedades de carácter dermatológico se encuentran entre las cinco primeras causas de asistencia médica de primer nivel en entornos rurales (INEC, 2019). Para el año 2018 se tuvo el reporte de que los casos por enfermedades en la piel constituyeron el 17.5% de los casos atendidos en los centros de atención de salud de primer nivel, debido a ello ya se considera como un problema de salud en el país (INEC, 2019). Las patologías en la piel pueden llegar a provocar cáncer de piel debido a muchos factores, entre los tipos más comunes son carcinoma basocelular, carcinoma espinocelular y melanoma. Según

Centros para el Control y Prevención de Enfermedades, el melanoma es el que más muertes provoca, y se origina debido al crecimiento descontrolado de los melanocitos, que son células que dan la tonalidad a la piel, estos pueden aparecer en cualquier parte del cuerpo; sin embargo, es más frecuente su aparición en el pecho y la espalda en el caso de los hombres, y por parte de las mujeres en las piernas (CDC, 2023). En la mayoría de los casos, el cáncer aparece en la epidermis y es capaz de extenderse a otras zonas del cuerpo, y hacia capas más profundas de la piel (American Cancer Society, 2019). En Ecuador, cerca del 30% de los casos de melanoma no fueron diagnosticados debido al inicio de la pandemia por el Covid-19, y según el dermatólogo Jorge Bonifaz “La falta de diagnóstico de estas enfermedades es una causa más de que evolucionen y llegue a tal punto de que las personas mueran” (Alvarado, 2021).

Ecuador debido a la posición geográfica en la que se encuentra, recibe los rayos solares de manera perpendicular y tiene luz solar constante de 12 horas diarias, por ende, sus habitantes se ven expuestos a mayor cantidad de radiación solar durante el transcurso del día (Ballesteros et al., 2023). Según la Encuesta Nacional de Empleo, Desempleo y Subempleo, en el año 2021 cerca del 29.7 % de mujeres y 32.9 % de hombres en el país se dedican a la agricultura y actividades relacionadas al turismo local (INEC, 2022). Considerando estas cifras, se especula que las personas que se dedican a esta labor están siendo afectadas por pasar largos periodos de tiempo a la exposición del sol, con lo cual es un factor importante considerar que pueden padecer lesiones en la piel de carácter cancerígeno. En la mayoría de los casos, son personas de edad avanzada (40 años en adelante) que se dedican a la agricultura, ganadería y turismo local. Tomando en cuenta la situación económica del país, se pretende que las personas que se dedican en este oficio no consideran realizarse exámenes médicos en caso de que tengan algún tipo de lesión en la piel, a veces por desconocimiento propio o por falta de recursos económicos.

Existen opciones de prevención para ello, como puede ser un protector solar o prendas; sin embargo, no ofrecen una garantía de que este tipo de lesiones no puedan aparecer (Merino, 2009). En la Asociación Agroturística Valle La Rinconada ubicada en la parroquia San Pablo del Lago, cantón de Otavalo, provincia de Imbabura, se ha determinado que la mayoría de las personas que la conforman son personas de edad avanzada que se dedican a la producción de alimentos y venta de los mismos en sus actividades turísticas que ofrecen en el sector “La Rinconada”. Debido a la situación económica actual, les resulta complicado la adquisición de algún tipo de protección solar que pueda ayudar a protegerlos diariamente durante su jornada de trabajo.

Para la detección temprana de posibles lesiones en la piel que puedan conllevar al desarrollo de enfermedades de mayor gravedad, se requiere de una herramienta que sea capaz de realizar un prediagnóstico rápido, a tal punto que resulte mucho más económico y sencillo que realizarse exámenes en un centro dermatológico sin tener algún tipo de conocimiento acerca de la lesión, considerando que por lo general los síntomas se pueden llegar a confundir con manchas, verrugas, lunares y granos que aparecen en la piel de manera repentina. Por lo que contar con un detector de patologías en la piel en la asociación resulta beneficioso, para que los socios en caso de presentar alguna lesión puedan realizarse un análisis, donde indique si existe algún tipo de lesión, recomendar que acciones tomar y proporcionar un informe con los resultados del prediagnóstico. Este detector deberá para ello contar con un dermatoscopio digital, el cual permite tomar la imagen de la lesión con la iluminación, definición y perspectiva adecuada, para después de ello ser analizada en el programa encargado de la clasificación e identificación de lesiones.

Un prediagnóstico oportuno permite que las lesiones que son identificadas a tiempo tengan menor probabilidad de evolucionar y dar paso a problemas de salud más graves.

Considerando que este tipo de lesiones se dan en personas de edad avanzada y que no tienen responsabilidad con el cuidado de la piel, pueden sufrir graves consecuencias, entre ellos la muerte. Como consecuencias secundarias son la afectación del núcleo familiar, dado que en la mayoría de los casos son cabezas de familia, el aumento de gastos médicos en caso de contraer cáncer de piel e impacto emocional en las personas cercanas del afectada/o. Con el detector de lesiones, lo que pretende es que los socios puedan realizarse las pruebas en caso de tener sospecha de alguna lesión y con ello afirmar o descartar de cierta manera el problema, para considerar acudir a un especialista en caso de que el resultado sea positivo.

1.3 Justificación

Este proyecto surge tras determinar la situación actual de las personas que trabajan bajo el sol por periodos prolongados diariamente, con ello se establece que uno de los sectores más afectados es el agroturístico. En general, es gente que se dedica diariamente a la producción agrícola y prestación de servicios turísticos de su misma localidad. Si bien este sector es muy importante económicamente para el país, existe descuido por parte de las autoridades locales y provinciales, de la salud y desarrollo económico de las personas que se dedican a ello (Chururuchumbi, 2020).

Es importante considerar la salud en este ámbito, dado que, al pasar por tiempos largos a la exposición solar, se ha llegado a determinar qué es una causa de la aparición de cáncer en la piel. Según estudios realizados, entre los años 1986 y 1990 el promedio de casos era de 21 cada 100 mil habitantes; sin embargo, con el pasar de los años y de los cambios climáticos que ha tenido el planeta, entre los años 2006 y 2010 la incidencia aumentó, llegando a los 33 por cada 100 mil habitantes y para la década actual estos valores han incrementado. Por consiguiente, el cáncer de piel ocupa el primer lugar

mundial en tumores malignos. Se manifiesta principalmente entre las edades de 60 y 70; sin embargo, se observan cada vez más casos de cáncer de piel en adultos jóvenes menores de 40 años (Cerón & Ayon, 2020).

Considerando la situación del país, según el Ministerio de Salud Pública, cerca del 19% de todos los casos de cáncer que se dan en el país son atribuidos a las exposiciones constantes al medio ambiente incluyendo el entorno laboral. En ese contexto se tiene registro de que en el año 2002 las radiaciones ultravioletas fueron las causantes de alrededor de 60000 muertes, 48000 por melanomas y cerca de 12000 por carcinomas basales y escamosos de la piel (MSP, 2017). Por ello, el MSP enfatiza en que se debe identificar los agentes cancerígenos laborales para poder adoptar maneras de protección, debido a que los agricultores son los que más riesgo tienen por la exposición a la radiación ultravioleta, polvos, aflatoxinas, virus y plaguicidas (MSP, 2017). En ese contexto a nivel país, el detector de melanomas propuesto ayudaría a reducir el porcentaje de cáncer provocado por carcinógenos físicos y químicos que afectan directamente a la piel, dado que con ello se obtendría un prediagnóstico mucho más rápido, económico y preventivo.

Un caso de estos ocurrió en la provincia de Tungurahua según la nota de prensa del Diario La Hora, se trata de Claudio Mena, un agricultor que poseía un grano en el rostro. Asegura que la zona en que se encontraba la lesión se irritaba y crecía cada vez que se rascaba, asistió al médico y le diagnosticaron cáncer de piel. Lo que supo manifestar el agricultor es que a sus 72 años nunca ha utilizado protector solar y lo único que conoce para ello es utilizar una gorra y colocarse bajo la sombra. Otro caso es el de Mercedes Lozada de 54 años, que menciona que tuvo una aparición de un lunar repentino en su brazo derecho, que con frecuencia se irritaba y crecía. Tras asistir al médico le diagnosticaron inicios de cáncer de piel y se le recomendó utilizar protección solar; sin embargo, ella menciona que debido a su situación económica no puede adquirirlo para

ella, ya que asegura que sus hijos que la acompañan diariamente presentan heridas en las mejillas y prefiere dárselo a ellos (Diario La Hora, 2022). Es importante considerar también que no únicamente ocurre estos casos debido al desconocimiento, sino que también influye directamente la situación económica de las personas y que indirectamente pueden ser afectados los familiares.

Uno de los Objetivos de Desarrollo Sostenible propuestos por la Organización de las Naciones Unidas es “Garantizar una vida sana y promover el bienestar para todos en todas las edades” (ONU, 2023). Este objetivo va de la mano con la temática del TIC, dado que lo que se busca es dar una solución al acceso de diagnósticos médicos para aquellas personas que no cuenten con los recursos económicos para realizarlo, debido a que, si bien el sistema de salud en el país puede ser gratuito, lo que respecta a transporte, medicinas específicas y tratamientos no se consideran a la hora de hablar de ese tema. Con esto se daría la facilidad de que las personas puedan conocer acerca de alguna molestia en la piel que le haya aparecido y poder ya considerar tratarse con un especialista, otro enfoque que se le puede dar es que, si bien en sus inicios las lesiones pueden tratarse, sería una manera de poder pre diagnosticarlo a tiempo y poder dar solución a la enfermedad.

Al considerar todo esto, el tema del TIC se encuentra orientado al cumplimiento de los objetivos del pilar 4 del eje de Cultura e Inclusión Digital de la Agenda de Transformación Digital del Ecuador 2022-2025 correspondiente a la Salud Digital, que hace énfasis a la impulsión de programas y proyectos tecnológicos en cuanto a la salud en Ecuador de manera digital, donde se considere zonas rurales y grupos prioritarios para su aplicación (Arcotel, 2022). De esta manera se encuentra orientado a lo que se requiere solucionar en la actualidad, con ello se brinda un aporte en términos de salud y genera mayor concientización en que las personas consideren el cuidado de la piel como una

práctica muy importante en su diario vivir. A la vez, este tipo de proyecto orienta a que se realicen más trabajos de este tipo de soluciones, que se enfoquen en el bienestar y salud de la comunidad de una manera eficiente, sustentable y acorde con la situación socioeconómica del entorno.

De igual manera está orientado hacia el Eje Social del Plan de Creación de Oportunidades 2021 – 2025 propuesto por la Secretaría Nacional de Planificación, en donde enfatiza el derecho al acceso a la salud integral, gratuita y de calidad. Este TIC se orienta a brindar prediagnósticos de melanomas de piel hacia aquellas personas que pertenecen a grupos prioritarios, donde el factor económico es un problema para el acceso a la atención médica. Resulta ser una opción mucho más accesible para la detección de un posible melanoma, con ello ahorrando gastos en exámenes de biopsia y orientando de mejor manera los recursos económicos a la adquisición de medicinas para un tratamiento adecuado (Secretaria Nacional de Planificación, 2021).

1.4 Objetivos

1.4.1 Objetivo General

- Desarrollar un detector de melanomas en la piel mediante la utilización de redes neuronales para el diagnóstico en las personas de la Asociación Agroturística Valle La Rinconada.

1.4.2 Objetivos Específicos

- Fundamentar el estado del arte en cuanto a la piel, enfermedades cutáneas, tratamientos, inteligencia artificial, visión por computador, redes neuronales, plataformas de desarrollo y dispositivos de obtención de imágenes dermatoscópicas.
- Establecer de manera precisa los requisitos fundamentales para el diseño y desarrollo efectivo de un detector de melanomas en la piel utilizando redes neuronales para la Asociación Agroturística Valle La Rinconada.
- Diseñar un detector de melanomas en la piel como herramienta de análisis de imágenes dermatoscópicas que compare e identifique mediante las redes neuronales las lesiones en la piel con un dataset previamente aprendido.
- Realizar pruebas y validar el funcionamiento del detector mediante bases de datos e imágenes dermatoscópicas obtenidas en las pruebas realizadas a las personas de la asociación.

CAPÍTULO II

FUNDAMENTACIÓN TEÓRICA

En el siguiente capítulo teórico, se abordan los conceptos fundamentales relacionados con el tema central del trabajo de integración curricular. Se indaga en aspectos como: los melanomas, técnicas de detección, redes neuronales, modelos preentrenados, entornos de entrenamiento, dataset de imágenes dermatoscópicas y la infraestructura computacional; temas que desempeñan un papel fundamental en el desarrollo del detector de melanomas en la piel de las personas. El propósito de este análisis teórico radica en establecer un contexto claro para la conceptualización e implementación del sistema de detección.

2.1 Melanoma

El melanoma es catalogado como el tumor maligno cutáneo más agresivo y mortal. Se origina en los melanocitos, los cuales son transformados malignamente y producen la metástasis en diferentes órganos en función de la profundidad del tumor. La aparición de los melanomas puede ser atribuida a dos factores: el incremento de la exposición solar y la disminución de la vigilancia epidemiológica (Weyers, 2018). En consecuencia, en los últimos años ha incrementado la incidencia promedio-edad con un aumento anual entre el 3% al 7% (Faizal, 2014). Los riesgos más comunes de desarrollar melanomas son poseer piel blanca y pasar largos periodos en exposición solar intensa. Las tasas más altas de aparición se encuentran en países del norte de Europa, Austria y Suiza a comparación de la población autóctona de Asia, África y Sudamérica (Faizal, 2014). Sin embargo, otra cuestión a considerar es que aquellos países que se encuentran cercanos a la línea ecuatorial son más propensos a percibir enfermedades de este tipo, por la radiación diaria que reciben.

Los melanomas pueden tomar diferentes apariencias, los doctores Clark & McGovern lo clasifican en cuatro tipos:

- Léntigo maligno.
- Lentiginoso acral.
- De diseminación superficial.
- Nodular.

(Clark, 2006)

2.1.1 Melanoma léntigo maligno

El tipo léntigo maligno por lo general se presenta en personas adultas de 65 años en donde las áreas de afectación más frecuentes son la cara, cabeza, cuello y raramente en el dorso de las manos. La apariencia se muestra como manchas de color café-negro, moteadas y son predominantes en el género femenino (Faizal, 2014). La lesión se representa a través de la Figura 1.

Figura 1

Melanoma “Léntigo maligno”




Nota. En la figura se puede visualizar una lesión de tipo melanoma léntigo maligno a la altura del rostro de una mujer de tercera edad. Fuente: Obtenido de (Faizal, 2014).

2.1.2 Melanoma diseminación superficial

El tipo diseminación superficial es el más común entre la población de piel blanca y aparece en edades tempranas, alrededor de los 40 años, un ejemplo de ello se representa en la Figura 2. En cuanto a las mujeres, las zonas afectadas son las piernas y el dorso en el caso de los hombres. Las lesiones son de contorno irregular y poseen signos de regresión focal representada por áreas hipopigmentadas en el centro de la lesión. Toman coloraciones variadas como negro, café, marrón, azul, rojo y blanco (Faizal, 2014).

Figura 2

Melanoma "Diseminación superficial"



Nota. En la figura se puede visualizar una lesión de tipo melanoma diseminación superficial en la zona inferior de la rodilla derecha de un hombre. Fuente: Obtenido de (Faizal, 2014).

2.1.3 Melanoma nodular

El tipo nodular es considerado como el de mayor agresividad y mortalidad, predomina en personas de género masculino y de piel blanca. Es localizado en la zona de la espalda en el 75% de los casos y su apariencia es de coloración negra, azul, roja o gris, además presenta un crecimiento rápido y de superficie esférica o lisa (Faizal, 2014). En la Figura 3 se representa el tipo de lesión mencionado.

Figura 3

Melanoma "Nodular"



Nota. En la figura se puede visualizar una lesión de tipo melanoma nodular en la zona izquierda del cuello de un hombre de tercera edad. Fuente: Obtenido de (Faizal, 2014).

2.1.4 Melanoma acral

El tipo acral es uno de los más frecuentes en países que se encuentran en vías de desarrollo y su incidencia generalmente es en personas de etnias latinas y afrodescendientes. Por lo general aparece en las plantas de los pies y esto se debe a no utilizar calzado, tal como se muestra en la Figura 4. Tiene una apariencia irregular y con bordes no definidos, la coloración suele ser de tonos cafés y negros. Comprende entre el 0.7% y el 3.5% de todos los casos de melanomas (Faizal, 2014).

Figura 4

Melanoma "Acral" (Léntiginoso acral)



Nota. En la figura se puede visualizar una lesión de tipo melanoma acral en la zona de la planta del pie izquierdo de una persona de la tercera edad. Fuente: Obtenido de (Faizal, 2014).

Los índices de supervivencia a estas enfermedades después de cinco años de haber sido diagnosticados son del 80% al 85% en áreas de alta incidencia, pero en las de baja incidencia las probabilidades son mucho menores (Durocher, 2012). La mayoría de los casos suelen desarrollarse por varios años y por lo general pasan por estados premalignos antes de alcanzar un estado potencial pleno, como suele suceder con las queratosis arsenicales y las queratosis actínicas (Durocher, 2012). En su mayoría las fases premalignas suelen ser detectadas de manera visual, pero se sugiere que las personas que tengan la sospecha de poseer cáncer de piel se realicen diagnósticos periódicos, ya que con ello existe la posibilidad real de reducir el nivel de mortalidad con un debido tratamiento.

2.2 Técnicas de detección

La detección temprana de melanomas es crítica, debido a que en el inicio de la evolución de la lesión existen altas probabilidades de poder eliminar el tumor. Sin embargo, por las características propias del tumor en su etapa temprana, resulta complicado identificarlo ya que suele ser confundido con lunares, marcas de nacimiento o verrugas. Una técnica médica indolora para la detección del melanoma es la microscopia de epiluminiscencia o dermatoscopia. Es llevada a cabo a través de un dispositivo manual, que es capaz de evaluar patrones de tamaño, forma y pigmentación de las lesiones (American Society of Clinical Oncology, 2019). Un aspecto relevante es que a través del uso de dermatoscopios por parte de profesionales médicos con experiencia, se ha reducido la cantidad de biopsias de lesiones pigmentadas para la detección de melanomas. Además, existe la microscopia confocal de escaneo láser, que es una técnica de mayor precisión para la detección de posibles melanomas; sin embargo, solo es utilizado en estudios de investigación y centro médicos importantes a nivel

mundial. En la Figura 5 se indica el aspecto general de un dermatoscopio digital para este tipo de aplicaciones.

Figura 5

Dermatoscopio digital




Nota. En la figura se puede visualizar un dispositivo conocido como dermatoscopio digital que captura imágenes de lesiones cutáneas. Fuente: Obtenido de (ACME, 2022).

La técnica de la dermatoscopia se define como una técnica diagnóstica que permite la visualización de lesiones en la piel a través de la amplificación con instrumentos ópticos y el uso de filtros de luz polarizada. Con la supresión del brillo de la superficie de la piel, se logra visualizar estructuras a mayor detalle, donde es muy difícil ver a simple vista. (Schwartz et al., 2011). En la Figura 6 se muestra una imagen dermatoscópica en la que existe la presencia de melanoma.

Figura 6

Melanoma en imagen dermatoscópica



Nota. En la figura se puede visualizar un melanoma capturado en una imagen dermatoscópica a través de un dermatoscopio digital. Fuente: Obtenido de (Gallegos et al., 2015).

Según Schwartz et al. (2011), se ha comprobado que la dermatoscopia mejora la sensibilidad del diagnóstico de lesiones de melanomas en aproximadamente un 20%, además que ha disminuido el número de biopsias innecesarias. Algo a considerar es que la precisión de la detección depende plenamente de la experiencia y capacidad del médico que la realice.

Una técnica utilizada para la exploración es la regla A-B-C-D-E que sugiere que si una anomalía cumple con las siguientes características se deba consultar con un especialista de inmediato:

- A (Asimetría en alguno de los ejes de la lesión)
- B (Bordes irregulares)
- C (Color variado, es decir no uniforme)
- D (Diámetro mayor a 6 mm)
- E (Evolución en los cambios de la lesión)

(IMED, 2013)

Otra técnica es la lista de verificación revisada de 7 puntos para melanoma de Glasgow, dicha técnica permite identificar lesiones en base a criterios de mayor y menor ponderación:

- **Criterios mayores:** cambio de tamaño, forma y colores irregulares.
- **Criterios menores:** diámetro mayor o igual a 7mm, inflamación, sangrado y cambio de sensación.

Se considera una sospecha de melanoma, en caso de que se obtenga como resultado un criterio mayor o sino tres o más criterios menores (Walter et al., 2013).

Otra técnica es la de CHAOS & CLUES que básicamente es un algoritmo que analiza patrones a través de la observación de asimetrías en la estructura y color de las lesiones, adicional a ello se basa en la detección de “señales” que proporcionen información para determinar si es maligna o no la lesión (Rosendahl et al., 2015).


2.3 Dataset de imágenes ISIC

La Colaboración Internacional de Imágenes de la Piel (ISIC) es una alianza entre el área académica e industria, creada con el propósito de emplear imágenes digitales de la piel para contribuir a disminuir la mortalidad causada por el cáncer de piel. El objetivo de trabajo es el desarrollo y la promoción de estándares para la captura de imágenes digitales de la piel, mediante la colaboración con las comunidades de dermatología y visión por computadora. Por otro lado, el objetivo clínico es respaldar los esfuerzos para disminuir las muertes por melanoma y evitar biopsias innecesarias, mejorando la precisión y la eficiencia en la detección temprana del melanoma (ISIC, 2024).

El dataset es de acceso público y se encuentra en constante crecimiento, sirve como un recurso público para la educación, la investigación, y el desarrollo de algoritmos de inteligencia artificial para diagnóstico. En la actualidad la galería del ISIC cuenta con 485079 imágenes con diferentes lesiones de la piel, entre ellas melanomas, carcinomas de células basales, carcinomas de células escamosas y queratosis actínicas (ISIC, 2024). Se encuentra compuesto por contribuciones de academias, centros de investigación, centros médicos, entre otros. El repositorio cuenta con varios filtros que permiten clasificar en función de los atributos del diagnóstico, atributos clínicos y atributos tecnológicos. En la Figura 7 se puede visualizar el repositorio de las imágenes con las que cuenta la ISIC.

Figura 7

Repositorio de imágenes ISIC



Nota. En la figura se puede visualizar cada uno de los filtros por los cuales se puede clasificar las imágenes para poder ser descargadas. Fuente: Obtenido de (ISIC, 2024).

La ISIC cuenta con varios grupos de trabajo, que se encargan de elaborar estándares para asegurar la calidad, la privacidad y la interoperabilidad de las imágenes

dermatológicas. Además se organizan talleres y desafíos de ML para involucrar a los investigadores de visión por computadora anualmente.

2.4 Inteligencia artificial

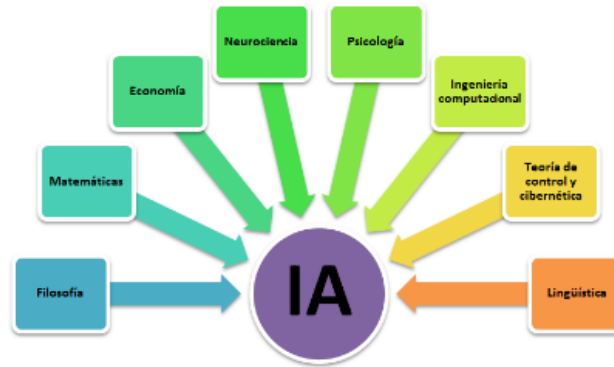
El término Inteligencia Artificial (IA) puede adoptar diversas definiciones según el contexto en el que se describa, pero según Pérez (2018), la inteligencia artificial se define como la rama de las ciencias computacionales que se encarga del diseño y construcción de sistemas capaces de realizar tareas asociadas con la inteligencia humana.

Es una disciplina académica que tiene como objetivo emular algunas de las facultades intelectuales humanas en sistemas artificiales, entre las más destacadas la capacidad de poder tomar decisiones en base a datos que pueda obtener el sistema de manera progresiva. Con facultades intelectuales humanas se refiere a la percepción sensorial (visión, audición, decisión, entre otros) y sus procesos de reconocimiento de patrones, por ello las aplicaciones más frecuentes son el tratamiento de datos e identificación a través de sistemas (Benitez, 2014).

El diseño de un sistema de inteligencia artificial se compone de otras disciplinas técnicas como el cálculo matemático, la estadística, la robótica, la neurociencia, el procesamiento de señales y la computación que es uno de los pilares fundamentales en su desarrollo, ya que los sistemas IA son entrenados, adaptados y utilizados sobre hardware de altas prestaciones que permite el funcionamiento de los procesos asociados al sistema. En la Figura 8 se muestra un diagrama que representa las disciplinas que constituyen la inteligencia artificial.

Figura 8

Componentes de la Inteligencia Artificial



Nota. En la figura se puede visualizar un esquema en donde indica cada una de las ciencias que componen la rama de la inteligencia artificial. Fuente: Obtenido de (Moreles, 2019).

De esta manera, la inteligencia artificial abarca diversas áreas que son usadas para el desarrollo de sistemas y aplicaciones, entre las más utilizadas son el aprendizaje supervisado, aprendizaje no supervisado, deep learning, redes neuronales, visión por computadora y procesamiento de lenguaje natural. Lo que tienen en común, es que los sistemas se componen de dos fases muy importantes, la primera fase de aprendizaje y la segunda fase de predicción. (Benitez, 2014).

2.4.1 Redes neuronales

Una red neuronal es una técnica de inteligencia artificial que permite a las computadoras analizar datos de una forma similar al funcionamiento del cerebro humano. Este enfoque pertenece a la rama machine learning, que emplea nodos o neuronas interconectadas organizadas en capas, imitando la estructura del cerebro (Amazon Web Services, 2024a).

Según Matich (2001), una red neuronal es un sistema de tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano, conocido como neurona. Estos modelos se adaptan

conforme a las técnicas y datos de aprendizaje que se le proporcione, donde su función principal es la modificación de los pesos de las conexiones entre las unidades básicas, mismas que interactúan entre sí para la toma de decisiones o predicciones (Reventós, 2019).

Se encuentran conformadas por tres capas: la primera, la capa de entrada y es por donde los datos ingresan, la segunda, la capa oculta y es en donde se realiza los cálculos, y por último, la capa de salida es la que proporciona los resultados de todo el sistema ya sea en datos o decisiones (Matich, 2001).

Las aplicaciones más comunes de las redes neuronales son la visión artificial, el reconocimiento de voz, procesamiento del lenguaje natural, los motores de búsqueda, entre otros. En cuanto a la visión artificial, permite a las computadoras extraer información y comprender imágenes y videos, por medio de la identificación y reconocimiento de imágenes de tal manera como lo realiza una persona (Amazon Web Services, 2024a).

2.4.2 Redes neuronales basadas en Transformers

Las redes neuronales basadas en transformadores son estructuras desarrolladas inicialmente para la manipulación de datos en el procesamiento de lenguaje natural hasta el análisis de sonido, imágenes, aprendizaje por refuerzo, bioinformática y economía (De la Torre, 2023). Se caracteriza por el sistema de auto atención que detecta patrones en la influencia y dependencia que tienen los datos entre sí representados a través de vectores (Merritt, 2022). La manera en que funcionan los transformadores es a través de la observación de distintas partes de una secuencia a la vez y con ello determinar cuales corresponden a las de mayor importancia dentro del vector de representación de los datos (Amazon Web Services, 2024). A través de una secuencia de entrada, genera dos

secuencias de salida, siendo la primera una representación numérica de los datos y la segunda corresponde a la posición vectorial de los datos de entrada que permite identificar la posición a la que corresponde cada dato. Las secuencias de entrada para el modelo transformer pueden ser datos de texto, imágenes o videos, ya que al final a través de matrices de valores numéricos son representadas para el proceso de embedding. Los modelos con transformadores son creados a partir de conjuntos grandes de datos y permiten realizar predicciones precisas que permiten ser utilizados en diversos campos; debido a su desarrollo ha ido reemplazando consecutivamente a las redes neuronales convolucionales en el ámbito de clasificación de imágenes (Merritt, 2022).

2.4.2.1 Modelo Data Efficient Image Transformer

El modelo Data Efficient Image Transformer (DeiT) es una adaptación del modelo de red neuronal Vision Transformer (ViT) para su uso en tareas de visión por computadora. En primera instancia las redes ViT requieren de un conjunto de cientos de millones de imágenes para que logre obtener resultados equivalentes a los alcanzados con redes neuronales convolucionales. Sin embargo, esta adaptación desarrollada por Facebook IA permite entrenar modelos cuando se tiene un limitado conjunto de datos (Meta, 2020). En pruebas realizadas en cuanto al entrenamiento con diferentes modelos se ha determinado que DeiT es mucho más eficiente que ViT, debido a que supera la dificultad de contar con un masivo dataset de entrenamiento para alcanzar niveles de precisión buenos. Utilizando ImageNet-1k con el modelo DeiT-B se ha alcanzado una precisión del 85.2%, en cambio con ViT-B una precisión de 78% (Touvron et al., 2020).

La esencia del modelo es la utilización de una técnica denominada como destilación, se basa en la agregación de un token adicional de destilación al final de la secuencia de tokens o parches de la imagen procesada, es uno adicional al utilizado en

ViT para la identificación de clase. En términos generales, utiliza la misma arquitectura de los Vision Transformer (ViT) con la diferencia que el token de destilación permite que el modelo aprenda de un modelo maestro. La función principal del token de destilación es reproducir la predicción de la etiqueta predicha por el modelo maestro. Los modelos maestros generalmente son redes neuronales convolucionales preentrenadas en su mayoría variaciones de ResNet que poseen mayor conocimiento en cuanto a la clasificación de imágenes (Ijaz, 2022).

El término destilación es un concepto iniciado por Geoffery Hinton en 2015, que declara a la “destilación de conocimientos” en un ejemplo donde se posee dos redes, una red maestro completa y preentrenada, y una red estudiante simple y de inicialización aleatoria. La red estudiante aprende de la red maestro minimizando la función de pérdida, en donde el objetivo es alcanzar la distribución de probabilidad de la red maestro (Ijaz, 2022).

En DeiT, existe dos tipos de destilación, blanda y dura. La blanda tiene como objetivo que la red estudiante aprenda de las etiquetas reales del dataset y a su vez de las predicciones que le indica el modelo maestro. En contra parte, la destilación dura tiene como enfoque que la red estudiante aprenda únicamente las etiquetas más probables predichas por el maestro, en otras palabras aprenda a predecir la misma clase que el modelo maestro (Tsang, 2022).

El proceso de entrenamiento con el modelo DeiT parte de la misma manera como sucede con ViT, se procesa una imagen dividiéndola en parches, similar a cómo los transformadores manejan el texto mediante incrustaciones de palabras. A partir de estos parches obtenidos de la imagen original, predice directamente las etiquetas de clase correspondientes a la imagen (Boesch, 2023). La predicción de la clase de las imágenes se da por medio del mecanismo de atención que permite medir la relación entre los

parches de las imágenes, este concepto es clave en el funcionamiento de los transformadores que funciona a través de tres variables conocidas como query, key y value (Toolify, 2024).

En primer lugar, la imagen de entrada es dividida en parches iguales con dimensiones idénticas tanto de alto como de ancho. Entonces si se divide en parches, cada uno de ellos toma las dimensiones 16x16x3. En la Figura 9 se representa la manera en la que la división de la imagen se lleva a cabo.

Figura 9

División en parches




Fuente: Adaptado de (Soomro et al., 2018).

Luego de realizar la división en parches procede a la proyección lineal de cada uno de ellos, que toman la forma de ser una secuencia consecutiva en donde la posición de cada uno de los parches es muy importante para el procesamiento posterior. En adición se agrega el token de clase y el token de destilación. Seguido de ello se procede a realizar la codificación posicional, en donde se agrega información posicional de cada uno de los parches en un mismo vector. Tal vector representa la posición espacial de cada parche dentro de la imagen original, que es muy importante para su presentación al codificador Transformer. En la Figura 10 se muestra la estructura de los parches, la agregación de

tokens y representación de los parches previos a ser ingresado en el codificador Transformer.

Figura 10

Representación de parches (tokens) en DeiT



Fuente: Adaptado de (Touvron et al., 2020).

Pasando al bloque de codificación Transformer, se divide en varias etapas, la primera es la atencional en la que los vectores ingresan a tres pequeñas redes neuronales en donde se procede a calcular los vectores query, key y value. Los query se proceden a comparar con los key a través de la multiplicación para obtener los puntajes en una matriz que indica el grado de asociación, a esto se le divide por el tamaño de los vectores y con la aplicación de la función softmax se convierten en valores de probabilidad. Finalmente, cada parche debe ser representado en un solo vector y para ello se procede a multiplicar la matriz resultante con la matriz que generan los vectores de value, con ello se obtiene nuevos vectores que representan lo más relevante de la información de cada uno. Este proceso se realiza por varias veces, con la finalidad de obtener mejores resultados en la información relevante de cada parche. En segundo lugar, ingresan a un bloque FFN en donde se realizan transformaciones no lineales a los resultados obtenidos del bloque de autoatención. Se compone de una red residual que agrega la entrada a la salida de la FFN para evitar la pérdida de información y una MLP con múltiples capas que genera una salida para el siguiente codificador FFN (Ijaz, 2022). En la Figura 11 se muestra de

manera gráfica el codificador Transformer con cada una de las etapas mencionadas anteriormente.

Figura 11

Codificador Transformer



Fuente: Adaptado de (Touvron et al., 2020).

El tamaño de la salida se mantiene como el de entrada, pero únicamente se toma en consideración el token de clase y el token de destilación de salida. Estos son pasados a través de dos capas lineales para proyectar el número de clases y realizar la predicción de clase o calcular la pérdida de entrenamiento (Ijaz, 2022). En la Figura 12 se muestra el bloque de función de pérdida de entropía cruzada para inferir la clase de una imagen por medio del token de clase y el de destilación.

Figura 12

Bloque de salida y clasificación



Fuente: Adaptado de (Touvron et al., 2020).

Un aspecto importante del uso del modelo DeiT es que al trabajar con una cantidad limitada de datos es importante utilizar técnicas como el aumento de datos, regularización y optimización, con la finalidad de tener mayor cantidad de representaciones variadas de los mismos datos (Touvron et al., 2020).

2.5 Infraestructura computacional

Un computador o computadora se basa en una arquitectura, se refiere a la organización y estructura de los componentes físicos de un sistema informático, que permiten su funcionamiento y procesamiento de datos. A nivel de hardware, se compone de elementos que trabajan en conjunto para ejecutar operaciones y almacenar información (Quiroga, 2010).

Existen varios tipos de arquitecturas dependiendo del tipo de computador, bien sea un computador personal, servidor, mainframe, supercomputador, dispositivo móvil, computador embebido, entre otros. Entre las más conocidas son x86, x86-64, ARM, PowerPC, SPARC, Itanium, PA-RISC y MIPS.

La más utilizada en computadores actuales es la x86-64, que no es más que una versión mejorada de x86, en donde funcionaba con sistemas de hasta 32 bits y con esta actualización llegó a los 64 bits impulsada inicialmente por AMD (González, 2023). Entre las características más destacables, es su acceso a mayor cantidad de memoria RAM para procesos que demandan de mayor cantidad de memoria, bases de datos, software de diseño, rendimiento mejorado y mayor capacidad de operaciones de punto flotante.

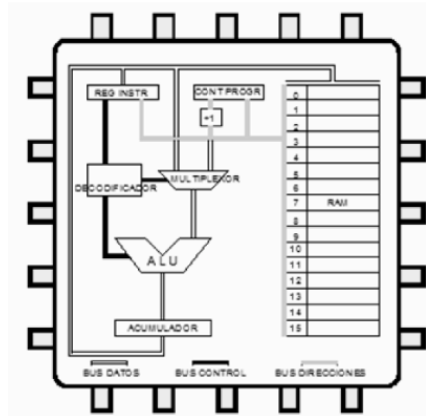
Los componentes básicos de la arquitectura son el procesador (CPU), memoria RAM, placa base, dispositivos E/S, almacenamiento, tarjetas de expansión y la fuente de alimentación de los componentes.

El CPU (Unidad Central de Proceso) contiene componentes (circuitos y chips) que realizan operaciones de interpretación, control y ejecución de instrucciones, a su vez son programables sus instrucciones y procesamiento de datos. Dentro se encuentra un microprocesador que se encuentra formado por una unidad aritmética-lógica que se encarga de realizar cálculos, comparaciones y toma de decisiones lógicas por una serie

de registros donde se almacena la información temporalmente (Quiroga, 2010). En la Figura 13 se muestra la vista interna de un CPU o microprocesador básico.

Figura 13

Vista interna de un CPU o microprocesador.



Fuente: Obtenido de (Martínez, 2012).


La memoria está construida con dispositivos semiconductores de silicio que forman espacios que permiten guardar bits de información, ya sea de manera permanente (memoria ROM) o transitoria (memoria RAM). La memoria RAM es de carácter volátil y de acceso rápido que se utiliza para almacenar temporalmente datos y programas que están siendo utilizados continuamente por el procesador. Se encuentra de tres tipos: estática, dinámica y caché (Martínez, 2012). En la estática permite leer y modificar la información varias veces, se guarda mientras el circuito integrado se mantiene alimentado eléctricamente. La dinámica permite la lectura y escritura pero requieren de una constante recarga eléctrica para conservar los datos. El rendimiento de este componente está directamente relacionado al uso de CPU, ya que si es de menor prestaciones, ralentiza al sistema en general y se convierte en un cuello de botella (Martínez, 2012).

La memoria RAM se encuentra compuesta por celdas de memoria que generalmente está dado por conjuntos de transistores y capacitores que son capaces de

almacenar carga eléctrica que representa a un bit de información. Cuenta con circuitos de control que permiten gestionar la lectura y escritura, buffers de entrada y salida para la comunicación con el procesador, buses de datos que permiten la transferencia de datos con otros componentes y en algunos casos circuitos de refresco para las memorias dinámicas (Quiroga, 2010). En la Figura 14 se puede visualizar la estructura básica de una memoria RAM.

Figura 14

Estructura básica de la memoria RAM



Fuente: Obtenido de (Pérez et al., 2014).


La memoria de almacenamiento permanente (ROM) permite que los datos se queden guardados a pesar de que el dispositivo sea apagado. Con esto permite que se alojen sistemas operativos y al iniciar los dispositivos se ejecuten tal cual quedó por última vez (Aller, 2024). Existen variaciones de este tipo de memoria como PROM, EPROM, EEPROM y Flash Memory. El último tipo, es utilizado en dispositivos de almacenamiento masivo como unidades USB, tarjetas de memoria, discos duros de almacenamiento y discos de estado sólido (SSD), debido a que cuenta con la capacidad de borrado y reprogramado en bloques grandes. Al igual que la memoria RAM cuenta

con elementos similares, pero se diferencia en que las celdas de memoria compuestas por transistores y capacitores se encuentran diseñados para no ser modificados fácilmente, los decodificadores de dirección se encuentran orientados únicamente a lectura, en cuanto a los circuitos de control tienen circuitos que permiten la programación y borrado, y por último el buffer de datos que se orienta a la salida hacia los demás componentes (Martínez, 2012).

En cuanto a los tipos de almacenamiento utilizados en computadores son HDD, SSD, SSD M.2, SSD PCIe, SSD U.2, unidades externas, unidades ópticas como CD, DVD, Blu-Ray y el almacenamiento en la nube. Las capacidades varían en función del tamaño y costo, pueden ir desde MB hasta varios TB. En la Figura 15 se puede visualizar la estructura básica de una memoria ROM.

Figura 15

Estructura básica de una memoria ROM



Fuente: Obtenido de (Pérez et al., 2018).

Otro componente en la arquitectura de una computadora es la tarjeta de video o también conocida como tarjeta gráfica. La unidad de procesamiento de gráficos (GPU) es un circuito electrónico que permite realizar tareas de cálculos matemáticos a gran velocidad, aliviando los procesos realizados en la CPU. Además se encarga de tareas

como la renderización de gráficos, pruebas de ML, edición de videos y representación gráfica en pantalla (Amazon, 2023). Se encuentra compuesta por los siguientes elementos en general:

- Procesador de comandos, Unidad de Rasterizado, Unidad de Texturizado, ROP, Unidad Shader: Son esenciales para el proceso de renderización de gráficos, desde la interpretación de comandos hasta la salida final en la pantalla.
- Unidad de intersección y Unidad de teselación: Son cruciales para técnicas avanzadas como el Ray Tracing y la mejora de la calidad visual de los modelos 3D.
- CODEC de Vídeo, Interfaz de memoria, DMA: Mejoran la eficiencia general del sistema al manejar tareas específicas como la decodificación de vídeo y la transferencia de datos.


(López, 2024)

Las GPUs se pueden clasificar en varias categorías según su integración y propósito. Las principales categorías son GPUs integradas, dedicadas y soluciones híbridas. Las integradas se encuentran en el mismo chip de la CPU y utilizan la memoria RAM del sistema para los procesos. Son utilizadas principalmente para tareas como la navegación por sitios web, ofimática y reproducción de video (Amazon, 2023). Algunas de las integradas son Intel Iris Xe, Intel Iris Plus, Intel UHD, AMD Radeon y AMD Radeon Vega. En cambio, las dedicadas son tarjetas de expansión separadas que se conectan a la placa base a través de ranuras PCIe, cuenta con memoria RAM para los procesos, lo cual mejora en gran medida el rendimiento en la ejecución de procesos (Amazon, 2023). Usualmente son utilizadas para juegos de exigencias altas, edición de video 3D, renderización de video y aplicaciones de ML. Algunos ejemplos son NVIDIA

con las familias de tarjetas GeForce GTX, GeForce RTX, Titan, Quadro, Tesla, A100 y GRID y en cuanto AMD cuenta con las familias de tarjetas Radeon RX, Radeon Pro, Radeon R9/R7/R5, Radeon VII y FirePro. Por último, las soluciones híbridas se encargan de combinar una GPU integrada y una dedicada, permitiendo intercalar su uso en base a la carga de trabajo. Son utilizadas en laptops debido a que requieren mantener el equilibrio entre rendimiento y uso de la batería (Amazon, 2023). Pueden lograr este mecanismo a través del uso de programas intermedios de los mismos fabricantes como es NVIDIA Control Panel y AMD Radeon Software Adrenalin. En la Figura 16 se visualiza la arquitectura de una GPU moderna basada en CUDA desarrollada por NVIDIA.

Figura 16

Arquitectura de GPU moderna



Fuente: Obtenido de (Reeshabh, 2024).

Existen más componentes en un computador; sin embargo, los más relevantes son los mencionados anteriormente para tareas en donde el rendimiento no es un factor importante. Sin embargo, en entornos donde las tareas resultan ser más complejas y abarcan mayor cantidad de información como aplicaciones de ML, se utilizan componentes de mayor rendimiento, en este caso las TPU (Unidad de Procesamiento Tensorial).

Son circuitos integrados desarrollados por Google para optimizar e incrementar la velocidad de procesamiento de tareas de aprendizaje automático (Google Cloud, 2022). Permite realizar cálculos paralelos de gran magnitud que incluyen tensores, en otras palabras matrices de datos multidimensionales (Kóstiko, 2024).

La arquitectura de las TPU se basa en los siguientes componentes esenciales, que permiten realizar eficientemente operaciones tensoriales:


- Unidad multiplicadora de matriz: Se encarga de realizar operaciones matriciales grandes, la capacidad es muy importante para la aceleración de cálculos troncales de las redes neuronales.
- Unidad de procesamiento de vectores: Se encarga de mejorar la capacidad de realizar operaciones vectoriales que son conjuntos que representan valores como características o predicciones, tales que benefician la simplificación de funciones de activación.
- Memoria: Posee una gran capacidad que permite el procesamiento rápido y fluido de grandes conjuntos de datos dentro y fuera de las unidades de procesamiento.
- Interconexiones: Son utilizadas cuando se requiere de transferencia de datos dentro y entre TPU, con lo cual se logra el procesamiento distribuido entre varias TPU que trabajen de manera simultánea.

(Kóstiko, 2024)

En la Figura 17 se muestra la arquitectura de un TPU y los elementos que componen tal unidad de procesamiento mencionados anteriormente.

Figura 17

Arquitectura de TPU



Fuente: Obtenido de (Sato & Young, 2017).

Los beneficios de utilizar los TPU es el alto rendimiento que alcanza al trabajar con tareas de aprendizaje automático en comparación al uso general de CPU y GPU; y por otro lado, consume menos energía realizando las mismas tareas, siendo una opción más rentable a gran escala. En contra parte, resultan ser menos flexibles en cuanto aplicaciones como son los CPU y GPU, el acceso es limitado y el costo inicial de implementación es elevado.

Las aplicaciones en lo que más se utilizan los TPU son el procesamiento de lenguaje natural, reconocimiento y procesamiento de imágenes, conducción autónoma, investigación científica, cuidado de la salud y servicios financieros (Kóstiko, 2024).

2.6 Entornos de entrenamiento

Existen diversos entornos de desarrollo de modelos ML con características adecuadas para el tipo de aplicación a implementar. En el ámbito del aprendizaje

profundo y desarrollo de redes neuronales, los casos de uso son sistemas de atención al cliente, asistentes virtuales, automatización industrial, servicios financieros, sistemas militares, atención médica, restauración de imágenes, traducción automática, aprendizaje de patrones, análisis de imágenes médicas, entre otros (Pathak, 2024). Cada uno de los entornos requieren de infraestructura computacional mínima para el diseño y entrenamiento de modelos, tomando como base la capacidad de CPU, GPU, tamaño de memoria RAM y tamaño de memoria de almacenamiento o en casos que requieran de alto rendimiento el uso de TPU.

A continuación, en la Tabla 1 se indican algunas de los entornos de desarrollo más utilizados para redes neuronales, considerando las características y ventajas que poseen.

Tabla 1

Entornos de desarrollo de redes neuronales artificiales

Características	Caffe	TensorFlow	PyTorch	MATLAB
Tipos de redes	CNN, RNN, GAN, DNN	CNN, RNN, GAN, DNN, Transformer, Autoencoder.	CNN, RNN, GAN, DNN, Transformer, Autoencoder.	CNN, RNN, DNN, Transformer, Autoencoder.
Flexibilidad y personalización	Limitada	Alta	Alta	Alta
Bibliotecas	Propia	Propia	Propia, externas	Propia, externas
Soporte de hardware	CPU, GPU	CPU, GPU, TPU	CPU, GPU, TPU	CPU, GPU
Comunidad y documentación	Moderada	Amplia	Amplia	Amplia

Facilidad de uso	Moderada	Moderada	Alta	Alta
Escalabilidad	Limitada	Alta	Alta	Alta
Desempeño	Bueno	Excelente	Excelente	Excelente
Compatibilidad	C++	Python, C++, etc	Python	MATLAB, Simulink
Licencia y costos	BSD	Apache 2.0	BSD	Comercial
Actualización y mantenimiento	Baja	Alta	Alta	Alta

Fuente: Elaborado por el autor con datos tomados de (Pathak, 2024).

Considerando que el tipo de red neuronal a utilizar se basa en transformadores, en este caso DeiT (Data efficient image Transformer), los entornos de entrenamiento que se adecuan son TensorFlow, PyTorch y MATLAB; sin embargo, es importante considerar que MATLAB cuenta con limitado soporte dado que recientemente se ha incorporado al entorno de desarrollo e implementarlo conllevaría codificar gran parte del modelo. Por otro lado, tanto TensorFlow como PyTorch pueden ser ejecutados en entornos de computación en la nube como es Google Colab, Amazon SageMaker, Microsoft Azure ML, IBM Watson Studio y FloydHub, que permiten acceder a mejor infraestructura computacional para el entrenamiento de modelos mucho más complejos.

CAPÍTULO III

DISEÑO Y DESARROLLO


En el siguiente capítulo, se describen los requisitos para el diseño del detector de melanomas en la piel para las personas de la Asociación Agroturística Valle La Rinconada ubicada en la parroquia San Pablo del Lago, cantón Otavalo, provincia de Imbabura del cual se trata el presente TIC. Para ello se ha aplicado la metodología de desarrollo Modelo en Cascada establecida en el PIC previamente aprobado.

3.1 Metodología de desarrollo

La metodología de desarrollo Modelo en Cascada permite llevar un enfoque secuencial y tomar control de cada una de las fases que componen el sistema. Una de las características principales del modelo es que cada fase depende de la anterior, con ello se establece la regla de que para avanzar a la siguiente se debe culminar con la fase previa. En la Figura 18 se puede visualizar cada una de las fases en las que está comprendido la metodología a utilizar.

Figura 18

Fases del Modelo en Cascada



Nota. En la figura se muestra cada una de las fases en las que se compone el Modelo en Cascada. Fuente: Obtenido de (Digital Talent Agency, 2022).

3.1.1 Fases del Modelo en Cascada

A continuación, se describe cada una de las fases considerando el enfoque principal del TIC a desarrollar y la importancia que tienen en cada etapa del proceso.

3.1.1.1 Fase 1: Requisitos

En la primera fase se establecen los requerimientos de stakeholders y requisitos del sistema como dispositivo de obtención de imágenes, dataset, entorno de desarrollo, algoritmos de procesamiento de las imágenes e infraestructura computacional para el entrenamiento del modelo.

3.1.1.2 Fase 2: Diseño

En esta fase se define la arquitectura general del sistema mediante la identificación de bloques en donde se describen los componentes de hardware, software e infraestructura computacional para la obtención de datos, el procesamiento digital de las imágenes, entrenamiento del modelo y finalmente la visualización de los resultados.

3.1.1.3 Fase 3: Implementación

En esta fase se construye el sistema en base a los requisitos y diseño establecido para la detección de melanomas, culminando en una interfaz gráfica intuitiva diseñada para la utilización simple de los usuarios.

3.1.1.4 Fase 4: Verificación

Es la fase en donde se realizan pruebas a las personas de la asociación y se valida el sistema a través del ingreso de muestras verdaderas y falsas de melanomas para la evaluación de la precisión del sistema y un análisis del entrenamiento del modelo en hardware de diferentes prestaciones.

3.1.1.5 Fase 5: Mantenimiento

En la última fase, se realiza la corrección de problemas y errores puntuales, así como la actualización del dataset, con la finalidad de mejorar la precisión de los resultados.

En las siguientes secciones se detalla el proceso del diseño del sistema con el fin de dar cumplimiento a los objetivos establecidos utilizando el modelo de desarrollo descrito anteriormente.

3.2 Análisis de la situación actual


Considerando la posición geográfica de Ecuador con respecto a los demás países de Latinoamérica, posee mayor cantidad de radiación ultravioleta que se considera maligna para la piel humana. En base a estudios realizados por Lema & Zuleta (2015), indican que los máximos diarios de radiación solar total oscilan entre 6.64 Watts/año y 16.53 Watts/año; por lo que se estima que si los valores permanecen aumentando tal cual se ha dado en los últimos años, aproximadamente en 10 años se tendrá un aumento entre el 4% y 6% en la región sierra. Las causas de este incremento no se han determinado científicamente, pero se presume que es debido al cambio climático que se vive a nivel mundial. Los datos tomados para dicho estudio son de la ciudad de Quito, provincia de Pichincha, considerados desde el año 2006 hasta el 2016 (Franco, 2017).

La intensidad de la radiación ultravioleta depende de factores como el ozono estratosférico, la hora del día, la posición del sol, la latitud, la altitud, condiciones climáticas, entre otros. Como se menciona anteriormente Ecuador se ve afectado durante todo el año, debido a la latitud y altitud a la que se encuentra, con respecto a la latitud se refiere a la distancia del Sol con respecto a Ecuador, teniendo una distancia más corta con respecto a otros países y por ende la distancia recorrida por los rayos ultravioletas es

menor. En consecuencia, la capa de ozono es de menor espesor y mayor cantidad de radiación UV atraviesa la atmósfera. En la Figura 19 se muestra los índices de radiación ultravioleta que recibe el país en cada una de sus regiones, siendo la región Sierra y Costa unas de las que mayor radiación percibe, teniendo niveles entre Muy alto y Extremadamente Alto.

Figura 19

Índice de radiación UV en Ecuador



Nota. En la figura se muestra los niveles de radiación según la región a fecha del 22 de octubre de 2024.

Fuente: Adaptado de (INAMHI, 2024).

La excesiva exposición solar conlleva afectaciones graves a la salud, cerca del 90% de los cánceres de piel son debidos a la radiación solar constante, causando melanomas en la piel donde su nivel de mortalidad supera al resto de neoplasias dérmicas. Son principalmente confundidos con lunares y manchas en la piel, además de contar con una alta capacidad metastásica, que se refiere a que las células cancerígenas pueden diseminarse por diferentes partes del organismo y aumentar la mortalidad de la enfermedad (Benavides, 2010).

En la Asociación Agroturística Valle La Rinconada ubicada en la parroquia de San Pablo del Lago, cantón Otavalo, provincia de Imbabura, cuentan con 40 socios, en donde la mayoría de sus integrantes son personas que superan los 40 años de edad, en general son personas de escasos recursos económicos y que se dedican a la producción agrícola y turismo de la zona diariamente. Después de una reunión con los dirigentes de la asociación, mencionaron que la protección y cuidado dermatológico de los socios no es el adecuado y que diariamente permanecen expuestos a los rayos solares por la labor que desempeñan. Se ha determinado que contar con un prediagnóstico de lesiones es crucial para la detección temprana de melanomas. Esto permite a los socios anticiparse a posibles problemas de salud y acudir a un profesional con una noción previa de la situación. En la Figura 20 se muestra la zona en donde se desempeñan las actividades, lugar que es propiedad de los mismos socios que componen la asociación.

Figura 20

La Rinconada - Parroquia San Pablo del Lago



Nota. En la figura se muestra el lugar en donde los socios realizan las actividades agroturísticas diariamente.

Fuente: El Autor.

A continuación, se describen cada uno de los requisitos para el desarrollo del sistema de detección de melanomas, para ello se ha determinado realizarlo a través de

imágenes dermatoscópicas las cuales van a ser procesadas, ingresadas a un sistema de inteligencia artificial y finalmente se obtendrán los resultados.

En las siguientes secciones se describe el propósito, ámbito y requerimientos del sistema perteneciente a la fase de requisitos de la metodología indicada anteriormente.

3.3 Propósito del sistema

El propósito del sistema está fundamentado en el objetivo general, el cual sustenta el TIC que es en desarrollar un detector de melanomas en la piel para las personas de la Asociación Agroturística Valle La Rinconada, bajo el entrenamiento de redes neuronales en hardware específico para el modelo, dicho modelo está entrenado a través de un dataset de imágenes verificadas médicamente, con la finalidad de proporcionar un prediagnóstico en la mayor precisión posible para la detección temprana de melanomas, que en base a la situación actual es la lesión de mayor peligro en la aparición de cáncer de piel por la excesiva radiación solar que existe en Ecuador.

3.4 Ámbito del sistema

Se ha determinado que el sistema de detección de melanomas en la piel a través de redes neuronales para personas va a ser implementado en el entorno de la Asociación Agroturística Valle La Rinconada, en donde los socios tengan la capacidad de poder auto realizarse prediagnósticos de alguna anomalía presente en la piel, con el objetivo de descartar o comprobar la presencia de lesiones malignas o benignas. El sistema está enfocado al ahorro económico de exámenes dermatológicos (biopsias) de los socios que tengan la sospecha de padecer enfermedades dermatológicas y con ello identificarlas de manera oportuna, para proceder a un tratamiento adecuado dictado por un profesional en el área.

3.5 Requisitos y requerimientos del sistema

En esta sección se establecen cada uno de los requerimientos en cuanto a stakeholders, sistema, arquitectura e infraestructura computacional necesaria para el desarrollo del detector de melanomas en la piel a través de estrategias de inteligencia artificial establecidas en el alcance y objetivos del TIC.

3.5.1 Nomenclatura de los requerimientos

En la Tabla 2, se detallan los acrónimos utilizados en el TIC para una mejor comprensión y manejo de los términos dentro del trabajo, que está compuesto por los requerimientos del sistema, requerimientos de los stakeholders, requerimientos de la arquitectura y requerimientos de infraestructura computacional que componen el TIC a desarrollar.

Tabla 2

Nomenclatura de los requerimientos

Acrónimos	Descripción
StSR	Requerimientos de Stakeholders
SySR	Requerimientos del Sistema
SrSH	Requerimientos de Arquitectura
SiSF	Requerimientos de Infraestructura

Fuente: El Autor

3.5.2 Prioridades de los requerimientos

A continuación, en la Tabla 3 se indica cada una de las prioridades determinadas para los requerimientos, en donde se contemplan las categorías Alta, Media y Baja, junto con su descripción que indica la relevancia dentro del sistema, mismas que son importantes para la selección de hardware y software para el propósito del TIC.

Tabla 3

Categorías de prioridades de los requerimientos

Prioridad	Descripción
Alta	Es un requisito fundamental en el desarrollo y funcionamiento del sistema, su exclusión afecta profundamente en la eficiencia y efectividad del sistema.
Media	Es un requisito que en situaciones extremas o de fuerza mayor puede llegar a ser omitido; sin embargo, su efectividad y funcionalidad puede verse afectada parcialmente.
Baja	Es un requisito que si no se contempla o incluye, no genera mayor impacto o relevancia en el funcionamiento y efectividad total del sistema.

Fuente: El Autor

3.5.3 Determinación de Stakeholders

En el contexto del TIC en curso, los stakeholders son los actores individuales o colectivos con interés directo e indirecto en el resultado final. Estos pueden ser personas o entidades que serán afectadas por el proyecto o que podrían obtener beneficio de él, ya sea de manera directa o indirecta. Los stakeholders se contemplan desde los usuarios finales del sistema hasta el desarrollador del TIC. Es fundamental considerar a los stakeholders en todas las fases del TIC, desde la identificación de requisitos hasta la implementación y evaluación, para asegurar que las necesidades y expectativas sean alcanzadas. En la Tabla 4 se muestra cada uno de los stakeholders considerados en el desarrollo del TIC con ética, responsabilidad y compromiso en el alcance de los objetivos propuestos.

Tabla 4*Lista de Stakeholders*

N°	Stakeholder	Descripción
1	MSc. Luis Suárez	Director del Trabajo de Integración Curricular
2	MSc. Edgar Maya	Asesor del Trabajo de Integración Curricular
3	Sr. Jorge Yacelga	Desarrollador
4	Dr. Harold Espín	Médico asesor
5	Sr. Fausto Proaño	Representante Legal de Asociación Agroturística Valle La Rinconada

Fuente: El Autor

3.5.4 Requerimientos de Stakeholders

Para la definición de los requerimientos de los stakeholders se ha considerado como punto inicial la situación actual de los integrantes de la asociación, aspectos socioeconómicos de los beneficiarios y funciones específicas para una adecuada utilización del sistema. En la Tabla 5 se detallan los requerimientos operacionales y del usuario.

Tabla 5*Requerimientos de Stakeholders*

REQUERIMIENTOS DE STAKEHOLDERS				
StSR				
N°	Requerimiento	Prioridad		
		Alta	Media	Baja
Requerimientos Operacionales				
StSR1	Acceso a la corriente eléctrica para la alimentación del sistema.	X		

StSR2	El sistema debe contar con un dispositivo para la toma de datos (imágenes) de la piel.	X	
StSR3	La detección debe utilizar mecanismos de inteligencia artificial.	X	
StSR4	El sistema deberá contar con datos (imágenes) de entrenamiento verificados.	X	
StSR5	El sistema deberá contar con una interfaz gráfica intuitiva para los usuarios.	X	
StSR6	La implementación deberá realizarse en un conjunto de personas.		X
StSR7	El sistema debe proporcionar la información obtenida a través de informes de resultados.	X	
StSR8	El sistema deberá contar con acceso a Internet.		X
Requerimientos del Usuario			
StSR9	Los usuarios deberán contar con un computador.	X	
StSR10	La interfaz gráfica debe componerse de ventanas para la utilización de los usuarios.	X	
StSR11	El área de toma de la prueba debe ser lo más pulcra posible sin objetos, bellos o tinta que afecten a la calidad de la imagen.	X	
StSR12	La aplicación no debe ocupar mucho espacio de memoria.		X
StSR13	La presentación de los resultados debe ser comprensible para los usuarios.	X	

Fuente: El Autor

3.5.5 Requerimientos del Sistema

En cuanto a los requerimientos del sistema se considera el conjunto de características y funcionalidades con las que debe contar para satisfacer el objetivo del TIC, además debe cumplir con las necesidades de los usuarios; dentro de este conjunto se encuentra los requerimientos funcionales, requerimientos de interfaz, requerimientos de datos y requerimientos físicos del sistema, de mejor manera se encuentra detallado en la Tabla 6.

Tabla 6

Requerimientos del sistema

REQUERIMIENTOS DEL SISTEMA				
SySR				
N°	Requerimiento	Prioridad		
		Alta	Media	Baja
Requerimientos Funcionales				
SySR1	El computador donde se instale el programa debe interactuar directamente con el dispositivo de obtención de imágenes.	X		
SySR2	El sistema debe poseer la capacidad de diagnosticar imágenes tomadas de las personas de la asociación.	X		
SySR3	El sistema debe permitir realizar prediagnósticos de varios usuarios.	X		
SySR4	El sistema debe proporcionar los resultados a través de un informe detallado.	X		
Requerimientos de Interfaz				

SySR5	La interfaz gráfica debe contar con varios menús para una utilización más sencilla.	X
SySR6	La interfaz gráfica debe contar con un control de ingreso de datos.	X
SySR7	La interfaz gráfica debe poseer indicadores sencillos de los resultados obtenidos.	X
SySR8	El sistema debe mostrar las etapas de procesamiento de las imágenes para la detección.	X
Requerimientos de los Datos		
SySR9	Las imágenes ingresadas al sistema deben ser en formato .jpg o .jpeg.	X
SySR10	Las imágenes tomadas deben ser obtenidas a través de un dermatoscopio digital.	X
SySR11	Las imágenes deben ser a color y con la menor interferencia posible alrededor y sobre la lesión.	X
SySR12	Las imágenes obtenidas no deben ser manipuladas por programas de edición externos.	X
Requerimientos Físicos		
SySR13	El computador donde se instale el software debe poseer tarjeta de red Wi-Fi para la comunicación con el dermatoscopio digital.	X
SySR14	El dermatoscopio debe contar con resolución mínima de 3MP o superior para obtener imágenes de calidad para el procesamiento.	X

SySR15	El sistema debe estar conectado directamente a la alimentación eléctrica.	X
SySR16	El programa no debe consumir demasiados recursos computacionales.	X
SySR17	La toma de las muestras debe realizarse en un lugar adecuado.	X
SySR18	El sistema debe contar con un soporte o carcasa del sistema.	X

Fuente: El Autor.

3.5.6 Requerimientos de la Arquitectura

En cuanto a los requerimientos de la arquitectura se encuentran compuestos por los aspectos de diseño, hardware y software que aportan a la funcionalidad total del sistema. En la Tabla 7 se indican los aspectos que han sido considerados para posteriormente la selección adecuada de los componentes del sistema en desarrollo.

Tabla 7

Requerimientos de la arquitectura

REQUERIMIENTOS DE LA ARQUITECTURA				
SrSH				
N°	Requerimiento	Prioridad		
		Alta	Media	Baja
Requerimientos de Diseño				
SrSH1	El sistema debe ser compatible con el dermatoscopio digital.	X		

SrSH2	El sistema debe poseer la capacidad de ingresar los datos del usuario antes del prediagnóstico.	X	
SrSH3	El formato y cantidad de las imágenes obtenidas debe ser compatible con la red neuronal.	X	
SrSH4	El programa debe ser compatible con el sistema operativo Windows 10 o superior.	X	
SrSH5	El sistema debe contar con un repositorio de los informes de prediagnósticos realizados.		X
SrSH6	El sistema debe contar con la capacidad de proporcionar los resultados a los usuarios a través de un archivo digital.	X	
Requerimientos de Hardware			
SrSH7	El dermatoscopio digital debe ser portátil, por ende, debe contar con batería recargable.	X	
SrSH8	El sistema debe contar con un mecanismo de comunicación entre el computador y el dermatoscopio digital.	X	
SrSH9	El computador debe contar con al menos 50 GB de espacio de almacenamiento.	X	
SrSH10	El computador debe contar con al menos 4 GB de memoria RAM.	X	
SrSH11	El computador debe ser portátil o contar con una pantalla para la visualización en caso de ser de sobremesa.	X	
Requerimientos de Software			

SrSH12	Se requiere de un entorno robusto de desarrollo del modelo de inteligencia artificial.	X
SrSH13	Se requiere documentación acerca del diseño de redes neuronales en la plataforma.	X
SrSH14	Se requiere de un lenguaje de programación capaz de adaptarse a la aplicación a realizar.	X
SrSH15	Se requiere compatibilidad con bibliotecas y herramientas de aprendizaje profundo en la plataforma.	X
SrSH16	Se requiere de una herramienta de desarrollo de aplicaciones de escritorio compatible.	X
SrSH17	Se requiere de un rendimiento óptimo del sistema en la detección y precisión de melanomas.	X

Fuente: El Autor

3.5.7 Requerimientos de Infraestructura

En cuanto a los requerimientos de infraestructura se encuentran compuestos por los aspectos del CPU, TPU, GPU, memoria RAM y almacenamiento. En la Tabla 8 se indica los aspectos que han sido considerados para posteriormente la selección adecuada de los componentes de infraestructura computacional.

Tabla 8

Requerimientos de infraestructura

REQUERIMIENTOS DE INFRAESTRUCTURA		
SISF		
N°	Requerimiento	Prioridad

		Alta	Media	Baja
Requerimientos de CPU				
SiSF1	El CPU debe ser de alto rendimiento, capaz de manejar cálculos intensivos para el entrenamiento de tareas de visión artificial.	X		
SiSF2	Se requiere que el CPU cuente con múltiples núcleos con una frecuencia de reloj alta para acelerar el tiempo de entrenamiento.	X		
SiSF3	La capacidad del CPU debe manejar múltiples hilos de ejecución simultánea para procesar grandes conjuntos de imágenes.	X		
Requerimientos de memoria RAM				
SiSF4	Se necesita de una cantidad de memoria RAM suficiente para almacenar los datos de entrenamiento y validación durante el proceso, y así evitar cuellos de botella.	X		
SiSF5	Se requiere que la velocidad de la RAM sea alta para tener un acceso rápido a los datos y con ello acelerar el proceso de entrenamiento.	X		
Requerimientos de GPU				
SiSF6	La GPU debe ser de alto rendimiento para acelerar el entrenamiento de las redes neuronales.	X		
SiSF7	Se requiere que posea varios núcleos de procesamiento y alta capacidad de cálculo.	X		

SiSF8	Se requiere que la memoria de la GPU sea de alto rendimiento para almacenar grandes volúmenes de datos de las imágenes durante el entrenamiento.	X
--------------	--	---

Requerimientos de almacenamiento

SiSF9	Se requiere que la unidad de almacenamiento sea de estado sólido (SSD), ya que permite acceder mucho más rápido a los datos.	X
--------------	--	---

SiSF10	El almacenamiento debe ser de alta capacidad, que permita alojar grandes conjuntos de imágenes utilizados en el entrenamiento.	X
---------------	--	---

Requerimientos de TPU

SiSF11	El TPU debe contar por lo menos con 4 núcleos para realizar el entrenamiento de modelos de clasificación de imágenes.	X
---------------	---	---

SiSF12	La memoria de la TPU debe ser mínimo de 4 GB por cada núcleo, con ello asegura el manejo de grandes tamaños de lotes y la complejidad del modelo.	X
---------------	---	---

SiSF13	El framework a utilizar debe ser TensorFlow o PyTorch ya que cuentan con soporte para el manejo de TPU.	X
---------------	---	---

Fuente: El Autor

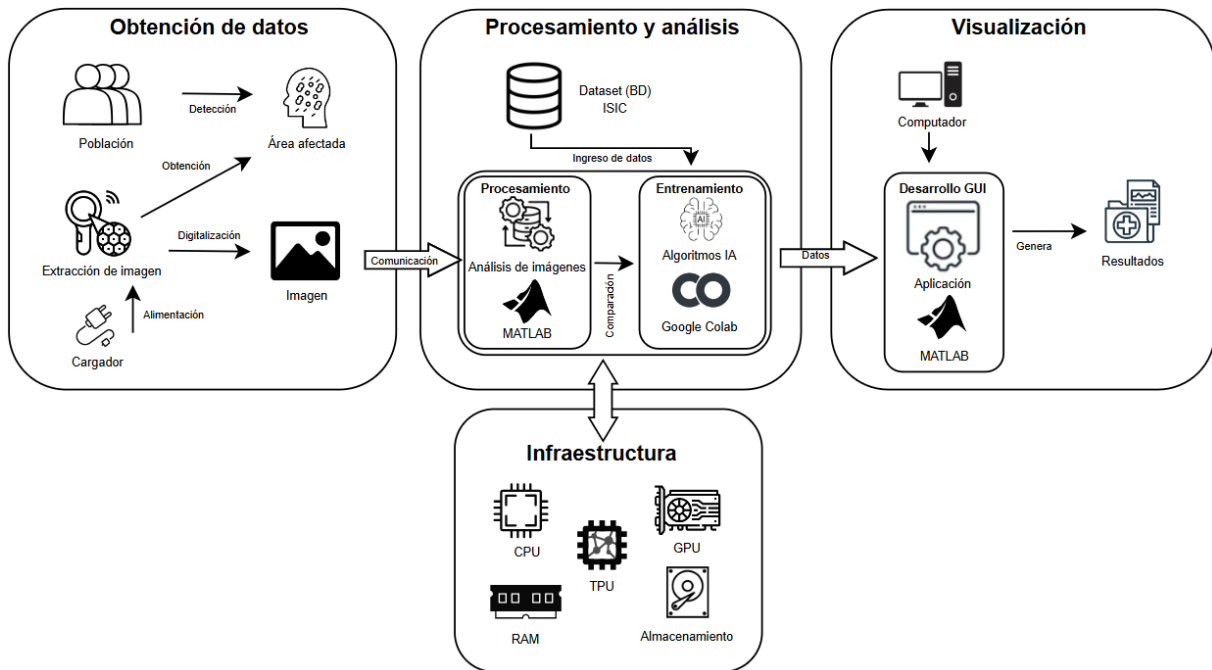
3.6 Diseño y descripción general del sistema

El objetivo principal del proyecto es el desarrollo de un detector de melanomas en la piel de las personas a partir del uso de técnicas de inteligencia artificial, en este caso se ha considerado la visión artificial por medio de redes neuronales basadas en transformadores a través de infraestructura computacional dedicada. Su elección se debe a que existe una rama de la dermatología que se la conoce como dermatoscopia, que está basada en el análisis manual de imágenes de lesiones como lunares, manchas, granos, verrugas, deformaciones, entre otros. Por lo general, en esta rama el análisis se realiza de manera manual, considerando reglas como la de ABCDE o la de ponderación de 7 puntos para melanomas de Glasgow. Debido a que el procedimiento de la dermatoscopia manual demanda de experiencia y tiempo del profesional en dermatología, además de considerar la evolución de la lesión para lograr un diagnóstico acertado. Para ello el planteamiento del sistema es agilizar la detección de melanomas en imágenes dermatoscópicas a través del entrenamiento de redes neuronales, mismas que son óptimas en la detección de patrones y clasificación de imágenes. Lo que con ello lleva al planteamiento de una interfaz gráfica en donde se tenga la capacidad del ingreso de los datos del usuario a prediagnosticar, así como la visualización de los resultados junto con los parámetros importantes en cuestiones de texturas y coloración.

Adicional a ello se considera que la toma de muestras (imágenes) se haga por medio de un dermatoscopio digital, para posterior a ello ingresar la imagen al programa en donde los resultados sean presentados de manera inmediata y además se proporcione un informe de los resultados para el usuario o profesional en dermatología. En la Figura 21 se muestra a mayor detalle los bloques y componentes que conforman la arquitectura del sistema planteado.

Figura 21

Arquitectura del sistema



Fuente: El Autor.

En la figura mostrada se puede visualizar la arquitectura que está compuesta por tres bloques: obtención de datos, procesamiento y análisis, y visualización. Partiendo desde el primer bloque, tenemos a la población o personas a diagnosticar, en donde previamente se tiene identificada la zona afectada para con ello proceder a utilizar el dermatoscopio digital en la obtención de imágenes de la lesión. Cabe destacar que el dispositivo es alimentado por un cargador y se comunica a través de Wi-Fi con el computador donde se encuentra el programa. En el segundo bloque, se encuentra la sección de procesamiento de las imágenes en MATLAB y entrenamiento de la red neuronal por medio de un dataset con imágenes verificadas a través de Google Colab; tal bloque de procesamiento se encuentra sobre la base de los componentes de hardware computacional necesarios para el entrenamiento del modelo en específico, donde se considera CPU, TPU, GPU, RAM y almacenamiento. En este bloque se realiza el análisis y detección de las lesiones para que los resultados sean trasladados al tercer bloque en

donde se visualizan a través de una interfaz gráfica desarrollada en MATLAB y se proporcione un informe del proceso de prediagnóstico.

3.6.1 Selección de hardware y software

Para la selección de hardware y software del sistema se ha establecido comparativas con base en los requerimientos propuestos para los stakeholders, sistema, arquitectura e infraestructura. Es importante destacar que se ha considerado los requerimientos más importantes para la determinación de los componentes que permitan la funcionalidad del sistema. Para un mejor análisis, se ha considerado las siguientes valoraciones que se encuentran detalladas en la Tabla 9.

Tabla 9

Descripción de valores

Descripción de valores	
Si cumple	1
No cumple	0

Nota. En la tabla se detalla la nomenclatura para la ponderación del cumplimiento de los requerimientos de stakeholders, sistema, arquitectura e infraestructura del TIC. Fuente: El Autor.

3.6.1.1 Elección de infraestructura

En esta sección se describe la elección de los elementos computacionales necesarios para el entrenamiento del modelo y desarrollo del sistema, para ello se ha considerado establecer requerimientos los cuales deben cumplir para una correcta elección de CPU, TPU, GPU, memoria RAM y almacenamiento, mismos que son parte fundamental del rendimiento y precisión de clasificación del sistema.

3.6.1.1.1 Elección de Unidad Central de Proceso (CPU)

En cuanto a la elección del CPU adecuado para el desarrollo del sistema se ha considerado por modelos, más no por versiones en específico, ya que existe una gran cantidad en el mercado y resulta demasiada compleja la elección. Para ello en la Tabla 10 se realiza la valoración de cada uno de los modelos contemplados a seleccionar.

Tabla 10

Selección del CPU

Selección de CPU				
Hardware	Requerimientos			Valoración
	SiSF1	SiSF2	SiSF3	total
Intel Core	1	1	0	3
Intel Xeon	1	1	1	3
Intel Celeron	0	0	0	0
Intel Pentium	0	0	0	0
AMD EPYC	1	1	1	3
AMD Opteron	1	1	1	3
AMD Ryzen	1	1	0	2
AMD Athlon	0	0	0	0

Fuente: El Autor.

A partir de la valoración obtenida se considera como los modelos óptimos a utilizar para desarrollar el sistema: Intel Xeon, Intel Core, AMD EPYC y AMD Opteron. Sin embargo, es importante tomar en consideración que los procesadores Intel Xeon, AMD EPYC y AMD Opteron son bastante costosos, ya que generalmente son utilizados en plataformas de computación en la nube gestionado por Google, AWS, Microsoft Azure, entre otros. Debido a ello, también existe la posibilidad de utilizar los procesadores

Intel Core, dado que son mucho más accesibles, aunque obtienen resultados en un mayor tiempo de procesamiento, pero para el desarrollo GUI y procesamiento de las imágenes de entrada, es una opción adecuada. Sin embargo, por cuestiones de rendimiento y optimización del entrenamiento se utiliza los de mayor capacidad a través de la plataforma de computación en la nube Google Colab que permite utilizar bajo demanda procesadores como Intel Xeon.

3.6.1.1.2 Elección de Unidad de Procesamiento Gráfico (GPU)

En esta sección se procede a determinar cuál GPU es necesaria para llevar a cabo los procesos de entrenamiento del modelo de la red neuronal, dado que necesita de capacidad adicional a la del CPU en cuanto a la etapa de entrenamiento y validación de los datos. En la Tabla 11 se establecen los modelos de GPU utilizados, considerando el mismo caso que para el CPU, existen demasiadas variantes en el mercado y por ello únicamente se valora en función de las familias de GPU.

Tabla 11

Selección de GPU

Selección de GPU				
Software	Requerimientos			Valoración total
	SiSF6	SiSF7	SiSF8	
NVIDIA GeForce	0	1	1	2
NVIDIA Tesla	1	1	1	3
NVIDIA Ampere	1	1	1	3

NVIDIA Ada Lovelace	1	1	1	3
AMD Radeon RX	0	1	1	2
AMD Radeon Pro	0	1	0	1
Intel Iris Plus	0	0	0	0

Fuente: El Autor.

Una vez realizada la comparación entre diferentes modelos de GPU, se ha llegado a determinar que existen varias opciones que cumplen con los requerimientos establecidos; sin embargo, considerando que el procesamiento gráfico que necesita es utilizado para el entrenamiento del modelo, se determina que NVIDIA Tesla, NVIDIA Ampere y NVIDIA Ada Lovelace son las adecuadas debido a su rendimiento y capacidad; sin embargo, son muy costosas y deben ser utilizadas a través de entornos de computación en la nube; en contra parte para el procesamiento de las imágenes y desarrollo GUI la NVIDIA GeForce y AMD Radeon RX son suficientes para dichas tareas.

3.6.1.1.3 Elección de Memoria RAM

En esta sección más que realizar una elección de un modelo en específico, se establece un valor adecuado del tamaño de memoria que pueda soportar toda la carga de procesamiento de datos que va a tener durante la fase de entrenamiento del modelo. En la Tabla 12 se establecen valores de memoria RAM en GB que permita operar para las características del desarrollo del sistema.

Tabla 12*Selección de Memoria RAM*

Selección de Memoria RAM			
Software	Requerimientos		Valoración total
	SiSF4	SiSF5	
2 GB	0	1	1
4 GB	0	1	1
8 GB	0	1	1
16 GB	1	1	2
32 GB	1	1	2

Fuente: El Autor.

Una vez valorado cada uno de los tamaños de memoria RAM en base a los requerimientos establecidos, se considera como un valor mínimo para el tipo de sistema a desarrollar en 16 GB, debido a la gran cantidad de datos y parámetros que debe procesar por el conjunto de imágenes utilizadas durante el procesamiento de imágenes, entrenamiento y validación del modelo.

3.6.1.1.4 Elección de Almacenamiento

En esta sección se procede a determinar el tipo de almacenamiento con el que debe contar el sistema de desarrollo, más no en el de implementación. Dado que el entorno de ejecución donde se realice el desarrollo deberá contar con el espacio suficiente en disco, además de la velocidad necesaria para la toma de datos por parte del CPU, GPU o TPU para el entrenamiento. Esta parte influye en el tiempo que le tome al entrenamiento del modelo en completarse. Para ello se ha establecido en la Tabla 13 una valoración de diferentes tecnologías de almacenamiento, junto con diferentes capacidades.

Tabla 13*Selección de Almacenamiento*

Selección de Almacenamiento			
Software	Requerimientos		Valoración total
	SiSF9	SiSF10	
SSD 512 GB	1	1	2
SSD 256 GB	1	1	2
SSD 1 TB	1	1	2
HDD 512 GB	0	1	1
HDD 256 GB	0	1	1
HDD 1 TB	0	1	1

Fuente: El Autor.

Después de comparar las opciones en función de los requerimientos establecidos, se ha determinado que la mejor opción son las que pertenecen a la tecnología SSD, debido a que poseen mayor velocidad, mayor durabilidad, menor consumo de energía y producen menos calor al no tener partes móviles. Además, se determina que el espacio suficiente para este tipo de aplicaciones es 256 GB por el peso de los archivos que pueden generar durante el proceso de entrenamiento.

3.6.1.1.5 Elección de Unidad de Procesamiento Tensorial (TPU)

A continuación se procede a seleccionar el TPU que va a ser utilizado para el entrenamiento del modelo en Google Colab, es importante considerar que los TPU son diseñados por Google y no existen diferentes variantes, sino más que actualizaciones de los mismos como se indica en la Tabla 14.

Tabla 14*Selección de TPU*

Selección de TPU				
Software	Requerimientos			Valoración total
	SiSF11	SiSF12	SiSF13	
TPU v1	1	1	1	3
TPU v2	1	1	1	3
TPU v3	1	1	1	3
TPU v4	1	1	1	3

Fuente: El Autor.

Al tratarse de actualizaciones de las versiones de TPU, todas cumplen con los requerimientos necesarios, dado que en función de la actualización aumenta el rendimiento y capacidad. Por ende el TPU a utilizar es la opción que se encuentre disponible en la versión de pago de Google Colab, en este caso la TPU v2-8.

3.6.1.2 Elección de Hardware

En esta sección se describe la elección de los componentes físicos del sistema, mismos que son considerados de acuerdo con el cumplimiento de ciertos requerimientos del sistema y de la arquitectura. Para ello se procede a seleccionar el dermatoscopio digital para la obtención de las imágenes.

3.6.1.2.1 Elección del dermatoscopio digital

Para la toma de muestras (imágenes) de las lesiones en la piel de las personas es necesario un instrumento que cumpla con parámetros adecuados de iluminación, definición y calidad, además de proporcionar la capacidad de que sea portátil debido a la

naturaleza de la aplicación del sistema. En la Tabla 15 se realiza una comparativa de distintos modelos y fabricantes de dermatoscopios digitales.

Tabla 15

Selección de dermatoscopio digital

Selección de dermatoscopio digital							
Hardware	Requerimientos						Valor ación total
	SySR9	SySR11	SySR14	SrSH3	SrSH7	SrSH8	
DermLite DL5	1	1	1	0	1	1	5
Tianyue M39	1	1	1	1	1	1	6
FireFly DE300	1	1	1	1	0	1	5
Heine Mini 3000 LED	0	1	0	0	1	0	2

Nota. En la siguiente tabla se muestra la selección del dermatoscopio digital en base a los requerimientos.

Fuente: El Autor.

A partir de la valoración total de cada uno de los dermatoscopios considerados en la tabla anterior, se ha seleccionado TIANYUE M39 debido a que cumple con la totalidad de los requerimientos y en adición a ello es el que tiene la mejor relación calidad-precio de las opciones presentadas. Para especificar de mejor manera el dispositivo, se tiene la Tabla 16 en donde se indican las características más relevantes.

Tabla 16

Características técnicas del dermatoscopio digital Tianyue M39

Parámetro	Descripción
Sensor de imagen	3 megapíxeles

Video resolución	720P
Modo de iluminación	8 luces LED
Rango de enfoque	5 mm a 50 mm
Factor de amplificación	50/200 ampliación óptica – 800 ampliación digital
Comunicación	Wi-Fi (IEEE 802.11n)
Alcance inalámbrico	10 – 30 metros
Compatibilidad	Android, IOS, Windows
Formato de imagen	JPEG
Formato de video	H.264
Peso	90 gramos
Dimensiones	150 mm (largo) * 33 mm (diámetro)
Fuente de alimentación	DC5V – Batería recargable
Precio	\$ 180.00

Fuente: Información adaptada de (Shenzhen Miracle Technology, 2024).

A continuación, en la Figura 22 se muestra el dermatoscopio digital sobre su base, cuenta con comunicación inalámbrica Wi-Fi y se conecta con el smartphone o el computador a través del sistema operativo con el que cuenta el dispositivo.

Figura 22

Representación gráfica del TIANYUE M39



Fuente: Obtenida de (Shenzhen Miracle Technology, 2024).

3.6.1.3 Elección de Software

Tomando como punto de partida los requerimientos de software de la Tabla 7, se procede a seleccionar el entorno de desarrollo, el dataset de imágenes y el modelo de red neuronal preentrenada, considerando los requerimientos del sistema, arquitectura e infraestructura del TIC.

3.6.1.3.1 Elección del entorno de desarrollo

En cuanto a la plataforma de desarrollo se ha considerado tres opciones: Python (TensorFlow/PyTorch), MATLAB y Caffe, mismas que van a ser valoradas en cuanto a los requerimientos establecidos. En la Tabla 17 se muestra de manera más detallada la valoración obtenida para cada entorno en base a los requerimientos planteados.

Tabla 17

Selección del entorno de desarrollo

Selección de entorno de desarrollo						
Software	Requerimientos					Valoración total
	SrSH12	SrSH13	SrSH14	SrSH15	SrSH16	
Python	1	1	1	1	1	5

MATLAB	1	1	1	1	1	5
Caffe	1	0	1	1	0	3

Fuente: El Autor.

A partir de la valoración total obtenida de cada plataforma de desarrollo en base a los requerimientos propuestos, se selecciona Python como el entorno de entrenamiento para el modelo de la red neuronal debido a la capacidad y documentación con la que cuenta; en cambio se selecciona MATLAB como el entorno de preprocesamiento de las imágenes y desarrollo de la GUI del sistema, debido a su versatilidad, facilidad de uso, compatibilidad y condensación de varias herramientas en un mismo entorno de programación que es útil con el TIC a desarrollar.

3.6.1.3.2 Elección del dataset de imágenes

En esta sección se lleva a cabo la selección del dataset de donde se va a importar la información de entrenamiento para el sistema de detección, es importante que la información (imágenes) sea verificada por expertos y sumamente variada para alcanzar niveles de rendimiento y precisión adecuados. Para ello se ha optado por datasets de libre uso como lo es ISIC, HAM10000 y SKIN-CAM Dataset, mismos que son evaluados en base a los requerimientos propuestos del TIC. En la Tabla 18 se valora cada uno de los datasets y se muestra la valoración total obtenida en base a los requerimientos indicados.

Tabla 18

Selección de dataset de imágenes

Selección de dataset de imágenes						
Software	Requerimientos					Valoración total
	StSR4	SySR9	SySR11	SySR12	SrSH3	

ISIC Dataset	1	1	1	1	1	5
HAM 10000 Dataset	1	1	0	1	1	4
SKIN-CAM Dataset	1	0	1	0	1	3

Fuente: El Autor

A partir de la valoración total obtenida de cada uno de los datasets propuestos, se selecciona el dataset proporcionado por la ISIC (International Skin Imaging Collaboration) ya que cumple con cada uno de los requerimientos del proyecto indicados, además de que es el dataset con mayor cantidad de imágenes de lesiones comprobadas y variadas de uso libre para la experimentación e investigación de patrones de detección. Por otro lado, es una organización reconocida en la investigación de esquemas y estrategias que anualmente desarrolla retos en donde se presentan propuestas y diseños de todo el mundo, además de que contribuye con imágenes verificadas por profesionales de todas partes cada año (ISIC, 2024).

3.6.1.3.3 Elección de la red preentrenada

En esta sección, se procede a la selección de la red neuronal preentrenada adecuada para la aplicación a llevar a cabo, es importante considerar que el uso de redes previamente entrenadas facilita al aprendizaje de patrones en las imágenes, asignación de pesos en cada una de las capas ocultas y clasificación final. A continuación, se va a realizar una valoración de algunas redes para su utilización en el desarrollo del sistema; sin embargo, cabe recalcar que cada una de las redes pueden ser modificadas y afinadas para el propósito. En la Tabla 19 se muestra la valoración en base a los requerimientos

del sistema y arquitectura para cada una de las redes neuronales basadas en transformadores preentrenadas propuestas.

Tabla 19

Selección de red neuronal preentrenada

Selección de red neuronal preentrenada						
Software	Requerimientos					Valoración total
	SySR2	SySR3	SrSH3	SrSH13	SrSH17	
ViT	1	1	0	1	1	4
Swin Transformer	1	1	0	1	1	4
MViT	1	1	0	1	1	4
T2T-ViT	1	1	0	1	1	4
DeiT	1	1	1	1	1	5

Fuente: El Autor.

A partir de las valoraciones obtenidas en cuanto a los tipos de redes neuronales basadas en transformadores preentrenadas, se selecciona DeiT debido a sus características de aprendizaje y que cumple con los requerimientos propuestos, en adición a ello, es importante considerar que permite alcanzar un rendimiento óptimo cuando la cantidad de datos de entrenamiento es limitada.

3.6.2 Diagramas del sistema

En esta sección previa al desarrollo del sistema se indica a través de representaciones gráficas el funcionamiento e incorporación de la selección tanto de hardware como de software en cada uno de los tres bloques que componen el


funcionamiento operativo del proyecto, basados sobre el bloque de infraestructura dedicado para ello.

3.6.2.1 Diagrama de bloques del sistema

En la Figura 23 se indica cada una de las etapas del sistema en orden cronológico de funcionamiento y además de ello se describe cada una en función de las acciones que realiza.

Figura 23

Diagrama de bloques del sistema



Nota. En la figura se muestran los tres bloques de funcionamiento que componen el sistema. Fuente: El Autor.

3.6.2.1.1 Bloque de obtención de datos

En este bloque inicial, es en donde se utiliza el dermatoscopio digital seleccionado para la toma de imágenes de la piel de los usuarios, mismas que deberán realizarse en condiciones idóneas y con la mayor calidad posible. La comunicación del dermatoscopio con el computador se realiza a través del software propio del dermatoscopio digital que se denomina MRKF. Es un software que permite la visualización y guardado de las imágenes en una carpeta para su posterior utilización en el prediagnóstico de melanomas.

La fuente de alimentación del dispositivo es a través de una batería recargable que cuenta con su propio cargador.

3.6.2.1.2 Bloque de procesamiento y análisis

En este bloque, se encuentra la esencia del TIC en donde se tiene el procesamiento de las imágenes obtenidas para el prediagnóstico. De igual manera se encuentran los mecanismos utilizados para el diseño y entrenamiento de las redes neuronales basadas en transformadores que se encargaran de obtener resultados acertados en la clasificación de imágenes con melanomas. Cada una de las funciones mencionadas parten de la base física de los recursos computacionales para el procesamiento y entrenamiento del modelo del sistema, considerando los requerimientos de infraestructura establecidos anteriormente. Por parte del entrenamiento se utiliza un dataset de 10000 imágenes dermatoscópicas comprobadas entre melanomas y benignas proporcionadas por el ISIC, mismas que son divididas porcentualmente para entrenamiento, validación y pruebas. Todas las especificaciones del caso son detalladas en la sección de desarrollo del sistema.

3.6.2.1.3 Bloque de visualización

En el último bloque, se encuentra la interfaz gráfica en donde el usuario tiene la capacidad de manipular el sistema, aquí es en donde se incorporan todos los resultados obtenidos en el bloque anterior con la finalidad de poder indicar de manera sencilla y clara tanto los resultados como proceso del prediagnóstico. En adición a ello, se genera un informe en formato PDF con las imágenes, resultados y parámetros obtenidos; esto con el objetivo de que un profesional en el área corrobore el prediagnóstico del sistema. La interfaz gráfica se presenta como un programa sencillo de utilizar en donde se ingresa la información básica del usuario para proceder al entorno de prediagnóstico, en donde


se encuentran cada una de las acciones de procesamiento, prediagnóstico y generación de resultados.

3.6.2.2 Diagrama de flujo del funcionamiento del sistema

En esta sección se presenta la secuencia de funcionamiento del sistema desde la toma de pruebas hasta la generación de los resultados del prediagnóstico, para ello se considera el siguiente diagrama de flujo de la Figura 24 en donde se encuentra detallado de mejor manera.

Figura 24

Diagrama de flujo del funcionamiento del sistema



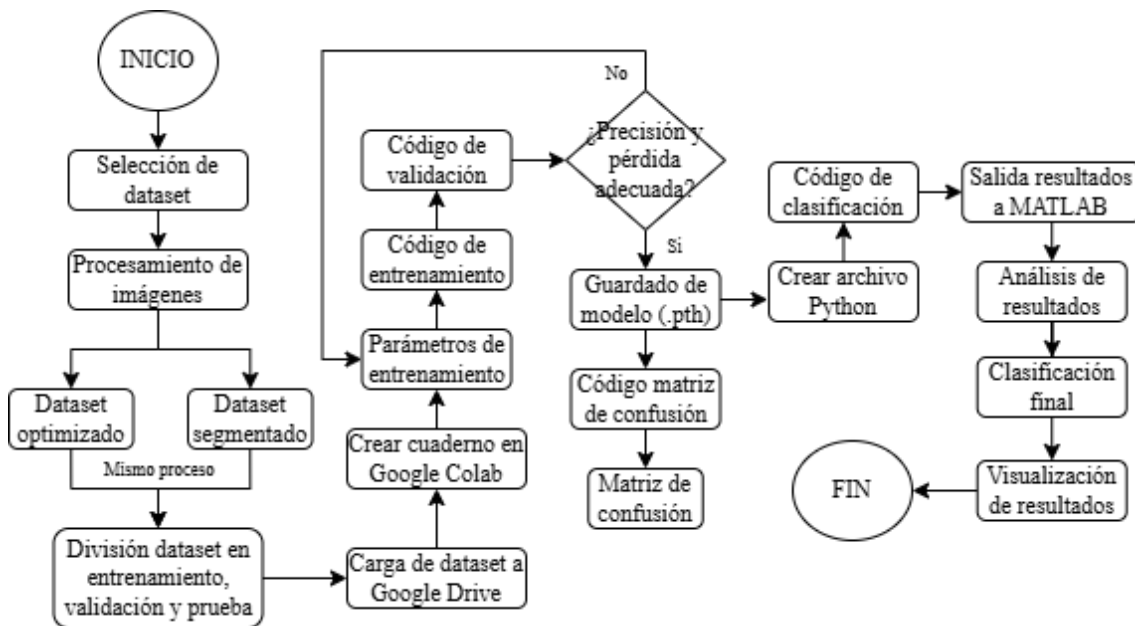
Fuente: El Autor.

3.6.2.3 Diagrama de flujo del entrenamiento y clasificación del sistema

En esta sección se indica cada uno de los pasos de entrenamiento, procesamiento y clasificación de las imágenes que son utilizados para el bloque de procesamiento y análisis del sistema a través del siguiente diagrama de flujo de la Figura 25.

Figura 25

Diagrama de flujo de entrenamiento y clasificación del sistema



Fuente: El Autor.

3.7 Desarrollo del sistema

En esta sección se detalla cada uno de los bloques que componen la arquitectura del sistema, considerando los aspectos y las características más importantes del diseño. Es importante mencionar que los elementos tanto de hardware y software seleccionados anteriormente son utilizados en el proceso, mismos que son pieza fundamental en el cumplimiento de cada uno de los requerimientos establecidos tanto para los stakeholders, sistema, arquitectura e infraestructura.

3.7.1 Bloque de obtención de datos

El bloque de obtención de datos se encarga de la adquisición de imágenes dermatoscópicas de las personas de la asociación. Para ello es necesario contar con un dispositivo especializado, en este caso el dermatoscopio digital TIANYUE M39 seleccionado en la sección 3.6.1.2.1 que cuenta con la capacidad de proporcionar las imágenes en un directorio del computador. A continuación, se detalla de mejor manera los aspectos de inicio a fin en la digitalización de las muestras.

3.7.1.1 Localización de zonas afectadas

Para la identificación de lesiones en la piel se debe considerar que pueden tener la apariencia de lunares, verrugas, manchas, protuberancias rojas, cicatrices o quistes. En la mayoría de los casos se presentan en personas mayores a 40 años y en zonas del cuerpo como brazos, pies, cuello y torso. Su apariencia suele tomar coloraciones marrones, oscuras, azuladas, moradas y rojizas, en cuanto a su forma presentan siluetas asimétricas y en cuestiones de tamaño, alcanzan un diámetro de 5 mm. En la Figura 26 se indica la manera en la que se identifican las lesiones en el torso de una persona.

Figura 26

Identificación de lesión en el torso




Fuente: Adaptado de (MedlinePlus, 2022).

3.7.1.2 Consideraciones en la toma de muestras

Con respecto a la toma de pruebas a las personas utilizando el dermatoscopio digital se debe asegurar que la zona de la lesión a diagnosticar cuente con la menor interferencia posible, evitando que se muestren pelos alrededor de la lesión, tinta sobre y cerca de la lesión, además de objetos como vendajes, curitas o telas que interfieran directa e indirectamente en la captura de las imágenes. Estas recomendaciones se las debe tomar con la finalidad de obtener resultados mucho más precisos en el prediagnóstico. En la Figura 27 se muestra un ejemplo erróneo de cómo no se debe realizar la toma de imágenes dermatoscópicas.

Figura 27

Ejemplo no adecuado en la toma de muestras



Nota. En la figura se indica la toma de una muestra de una lesión sin considerar las recomendaciones.

Fuente: Obtenido de (ISIC, 2024).

Por otro lado, en la Figura 28 se indica un ejemplo adecuado para la toma de muestras a través de imágenes dermatoscópicas, en donde no existen interferencias con la lesión y es el centro de toda la imagen. Una consideración adicional, es intentar obtener las muestras sin los bordes oscurecidos, con la finalidad de ayudar al procesamiento de la imagen.

Figura 28

Ejemplo adecuado en la toma de muestras



Nota. En la siguiente figura se indica un ejemplo correcto de la toma de una muestra a través de imágenes dermatoscópicas. Fuente: Obtenido de (ISIC, 2024).

En la sección siguiente, se detalla aspectos relevantes en la configuración del dispositivo de toma de imágenes, entre ellos los modos de funcionamiento, enfoque y desenfoque del lente, comunicación con el computador del sistema y transferencia de archivos.

3.7.1.3 Configuración del dermatoscopio digital

Para la utilización del dermatoscopio TIANYUE M39 se utiliza un software intermedio denominado MRKF, que es propio del fabricante del dispositivo. En la Figura 29 se identifica los archivos que componen el software.

Figura 29

Archivos del software MRKF

Language	10/4/2024 21:51	Carpeta de archivos	
New	2/4/2015 9:01	Carpeta de archivos	
MRKF	10/4/2024 21:51	Aplicación	1.716 KB
setting	10/4/2024 21:51	Opciones de confi...	1 KB

Nota. En la figura indicada se muestran los archivos de configuración y el ejecutable del programa que permitirá capturar las imágenes del dermatoscopio digital. Fuente: El Autor.

El entorno de captura de imágenes se representa en la Figura 30, además de ello existe la posibilidad de seleccionar o crear directorios en donde se almacenen las imágenes.

Figura 30

Entorno de captura de imágenes MRKF




Nota. En la siguiente figura se muestra un ejemplo de la toma de una muestra, para el caso se ha obtenido imágenes de la piel con tinta. Fuente: El Autor.

Un aspecto importante es la comunicación inalámbrica con el computador y para ello es necesario la conectividad con el dermatoscopio digital a través del punto de acceso generado por el mismo dispositivo. Se muestra con el SSID m30013368 al cual se debe conectar el computador que este siendo utilizado para el funcionamiento del sistema. En la Figura 31 se muestra la conexión exitosa del computador con el dermatoscopio digital vía Wi-Fi (utilizando el protocolo IEEE 802.11n).

Figura 31

Conexión exitosa del dermatoscopio digital al computador



Fuente: El Autor

En cuanto a la alimentación eléctrica del dermatoscopio se da por medio de un cargador con las siguientes características mencionadas en la Tabla 20.

Tabla 20

Especificaciones del cargador

CARACTERÍSTICA	DESCRIPCIÓN
Modelo	BDL-003
Voltaje de entrada	100-240V 50/60 Hz
Voltaje de salida	5V
Corriente de entrada	0.3A
Corriente de salida	1A

Fuente: El Autor.

A continuación, en la Figura 32 se muestra la representación del cargador utilizado para la alimentación eléctrica del dispositivo.

Figura 32

Cargador del dermatoscopio TIANYUE M39



Fuente: El Autor.

3.7.1.4 Obtención de imágenes dermatoscópicas

En primera instancia se debe realizar el encendido del dispositivo que se indica a través de la titilación del indicador Wi-Fi de color verde, además de un segundo led que

indica la interacción del dispositivo con el computador o smartphone. En la Figura 33 se muestra los indicadores leds mencionados en el encendido del dispositivo.

Figura 33

Indicadores de interacción del dispositivo




Fuente: El Autor.

En cuanto a la obtención de las imágenes se realiza a través del contacto directo del dispositivo en la piel, como se indica en la Figura 34 en donde se realiza un ejemplo a través de una mancha realizada con tinta. La captura se realiza a través del botón sobre el cual descansa el dedo en la figura y la rueda plateada se utiliza para el enfoque y desenfoco del objetivo.

Figura 34

Ejemplo de toma de imagen de muestra




Fuente: El Autor.

Las imágenes capturadas son guardadas en el directorio creado al momento de ejecutar la aplicación como se muestra en la Figura 35.

Figura 35

Directorio de almacenado de imágenes



Fuente: El Autor.

En el bloque siguiente se detalla los aspectos en cuanto al procesamiento de las imágenes obtenidas en el bloque anterior, además de la selección del dataset, algoritmos de segmentación, red neuronal preentrenada, entre otros aspectos relevantes en el diseño.

3.7.2 Bloque de procesamiento y análisis

Una vez que se obtienen las imágenes dermatoscópicas, se procede con el bloque de procesamiento de las imágenes y entrenamiento de redes neuronales basadas en transformadores para la detección de patrones que permitan analizar e identificar las imágenes con melanomas.

En cuanto al procesamiento de las imágenes se debe considerar procesarlas en el formato JPG, por las siguientes consideraciones:

- Tamaño de archivo reducido.
- Alta resolución.
- Compatibilidad con software y dispositivos.
- Dataset de imágenes más ligero.


Considerando el formato de las imágenes, en las secciones posteriores se detalla de mejor manera los mecanismos de procesamiento implementados, pero para ello a continuación se establece el dataset sobre el cual se va a trabajar.

3.7.2.1 Obtención del dataset de imágenes

La obtención se realiza desde la base de datos seleccionada en la sección 3.6.1.3.2 que indica el dataset proporcionado por la ISIC como la mejor opción. La ISIC (International Skin Imaging Collaboration) proporciona una amplia gama de imágenes de lesiones cutáneas verificadas por especialistas de diversos institutos, hospitales, universidades y centros de investigación, en donde existe una galería con 485079 imágenes hasta la actualidad. Para los fines de este sistema se han aplicado filtros como: tipo de imagen (dermatoscópica), neoplasia (maligno o benigno) y prediagnóstico de lesión (melanoma). Otra consideración es que la información proporcionada por la organización es de uso libre con fines investigativos y de desarrollo. En la Figura 36 se muestra el entorno en donde se encuentra la galería del ISIC con todas las imágenes mencionadas anteriormente.

Figura 36

Galería de imágenes del ISIC 2024



Nota. En la siguiente figura se muestra el filtrado de imágenes dermatoscópicas con melanomas, en donde arroja como resultado 7196 imágenes. Fuente: Obtenido de (ISIC, 2024).

Para el procesamiento de las imágenes con las que se entrena la red neuronal basada en transformadores se utiliza un dataset de 10000 imágenes, consideradas entre benignas y malignas (melanomas). Dicha cantidad es determinada debido a la complejidad y variedad de perspectivas en la captura de las imágenes; requiere de equilibrio entre calidad y cantidad, dado que existe diversidad en cuanto a muestras, edad del paciente, ubicación en el cuerpo y calidad de la imagen.

Las imágenes del dataset previamente deben ser seleccionadas de manera adecuada y aleatoriamente, para ello en la Tabla 21 se plantea la siguiente distribución para el entrenamiento.

Tabla 21

Distribución de dataset para entrenamiento

Distribución de dataset de entrenamiento		
Tipo de imagen	Benignas	Malignas (Melanoma)
Imágenes de entrenamiento	70% (3500 imágenes)	70% (3500 imágenes)
Imágenes de validación	20% (1000 imágenes)	20% (1000 imágenes)
Imágenes de prueba	10% (500 imágenes)	10% (500 imágenes)
Total	100% (5000 imágenes)	100 % (5000 imágenes)

Fuente: El Autor.

3.7.2.2 Procesamiento de las imágenes

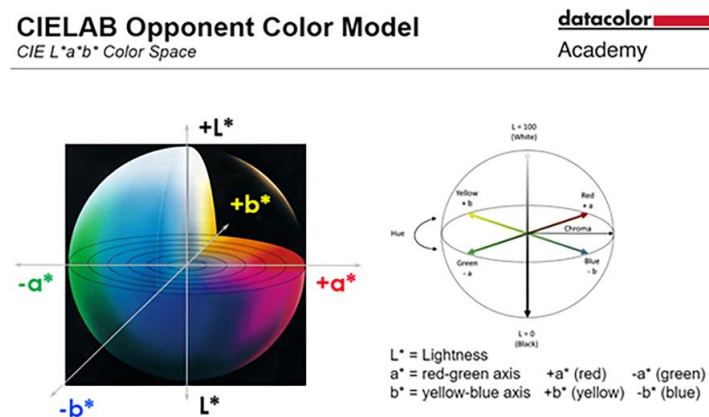
El procesamiento de las imágenes se centra en la optimización y la segmentación de las lesiones detectadas del fondo de las imágenes a través de mecanismos de conversión de espacios de color, detección de bordes, eliminación de objetos, aplicación de filtros, dilatación y clustering.

La representación de colores que se utiliza en las imágenes es CIE L*A*B, por ello se realiza una previa conversión de RGB a CIE L*A*B a través de la función `rgb2lab`.

El espacio de color CIE L^*A^*B cubre toda la gama de colores que son perceptibles en el ojo humano, manteniendo uniformidad en toda la imagen. Está modelado en base al principio que establece que dos colores no pueden ser rojo y verde o amarillo y azul al mismo tiempo. En cuanto a sus variables L, A y B, se encuentra determinado L para indicar la luminosidad, A y B las coordenadas cromáticas (Datacolor, 2024). En la Figura 37 se indica la manera en la que se encuentra representado el espacio de color CIE L^*A^*B , considerando sus coordenadas tridimensionales.

Figura 37

*Representación gráfica del espacio de color CIE L^*A^*B*



Fuente: Obtenido de (Datacolor, 2024).

Una vez aplicado la conversión del espacio de color en el que está representado las imágenes, se procede a la separación en canales tanto L, A y B para la aplicación de un filtro anisotrópico con la finalidad de reducir el ruido en áreas homogéneas mientras se preservan los bordes y discontinuidades de las lesiones en las imágenes.

Los filtros anisotrópicos generalmente son utilizados en el procesamiento de imágenes médicas ya que ayudan a la reducción de ruido en zonas homogéneas además que realiza un suavizado entre las regiones sin perder información importante en ciertas direcciones (Gómez, 2018).

Son utilizados con la finalidad de lograr mejorar la calidad de las texturas que se encuentran más alejadas del campo de visión natural en las imágenes. Con ello permite reducir el efecto de difuminación y aumentar los detalles. Existen niveles de filtrado, en donde mientras mayor sea el valor, mayor calidad se obtendrá y de igual manera el consumo de recursos gráficos aumentará (Catness, 2023).

Para la aplicación del filtro, previamente se realiza una conversión de CIE L*A*B a escala de grises con el propósito de que el filtro procese la información de una manera mucho más rápida y efectiva.

En la Figura 38 se visualiza de manera gráfica las diferencias que existe en una imagen después de pasar por el proceso de filtración de difusión anisotrópica.

Figura 38

Aplicación de filtro anisotrópico



Fuente: El Autor.

Después de aplicar el filtro anisotrópico, se procede con la aplicación de clustering automático utilizando el algoritmo K-Means. Se debe entender que el clustering es un proceso que consta de la organización de objetos y elementos que guarden similitud entre ellos. Entendiendo que un cluster es un conjunto de objetos parecidos entre ellos y diferentes a los de otro cluster (Yarasca, 2013).

En el contexto del sistema, se trata de la separación de la lesión de la piel del fondo de la imagen. Para ello se utiliza un algoritmo conocido como K-Means, que es de clasificación no supervisada que agrupa objetos en K grupos tomando como referencia de clasificación sus características. El método de agrupamiento funciona disminuyendo la suma de las distancias entre cada objeto y el centroide del cluster (Aranda et al., 2015). El algoritmo se encuentra compuesto por tres fases:


- Inicialización: Después de seleccionar el número de grupos K, se establecen K centroides en el espacio de datos.
- Asignación de objetos: Cada objeto de datos es asignado al centroide más cercano.
- Actualización: Se actualiza la posición del centroide de cada grupo tomando como nuevo centroide la posición media de los objetos del grupo.

(Aranda et al., 2015)

En la Figura 39 se visualiza un ejemplo del resultado del clustering de una imagen, en donde se separa la lesión del resto de la piel de la imagen.

Figura 39

Segmentación a través de clustering automático k-means



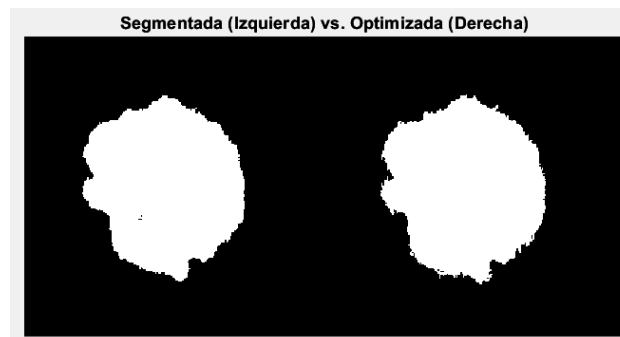
Fuente: El Autor.

Para mejorar la segmentación obtenida anteriormente, se utiliza la función de crecimiento de contorno activo o también conocido como serpientes que mejora las regiones del contorno, logrando ser más preciso en los detalles de segmentación. Un contorno activo o serpiente es una curva elástica aproximada que sobre una imagen se deforma a partir de una forma inicial con la finalidad de delimitar las regiones de interés de la imagen (Rodríguez, 2020).

Para la función de contornos activos se utiliza el algoritmo Chan-Vese que es utilizado comúnmente en imágenes médicas, se trata de un algoritmo potente y flexible que utiliza métodos basados en umbrales o gradientes (Cohen, 2010). En la Figura 40 se puede identificar la optimización en la segmentación de la lesión, en donde los detalles son más pronunciados en la imagen de la derecha.

Figura 40

Optimización de la segmentación




Fuente: El Autor.

Además de ello es necesario detectar los bordes que no son importantes en la zona de la lesión, pueden presentarse debido a las características del dispositivo de captura de imágenes o adaptadores que influyen en la calidad de la imagen. En esta parte del procesamiento es útil utilizar la función edge que permite encontrar bordes en imágenes en escala de grises a través del uso del algoritmo Canny. Es un operador de detección de bordes que se encuentra compuesto de varias capas. Se compone de una capa de reducción

de ruido, cálculo de gradiente, supresión no máxima, doble umbral y seguimiento de bordes por histéresis (Singh, 2020), dando como resultado en el contexto del sistema la limitación de la lesión como se indica en la Figura 41.

Figura 41

Detección de bordes de la lesión




Fuente: El Autor.

En cuanto a las interferencias con la lesión como los pelos en la piel, pueden ser eliminados por medio de funciones específicas para objetos pequeños en imágenes binarias, en este caso `bwareaopen`. En el caso de MATLAB es una función que permite eliminar todos los componentes conectados (objetos) que tienen menos de P píxeles en una imagen binaria (MATLAB, 2023). En la Figura 42 se puede visualizar el proceso de eliminación de objetos que sean menores a 500 píxeles.

Figura 42

Eliminación de objetos



Fuente: El Autor.

Por último, para el procesamiento de las imágenes se tiene en consideración la dilatación morfológica, con la finalidad de que píxeles adyacentes se unan en una misma región, eso es útil en la segmentación de imágenes ya que con ello permite rellenar agujeros en objetos y la eliminación de ruido que puede representarse como píxeles sueltos que interfieren en el objetivo de la aplicación de entrenamiento posterior. La dilatación se lleva a cabo desde la estructura de un objeto, en este caso un disco de 3 píxeles que va a ir combinando todos los adyacentes en regiones para eliminar ruido en la imagen. En la Figura 43 se representa el resultado de aplicar la dilatación morfológica a una imagen segmentada.

Figura 43

Dilatación de la imagen segmentada



Fuente: El Autor.

En esta sección de procesamiento de las imágenes se describe el proceso que se realiza con las muestras (imágenes) que son obtenidas de las personas de la asociación, mismas que serán utilizadas para el prediagnóstico posterior. En cuanto a la siguiente sección de entrenamiento de las redes neuronales basadas en transformadores, se hace énfasis en el procesamiento digital del dataset, características de la red neuronal preentrenada utilizada, adaptación del modelo y parámetros importantes a configurar previo al entrenamiento de la red.

3.7.2.3 Entrenamiento del modelo DeiT

En cuanto al proceso de entrenamiento del modelo DeiT se realiza en infraestructura de computación en la nube, en este caso Google Colab debido a los entornos de ejecución con los que cuenta, que son aptos para el entrenamiento del modelo seleccionado en la sección 3.6.1.3.3.

Por otra parte, el procesamiento digital del dataset es realizado en un entorno local, en este caso el computador personal que cuenta con las características de hardware adecuadas para llevar a cabo tal tarea. En la Tabla 22 se indica las especificaciones del computador HP Victus Gaming 15-FA1004LA que ha sido utilizado.

Tabla 22

Especificaciones del computador

Características del computador	
Procesador	Intel Core i5-12450H
Memoria ROM	512 GB SSD
Memoria RAM	16 GB DDR4 3200
Tarjeta de video	Nvidia GeForce GTX 1650 4GB
Pantalla	15.6" 144 Hz
Sistema Operativo	Windows 11 Home

Fuente: Adaptado de (HP, 2024).

3.7.2.3.1 Procesamiento digital del dataset

Inicialmente el conjunto de imágenes que se obtiene de la galería del ISIC es mucho mayor a las 10000 imágenes que van a ser utilizadas para el entrenamiento del sistema, para ello se realiza un proceso de selección aleatoria tanto para las imágenes de entrenamiento, validación y prueba. Las imágenes obtenidas son del tipo

dermatoscópicas, ya que cumplen con los criterios de iluminación y calidad de las muestras mencionadas en la sección 3.7.1.2. Se emplea un código de selección aleatoria con la finalidad de contar con la cantidad especificada para ambas clases.

Dado que las imágenes pertenecen a un repositorio internacional, las dimensiones de cada una son diferentes, entonces para ello, se procede con el proceso de redimensionamiento de cada una considerando el tamaño 224x224 píxeles. De igual manera a través de un algoritmo de codificación se procede al proceso de redimensionamiento de todas las imágenes en un directorio específico, como se muestra en la Figura 44.

Figura 44

Adaptación de dataset para el entrenamiento



Fuente: El Autor.

Dicho procesamiento es útil para la red neuronal entrenada con las imágenes originales; sin embargo, se va a trabajar con una red neuronal adicional de las imágenes anteriores pero segmentadas, con la finalidad de que el modelo obtenga dos resultados y en base a los niveles de precisión de clasificación proporcione un resultado final. Entonces considerando eso, se realiza el proceso de segmentación de las imágenes tomando en cuenta el procesamiento de las imágenes mencionado en la sección 3.7.2.2.

En la Figura 45 se muestra un extracto del código utilizado para la segmentación de las imágenes del dataset.

Figura 45

Porción del código de segmentación de las imágenes del dataset

```
% Convertir a espacio de color LAB
X = rgb2lab(LAB);

% Separar los canales de color
l = X(:,:,1);
a = X(:,:,2);
b = X(:,:,3);

% Aplicar filtro anisotrópico a cada canal
numIter = 10; % Número de iteraciones del filtro
l_filt = imdiffusefilt(l, 'NumberOfIterations', numIter);
a_filt = imdiffusefilt(a, 'NumberOfIterations', numIter);
b_filt = imdiffusefilt(b, 'NumberOfIterations', numIter);

% Combinar los canales filtrados
X_filt = cat(3, l_filt, a_filt, b_filt);


% Clustering automático
L = imsegkmeans(single(X_filt), 3, 'NumAttempts', 50);
```

Fuente: El Autor.

En la Figura 46 se visualiza el resultado del proceso de segmentación del dataset junto con las dimensiones determinadas para el entrenamiento en un directorio en específico para su entrenamiento posterior.

Figura 46

Segmentación del dataset para el entrenamiento



Fuente: El Autor.

Después del procesamiento del dataset para ambas redes neuronales, se procede en la siguiente sección a detallar la adaptación del modelo de entrenamiento que es utilizado.

3.7.2.3.2 Adaptación del modelo de entrenamiento

Considerando el entorno de entrenamiento de Google Colab, se utiliza tres entornos de ejecución con diferentes prestaciones de infraestructura. De mejor manera en el capítulo siguiente se especifica los rendimientos y tiempos alcanzados con cada una, para de igual manera determinar la mejor opción en este trabajo. Al determinar la red neuronal preentrenada en la sección 3.6.1.3.3 como DeiT, en la siguiente Tabla 23 se muestran especificaciones técnicas de DeiT-B Distillation siendo el modelo base de la red neuronal mencionada.

Tabla 23

Especificaciones de la red neuronal preentrenada

Modelo de red neuronal preentrenada	
DeiT	DeiT-B Distillation
N° de capas	12
N° de conexiones	Densamente conectadas (Transformers)
Profundidad	12 bloques Transformer
Parámetros	86 M
Tamaño de entrada	224x224

Fuente: Adaptado de (Touvron et al., 2020).

Dentro del entorno de Google Colab, se inicia un nuevo cuaderno, en donde en primer lugar se monta Google Drive para acceder al dataset previamente cargado, junto

con la instalación e importación de las librerías transformers, torch, timm, matplotlib, torchvision como se muestra en la Figura 47.

Figura 47

Montaje de Google Drive, instalación e importación de librerías

```
# Instalar las librerías necesarias
!pip install transformers datasets torch torchvision timm matplotlib

# Montar Google Drive para acceder a los datos
from google.colab import drive
drive.mount('/content/drive')

# Importar librerías
import os
import torch
import timm
from torchvision import datasets, transforms
from torch.utils.data import DataLoader
from torch import nn
from torch.optim import AdamW
from torch.optim.lr_scheduler import ReduceLROnPlateau
from torch.cuda.amp import autocast, GradScaler
import copy
```

Fuente: El Autor.

Seguido de ello se determina la ruta de los datasets, además que se contempla funciones de aumento de datos como rotaciones, cambio de color como brillo, saturación, contraste, tono y cambios de rotaciones horizontales. Se cargan los datasets de entrenamiento junto con el aumento de datos y finalmente se condensa en lotes a través de los DataLoaders. La codificación implementada se muestra en la Figura 48.

Figura 48

Carga de dataset y aumento de datos

```
# Rutas del dataset
train_data_dir = '/content/drive/MyDrive/dataset/train'
val_data_dir = '/content/drive/MyDrive/dataset/verify'

# Transformaciones de las imágenes (Aumento de datos)
transform = transforms.Compose([
    transforms.Resize((224, 224)),
    transforms.RandomHorizontalFlip(),
    transforms.RandomRotation(15),
    transforms.ColorJitter(brightness=0.2, contrast=0.2, saturation=0.2, hue=0.1),
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225]),
])

# Cargar los datasets de entrenamiento y validación
train_dataset = datasets.ImageFolder(root=train_data_dir, transform=transform)
val_dataset = datasets.ImageFolder(root=val_data_dir, transform=transform)

# Crear DataLoaders para entrenamiento y validación
train_loader = DataLoader(train_dataset, batch_size=256, shuffle=True, num_workers=8, pin_memory=True)
val_loader = DataLoader(val_dataset, batch_size=256, shuffle=False, num_workers=8, pin_memory=True)
```

Fuente: El Autor.

A continuación, el código de la Figura 49 carga el modelo DeiT Base Distillation y se ajusta las últimas capas para la clasificación y capa de destilación.

Figura 49

Carga de modelo DeiT-B Distillation y ajuste de capas

```
# Cargar el modelo DeiT base distillation
model = timm.create_model('deit_base_distilled_patch16_224', pretrained=True)

# Ajustar la última capa para la clasificación
model.head = nn.Sequential(
    nn.Dropout(0.3), # Dropout para evitar sobreajuste
    nn.Linear(model.head.in_features, 2)
)

# Ajustar la capa para el distillation (cabeza secundaria)
model.head_dist = nn.Sequential(
    nn.Dropout(0.3), # Dropout para evitar sobreajuste
    nn.Linear(model.head_dist.in_features, 2)
)
```

Fuente: El Autor.

Luego de ello se aplican mecanismos para identificar el entorno de ejecución, la función de pérdida CrossEntropyLoss para evaluar el rendimiento y el optimizador AdamW con decaimiento del peso para evitar el sobreajuste. Se añade un scheduler que reduce la tasa de aprendizaje si la precisión de validación no mejora, y se utiliza un escalador de gradiente para optimizar el entrenamiento con precisión mixta. Además, se implementa Early Stopping para detener el entrenamiento si no hay mejoras en varias épocas. En la Figura 50 se muestra la codificación de las técnicas mencionadas.

Figura 50

Técnicas para mejorar el entrenamiento y sobreajuste

```
# Identifica el dispositivo
device = torch.device('cuda' if torch.cuda.is_available() else 'cpu')
model = model.to(device)

# Define el criterio de pérdida y el optimizador con un decaimiento del peso
criterion = nn.CrossEntropyLoss()
optimizer = AdamW(model.parameters(), lr=1e-4, weight_decay=1e-4)

# Utiliza Scheduler para reducir el learning rate si no mejora la precisión de validación
scheduler = ReduceLROnPlateau(optimizer, mode='max', factor=0.1, patience=3, verbose=True)

# Utiliza escalar de gradiente para acelerar el entrenamiento
scaler = GradScaler()

# Implementa Early Stopping para parar si la precisión no mejora
early_stopping_patience = 5
best_model_wts = copy.deepcopy(model.state_dict())
best_accuracy = 0.0
early_stopping_counter = 0
```

Fuente: El Autor.

Después se lleva a cabo el entrenamiento del modelo en cada época, procesando el conjunto de datos de entrenamiento. Primero, se trasladan las imágenes y etiquetas a la unidad de procesamiento, y se restablece el gradiente del optimizador. Luego se aplica la aceleración automática para aumentar la eficiencia, y se obtienen las salidas del modelo. Si el modelo genera dos salidas (una principal y otra de distillation), se calcula la pérdida combinando ambas; si no, se utiliza únicamente la pérdida principal. Después, se escala la pérdida y se realiza la retropropagación para modificar los pesos del modelo. Por último, se actualizan las métricas de pérdida y precisión acumulando los resultados de las predicciones. En la Figura 51 se indica la codificación para el entrenamiento del modelo mencionado.

Figura 51

Código del entrenamiento del modelo DeiT-B Distillation

```
# Entrenamiento
for images, labels in train_loader:
    images, labels = images.to(device), labels.to(device)

    optimizer.zero_grad()

    # Aceleración
    with autocast():
        outputs = model(images)

    # Verificamos si el modelo devuelve dos salidas (principal y distillation)
    if isinstance(outputs, tuple):
        outputs, dist_outputs = outputs
        loss_main = criterion(outputs, labels)
        loss_distillation = criterion(dist_outputs, labels)
        # Ponderar la pérdida principal y la de distillation
        loss = loss_main + distillation_loss_weight * loss_distillation
    else:
        # Si solo devuelve una salida, usar la principal
        loss = criterion(outputs, labels)

    scaler.scale(loss).backward()
    scaler.step(optimizer)
    scaler.update()

    train_loss += loss.item() * images.size(0)
    _, predicted = torch.max(outputs, 1)
    correct += (predicted == labels).sum().item()
    total += labels.size(0)
```

Fuente: El Autor.

Finalmente, en esta sección del código se realiza la validación del modelo tras cada época de entrenamiento. Se establece el modelo en modo evaluación, se inicializan

las métricas de pérdida y precisión, y se recorre el conjunto de datos de validación. Para cada lote de imágenes, se generan las salidas del modelo y se calcula la pérdida. Si el modelo devuelve dos salidas, se extraen ambas; de lo contrario, se usa solo la salida principal. La pérdida total y las predicciones correctas se almacenan, y al final se calcula la pérdida y precisión promedio dividiendo por el tamaño del conjunto de datos. Luego de ello se realiza el proceso de guardado del modelo en base a la mejor precisión de validación. En la Figura 52 se muestra el código utilizado para la validación del entrenamiento explicado anteriormente.

Figura 52

Código de validación del entrenamiento

```
# Validación
model.eval()
val_loss = 0.0
correct_val = 0
total_val = 0
with torch.no_grad():
    for images, labels in val_loader:
        images, labels = images.to(device), labels.to(device)
        outputs = model(images)

        if isinstance(outputs, tuple):
            outputs, dist_outputs = outputs
            loss = criterion(outputs, labels)

            val_loss += loss.item() * images.size(0)
            _, predicted = torch.max(outputs, 1)
            correct_val += (predicted == labels).sum().item()
            total_val += labels.size(0)

train_loss /= len(train_loader.dataset)
val_loss /= len(val_loader.dataset)
train_accuracy = correct / total
val_accuracy = correct_val / total_val
```

Fuente: El Autor.

En la siguiente sección se detalla los parámetros de entrenamiento considerados para la red neuronal, tomando en cuenta que su desarrollo es realizado en diferentes entornos de ejecución en Google Colab.

3.7.2.3.3 Parámetros de entrenamiento

A continuación, se presenta las opciones de entrenamiento utilizadas tanto para el entrenamiento de la red neuronal con las imágenes dermatoscópicas originales y las

segmentadas obtenidas en el procesamiento previo. En la Tabla 24 se indica las opciones finales utilizadas en el entrenamiento de la red neuronal principal.

Tabla 24

Configuración de entrenamiento red neuronal originales.

Configuración	Valor
Tamaño de la imagen	224x224
Solver	AdamW
InitialLearnRate	0.0001
ValidationFrecuency	Cada época
MaxEpochs	20
MiniBatchSize	256
ExecutionEnviroment	GPU
L2Regularization	0.0001
LearnRateSchedule	ReduceLROnPlateau
LossFunction	CrossEntropyLoss

Fuente: El Autor.

En cambio, en la Tabla 25 se muestra las opciones de entrenamiento utilizadas finalmente para el entrenamiento de la red neuronal con las imágenes segmentadas.

Tabla 25

Configuración de entrenamiento red neuornal segmentadas.

Configuración	Valor
Tamaño de la imagen	224x224
Solver	AdamW
InitialLearnRate	0.0001
ValidationFrecuency	Cada época

MaxEpochs	20
MiniBatchSize	64
ExecutionEnvironment	GPU
L2Regularization	0.001
LearnRateSchedule	ReduceLROnPlateau
LossFunction	CrossEntropyLoss

Fuente: El Autor.

En el capítulo siguiente se especifica los niveles de precisión y pérdida para el entrenamiento con entornos de diferentes prestaciones, haciendo énfasis en la importancia que tiene dichas características en la ejecución de este tipo de aplicaciones computacionales. De este proceso de entrenamiento se generan archivos .pth en el entorno de desarrollo de Google Colab, pero para su ejecución en la GUI de MATLAB requiere de un procesamiento adicional, que es un script de Python para el proceso de clasificación de las imágenes de ambas redes neuronales.

3.7.2.3.4 Script de Python (Clasificación de imágenes)

El script tiene como finalidad realizar la predicción de las imágenes, para ello requiere de la instalación de librerías como timm, torch, numpy, torchvision y pillow. Se aplica para la predicción de imágenes originales y segmentadas de ambas redes neuronales. El script funciona a través de la importación de variables de MATLAB que contienen la información de la imagen a clasificar y de igual manera se encarga de exportar los valores de predicción a MATLAB para que puedan ser mostrados de manera interactiva al usuario. En la Figura 53 se muestra el código del script Python para la clasificación de imágenes.

Figura 53

Código de clasificación de imágenes Python

```
# Importar librerías
import torch
import timm
from torchvision import transforms
from PIL import Image
import sys
import warnings

# Ignorar advertencias futuras
warnings.simplefilter('ignore', category=FutureWarning)

# Cargar el modelo
model_path = 'C:/Program Files/UTN/Recursos/DeiT_B_Dis_A100_20e_best_model.pth'
image_path = sys.argv[1] # La ruta de la imagen es el único argumento

device = torch.device('cuda' if torch.cuda.is_available() else 'cpu')

# Cargar el modelo DeiT Base Distillation
model = timm.create_model('deit_base_distilled_patch16_224', pretrained=False)
model.head = torch.nn.Sequential(
    torch.nn.Dropout(0.3),
    torch.nn.Linear(model.head.in_features, 2)
)
model.head_dist = torch.nn.Sequential(
    torch.nn.Dropout(0.3),
    torch.nn.Linear(model.head_dist.in_features, 2)
)

# Cargar el modelo guardado
model.load_state_dict(torch.load(model_path, map_location=device))
model = model.to(device)
model.eval()

# Definir las transformaciones de imagen
transform = transforms.Compose([
    transforms.Resize((224, 224)),
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225]),
])

# Cargar y transformar la imagen
image = Image.open(image_path).convert('RGB')
image = transform(image).unsqueeze(0).to(device)

# Realizar la inferencia
with torch.no_grad():
    outputs = model(image)
    if isinstance(outputs, tuple):
        outputs, dist_outputs = outputs
    probabilities = torch.softmax(outputs, dim=1) # Calcular probabilidades
    predicted_class = torch.argmax(outputs, dim=1).item()
    confidence = probabilities[0][predicted_class].item() # Obtener la confianza de la predicción

# Imprimir la clase predicha y la confianza
print(predicted_class, confidence)
```

Fuente: El Autor.

3.7.3 Bloque de visualización

En el último bloque del sistema, se centra en la representación gráfica tanto para la manipulación de las imágenes como la visualización de los resultados de los prediagnósticos realizados.

3.7.3.1 Desarrollo de Interfaz Gráfica de Usuario

En base a la selección del entorno de desarrollo realizado en la sección 3.6.1.3.1, MATLAB cuenta con un entorno gráfico propio para el diseño de aplicaciones de escritorio compatibles con el sistema operativo Windows conocido como App Designer y MATLAB Compiler. Considerando ello se ha establecido el diseño en las siguientes ventanas:

- Ventana de inicio de sesión.
- Ventana de menú de opciones.
- Ventana de ingreso de información del paciente.
- Ventana de prediagnóstico de muestras.
- Ventana de información del desarrollador y salida.

A continuación, se muestra la ventana de inicio de sesión en donde el administrador ingresa las credenciales proporcionadas para acceder al control del sistema, en este espacio realiza la comprobación de que el usuario y contraseña sean los correctos. En caso de presentar inconsistencias en las credenciales, se presenta un mensaje emergente de error. En la Figura 54 se muestra un ejemplo de un ingreso satisfactorio al sistema.

Figura 54

Ventana de ingreso de credenciales de acceso



Fuente: El Autor.

Una vez validado las credenciales, se muestra el menú general que indica las opciones disponibles como realizar un nuevo prediagnóstico, ver los informes obtenidos anteriormente y el cierre de la aplicación. En la Figura 55 se puede visualizar la ventana con cada una de las opciones mencionadas junto con una descripción de lo que realiza.

Figura 55

Ventana del menú de opciones



Fuente: El Autor.

En la opción Nuevo Prediagnóstico, al ingresar se muestra de inmediato la ventana de información del paciente. En la ventana se solicita el número de cédula, nombre, apellido, edad, sexo y enfermedad en caso de padecer alguna. En la Figura 56 se muestra la ventana indicada con un ejemplo de ingreso de datos; en caso de faltar un dato, se informa al usuario del error cometido.

Figura 56

Ventana de ingreso de información del paciente



MATLAB App

INFORMACIÓN DEL PACIENTE

Cédula:

Nombre:

Apellido:

Edad:

Sexo:

Posee alguna enfermedad No Si

Enfermedad (Opcional):

Fuente: El Autor.

Para el ingreso de los datos se utiliza una estructura de control “if else” que permite tomar decisiones basadas en condiciones. Para ello se toman los datos ingresados a través de variables globales, debido a que para la generación del informe se requerirá de los mismos. En la Figura 57 se muestra un extracto del código utilizado para el control del ingreso de los datos del paciente.

Figura 57

Estructura de control de datos del paciente

```
% REGLAS PARA INGRESO DE DATOS ERRONEOS
if isempty(nombre_user) || isempty(apellido_user) || isempty(edad_user) || isempty(sexo_user) || isequal(enfermedad_user, valor_enfermedad)

    if isempty(tipo_enfermedad_user) || isempty(nombre_user) || isempty(apellido_user) || isempty(edad_user) || isempty(sexo_user)

        close(app.Informacion);

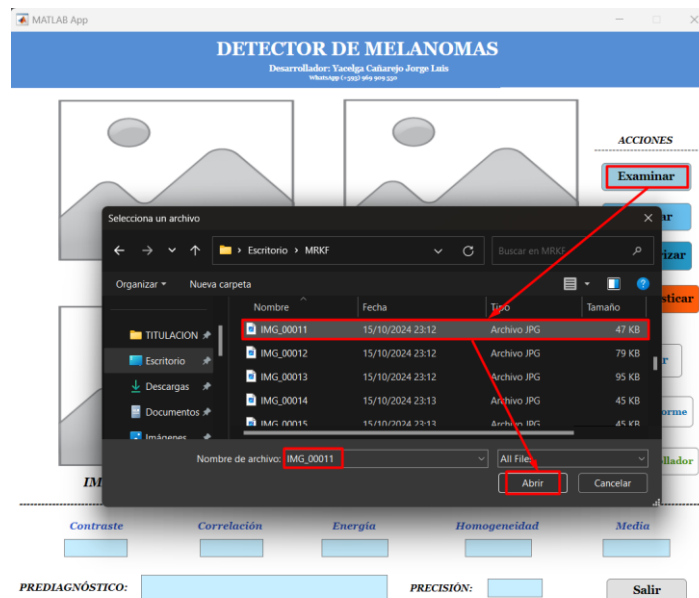
        % VENTANA EMERGENTE DE DATOS FALTANTES
        h = msgbox("Datos no ingresados", "Error", "error");
        uiwait(h);
        informacion;
    else
        close(app.Informacion);
        diagnostico;
    end
else
    close(app.Informacion);
    diagnostico;
end
```

Fuente: El Autor.

Al ingresar adecuadamente los datos del paciente, se abre la siguiente ventana en donde se muestra un entorno con cuadros que indican el procesamiento de la imagen, los paneles de visualización de los resultados y botones de acción para el prediagnóstico de la muestra. En la Figura 58 se indica el proceso de carga de una imagen al sistema.

Figura 58

Carga de imagen al sistema



Nota. En la siguiente figura se visualiza el cuadro de selección de imagen al accionar el botón de examinar.

Fuente: El Autor.

Para la selección de la imagen se utiliza el siguiente código que permite la conversión de la imagen al formato JPG en caso de existir algún otro tipo de formato que se encuentre ingresando al sistema de detección. En la Figura 59 se detalla de mejor manera las sentencias y funciones utilizadas para lo mencionado.

Figura 59

Código de selección de la imagen a ingresar al sistema

```
% SELECCION DE IMAGEN DESDE EXPLORADOR
[archivo, ruta] = uigetfile('*..*', 'Selecciona un archivo');

if archivo ~= 0
    % CONSTRUCCION DE LA RUTA DEL ARCHIVO
    app.img_bmp = fullfile(ruta, archivo);
    info_img = imfinfo(app.img_bmp);
    name_img = info_img.FileName;

    % Extraer el nombre y la extensión del archivo
    [~, nombre_sin_extension, ~] = fileparts(name_img);
    app.nombre = [nombre_sin_extension, '.jpg'];
    bmp = imread(app.img_bmp);

    % Guarda la imagen como JPEG
    imwrite(bmp, app.nombre, 'jpg', 'Quality', 90);

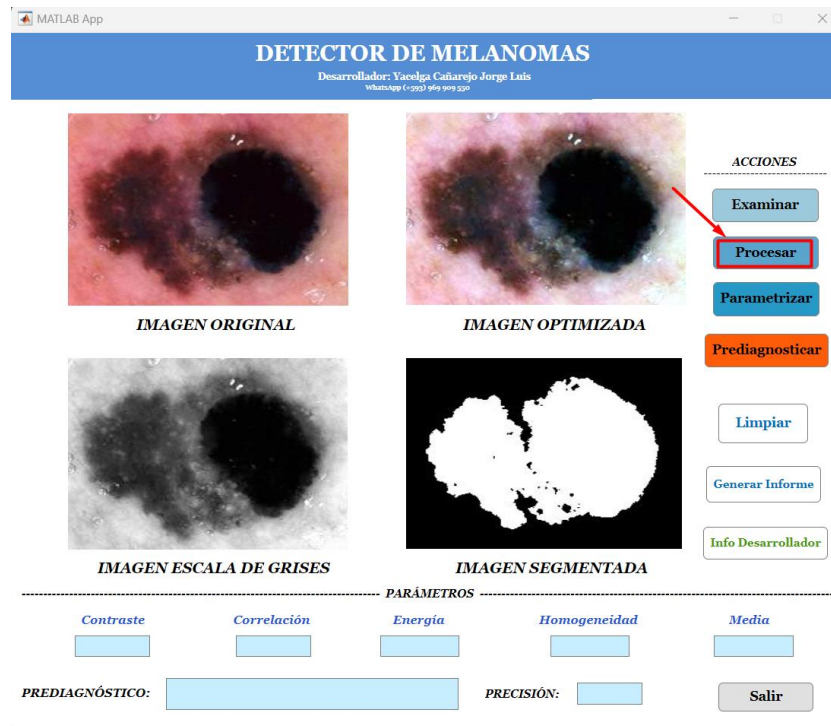
    % VISUALIZA LA IMAGEN SELECCIONADA
    app.ImageOriginal.ImageSource = app.nombre;
else
    % MUESTRA MENSAJE DE ERROR
    not = msgbox("IMAGEN NO SELECCIONADA", "Error", "error");
    uiwait(not);
end
```

Fuente: El Autor.

A continuación, se muestra el proceso que realiza el sistema al accionar el botón Procesar, existen cuatro cuadros de visualización en los que se indica la imagen original, imagen optimizada, imagen en escala de grises y la segmentación de la lesión detectada. El tiempo de inferencia del procesamiento de la imagen tarda varios segundos, dependiendo de las características del hardware del computador donde se encuentre ejecutando el sistema. En la Figura 60 se puede visualizar un ejemplo del procesamiento de la imagen considerando las funciones, algoritmos y técnicas de procesamiento de imágenes indicadas anteriormente.

Figura 60

Procesamiento de la imagen ingresada



Fuente: El Autor.

El código utilizado para el procesamiento de la imagen ingresada se realiza en base a las técnicas de procesamiento de las imágenes especificadas en la sección 3.7.2.2, en donde se contempla la optimización, filtros, clustering, detección de bordes, eliminación de objetos y dilatación. En la Figura 61 se muestra una porción del código en donde se lee la ruta de la imagen, se redimensiona, se obtiene la imagen en escala de grises, se ajusta los parámetros de la imagen y se inicia el proceso de segmentación.

Figura 61

Código del procesamiento de las imágenes ingresadas al sistema

```
% LEER LA RUTA DONDE SE ENCUENTRA LA IMAGEN
imagen = imread(app.nombre);

%% REDIMENSIONAMIENTO

% ESPECIFICA LAS DIMENSIONES
ancho = 224;
alto = 224;

% AJUSTA EL TAMAÑO DE LA IMAGEN
imagen = imresize(imagen, [alto, ancho]);

%% MEJORA Y ESCALA DE GRISES

% OBTIENE LOS LÍMITES DE INTENSIDAD PARA REALIZAR AUTOCONTRASTE
low_high = stretchlim(imagen);

% APLICACIÓN DEL AUTOCONTRASTE - OBTENCION DE IMAGEN OPTIMIZADA
imagen_optimizada = imadjust(imagen, low_high, []);

% CONVERSION A ESCALA DE GRISES
app.imagen_gris = rgb2gray(imagen_optimizada);

%% SEGMENTACION

% DECLARACION EN OTRA VARIABLE PARA EXPORTACIÓN
app.RGB = imagen;

% CONVERSION DE RGB A CIELAB
X = rgb2lab(app.RGB);
```

Fuente: El Autor.

El botón Parametrizar es una función implementada para extraer características y parámetros numéricos en cuanto a la estructura de la imagen, considerando aspectos como el nivel de contraste, correlación, energía, homogeneidad y media de las imágenes procesadas. En la Figura 62 se visualiza los valores de los parámetros mencionados para cada prediagnóstico realizado.

Figura 62

Obtención de los parámetros de la imagen ingresada

The screenshot displays a software interface for image processing. It features four image thumbnails: 'IMAGEN ORIGINAL' (a skin lesion), 'IMAGEN OPTIMIZADA' (the same lesion with enhanced contrast), 'IMAGEN ESCALA DE GRISES' (the optimized image in grayscale), and 'IMAGEN SEGMENTADA' (the grayscale image with the lesion highlighted in white). To the right is a control panel with buttons: 'Parametrizar' (highlighted in red), 'Prediagnosticar', 'Limpiar', 'Generar Informe', and 'Info Desarrollador'. Below the images is a table titled 'PARÁMETROS' with the following data:

Contraste	Correlación	Energía	Homogeneidad	Media
84.7364	0.99363	0.0025347	0.33746	99.6469

Fuente: El Autor.

Para la obtención de los parámetros indicados se calcula la matriz de co-ocurrencia con la finalidad de analizar las texturas para poder obtener la relación espacial entre los píxeles de una imagen, con ello se calcula los valores medios para cada uno de los parámetros mencionados. En la Figura 63 se muestra el código utilizado para el cálculo de la matriz de co-ocurrencia y los valores de las propiedades texturales.

Figura 63

Código para el cálculo de los parámetros de textura de las imágenes

```
% DEFINICION DE PARAMETROS PARA LA MATRIZ DE CO-OCURRENCIA
distancia = 1; % Distancia entre los píxeles para calcular la matriz
num_niveles_gris = 256; % Número de niveles de gris

% CALCULAR LA MATRIZ DE CO-OCURRENCIA
glcm = graycomatrix(app.imagen_gris, 'NumLevels', num_niveles_gris, 'Offset', [0 distancia; ...
-distancia distancia; -distancia 0; -distancia -distancia], 'Symmetric', true);

% CALCULO DE CARACTERISTICAS DE TEXTURA
contraste = graycoprops(glcm, 'Contrast');
correlacion = graycoprops(glcm, 'Correlation');
energia = graycoprops(glcm, 'Energy');
homogeneidad = graycoprops(glcm, 'Homogeneity');

% PROMEDIO DE CADA CARACTERISTICA EN BASE A LOS ANGULOS CONSIDERADOS
app.contraste_promedio = mean(contraste.Contrast);
app.correlacion_promedio = mean(correlacion.Correlation);
app.energia_promedio = mean(energia.Energy);
app.homogeneidad_promedio = mean(homogeneidad.Homogeneity);


% CALCULO DE LA MEDIA RGB
app.media_rgb = mean2(app.RGB);
```

Fuente: El Autor.

El botón Prediagnosticar al accionarlo inicia el proceso de clasificación de la muestra en base al conocimiento obtenido en la etapa de entrenamiento. Su función principal es identificar si la muestra pertenece a una lesión benigna o una lesión maligna (melanoma). El resultado se visualiza a través de los paneles de diagnóstico. En la Figura 64 se indica un ejemplo del prediagnóstico para una muestra con una lesión benigna.

Figura 64

Ejemplo de prediagnóstico benigno




Fuente: El Autor.

De la misma manera en la Figura 65 se indica un ejemplo en este caso para una muestra con una lesión maligna (melanoma).

Figura 65

Ejemplo de prediagnóstico maligno (melanoma)



Fuente: El Autor.

Este botón es el más importante del sistema de detección, en donde utiliza el siguiente código, mismo que hace uso del archivo Python donde se realiza el proceso de clasificación para exportar las variables con los resultados. En la Figura 66 se muestra un extracto del código utilizado en el botón Prediagnosticar, mismo que se encarga de ejecutar el script de Python y obtener el valor de la clasificación de la imagen de la red neuronal.

Figura 66

Código del prediagnóstico de las muestras ingresadas

```
% Seleccionar la imagen en MATLAB
image_path = app.nombre;
image_path = strrep(image_path, '\', '\\'); % Reemplaza las barras invertidas

% Obtener la ruta relativa del script de Python
python_script_path = 'C:\Program Files\UTN\Recursos\red1.py';

% Ejecutar el script de Python y capturar la salida
[status, cmdout] = system(['python "', python_script_path, '" ', image_path]);

% Convertir la salida (cmdout) en un valor numérico
predicted_class = str2double(cmdout);
```

Fuente: El Autor.

La valoración de los resultados de detección se encuentra detallada en el capítulo IV del TIC, en donde se indica las pruebas de campo realizadas, los niveles de precisión alcanzados y los tiempos de inferencia del sistema.

Además de ello cuenta con la opción para generar informes de los resultados obtenidos; sin embargo, una vez culminado el proceso de prediagnóstico existe una opción de salida, en donde automáticamente se muestra la información del desarrollador junto con el botón de cierre total de la aplicación. En la Figura 67 se muestra la ventana mencionada en donde se ve la información de contacto del desarrollador.

Figura 67

Ventana de información del desarrollador y salida



Fuente: El Autor.

En cuanto al botón Generar Informe, se encarga de tomar los datos del paciente ingresados inicialmente junto con los resultados del prediagnóstico realizado, el formato del informe se presenta como un archivo PDF y se muestra un extracto del código implementado en la Figura 68.

Figura 68

Código para la generación de informes

```
% VARIABLES GLOBALES DE VENTANA INFORMACION
global cedula_user;
global nombre_user;
global apellido_user;
global edad_user;
global sexo_user;
global enfermedad_user;
global tipo_enfermedad_user;

% DOCUMENTO FORMATO
nombre_archivo = 'C:\Program Files\UTN\Recursos\documento_formato.docx';

% Verifica si el archivo existe
if exist(nombre_archivo, 'file') ~= 2
    error('El archivo formato no existe: %s', nombre_archivo);
end


% INICIO DE SERVIDOR WORD
try
    word = actxserver('Word.Application');
    word.Visible = false; % Ejecutar Word en modo invisible
catch
    error('No se puede iniciar el servidor de Word. Verifique la instalación de Word.');
```

Fuente: El Autor.

Además, el botón Info Desarrollador muestra los tiempos de inferencia que le ha llevado ejecutarse cada una de las acciones del sistema en el computador. Tales valores sirven de información para el desarrollador, con el propósito de mejorar el código y optimizar el funcionamiento de detección. En la Figura 69 se muestra la información que despliega al ejecutar el botón mencionado.

Figura 69

Información del desarrollador



Fuente: El Autor.

Después de haber explicado cada uno de los botones de acción de la ventana de prediagnósticos de muestras, considerando el menú inicial de opciones indicado anteriormente, existe la posibilidad de visualizar los informes realizados como se indica en la Figura 70 a través del botón Historial de Informes.

Figura 70

Ingreso al directorio con los informes realizados anteriormente

Nombre	Fecha de modificación	Tipo	Tamaño
Informe_1002003000	20/4/2024 19:14	Documento PDF	88 KB
Informe_1720444353	10/4/2024 19:14	Documento PDF	88 KB

Fuente: El Autor.


3.7.3.2 Obtención de informe de resultados

Considerando la generación de informes, en el entorno de prediagnóstico de muestras al accionar el botón Generar Informe, se inicializa un proceso en donde se

genera un archivo con extensión PDF, que cuenta con la información del paciente, la imagen de la lesión ingresada, los parámetros obtenidos anteriormente y el resultado del prediagnóstico junto con el nivel de precisión alcanzado por la red entrenada. En la Figura 71 se muestra un ejemplo de un informe generado en base a un prediagnóstico realizado a un usuario ficticio.

Figura 71

Ejemplo de un informe de resultados generado



Fuente: El Autor.

Es importante considerar que para la generación de informes el computador cuente con Microsoft Word en una versión 2016 o superior para la creación de los archivos y además de un visualizador de archivos PDF en el computador que esté ejecutando el sistema.

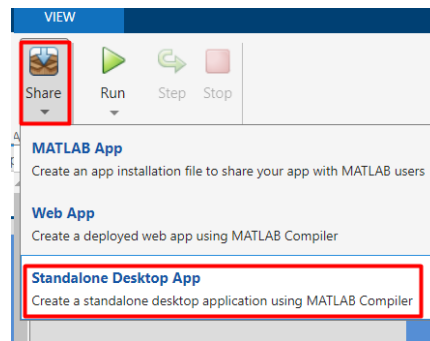
3.7.3.3 Compilación de aplicación de escritorio

Por último, es importante que el sistema pueda ser ejecutado en un computador donde no se cuente con una licencia de MATLAB, para ello se utiliza el compilador de

App Designer que permite crear aplicaciones de escritorio para poder ser instalado y ejecutado en otros computadores. En la Figura 72 se indica la herramienta que permite compilar aplicaciones de escritorio mencionada anteriormente.

Figura 72

Herramienta de compilación de aplicaciones de escritorio




Fuente: El Autor.

Se presenta el siguiente entorno en donde se especifica los archivos necesarios que deberán integrarse a la aplicación para que pueda ser ejecutada y además de ellos los parámetros de empaquetado de la aplicación. En la Figura 73 se visualiza el entorno gráfico para la compilación de la aplicación del sistema.

Figura 73

Entorno de compilación de aplicaciones

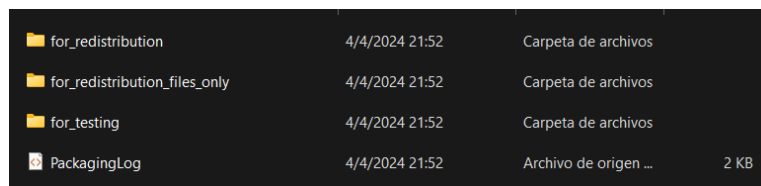


Fuente: El Autor.

Como resultado de la compilación se obtiene los siguientes directorios en donde for_redistribution cuenta con la aplicación para la instalación en computadores que no cuenten con licencia MATLAB. Es importante contar con acceso a Internet únicamente por primera vez para la instalación, ya que deberá descargar complementos para que pueda ser ejecutado como MATLAB Runtime que es gratuito. En la Figura 74 se puede ver los directorios que se genera de la compilación de la aplicación para su distribución.

Figura 74

Directorios de distribución de la aplicación



for_redistribution	4/4/2024 21:52	Carpeta de archivos	
for_redistribution_files_only	4/4/2024 21:52	Carpeta de archivos	
for_testing	4/4/2024 21:52	Carpeta de archivos	
PackagingLog	4/4/2024 21:52	Archivo de origen ...	2 KB

Fuente: El Autor.

En el capítulo siguiente se describe el plan de pruebas realizado en las personas de la asociación y adultos mayores, análisis de los resultados obtenidos en los prediagnósticos, la precisión y pérdida de entrenamiento alcanzadas en el modelo Data Efficient Image Transformer del sistema, los tiempos de inferencia del sistema, la evaluación de rendimiento al entrenar el modelo en infraestructura de diferentes prestaciones y un análisis de costo/beneficio de la implementación del sistema.

CAPÍTULO IV

PRUEBAS Y RESULTADOS

En este último capítulo se realiza las pruebas y validación del funcionamiento del sistema correspondiente a la fase de verificación del Modelo en Cascada utilizado para el desarrollo del TIC. Se encuentra compuesto por la evaluación de las dos redes neuronales entrenadas del sistema en distinta infraestructura computacional, las pruebas del sistema, los tiempos de inferencia para el procesamiento, parametrización y prediagnóstico, y el análisis costo-beneficio del desarrollo e implementación. Es importante considerar que para la etapa de validación de pruebas se ha considerado utilizar tanto las imágenes de la piel de las personas que conforman la asociación, las proporcionadas por el dataset de ISIC y otras adicionales en adultos mayores.

4.1 Evaluación del modelo de entrenamiento en distintas infraestructuras computacionales

En esta sección se procede a realizar la evaluación del entrenamiento del modelo DeiT (Data Efficient Image Transformer), el cual ha sido considerado como idóneo para las dos redes neuronales entrenadas, tomando en consideración el dataset utilizado para entrenamiento, validación y pruebas. Se procede a analizar los valores de precisión y pérdida obtenidos al entrenar en diferente infraestructura computacional. En la Tabla 26 se detalla las infraestructuras computacionales consideradas para ello.

Tabla 26

Infraestructura computacional para entrenamiento

Entorno	CPU	GPU	TPU	RAM	RAM	Almacenamiento
				GPU	Sistema	

Google Colab / A100	Intel Xeon	A100	No aplica	40 GB	83.5 GB	112.6 GB
Google Colab / L4	Intel Xeon	L4	No aplica	22.5 GB	53 GB	112.6 GB
Google Colab / TPUv2-8	Intel Xeon	No aplica	TPUv2 -8	No aplica	334.6 GB	225.3 GB

Fuente: El Autor.

Una vez especificado cada una de las infraestructuras a considerar en la evaluación del entrenamiento de las redes neuronales, se determina las configuraciones de entrenamiento, tiempos de entrenamiento, valores de precisión y pérdida obtenidos durante el proceso.

4.1.1 Entrenamiento en infraestructura computacional (Google Colab / A100)

En la infraestructura A100 de Google Colab, se ha considerado realizar entrenamientos con hasta 50 épocas debido a que al aumentar el número de épocas los valores de precisión y pérdida bajan, debido al incremento del sobreajuste que existe en los pesos del modelo de la red neuronal originales, correspondiente a la que utiliza el dataset sin previo procesamiento, en otras palabras las imágenes sin segmentar. En la Tabla 27 se detalla cada uno de los parámetros de entrenamiento considerados durante el entrenamiento de la red neuronal originales en este entorno de ejecución.

Tabla 27

Parámetros de entrenamiento en infraestructura (Google Colab / A100) – Red neuronal originales.

Configuración de entrenamientos – Red neuronal Originales			
Configuración	10 épocas	20 épocas	50 épocas

	Valor	Valor	Valor
Tamaño de la imagen	224x224	224x224	224x224
Solver	AdamW	AdamW	AdamW
InitialLearnRate	0.0001	0.0001	0.0001
ValidationFrecuenc y	Cada época	Cada época	Cada época
MaxEpochs	10	20	50
MiniBatchSize	256	256	256
ExecutionEnvirome nt	GPU	GPU	GPU
L2Regularization	0.0001	0.0001	0.0001
LearnRateSchedule	ReduceLROnPlate au	ReduceLROnPlate au	ReduceLROnPlate au
LossFunction	CrossEntropyLoss	CrossEntropyLoss	CrossEntropyLoss

Fuente: El Autor.

Por otro lado, en la Tabla 28 se muestra los parámetros considerados en cuanto a la red neuronal segmentadas, que corresponde a la que utiliza el dataset con las imágenes previamente procesadas, es decir segmentadas. Los criterios de entrenamiento varían debido a las características del dataset utilizado, configuración del entrenamiento y técnicas del aumento de datos.

Tabla 28

Parámetros de entrenamiento en infraestructura (Google Colab / A100) – Red neuronal segmentadas

Configuración de entrenamientos – Red neuronal Segmentadas

Configuración	10 épocas	20 épocas	50 épocas
	Valor	Valor	Valor
Tamaño de la imagen	224x224	224x224	224x224
Solver	AdamW	AdamW	AdamW
InitialLearnRate	0.0001	0.0001	0.0001
ValidationFrecuenc y	Cada época	Cada época	Cada época
MaxEpochs	10	20	50
MiniBatchSize	64	64	64
ExecutionEnvirome nt	GPU	GPU	GPU
L2Regularization	0.001	0.001	0.001
LearnRateSchedule	ReduceLROnPlate au	ReduceLROnPlate au	ReduceLROnPlate au
LossFunction	CrossEntropyLoss	CrossEntropyLoss	CrossEntropyLoss

Fuente: El Autor.

Una vez determinados los parámetros de entrenamiento utilizados para cada red neuronal, se obtiene los siguientes valores de precisión y pérdida de entrenamiento. Se determina que los valores de la red neuronal originales son superiores, debido a la versatilidad de la información del dataset utilizado, y en contra parte, el de la red neuronal segmentadas es menor debido al procesamiento previo del dataset, que de cierta manera influye en el aprendizaje del modelo. En la Tabla 29 se detalla cada uno de los valores asociados a cada entrenamiento realizado para ambas redes neuronales.

Tabla 29*Valores del entrenamiento en infraestructura A100*

Valores de entrenamiento A100			
Red Neuronal Originales			
N° Épocas	Precisión	Pérdida	Tiempo
10 épocas	85.75 %	0.4725	7 min
20 épocas	88.10 %	0.3585	16 min
50 épocas	87.60 %	0.5873	42 min
Red Neuronal Segmentadas			
N° Épocas	Precisión	Pérdida	Tiempo
10 épocas	75.95 %	0.5095	6 min
20 épocas	74.80 %	0.5201	13 min
50 épocas	74.70 %	0.5135	37 min

Fuente: El Autor.


De los valores obtenidos, se determina que para la red neuronal originales, el mejor entrenamiento corresponde al de 20 épocas en el cual se alcanza una precisión de validación de 88.10 % y una pérdida de validación de 0.3585 en un tiempo de 16 minutos; en cambio, para la red neuronal segmentadas es el entrenamiento que corresponde al de 10 épocas en donde se alcanza una precisión de validación de 75.95 % y una pérdida de validación de 0.5096 en un tiempo de 6 minutos. De lo cual se puede inferir que para la red neuronal originales, a partir de las 50 épocas el modelo ya no sigue aprendiendo por lo cual no es recomendable incrementar tal valor; por otro lado, en la red neuronal segmentadas se evidencia que a partir de las 20 épocas el modelo no aumenta el aprendizaje y por lo tanto no requiere de cantidad de épocas, sino realizar un aumento de

datos o mejorar las características del dataset, que sería en otras palabras una optimización en las estrategias de segmentación implementadas.

A continuación, se muestra las matrices de confusión obtenidas de los modelos entrenados con cada cantidad de épocas. Las matrices de confusión representan la cantidad de aciertos y errores de predicción que ha obtenido el modelo del resultado de su entrenamiento. En la Figura 75 se muestra las matrices de confusión obtenidas en el entrenamiento de la red neuronal originales, en donde la matriz de confusión con mejor relación acierto-error es la b con 1742 aciertos de 2000 posibles.

Figura 75

Matrices de confusión de red neuronal originales – A100




Fuente: El Autor.

En la Figura 76 en cambio se muestra las matrices de confusión obtenidas en el entrenamiento de la red neuronal segmentadas con el entorno A100, en donde se muestra que la matriz de confusión con mejor relación acierto-error es la a con 1490 aciertos de 2000 posibles.

Figura 76

Matrices de confusión de red neuronal segmentadas – A100



Fuente: El Autor.

En la siguiente sección, se presenta los parámetros de entrenamiento, valores de precisión y validación, y matrices de confusión obtenidos del entrenamiento con el entorno de ejecución de Google Colab L4, que en cuestión de prestaciones de infraestructura computacional es menor al de A100.

4.1.2 Entrenamiento en infraestructura computacional (Google Colab / L4)

En la infraestructura L4 de Google Colab, de igual manera al entorno anterior, se ha considerado realizar el entrenamiento del modelo hasta 50 épocas debido a los problemas de sobreajuste que existe para el caso de la red neuronal originales. En la Tabla 30 se muestra los parámetros considerados para el entrenamiento con distinta cantidad de épocas para la red neuronal originales en el entorno L4.

Tabla 30

Parámetros de entrenamiento en infraestructura (Google Colab / L4) – Red neuronal originales

Configuración de entrenamientos – Red neuronal Originales			
Configuración	10 épocas	20 épocas	50 épocas

	Valor	Valor	Valor
Tamaño de la imagen	224x224	224x224	224x224
Solver	AdamW	AdamW	AdamW
InitialLearnRate	0.0001	0.0001	0.0001
ValidationFrecuenc y	Cada época	Cada época	Cada época
MaxEpochs	10	20	50
MiniBatchSize	256	256	64
ExecutionEnvirome nt	GPU	GPU	GPU
L2Regularization	0.0001	0.0001	0.0001
LearnRateSchedule	ReduceLROnPlate au	ReduceLROnPlate au	ReduceLROnPlate au
LossFunction	CrossEntropyLoss	CrossEntropyLoss	CrossEntropyLoss

Fuente: El Autor.

En cambio, en la Tabla 31 se detalla los parámetros de entrenamiento de la red neuronal segmentadas que corresponde a la del dataset segmentado. Los valores difieren de la primera red debido a las características propias de las imágenes y de las técnicas utilizadas para el aumento de datos en este caso.

Tabla 31

Parámetros de entrenamiento en infraestructura (Google Colab / L4) – Red neuronal segmentadas

Configuración de entrenamientos – Red neuronal Segmentadas			
Configuración	10 épocas	20 épocas	50 épocas
	Valor	Valor	Valor

Tamaño de la imagen	224x224	224x224	224x224
Solver	AdamW	AdamW	AdamW
InitialLearnRate	0.0001	0.0001	0.0001
ValidationFrecuency	Cada época	Cada época	Cada época
MaxEpochs	10	20	50
MiniBatchSize	64	64	64
ExecutionEnvironment	GPU	GPU	GPU
L2Regularization	0.001	0.001	0.001
LearnRateSchedule	ReduceLROnPlateau	ReduceLROnPlateau	ReduceLROnPlateau
LossFunction	CrossEntropyLoss	CrossEntropyLoss	CrossEntropyLoss

Fuente: El Autor.

Luego de realizar el proceso de entrenamiento de cada una de las redes para diferente cantidad de épocas, se obtiene los siguientes valores de precisión de validación y pérdida de validación para el entorno L4 detallado en la Tabla 32. Para el caso de la red neuronal originales los valores alcanzados son superiores a los de la red neuronal segmentadas por los mismos motivos expuestos en el caso anterior.

Tabla 32

Valores del entrenamiento en infraestructura L4

Valores de entrenamiento L4
Red Neuronal Originales

N° Épocas	Precisión	Pérdida	Tiempo
10 épocas	86.00 %	0.4077	14 min
20 épocas	87.50 %	0.4700	26 min
50 épocas	87.85 %	0.5648	57 min

Red Neuronal Segmentadas			
N° Épocas	Precisión	Pérdida	Tiempo
10 épocas	75.45 %	0.5149	18 min
20 épocas	75.95 %	0.4957	25 min
50 épocas	74.45 %	0.5198	53 min


Fuente: El Autor.

De los valores obtenidos, se determina que para la red neuronal originales, la mejor opción de entrenamiento es la que corresponde a la de 20 épocas ya que la relación entre precisión y pérdida es mejor que las demás, en este caso tiene una precisión de validación de 87.50 % y una pérdida de validación de 0.4700; por otro lado, en el caso de la red neuronal segmentadas, la mejor opción de entrenamiento corresponde a la de 20 épocas de igual manera, teniendo una precisión de validación de 75.95 % y una pérdida de validación de 0.4957. Considerando esto, se infiere que a partir de las 20 épocas, los valores de precisión y pérdida no mejoran sustancialmente, sino más bien comienza a existir un sobreajuste en el entrenamiento, por ello aumenta el valor de pérdida que describe las predicciones erróneas durante la fase de validación del entrenamiento.

De igual manera se representa las matrices de confusión obtenidas del entrenamiento con cada una de las redes en diferente cantidad de épocas. En la Figura 77 se detalla los valores de las matrices de confusión obtenidas del entrenamiento de la red neuronal originales en el entorno L4, en donde la matriz de confusión b tiene la mejor relación con 1747 aciertos de 2000.

Figura 77

Matrices de confusión de red neuronal originales – L4




Fuente: El Autor.

En cambio, en la Figura 78 se detalla las matrices de confusión obtenidas del entrenamiento de la red neuronal segmentadas en el entorno L4, en donde la mejor es la matriz de confusión b con 1503 aciertos de 2000.

Figura 78

Matrices de confusión de red neuronal segmentadas – L4



Fuente: El Autor.

A continuación, se detallan los parámetros de entrenamiento, valores de precisión y validación, y matrices de confusión obtenidas durante del entrenamiento con el entorno

de Google Colab TPUv2-8, que en cuestión de prestaciones de infraestructura computacional es totalmente diferente a las anteriores, ya que utiliza otro tipo de unidad de procesamiento, en este caso tensoriales, lo cual conlleva una adaptación del modelo utilizado en PyTorch para TPU.

4.1.3 Entrenamiento en infraestructura computacional (Google Colab / TPUv2-8)

En la infraestructura TPUv2-8 de Google Colab , tal como en los entornos anteriores se ha entrenado hasta con 50 épocas por las consideraciones ya mencionadas. En la Tabla 33 se indica los parámetros de entrenamiento correspondientes a la red neuronal originales de las imágenes sin procesamiento previo para el entorno TPUv2-8.

Tabla 33

Parámetros de entrenamiento en infraestructura (Google Colab / TPUv2-8) – Red neuronal originales

Configuración de entrenamientos – Red neuronal Originales			
Configuración	10 épocas	20 épocas	50 épocas
	Valor	Valor	Valor
Tamaño de la imagen	224x224	224x224	224x224
Solver	AdamW	AdamW	AdamW
InitialLearnRate	0.0001	0.0001	0.0001
ValidationFrecuenc y	Cada época	Cada época	Cada época
MaxEpochs	10	20	50
MiniBatchSize	64	64	64
ExecutionEnvirome nt	TPU	TPU	TPU

L2Regularization	0.0001	0.0001	0.0001
LearnRateSchedule	ReduceLROnPlate au	ReduceLROnPlate au	ReduceLROnPlate au
LossFunction	CrossEntropyLoss	CrossEntropyLoss	CrossEntropyLoss

Fuente: El Autor.

En cuanto a la red neuronal segmentadas, por medio de la Tabla 34 se detalla los parámetros de entrenamiento utilizados, considerando que en esta red se utiliza el dataset que ha sido procesado.

Tabla 34

Parámetros de entrenamiento en infraestructura (Google Colab / TPUv2-8) – Red neuronal segmentadas

Configuración de entrenamientos – Red neuronal Segmentadas			
Configuración	10 épocas	20 épocas	50 épocas
	Valor	Valor	Valor
Tamaño de la imagen	224x224	224x224	224x224
Solver	AdamW	AdamW	AdamW
InitialLearnRate	0.0001	0.0001	0.0001
ValidationFrecuenc y	Cada época	Cada época	Cada época
MaxEpochs	10	20	50
MiniBatchSize	64	64	64
ExecutionEnvirome nt	TPU	TPU	TPU
L2Regularization	0.0001	0.0001	0.0001

LearnRateSchedule	ReduceLROnPlate	ReduceLROnPlate	ReduceLROnPlate
	au	au	au
LossFunction	CrossEntropyLoss	CrossEntropyLoss	CrossEntropyLoss

Fuente: El Autor.

Al considerar los parámetros de entrenamiento del entorno TPUv2-8, se procede a entrenar y los valores alcanzados de precisión de validación y pérdida de validación para ambas redes neuronales se encuentran detallados en la Tabla 35, en donde se evidencia de la misma manera una mejora en cuanto a la red neuronal originales con respecto a la red neuronal segmentadas.

Tabla 35

Valores del entrenamiento en infraestructura TPUv2-8

Valores de entrenamiento TPUv2-8			
Red Neuronal Originales			
N° Épocas	Precisión	Pérdida	Tiempo
10 épocas	86.80 %	0.4137	21 min
20 épocas	87.55 %	0.4589	43 min
50 épocas	87.40 %	0.6010	107 min
Red Neuronal Segmentadas			
N° Épocas	Precisión	Pérdida	Tiempo
10 épocas	75.55 %	0.5475	22 min
20 épocas	74.50 %	0.8071	44 min
50 épocas	75.20 %	0.4990	106 min


Fuente: El Autor.

Los valores obtenidos demuestran que para el caso de la red neuronal originales, la mejor opción de entrenamiento es la de 20 épocas que corresponde a una precisión de validación de 87.55 % y una pérdida de validación de 0.4589; en cambio, para la red neuronal segmentadas la opción más adecuada es la de 50 épocas donde tiene una precisión de validación de 75.20 % y una pérdida de validación de 0.4990. De esta manera, se determina que en el caso de la red neuronal originales, el aumento de épocas no favorece en el aprendizaje del modelo; por otro lado, la red neuronal segmentadas demuestra que el incremento de épocas aumenta ligeramente el aprendizaje, aunque con un máximo de 50 épocas es más que suficiente.

Al igual que con los entornos anteriores, se obtiene las matrices de confusión para cada uno de los entrenamientos de ambas redes neuronales, en donde se demuestra la relación entre predicciones correctas e incorrectas. En la Figura 79 se muestra las matrices de confusión de los entrenamientos de 10, 20 y 50 épocas para la red neuronal originales del entorno TPUv2-8, en donde la que corresponde a la de 20 épocas tiene la mejor relación acierto-error con 1758 aciertos de 2000 posibles.

Figura 79

Matrices de confusión de red neuronal originales – TPUv2-8




Fuente: El Autor.

Además, en la Figura 80 se indica las matrices de confusión obtenidas del entrenamiento de la red neuronal segmentadas para el entorno TPUv2-8, en donde la mejor opción es la c con 1509 aciertos de 2000.

Figura 80

Matrices de confusión de red neuronal segmentadas – TPUv2-8



Fuente: El Autor.

Los valores de precisión y pérdida obtenidos en los entrenamientos de cada red neuronal en las diferentes infraestructuras computacionales son analizados en la siguiente sección, en donde se selecciona el modelo más adecuado para la clasificación de imágenes en ambas redes neuronales.

4.1.4 Análisis el entrenamiento en diferente infraestructura

En esta sección se realiza un análisis de los mejores resultados alcanzados en el entrenamiento del modelo para cada red neuronal en distinta infraestructura computacional, con varias épocas y parámetros de entrenamiento. De ello, se determina el modelo a utilizar en el sistema, considerando la mejor precisión de validación y pérdida de validación alcanzada. Tales resultados se encuentran detallados de mejor manera en la Tabla 36.

Tabla 36*Resumen de valores de precisión y pérdida del entrenamiento*

Resumen de valores de precisión y pérdida de entrenamiento			
Red Neuronal Originales			
Tipo de infraestructura	Épocas	Precisión	Pérdida
A100	<u>20 épocas</u>	<u>88.10 %</u>	<u>0.3585</u>
L4	20 épocas	87.50 %	0.4700
TPUv2-8	20 épocas	87.55 %	0.4589
Red Neuronal Segmentadas			
Tipo de infraestructura	Épocas	Precisión	Pérdida
A100	10 épocas	75.95 %	0.5095
L4	<u>20 épocas</u>	<u>75.95 %</u>	<u>0.4957</u>
TPUv2-8	50 épocas	75.20 %	0.4990

Fuente: El Autor.

Considerando los valores indicados en la tabla, se determina que la mejor opción de infraestructura computacional para el entrenamiento de la red neuronal originales es A100, dado que en el entrenamiento durante 20 épocas alcanzó una precisión de validación de 88.10 % y una pérdida de validación de 0.3585, que corresponde al modelo de mayor rendimiento. Por otro lado, en cuanto a la red neuronal segmentadas, la mejor infraestructura computacional para el entrenamiento, considerando la relación entre precisión y pérdida es L4, ya que ha alcanzado una precisión de validación de 75.95 % y una pérdida de validación de 0.4957 en el entrenamiento durante 20 épocas. Es importante considerar que para ambos casos el mejor rendimiento alcanzado es durante las primeras

20 épocas, ya que si progresivamente se aumenta las épocas, el sobreajuste del modelo va incrementando y por ende el modelo tiende a confundir aspectos importantes de las imágenes durante el entrenamiento.

4.1.5 Tiempos de inferencia del sistema

En cuanto a los tiempos de inferencia del sistema, se ha considerado tres: tiempo para el procesamiento de la imagen, tiempo para la obtención de parámetros y tiempo para el prediagnóstico. Cada uno de estos valores depende en función de la imagen a procesar y del computador en donde se ejecuta. Tomando como referencia el computador HP Victus Gaming 15-FA1004LA donde se desarrolla el sistema, se tiene un promedio de tiempos de inferencia detallados en la Tabla 37.

Tabla 37

Tiempos de inferencia del sistema

Tiempos de inferencia		
Tipo	Cantidad	Tiempo en ms (Rango)
Procesamiento imagen		452 ms – 1079 ms
Parámetros imagen	100 pruebas	27 ms – 135 ms
Prediagnóstico imagen		5782 ms – 12595 ms

Fuente: El Autor.

De los valores obtenidos en las pruebas del sistema realizadas, se determina que tanto el procesamiento de la imagen como la obtención de los parámetros texturales son muy buenos, sin embargo, el tiempo de prediagnóstico tarda varios segundos y dependiendo de la infraestructura del computador donde se utilice el sistema tardará más o menos segundos el llevar a cabo el procesamiento.

4.2 Pruebas del sistema

En esta sección se procede a realizar las pruebas correspondientes al funcionamiento del sistema completo, considerando las pruebas de funcionamiento que corresponden a la explicación del proceso de inicio a fin en la toma de muestras y prediagnóstico, así como la instalación del sistema en el computador del usuario. Por otra parte, en la sección de pruebas de campo se realiza un conjunto de pruebas a una parte de la población de la asociación junto con muestras del dataset de ISIC, con la finalidad de obtener los resultados y establecer un umbral de confianza de los resultados que proporciona el sistema en funcionamiento.

4.2.1 Pruebas de funcionamiento del sistema

Para comenzar con las pruebas de funcionamiento, en primer lugar, se debe considerar la instalación del programa de detección alojado en un dispositivo de almacenamiento externo como USB, microSD, entre otros. Es importante que el computador donde se realice la instalación cuente con acceso a Internet, ya que al tratarse de ser una aplicación desarrollada en MATLAB, deberá descargar complementos para que pueda instalarse y posteriormente ser utilizado sin la necesidad de contar con acceso a Internet. Para este caso se ha utilizado un computador portátil con las siguientes características detalladas en la Tabla 38.

Tabla 38

Características del computador de la implementación

Característica	Descripción
Sistema Operativo	Windows 10 Home
Procesador (CPU)	Intel Core i7-8550U
Memoria RAM	12 GB

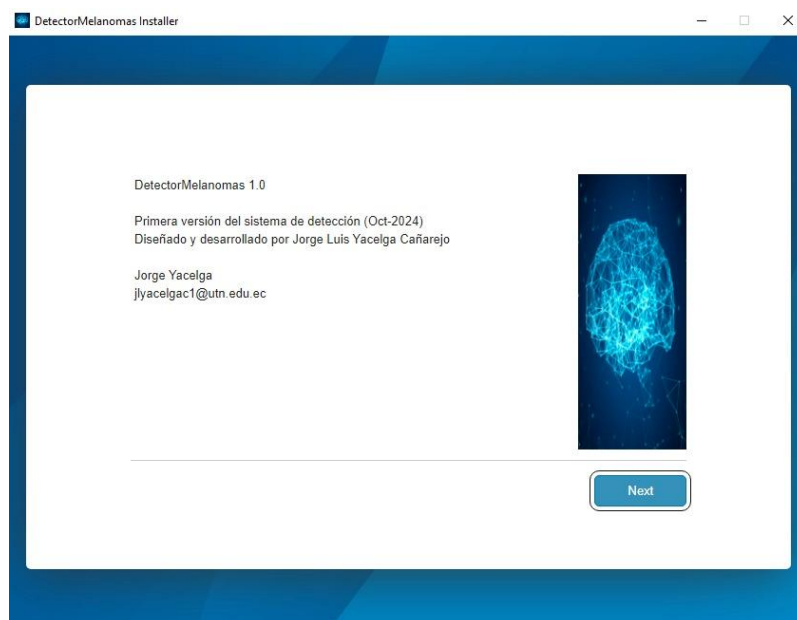
Almacenamiento	HDD 932 GB
Tarjeta Gráfica (GPU)	Integrada Intel

Fuente: El Autor.

Se procede con la instalación del programa siguiendo los pasos del asistente MyAppInstaller_web, la ventana que se mostrará al ejecutar el instalador es similar a la que se indica en la Figura 81.

Figura 81

Asistente de instalación del programa




Fuente: El Autor.

Una vez terminada la instalación, es importante que la carpeta Recursos se guarde en el directorio C:\Program Files\UTN, seguido de ello es esencial instalar Python 3.11.3, dado que requiere de dependencias para ejecutar el sistema. En la Figura 82 se indica el proceso de instalación de Python en la versión indicada.

Figura 82

Instalación de Python



Fuente: El Autor.

Una vez finalizada la instalación, se requiere abrir el terminal del computador e instalar las siguientes librerías: numpy, torch, torchvision, timm y pillow, ya que son esenciales para que se ejecuten los scripts de Python que realizan la clasificación. En la Figura 83 se muestra el comando a ingresar para la debida instalación.

Figura 83

Instalación de librerías

```
C:\Users\USER>pip install numpy torch torchvision timm pillow
```

Fuente: El Autor.

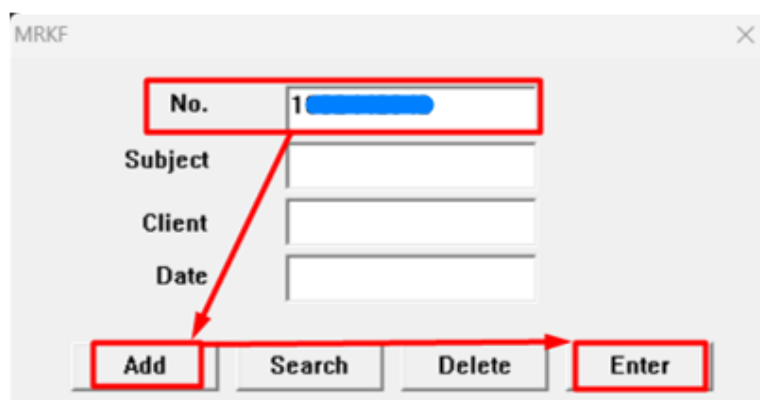
Una vez que se haya instalado todas las dependencias, para poder ejecutar el programa se debe realizar como administrador, ya que requiere de permisos para acceder a los recursos que se encuentran en la ruta C:\Program Files\UTN.

Luego de ello se continúa con la instalación del programa intermedio que va a permitir la captura de imágenes dermatoscópicas denominado MRKF, mismo que permite

guardar las imágenes tomadas a los pacientes. Únicamente se debe arrastrar la carpeta del programa al escritorio y ejecutar. En la Figura 84 se muestra la manera en la que se ejecuta el programa.

Figura 84

MRKF en ejecución



Fuente: El Autor.

Es importante que en el casillero No. se ingrese el número de cédula del paciente para que puedan alojarse dentro de una misma carpeta las imágenes correspondientes al paciente en proceso de prediagnóstico.

Seguidamente se enciende el dermatoscopio digital y se procede a configurar tal cual se muestra en la sección 3.7.1.3 del capítulo anterior. Se procede a tomar las muestras en imágenes de la piel de las personas como se indica en la Figura 85. Para ello fue necesario solicitar permiso a la asociación, para poder acceder a tomar pruebas a las personas que conforman la misma, permiso que se encuentra constatado en el Anexo B.

Figura 85

Toma de pruebas a las personas (1)




Nota. En la figura se presenta la toma de una prueba a una mujer de 63 años de edad en el antebrazo derecho, lugar donde se presenta un lunar. Fuente: El Autor.

Dentro del programa MRKF, la captura de la imagen se muestra de la siguiente manera, es importante considerar la carpeta en la que se encuentran alojadas las imágenes tomadas. En la Figura 86 se muestra el entorno de MRKF al tomar una muestra en una persona.

Figura 86

Entorno de toma de muestras con el dermatoscopio



Fuente: El Autor.

Se procede a ejecutar el programa principal instalado como administrador. En la Figura 87 se indica la manera en la que se debe realizar desde el escritorio de aplicaciones.

Figura 87

Ejecución del software de detección



Fuente: El Autor.

De inmediato se abre la siguiente ventana en la que se ingresa las credenciales del administrador del sistema. Seguido de ello se selecciona la opción Nuevo Prediagnóstico o en caso de ver los informes anteriores, la opción Historial de informes. En la Figura 88 se muestra la ventana de ingreso de credenciales del administrador del sistema.

Figura 88

Ingreso de credenciales de administrador

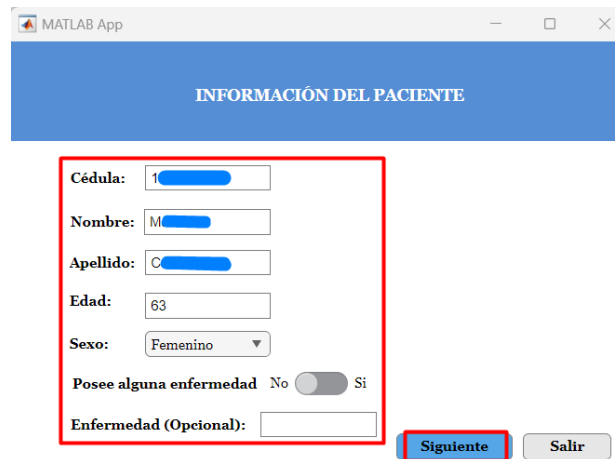


Fuente: El Autor.

Una vez tomada la imagen se procede a ingresar los datos del paciente, en este caso la señora M.C de 63 años de edad. El proceso de ingreso de datos se muestra en la Figura 89.

Figura 89

Ingreso de datos del paciente



The screenshot shows a MATLAB App window with the title 'MATLAB App' and a blue header bar containing the text 'INFORMACIÓN DEL PACIENTE'. Below the header is a form with the following fields:

- Cédula: 1
- Nombre: M
- Apellido: C
- Edad: 63
- Sexo: Femenino
- Posee alguna enfermedad: No (toggle switch is off)
- Enfermedad (Opcional):


At the bottom right of the form are two buttons: 'Siguiete' (highlighted with a red box) and 'Salir'.

Fuente: El Autor.

A continuación, se muestra la ventana donde se realiza el prediagnóstico de las pruebas, para ello se carga la imagen obtenida del dermatoscopio, se procede a procesar la imagen y obtención de los parámetros como se menciona en la sección 3.7.3 del capítulo anterior. En la Figura 90 se muestra el prediagnóstico de la prueba realizada en la mujer de 63 años de edad.

Figura 90

Ejemplo de un prediagnóstico de una muestra



Fuente: El Autor.

Una vez obtenido los resultados, se procede a obtener un informe en formato PDF con los resultados, datos del paciente e imagen de la prueba realizada para que puedan ser interpretados en caso de ser necesario por un especialista. Es importante considerar que este tipo de prediagnósticos no demuestran un resultado final de detección, ya que únicamente sirve como un diagnóstico previo y rápido que resulta ser útil para identificar anomalías en lesiones que aparezcan en la piel de manera repentina. Para la obtención del informe se debe dar click en el botón Generar Informe que se muestra en la figura anterior. En la Figura 91 se indica el informe obtenido de la prueba realizada a la mujer anteriormente.

Figura 91

Informe PDF del resultado de la prueba



REPORTE DE DIAGNÓSTICO
DESARROLLADO POR JORGE YACELGA
WhatsApp: +593 919 979 529

-----INFORMACIÓN DEL PACIENTE-----

Cédula: 1 [REDACTED]
Nombre: M [REDACTED]
Apellido: C [REDACTED]
Edad: 63 años
Sexo: Femenino
Alguna Enfermedad: No
Tipo de enfermedad:

-----PARÁMETROS-----

Contraste: 167.4799
Correlación: 0.97472
Energía: 0.000302
Homogeneidad: 0.24583
Media RGB: 140.9652

-----RESULTADO-----

Resultado: Melanoma no detectado
Precisión: 92.7234 %



Todos los derechos reservados © DetectMelanoma - JY 2024

Fuente: El Autor.

Con este informe culmina el proceso de la prueba de funcionamiento del sistema, es importante recalcar nuevamente que los resultados que se obtengan de este análisis para cuestiones médicas deberán ser analizados por un especialista, con la finalidad de corroborar el resultado y tomar acciones.

4.2.2 Pruebas de campo del sistema

En esta sección se procede a realizar las pruebas de campo del sistema, se refiere a la toma de muestras y realización de prediagnósticos en un entorno real, es decir en la asociación donde se desarrolla el TIC. Para ello ha sido necesario asistir de manera presencial al lugar donde desarrollan sus actividades las personas que conforman la asociación. A continuación, se procede a identificar la población en la cual se ha realizado las pruebas, la manera en la que está conformada, la metodología para la selección de muestras, la toma de muestras, el análisis de los resultados obtenidos, la validación de los resultados alcanzados durante el proceso y el umbral de confianza que tiene el sistema de detección.

4.2.2.1 Identificación de la población

El grupo de personas en donde se desarrollan las pruebas de campo es en la Asociación Agroturística Valle La Rinconada, ubicada en la parroquia de San Pablo del Lago, cantón Otavalo, provincia de Imbabura. Actualmente se encuentra conformada por 40 socios, de los cuales el Sr. Fausto Proaño es el representante legal de dicha asociación. Las actividades a las que se dedican las personas son la agricultura y turismo de la zona, en donde por la topografía del lugar, la recepción de radiación solar es directa durante todos los días del año. Se ha considerado dicho grupo de personas, debido a que la mayoría de sus integrantes son personas de edad avanzada y que cuentan con recursos económicos limitados. En la sección 1.3 del capítulo I, se detalla de mejor manera la justificación por la cual se ha considerado realizar en este grupo de personas. Para realizar la toma de muestras en las personas de la asociación, se ha llevado por medio de un permiso por parte del representante de la asociación, previamente informando a las

personas de la actividad a realizar, en el Anexo A se especifica los detalles del permiso concedido para el desarrollo de pruebas e implementación del sistema en la asociación.

4.2.2.2 Metodología de selección

La realización de pruebas a las personas de la asociación permite probar el funcionamiento del sistema en condiciones reales, dando como resultado prediagnósticos válidos y erróneos. Considerando que la población general es reducida, apenas de 40 personas, se establece la siguiente metodología de selección, considerando los siguientes criterios para definir la cantidad de pruebas a realizar:

- Tamaño de la población.
- Variabilidad de tonalidad de piel.
- Objetivo del sistema.

Dado que el objetivo del sistema es la detección de melanomas en imágenes dermatoscópicas tomadas a personas de la asociación y arrojar resultados lo más precisos posibles, es importante que se realice el mayor número de pruebas posibles dentro de la población. En adición a ello, considerando aspectos físicos como la variación que existe entre la tonalidad de piel entre personas, es un factor que afecta ligeramente al prediagnóstico de las muestras, por último al tratarse de un tema médico se sugiere realizar la mayor cantidad de pruebas reales; sin embargo, considerando el cuarto objetivo específico planteado en el presente TIC y la cantidad de personas disponibles para las pruebas reales, se añade un conjunto de 560 imágenes de manera aleatoria perteneciente al dataset destinado a pruebas (compuesto por 1000 imágenes), dando un total de 600 pruebas a prediagnosticar con el sistema en funcionamiento. Este valor es considerado en correspondencia al 97% de nivel de confianza y 3% de margen de error, que es un valor aceptable para la representación de los resultados del conjunto de datos. Con ello se logra

un análisis porcentual más acercado a la realidad de la precisión en la detección de lesiones en imágenes dermatoscópicas. En la Tabla 39 se detalla el conjunto de pruebas a realizar, compuesto por muestras reales en personas e imágenes pertenecientes al subconjunto de pruebas del dataset utilizado.

Tabla 39

Conjunto de pruebas de campo del sistema

Conjunto de pruebas de campo		
Tipo de muestra	Cantidad	Porcentaje
Muestras reales (En personas)	40 muestras	6.66 %
Muestras de prueba (Del dataset)	560 muestras	93.33 %
Total	600 muestras	100 %

Fuente: El Autor.

4.2.2.3 Toma de muestras

En esta sección se detalla las muestras tomadas a las personas de la asociación considerando la metodología de selección anterior. En la Figura 92 se evidencia la toma de muestras a las personas de la asociación realizada el 19 de mayo de 2024.

Figura 92

Toma de pruebas a las personas (2)



Nota. En la figura se puede visualizar la toma de una prueba en el antebrazo izquierdo de una mujer de 62 años de edad, donde se presenta una mancha de coloración marrón. Fuente: El Autor.

De igual manera en la Figura 93 se realiza la toma de una muestra a otra persona perteneciente a la asociación.

Figura 93

Toma de pruebas a las personas (3)



Nota. En la siguiente figura se puede visualizar la toma de una muestra a una mujer de 53 años de edad en la zona izquierda del cuello, donde se presenta un lunar. Fuente: El Autor.

En la Figura 94 se muestra la bienvenida por parte de los socios de la asociación hacia el desarrollador del TIC.

Figura 94

Bienvenida por parte de los socios hacia el desarrollador



Nota. En la siguiente figura se muestra la bienvenida por parte de las personas que conforman la asociación durante la mañana. Fuente: El Autor.

En la Figura 95 se muestra la conversación con el Sr. Fausto Proaño, representante legal de la Asociación Agroturística Valle La Rinconada, en donde se procede a dar las indicaciones iniciales previo a la toma de muestras en las personas que conforman la población a prediagnosticar.

Figura 95

Indicaciones iniciales con el representante de la asociación



Fuente: El Autor.

En la Tabla 40 se indica el resumen de las muestras tomadas a cada una de las personas e imágenes obtenidas del dataset, considerando la zona donde ha sido extraída la imagen y el sexo de la persona a la cual se realizó la prueba. En el Anexo D se especifica de mejor manera el mecanismo de tabulación de las muestras obtenidas.

Tabla 40

Resumen de las muestras

Zona de toma de muestra	Sexo de la persona	
	N° Hombres	N° Mujeres
Antebrazo izquierdo	-	2
Antebrazo derecho	-	1
Oreja izquierda	1	-
Cuello	2	2
Cachete izquierdo	3	-
Cachete derecho	2	1

Frente	-	2
Nuca	2	4
Barbilla	2	-
Hombro izquierdo	2	-
Hombro derecho	3	1
Tras la oreja izquierda	-	1
Tras la oreja derecha	1	2
Palma de la mano	1	1
Mano	2	1
Espalda	1	-
Total	22	18
Muestras del dataset (Pruebas)		
Sin especificar	560 muestras	

Fuente: El Autor

4.2.2.4 Análisis de los resultados

En esta sección se indica el resumen de los resultados obtenidos después de haber sido examinadas las muestras a través del sistema de detección. En la Tabla 41 se detalla la cantidad de resultados obtenidos. En el Anexo E se detalla de mejor manera los resultados obtenidos de las pruebas realizadas.

Tabla 41

Resultados de las pruebas de campo del sistema

Resultado Sistema	Resultado Especialista	Cantidad de muestras	Acierto
Posible melanoma	Posible melanoma	208	Si

No melanoma	No melanoma	320	Si
Posible melanoma	No melanoma	32	No
No melanoma	Posible melanoma	40	No
Total		600	

Fuente: El Autor

Luego de haber realizado las pruebas de cada una de las muestras, se tienen predicciones correctas y erróneas que son corroboradas con los diagnósticos dictados por un especialista, y en cuanto a las muestras de prueba se corroboran los resultados con el diagnóstico inicial dado en el dataset original. En la siguiente sección se procede con la validación de los resultados obtenidos en el sistema por un especialista que comprueba y respalda si los resultados y nivel de precisión son los adecuados para un prediagnóstico.

4.2.2.5 Validación de los resultados

En esta sección se detalla la validación de los resultados y precisión alcanzada en el prediagnóstico de muestras, en el cual se realiza una valoración muestra a muestra junto con el Dr. Harold Espín, en donde a través del Anexo C indica que el nivel de precisión en la detección a través del sistema es **ACEPTABLE**. En términos generales, se alcanza una precisión en la clasificación e identificación de melanomas del 88.10 % en el entrenamiento del sistema. Es decir que de cada 100 pruebas realizadas, aproximadamente 12 corresponden a falsas predicciones, por lo cual el sistema aún no se encuentra apto para funcionar como un diagnóstico final, sino como un prediagnóstico que sirve como una alerta temprana de sufrir algún tipo de lesión maligna para las personas que tengan sospecha de tener alguna anomalía en la piel.

4.2.2.6 Umbral de confianza

En base a la validación de los resultados por parte del especialista, en esta sección se procede a detallar el umbral de confianza de los resultados comparando los obtenidos por parte de las muestras reales y de igual manera las que corresponden al dataset. En primera instancia se procede a calcular el índice de fallas con la siguiente fórmula:

$$TF\% = \frac{\text{Número de fallas}}{\text{Número de prediagnósticos realizados}}$$

Fuente: Adaptado de (Jarrín, 2020).

Considerando la ecuación anterior se tiene lo siguiente:

$$TF\% = \frac{72}{600} = 12\%$$

El valor obtenido hace relación al nivel de precisión detallado anteriormente, por lo que 12 % corresponde a la cantidad de fallas de prediagnósticos en el sistema, en contraparte el 88 % de los prediagnósticos realizados concuerdan con los diagnósticos originales y los dictados por el especialista en cuanto a la veracidad de los resultados. En la Tabla 42 se detalla la precisión de los resultados alcanzados y con ello se determina el umbral de confianza de manera porcentual.

Tabla 42

Umbral de confianza de los resultados

Umbral de confianza					
Tipo de muestra	Cantidad total de muestras	Clasificación	Diagnóstico Real	Prediagnóstico Detectado	Umbral de Confianza %

Reales (Personas)	40	Posible	3	2	66.66 %
		melanoma			
		No	37	32	86.49 %
		melanoma			
Pruebas (Dataset)	560	Melanoma	246	214	87.00 %
		No	314	280	89.17 %
		melanoma			
Total:			600	528	88.00 %

Nota. En la siguiente tabla se describe la cantidad de diagnósticos reales y los detectados por el sistema para determinar el nivel de precisión de confiabilidad de los resultados. Fuente: El Autor.

A continuación, en la siguiente sección se realizan pruebas adicionales enfocadas a personas adultas mayores, en donde se contempla el caso específico de la aparición de manchas seniles. Tales manchas aparecen por la acumulación de exposición solar a lo largo de los años, lo que produce un aumento de melanina en áreas específicas, dando una coloración marrón, negro o gris.

4.2.3 Pruebas externas

Para las pruebas externas se ha considerado realizar a cuatro personas que superen los 70 años de edad, las cuales presentan manchas seniles en el rostro. En el Anexo F se muestra la evidencia de las pruebas realizadas a las personas mencionadas.

En la Tabla 43 se muestra los resultados obtenidos de los prediagnósticos realizados y el diagnóstico del médico asesor, para identificar la precisión en la detección de melanomas en manchas por consecuencia de la edad.

Tabla 43*Resultados de pruebas externas realizadas*

Pruebas externas				
N° prueba	Prediagnóstico	Precisión	Diagnóstico	Acierto
	detectado	prediagnóstico	Real	
1 - Mujer (78 años)	Posible melanoma	68.37%	No melanoma	No
2 – Mujer (92 años)	No melanoma	97.30%	No melanoma	Si
3 – Mujer (83 años)	Posible melanoma	64.05%	No melanoma	No
4 – Hombre (86 años)	Posible melanoma	81.89%	Posible melanoma	Si

Fuente: El Autor.

De los resultados indicados en la tabla, se obtiene 2 aciertos de 4. Sin embargo, los niveles de precisión no son los adecuados, por lo que en la prueba 1 y 3 se puede considerar como falsos positivos. Para mejorar la efectividad en la detección, se requiere de mayor cantidad de imágenes de entrenamiento, en la cual se incremente este tipo de manchas, para lograr tener una mejor generalización de aquellas lesiones que no correspondan a la clase maligna (melanoma).

4.3 Análisis Costo/Beneficio

En esta sección se detallan cada uno de los costos asociados al desarrollo e implementación del trabajo “DETECTOR DE MELANOMAS EN LA PIEL UTILIZANDO REDES NEURONALES PARA LAS PERSONAS DE LA ASOCIACIÓN AGROTURÍSTICA VALLE LA RINCONADA”, entre los cuales se

destacan costos de hardware, software, infraestructura y desarrollo. Los costos de hardware hacen referencia a los elementos físicos que son parte del sistema en funcionamiento. Por otro lado, los costos de software están relacionados a los programas, entornos de desarrollo, bases de datos y elementos intangibles que son parte del sistema y de su desarrollo. En cuanto a los costos de infraestructura, hacen referencia a los elementos de cómputo que permiten el diseño y desarrollo del sistema que han sido utilizados. Por último, los costos de desarrollo son la mano de obra e ingeniería desde el diseño hasta la implementación del sistema.

4.3.1 Costo general del sistema

Los costos del sistema se encuentran fundamentados en relación con el segundo objetivo específico del TIC. En la Tabla 44 se evidencia cada uno de los costos de hardware, software, infraestructura y desarrollo. Se considera tanto costos reales como actuales, ya que algunos de los elementos para el desarrollo e implementación se los poseía previamente al comienzo del desarrollo del trabajo.

Tabla 44

Descripción de los costos del sistema

Costos del sistema					
Hardware					
Componente	Cantidad	Costo	Costo	Subtotal	Subtotal
		Real	Actual	Real	Actual
		Unitario	Unitario	(USD)	(USD)
		(USD)	(USD)		
Dermatoscopio	1	\$ 180.00	\$ 180.00	\$ 180.00	\$ 180.00
TIANYUE M39					

Total (Hardware) (USD):			\$ 180.00	\$ 180.00
--------------------------------	--	--	-----------	-----------

Software

Software	Costo	Costo	Subtotal	Subtotal
	Real	Actual	Real	Actual
	Unitario	Unitario	(USD)	(USD)
	(USD)	(USD)		
MATLAB Student Suite	\$ 55.00	\$ 55.00	\$ 55.00	\$ 55.00
Deep Learning Toolbox	\$ 6.00	\$ 6.00	\$ 6.00	\$ 6.00
Dataset ISIC	\$ 0.00	\$ 0.00	\$ 0.00	\$ 0.00
MRKF Software	\$ 0.00	\$ 0.00	\$ 0.00	\$ 0.00
Cuenta Google Colab Pro	\$ 20.00	\$ 20.00	\$ 20.00	\$ 20.00
Total (Software) (USD):			\$ 81.00	\$ 81.00

Infraestructura

Componente	Cantidad	Costo	Costo	Subtotal	Subtotal
		Real	Actual	Real	Actual
		Unitario	Unitario	(USD)	(USD)
		(USD)	(USD)		
HP Victus PC	1	\$ 891.16	\$ 0.00	\$ 891.16	\$ 0.00
Gaming 15					
Total (Infraestructura) (USD):			\$ 891.16	\$ 0.00	

Desarrollo

Actividad	Cantidad	Costo Unitario (USD)	Subtotal (USD)
Diseño del sistema	30 horas	\$ 8.00	\$ 240.00

Entrenamiento del modelo	80 horas	\$ 2.50	\$ 200.00
Implementación del sistema	10 horas	\$ 16.00	\$ 160.00
Total (Desarrollo) (USD):			\$ 600.00

Fuente: El Autor.

Después de detallar cada uno de los costos asociados al diseño, desarrollo e implementación del sistema, en la Tabla 45 se especifica los costos totales de cada uno de los componentes, software y actividades considerando si se poseía antes del inicio del proyecto o no.

Tabla 45

Descripción del costo general del sistema

Costo general del sistema		
Tipo de costo	Valor Real (USD)	Valor Actual (USD)
Costo de hardware	\$ 180.00	\$ 180.00
Costo de software	\$ 81.00	\$ 81.00
Costo de infraestructura	\$ 891.16	\$ 0.00
Costo de desarrollo	\$ 600.00	\$ 600.00
Total (USD):	\$ 1752.16	\$ 861.00

Fuente: El Autor.

4.3.2 Cálculo del costo/beneficio

En esta sección se procede a calcular el costo/beneficio del sistema orientado a los siguientes criterios que permiten determinar si es viable o no:

- Si $C/B > 1$, el proyecto es viable.

- Si $C/B < 1$, el proyecto no es viable.

Tomando en consideración la siguiente fórmula se puede realizar el cálculo de la viabilidad del proyecto.

$$C/B = \frac{\text{Beneficios netos}}{\text{Costos}}$$

Considerando que los precios de una consulta de un dermatólogo promedio en el país se encuentran alrededor de 50\$ y que un examen de biopsia de la piel vale 150.00\$ en adelante; en promedio una consulta especializada tiene un valor de 200.00\$ (Provital, 2024). Para ello, se considera n al número de consultas por los cuales debe multiplicarse el valor de cada consulta especializada, considerando que para que el proyecto sea viable debe tener un valor mayor a 1, se describe lo siguiente:

$$1 < \frac{n * \text{Valor consulta}}{\text{Costos}}$$

$$1 < \frac{n * 200}{1752}$$

$$n > \frac{1752}{200}$$

$$n > 8.76 \text{ consultas}$$

$$n \approx 9 \text{ consultas}$$

Se determina que para satisfacer la inversión del proyecto es con aproximadamente 9 consultas, por lo que se procede a realizar el cálculo de la relación costo/beneficio.

$$C/B = \frac{9 * 200}{1752}$$

$$C/B = 1.03$$

Con este valor, se concluye que el sistema es **VIABLE**, ya que el valor es mayor a 1 como se determinó en los criterios, entonces es rentable realizar una inversión de este tipo para centros dermatológicos que realicen exámenes de manera frecuente, más no para uso personal, en donde no se satisfaga la cantidad de exámenes de biopsia.

CONCLUSIONES

En base a la fundamentación teórica y desarrollo del sistema, se determina que es importante darle el cuidado y protección a la piel de la exposición solar; dado que como se menciona en la base bibliográfica del trabajo, es una de las causas más graves de contraer cáncer de piel por enfermedades conocidas como melanoma.

El sistema de detección funciona como una herramienta de prediagnóstico de lesiones en la piel, que por medio del ingreso de imágenes dermatoscópicas al sistema, permite determinar si existe o no la presencia de melanomas. El tipo de inteligencia artificial utilizado son redes neuronales, ya que permiten aprender patrones característicos de los datos, en este caso imágenes. La integración de DeiT (Data Efficient Image Transformer) es un factor importante en el entrenamiento del modelo de clasificación, debido a que no requiere de grandes cantidades de imágenes y por lo tanto utilizar un dataset de acceso público como lo es ISIC es una buena opción para el entrenamiento del modelo.

Se ha determinado que a través del entrenamiento en diferentes infraestructuras computacionales, la mejor opción para llevar a cabo tareas de machine learning es utilizando GPUs dedicadas para ello, en este caso se ha utilizado la NVIDIA A100 proporcionada por Google Colab, la cual ha demostrado tener mejor rendimiento y flexibilidad a la hora de llevar a cabo entrenamientos de modelos de clasificación de imágenes como se ha realizado en este trabajo.

En cuanto a los resultados alcanzados del entrenamiento de la red neuronal, se ha llevado a cabo por medio de dos redes paralelas, la primera entrenada con el dataset original y la segunda con el dataset procesado para trabajar con la segmentación de las imágenes. En términos generales, el nivel de precisión alcanzado en la detección es del 88.10 % como se indica en los resultados del entrenamiento del capítulo final del TIC.

RECOMENDACIONES

Se sugiere investigar e implementar mejores técnicas de procesamiento de imágenes para lograr obtener una mejor segmentación de lesiones en las imágenes del dataset, ya que como se detalla en los resultados obtenidos, existe una diferencia notoria entre la precisión de validación de clasificación entre ambas redes neuronales entrenadas.

Por otro lado, para disminuir los valores de pérdida de validación del entrenamiento, se recomienda utilizar modelos pre entrenados más grandes y complejos, pero para ello se necesita de mayores recursos de infraestructura computacional, que en este caso requiere de una inversión económica superior a la que se utilizó en el desarrollo de este trabajo.

Es importante llevar a cabo múltiples pruebas de entrenamiento durante este proceso, ya que se debe ajustar el modelo a las necesidades propias del dataset utilizado para el entrenamiento, en este caso es la modificación de capas finales del modelo o reajustar parámetros de entrenamiento, así como utilizar diferentes técnicas para el aumento de datos.

Se recomienda realizar el entrenamiento en entornos de desarrollo que sean compatibles con Python, ya que para este tipo de tareas cuenta con mayor soporte y librerías de desarrollo, facilitando la adaptación de modelos para la clasificación de imágenes.

El acompañamiento con un especialista en el área es recomendable para certificar que los resultados obtenidos sean correctos a lo etiquetado en el dataset; sin embargo, constantemente aumentan nuevas imágenes en el repositorio de ISIC, y realizar entrenamientos del modelo con nuevos datos mejoraría su eficacia en la detección.

REFERENCIAS BIBLIOGRÁFICAS

- ACME. (2022). *Dermoscopio Dermlite DL200 HR*.
<https://www.libreriacienciaymedicina.com/aparatos-de-diagnostico/962-dermatoscopio-dermlite-ii-pro-hr.html>
- Aller, Á. (2024). *Memoria ROM, qué es y en qué dispositivos se encuentra*.
<https://www.pccomponentes.com/memoria-rom-que-es>
- Alvarado, A. (2021). *Se registra diagnóstico acumulado de cáncer de piel en Ecuador*.
EL COMERCIO. <https://www.elcomercio.com/tendencias/bienestar/diagnostico-acumulado-cancer-piel-ecuador.html>
- Amazon. (2023). *¿Qué es una GPU?* <https://aws.amazon.com/es/what-is/gpu/>
- Amazon Web Services. (2024a). *¿Qué es una red neuronal?*
<https://aws.amazon.com/es/what-is/neural-network/>
- Amazon Web Services. (2024b). *¿Qué son los transformadores en la inteligencia artificial?*
<https://aws.amazon.com/es/what-is/transformers-in-artificial-intelligence/#:~:text=Los%20transformadores%20son%20un%20tipo,color%20es%20el%20cielo%3F%E2%80%9D>.
- American Cancer Society. (2019). *¿Qué es el cáncer de piel tipo melanoma?*
<https://www.cancer.org/es/cancer/tipos/cancer-de-piel-tipo-melanoma/acerca/que-es-melanoma.html#:~:text=El%20melanoma%20es%20un%20tipo,comienzan%20a%20crecer%20sin%20control>.

- American Society of Clinical Oncology. (2019, enero). *Melanoma: Detección*.
<https://www.cancer.net/es/tipos-de-cancer/melanoma/deteccion#:~:text=Una%20t%C3%A9cnica%20m%C3%A9dica%20indolora%20que,lesiones%20en%20la%20piel%20pigmentada.>
- Aranda, T., García, E., Sánchez, F., & Suárez, S. (2015). *El algoritmo k-means aplicado a clasificación y procesamiento de imágenes*.
https://www.unioviado.es/compnum/laboratorios_py/new/kmeans.html
- Arcotel. (2022). *Agenda de Transformación Digital del Ecuador 2022-2025*.
<https://www.arcotel.gob.ec/wp-content/uploads/2022/08/Agenda-transformacion-digital-2022-2025.pdf>
- Ballesteros, N., Melena, J., & Narváez, A. (2023). PERFIL EPIDEMIOLÓGICO DEL CÁNCER DE PIEL EN ECUADOR. ESTUDIO OBSERVACIONAL DESCRIPTIVO. *Revista Médica Vozandes*, 35.
<https://doi.org/10.48018/rmv.v34.i1.3>
- Benavides, H. (2010). *INFORMACIÓN TÉCNICA SOBRE LA RADIACIÓN ULTRAVIOLETA, EL ÍNDICE UV Y SU PRONÓSTICO*.
<https://docplayer.es/18789152-Informacion-tecnica-sobre-la-radiacion-ultravioleta-el-indice-uv-y-su-pronostico.html>
- Benitez, R. (2014). *Inteligencia artificial avanzada*. Editorial UOC.
<https://elibro.net/es/lc/utnorte/titulos/57582>
- Boesch, G. (2023). *Vision Transformers (ViT) in Image Recognition – 2024 Guide*.
<https://viso.ai/deep-learning/vision-transformer-vit/>

- Catness. (2023). *Filtrado anisotrópico*. <https://catnessgames.com/es/wikigame/filtrado-anisotropico/>
- CDC. (2023, abril 18). *Cáncer de piel*. https://www.cdc.gov/spanish/cancer/skin/basic_info/what-is-skin-cancer.htm
- Cerón, D., & Ayon, A. (2020). Prevalencia de cáncer de piel en pacientes de 18 a 50 años en el Hospital Teodoro Maldonado Carbo durante el periodo 2014 - 2019. *Revista Oncología*. <https://doi.org/10.33821/474>
- Chururuchumbi, E. (2020). *Crisis en la producción agroalimentaria: perspectivas desde un territorio en Ecuador*. <https://blog.ica.int/blog/crisis-en-produccion-agroalimentaria-perspectivas-desde-un-territorio-en-ecuador>
- Clark, P. B. (2006). Futility of Fluorodeoxyglucose F 18 Positron Emission Tomography in Initial Evaluation of Patients With T2 to T4 Melanoma. *Archives of Surgery*, 141(3), 284. <https://doi.org/10.1001/archsurg.141.3.284>
- Cohen, R. (2010). *The Chan-Vese Algorithm*. <https://arxiv.org/ftp/arxiv/papers/1107/1107.2782.pdf>
- Datacolor. (2024). *¿Qué es el CIELAB?* <https://www.datacolor.com/es/business-solutions/blog/que-es-cielab/>
- De la Torre, J. (2023). *TRANSFORMADORES: FUNDAMENTOS TEÓRICOS Y APLICACIONES*. <https://arxiv.org/pdf/2302.09327>
- Diario La Hora. (2022). *Cáncer de piel, enemigo silencioso de los agricultores*. <https://www.lahora.com.ec/tungurahua/cancer-piel-enemigo-silencioso-agricultores/>

- Digital Talent Agency. (2022). Metodologías de gestión de proyectos. *Digital Talent Agency*.
- Durocher, L.-P. (2012). *Capítulo 12. Enfermedades de la piel. Enciclopedia de la OIT* (p. 24). D - INSHT (Instituto Nacional de Seguridad e Higiene en el Trabajo). <https://elibro.net/es/lc/utnorte/titulos/96224>
- Faizal, M. (2014). *Cancer de la piel*. Universidad Nacional de Colombia. <https://elibro.net/es/lc/utnorte/titulos/129787>
- Fonseca, D., & Sánchez, R. (2018). Cáncer de piel en pacientes un policlínico de Manzanillo. En 2016-2017. *MULTIMED* (p. 22 5). <https://revmultimed.sld.cu/index.php/mtm/article/view/999>
- Franco, K. (2017). *ANÁLISIS COMPARATIVO DE RADIACIÓN SOLAR VS ACTIVIDAD SOLAR EN QUITO Y SUS EFECTOS SOBRE LA SALUD EN EL PERIODO 2007-2016* [Universidad Central del Ecuador]. <https://dspace.ups.edu.ec/bitstream/123456789/13733/1/UPS%20-%20ST003010.pdf>
- Gallegos, J., Ortiz, A., Minauro, G., Arias, H., & Hernández, M. (2015). Dermatoscopia en melanoma cutáneo. *Cirugía y Cirujanos*, 83(2), 107-111. <https://doi.org/10.1016/j.circir.2015.04.004>
- Gómez, W. (2018). *Filtros espaciales suavizantes*. <https://www.tamps.cinvestav.mx/~wgomez/diapositivas/AID/Clase04.pdf>
- González, S. (2023). *Arquitectura X86-64: introducción al desarrollador*. <https://appmaster.io/es/blog/arquitectura-x86-64-manual-para-desarrolladores>

- Google Cloud. (2022). *Cloud Tensor Processing Unit (TPU)*.
<https://cloud.google.com/tpu/docs/tpus?hl=es-419>
- HP. (2024). *Laptop Gaming Victus 15-fa1005la (8U887LA)*. <https://www.hp.com/ec-es/products/laptops/product-details/product-specifications/2101940061>
- Ijaz, M. (2022, febrero 6). *DeiT — Training Data-Efficient Image Transformer & distillation through attention, Facebook AI -ICML'21*.
<https://medium.com/aiguys/deit-training-data-efficient-image-transformer-distillation-through-attention-facebook-ai-9b60aea3da07>
- IMED. (2013, julio 17). *Regla A-B-C-D-E para la prevención del cáncer de piel*.
<https://www.imedhospitales.com/es/actualidad/regla-a-b-c-d-e-para-la-prevencion-del-cancer-de-piel/>
- INAMHI. (2024). *Instituto Nacional de Meteorología e Hidrología*.
<https://www.inamhi.gob.ec/>
- INEC. (s. f.). *Encuesta de Superficie y Producción Agropecuaria Continua (ESPAC) 2021*.
https://www.ecuadorencifras.gob.ec/documentos/web-inec/Estadisticas_agropecuarias/espac/espac-2021/Metodolog%C3%ADa%20de%20la%20OE.pdf
- INEC. (2019). *Perfil epidemiológico*.
- ISIC. (2024a). *The International Skin Imaging Collaboration*. <https://www.isic-archive.com/>
- ISIC. (2024b). *The International Skin Imaging Collaboration*. <https://www.isic-archive.com/>

- Jarrín, J. (2020). *Sistema de detección del ángulo articular en los movimientos de miembro superior para evaluación en fisioterapia mediante visión artificial*. [Universidad Técnica del Norte].
<https://repositorio.utn.edu.ec/bitstream/123456789/10295/2/04%20RED%20245%20TRABAJO%20GRADO.pdf>
- Kóstiko, N. (2024). *¿Qué es una unidad de procesamiento de tensores (TPU)?*
<https://phoenixnap.mx/glosario/%C2%BFQu%C3%A9-es-una-unidad-de-procesamiento-tensorial%3F>
- Lema, C., & Zuleta, D. (2015). *Solmáforo (Semáforo Solar): modelo ambiental de alerta por exposición a la radiación solar en Quito* [Universidad Politécnica Salesiana].
<http://dspace.ups.edu.ec/handle/123456789/10091>
- López, J. (2024). *Seguro que sabes lo que es una tarjeta gráfica pero, ¿y una GPU?*
<https://hardzone.es/reportajes/que-es/gpu-caracteristicas-especificaciones/>
- Martínez, H. (2012). *Arquitectura de computadoras: basado en competencias para nivel superior*. <https://elibro.net/es/lc/utnorte/titulos/130397>
- MathWorks. (2023). *Deep Learning Toolbox*. <https://es.mathworks.com/products/deep-learning.html>
- Matich, D. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*.
https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograias/matich-redesneuronales.pdf
- MATLAB. (2023). *Function bwareaopen*.
<https://la.mathworks.com/help/images/ref/bwareaopen.html>

- MedlinePlus. (2022). *Melanoma*.
<https://medlineplus.gov/spanish/ency/article/000850.htm>
- Merino, M. (2009). *Prevención del cáncer de piel y consejo de protección solar*.
<https://previnfad.aepap.org/monografia/proteccion-solar>
- Merritt, R. (2022). *¿Qué es un Modelo Transformer?*
<https://la.blogs.nvidia.com/blog/que-es-un-modelo-transformer/>
- Meta. (2020, diciembre 23). *Data-efficient image Transformers: A promising new technique for image classification*. <https://ai.meta.com/blog/data-efficient-image-transformers-a-promising-new-technique-for-image-classification/>
- Moreles, S. (2019, junio 30). *Ciencias relacionadas con la Inteligencia Artificial*.
<https://saulmoreles.blogspot.com/2019/06/hay-varias-ciencias-relacionadas-con-la.html>
- MSP. (2017). *ESTRATEGIA NACIONAL PARA LA ATENCIÓN INTEGRAL DEL CÁNCER EN EL ECUADOR*.
https://aplicaciones.msp.gob.ec/salud/archivosdigitales/documentosDirecciones/dn n/archivos/ac_0059_2017.pdf
- ONU. (2023). *Objetivos de Desarrollo Sostenible*. Obtenido de.
<https://www.un.org/sustainabledevelopment/es/health/>
- Pathak, A. (2024, enero 2). *11 software de aprendizaje profundo en 2024*.
<https://geekflare.com/es/deep-learning-software/>
- Pérez, B. (2018). *Inteligencia artificial*.
https://www.foroconsultivo.org.mx/INCYTU/documentos/Completa/INCYTU_18-012.pdf

- Pérez, S., Facchini, H., & Argüello, D. (2014). *Arquitectura de Computadoras*.
<https://doi.org/10.13140/RG.2.1.3273.2640>
- Pérez, S., Morales, H., Argüello, D., Molina, S., & Pasero, A. (2018). *UNIDAD 3 MEMORIAS ELECTRÓNICAS*.
<http://www1.frm.utn.edu.ar/arquitectura/unidad3.pdf>
- Provital. (2024). *Provital - Servicio Integral de Salud*. <https://provital.ec/>
- Quiroga, P. (2010). *Arquitectura de computadoras*.
https://books.google.com.ec/books?id=LaFxEAAAQBAJ&printsec=frontcover&hl=es&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false
- Reeshabh, C. (2024). *Auge de las GPU y la arquitectura de las GPU*.
<https://www.linkedin.com/pulse/rise-gpus-gpu-architecture-reeshabh-choudhary-6jekf/>
- Reventós, V. (2019). *Qué es la inteligencia artificial*.
<https://openaccess.uoc.edu/bitstream/10609/148039/3/QueEsLaInteligenciaArtificial.pdf>
- Rodríguez, B. (2020). *SEGMENTACIÓN ESTÉREO MEDIANTE CONTORNOS ACTIVOS*.
<https://biblus.us.es/bibing/proyectos/abreproy/70265/fichero/Cap%C3%ADtulo+3.pdf>
- Rosendahl, C., Cameron, A., Tschandl, P., Bulinska, A., Gourhant, J.-Y., Keir, J., & Kittler, H. (2015). *CHAOS & CLUES*. <https://www.melnet.org.nz/uploads/4.-Chaos-Clues-March-8-2015-PDF-email.pdf>

- Sato, K., & Young, C. (2017). *An in-depth look at Google's first Tensor Processing Unit (TPU)*. <https://cloud.google.com/blog/products/ai-machine-learning/an-in-depth-look-at-googles-first-tensor-processing-unit-tpu>
- Schwartz, R., Vial, G., & Schwartz, R. (2011). Estrategias de detección precoz de melanoma cutáneo. *Revista Médica Clínica Las Condes*, 22(4), 466-475. [https://doi.org/10.1016/S0716-8640\(11\)70452-7](https://doi.org/10.1016/S0716-8640(11)70452-7)
- Secretaria Nacional de Planificación. (2021). *Plan de Creación de Oportunidades 2021 - 2025*. <https://www.planificacion.gob.ec/wp-content/uploads/2021/09/Plan-de-Creacio%CC%81n-de-Oportunidades-2021-2025-Aprobado.pdf>
- Shenzhen Miracle Technology. (2024a). *Chieomi*. <http://www.china-miracle.com/>
- Shenzhen Miracle Technology. (2024b). *Chieomi*. <http://www.china-miracle.com/>
- Singh, S. (2020). *¿Qué es la detección de bordes astutos?* <https://medium.com/simply-dev/what-is-canny-edge-detection-cfefa272a8d0>
- Soomro, M., Najafali, F., Kerrigan, A., & Malley, C. (2018). *A Review of "Training data-efficient image transformers & distillation through attention"*. https://www.crcv.ucf.edu/wp-content/uploads/2018/11/deit_presentation.pdf
- Toolify. (2024). *Descubre las aplicaciones del Vision Transforme*. <https://www.toolify.ai/es/ai-news-es/descubre-las-aplicaciones-del-vision-transformer-570649>
- Touvron, H., Cord, M., Douze, M., Massa, F., Sablayrolles, A., & Jégou, H. (2020). *Training data-efficient image transformers & distillation through attention*.

- Tsang, S.-H. (2022, febrero 11). *Review: Data Efficient Image Transformer (DeiT)*.
<https://sh-tsang.medium.com/review-deit-data-efficient-image-transformer-b5b6ee5357d0>
- Walter, F. M., Prevost, A. T., Vasconcelos, J., Hall, P. N., Burrows, N. P., Morris, H. C., Kinmonth, A. L., & Emery, J. D. (2013). Using the 7-point checklist as a diagnostic aid for pigmented skin lesions in general practice: a diagnostic validation study. *British Journal of General Practice*, 63(610), e345-e353.
<https://doi.org/10.3399/bjgp13X667213>
- Weyers, W. (2018). Screening for malignant melanoma—a critical assessment in historical perspective. *Dermatology Practical & Conceptual*, 8(2), 89-103.
<https://doi.org/10.5826/dpc.0802a06>
- Yarasca, J. (2013). *Compresión de imágenes utilizando clustering bajo el enfoque de colonia de hormigas* [Universidad Nacional Mayor de San Marcos].
https://cybertesis.unmsm.edu.pe/bitstream/handle/20.500.12672/13888/Yarasca_Carranza_Juan_Eduardo_2013.pdf?sequence=2&isAllowed=y

ANEXOS

ANEXO A.- Aceptación de la Asociación Agroturística Valle La Rinconada



CARTA DE AUTORIZACIÓN

San Pablo del Lago, 27 de noviembre de 2023

Por medio de la presente, la Asociación Agroturística Valle La Rinconada representada por el Sr. Fausto Proaño Araguillín, acepta la solicitud del Sr. Yacelga Cañarejo Jorge Luis con C.I 1720444353, estudiante de la Carrera de Telecomunicaciones de la Universidad Técnica del Norte, para llevar a cabo su trabajo de titulación "DETECTOR DE MELANOMAS EN LA PIEL UTILIZANDO REDES NEURONALES PARA LAS PERSONAS DE LA ASOCIACIÓN AGROTURÍSTICA VALLE LA RINCONADA" dentro de la asociación.

La asociación reconoce la importancia de este trabajo, que consiste en la implementación y desarrollo de un sistema de detección de melanomas a través de imágenes utilizando estrategias de inteligencia artificial, y con ello se compromete a brindar el apoyo necesario durante la ejecución.


Agradecemos la iniciativa y estamos a disposición para colaborar en lo que sea necesario para el éxito del trabajo de titulación.

Cordialmente,



Representante Legal
Sr. Fausto Proaño Araguillín
C.I 1001765260

ANEXO B.- Permiso de toma de pruebas en la Asociación Agroturística Valle La Rinconada



PERMISO DE TOMA DE PRUEBAS

San Pablo del Lago, 19 de mayo de 2024

La Asociación Agroturística Valle La Rinconada representada por el Sr. Fausto Proaño Araguillín, concede el permiso al Sr. Yacelga Cañarejo Jorge Luis con C.I. 1720444353, estudiante de la Carrera de Telecomunicaciones de la Universidad Técnica del Norte, para la toma de pruebas (imágenes) en las personas que conforman la asociación, bajo el consentimiento de las mismas.

Estas imágenes serán utilizadas exclusivamente para la elaboración y desarrollo de su trabajo de titulación "DETECTOR DE MELANOMAS EN LA PIEL UTILIZANDO REDES NEURONALES PARA LAS PERSONAS DE LA ASOCIACIÓN AGROTURÍSTICA VALLE LA RINCONADA" cumpliendo con todos los lineamientos éticos establecidos por nuestra asociación.

Sin más, se extiende este permiso con la confianza de que las imágenes y resultados serán tratados con la debida confidencialidad y respeto a la privacidad de las personas involucradas.

Atentamente,



Representante Legal
Sr. Fausto Proaño Araguillín
C.I. 1001765260

ANEXO C.- Validación de los resultados con el médico asesor

CONSULTORIO MEDICO "LA DOLOROSA"
DR. HAROLD ESPIN ROMERO
MEDICINA INTERNA – PEDIATRIA – GINECOLOGIA – OBSTETRICIA
CIRUGIA GENERAL -HIDRATACION – FISIOTERAPIA RESPIRATORIA
San Pablo del Lago, Barrio Mariscal Sucre, calle Sucre y La Unión
Teléfono: 0982560016 Email: espinromero@gmail.com

CERTIFICADO

San Pablo, 18 de septiembre de 2024

A quien corresponda

Certifico que el señor YACELGA CAÑAREJO JORGE LUIS, con cédula de identidad 1720444353, estudiante de la Carrera de Telecomunicaciones de la UNIVERSIDAD TÉCNICA DEL NORTE, realizó las pruebas de funcionamiento de su trabajo de titulación "DETECTOR DE MELANOMAS EN LA PIEL UTILIZANDO REDES NEURONALES PARA LAS PERSONAS DE LA ASOCIACIÓN AGROTURÍSTICA VALLE LA RINCONADA" el domingo 19 de mayo de 2024, y posteriormente, bajo mi supervisión, se llevaron a cabo los prediagnósticos de las pruebas realizadas, arrojando resultados ACEPTABLES en cuanto a la detección de melanomas en las imágenes dermatoscópicas obtenidas y del dataset de pruebas.

Es todo cuanto puedo certificar, para los fines que el interesado estime pertinentes.

Cordialmente,


Dr. Harold Espin Romero
C.I: 1002356499






CONSULTORIO MEDICO
"LA DOLOROSA"
DR. HAROLD ESPIN ROMERO
C.I. 1002356499








ANEXO D.- Muestras tomadas en las personas de la asociación y pertenecientes al dataset (pruebas)

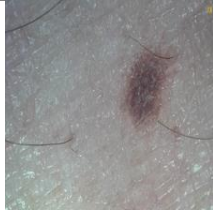






En la Tabla 46 se muestra 100 muestras de 600 obtenidas, debido a que colocar cada una extendería demasiado el documento, pero en términos generales se presenta la manera en la que se tabula cada una de ellas.








Tabla 46






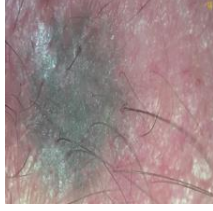

Tabulación de 100 muestras


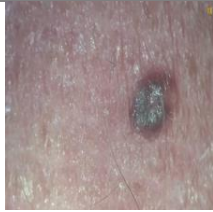





Toma de muestras			
N°.	Tipo de muestra	Zona de análisis	Imagen
1	Mujer (48 años)	Antebrazo Izquierdo	
2	Hombre (53 años)	Oreja izquierda	
3	Mujer (46 años)	Cuello	
4	Mujer (56 años)	Cachete izquierdo	
5	Mujer (53 años)	Frente	

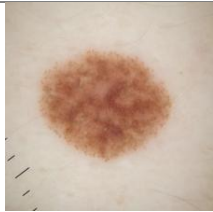
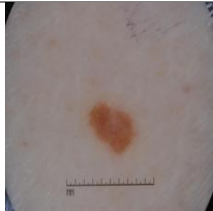
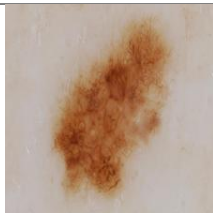

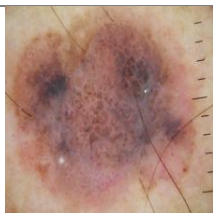


6	Mujer (49 años)	Antebrazo derecho	
7	Hombre (47 años)	Cuello	
8	Mujer (49 años)	Nuca	
9	Hombre (56 años)	Cachete derecho	
10	Hombre (52 años)	Nuca	
11	Hombre (58 años)	Barbilla	
12	Hombre (47 años)	Hombro derecho	

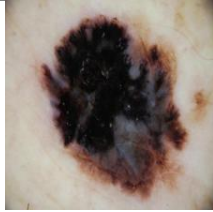


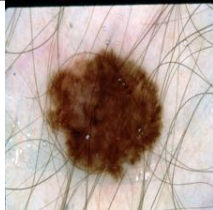



13	Mujer (46 años)	Nuca	
14	Mujer (60 años)	Cuello	
15	Mujer (47 años)	Nuca	
16	Hombre (44 años)	Hombro derecho	
17	Mujer (54 años)	Tras la oreja izquierda	
18	Mujer (46 años)	Palma de la mano izquierda	
19	Mujer (60 años)	Tras de la oreja derecha	






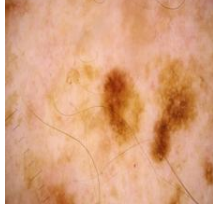

20	Hombre (58 años)	Cuello	
21	Hombre (54 años)	Mano derecha	
22	Hombre (45 años)	Hombro izquierdo	
23	Hombre (64 años)	Cachete derecho	
24	Hombre (60 años)	Cachete izquierdo	
25	Mujer (47 años)	Hombro derecho	
26	Hombre (59 años)	Cachete izquierdo	

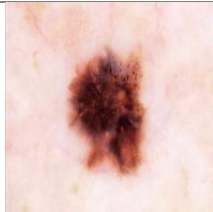






27	Hombre (56 años)	Barbilla	
28	Mujer (49 años)	Tras la oreja derecha	
29	Mujer (50 años)	Frente	
30	Hombre (52 años)	Nuca	
31	Hombre (45 años)	Espalda	
32	Mujer (62 años)	Nuca	
33	Hombre (55 años)	Hombro izquierdo	

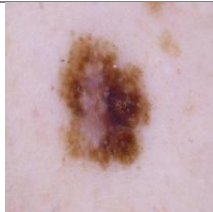
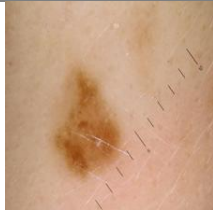


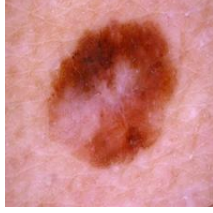
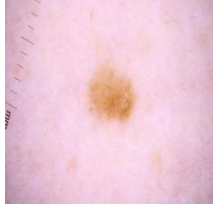
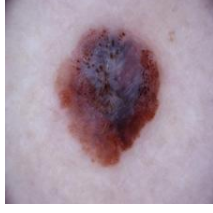
34	Hombre (49 años)	Palma de la mano izquierda	
35	Hombre (56 años)	Tras de la oreja derecha	
36	Hombre (46 años)	Mano derecha	
37	Mujer (44 años)	Brazo izquierdo	
38	Hombre (43 años)	Hombro derecho	
39	Mujer (46 años)	Cachete derecho	
40	Mujer (49 años)	Mano izquierda	



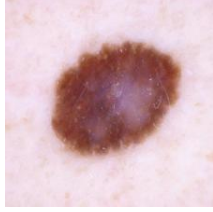
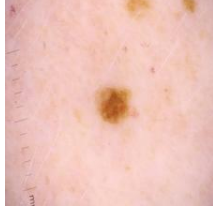
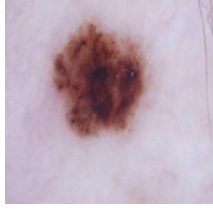

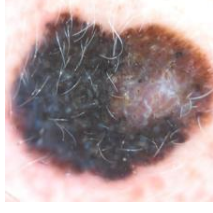
41	Dataset pruebas	Sin especificar	
42	Dataset pruebas	Sin especificar	
43	Dataset pruebas	Sin especificar	
44	Dataset pruebas	Sin especificar	
45	Dataset pruebas	Sin especificar	
46	Dataset pruebas	Sin especificar	
47	Dataset pruebas	Sin especificar	



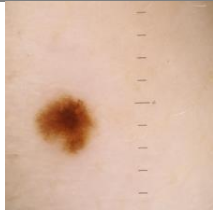


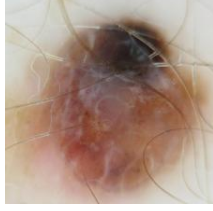

48	Dataset pruebas	Sin especificar	
49	Dataset pruebas	Sin especificar	
50	Dataset pruebas	Sin especificar	
51	Dataset pruebas	Sin especificar	
52	Dataset pruebas	Sin especificar	
53	Dataset pruebas	Sin especificar	
54	Dataset pruebas	Sin especificar	



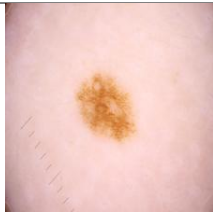


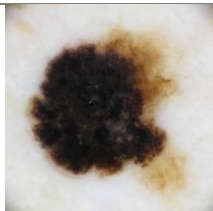

55	Dataset pruebas	Sin especificar	
56	Dataset pruebas	Sin especificar	
57	Dataset pruebas	Sin especificar	
58	Dataset pruebas	Sin especificar	
59	Dataset pruebas	Sin especificar	
60	Dataset pruebas	Sin especificar	
61	Dataset pruebas	Sin especificar	





62	Dataset pruebas	Sin especificar	
63	Dataset pruebas	Sin especificar	
64	Dataset pruebas	Sin especificar	
65	Dataset pruebas	Sin especificar	
66	Dataset pruebas	Sin especificar	
67	Dataset pruebas	Sin especificar	
68	Dataset pruebas	Sin especificar	

69	Dataset pruebas	Sin especificar	
70	Dataset pruebas	Sin especificar	
71	Dataset pruebas	Sin especificar	
72	Dataset pruebas	Sin especificar	
73	Dataset pruebas	Sin especificar	
74	Dataset pruebas	Sin especificar	
75	Dataset pruebas	Sin especificar	

76	Dataset pruebas	Sin especificar	
77	Dataset pruebas	Sin especificar	
78	Dataset pruebas	Sin especificar	
79	Dataset pruebas	Sin especificar	
80	Dataset pruebas	Sin especificar	
81	Dataset pruebas	Sin especificar	
82	Dataset pruebas	Sin especificar	

83	Dataset pruebas	Sin especificar	
84	Dataset pruebas	Sin especificar	
85	Dataset pruebas	Sin especificar	
86	Dataset pruebas	Sin especificar	
87	Dataset pruebas	Sin especificar	
88	Dataset pruebas	Sin especificar	
89	Dataset pruebas	Sin especificar	

90	Dataset pruebas	Sin especificar	
91	Dataset pruebas	Sin especificar	
92	Dataset pruebas	Sin especificar	
93	Dataset pruebas	Sin especificar	
94	Dataset pruebas	Sin especificar	
95	Dataset pruebas	Sin especificar	
96	Dataset pruebas	Sin especificar	

97	Dataset pruebas	Sin especificar	
98	Dataset pruebas	Sin especificar	
99	Dataset pruebas	Sin especificar	
100	Dataset pruebas	Sin especificar	

Nota. En la tabla se indica 100 muestras de las 600 tomadas en las personas de la asociación, al igual que las obtenidas del dataset de pruebas con el que se ha entrenado el modelo. Fuente: El Autor “de las imágenes de muestras reales” e (ISIC, 2024) “de las imágenes del dataset”.

ANEXO E.- Resultados de los prediagnósticos realizados.

En la Tabla 47 se muestra 100 resultados de las 600 pruebas realizadas, con la finalidad de indicar la manera en la que se han extraído cada uno de los resultados junto con el número de muestra y especificación del acierto o no.

Tabla 47

Resultados de 100 prediagnósticos

Resultados de muestras			
Muestras reales			
N°. Muestra	Resultado sistema	Diagnóstico especialista	Acierto
1	No melanoma	No melanoma	Si
2	Posible Melanoma	No melanoma	No
3	No melanoma	No melanoma	Si
4	No melanoma	No melanoma	Si
5	No melanoma	No melanoma	Si
6	No melanoma	No melanoma	Si
7	No melanoma	No melanoma	Si
8	Posible melanoma	No melanoma	No
9	Posible Melanoma	No melanoma	No
10	No melanoma	No melanoma	Si
11	No melanoma	No melanoma	Si
12	No melanoma	No melanoma	Si
13	No melanoma	No melanoma	Si
14	Posible Melanoma	No melanoma	No
15	No melanoma	No melanoma	Si

16	No melanoma	No melanoma	Si
17	No melanoma	No melanoma	Si
18	No melanoma	No melanoma	Si
19	No melanoma	No melanoma	Si
20	No melanoma	No melanoma	Si
21	No melanoma	No melanoma	Si
22	No melanoma	No melanoma	Si
23	Posible melanoma	No melanoma	No
24	No melanoma	Posible Melanoma	No
25	No melanoma	No melanoma	Si
26	Posible melanoma	Posible melanoma	Si
27	No melanoma	No melanoma	Si
28	No melanoma	No melanoma	Si
29	No melanoma	No melanoma	Si
30	No melanoma	No melanoma	Si
31	No melanoma	No melanoma	Si
32	Posible melanoma	Posible melanoma	Si
33	No melanoma	No melanoma	Si
34	No melanoma	No melanoma	Si
35	No melanoma	No melanoma	Si
36	No melanoma	No melanoma	Si
37	No melanoma	No melanoma	Si
38	No melanoma	No melanoma	Si
39	No melanoma	No melanoma	Si

40	No melanoma	No melanoma	Si
Muestras de prueba			
N°. Muestra	Resultado sistema	Diagnóstico	Acierto
41	No melanoma	No melanoma	Si
42	No melanoma	No melanoma	Si
43	Posible melanoma	Melanoma	Si
44	No melanoma	No melanoma	Si
45	Posible melanoma	Melanoma	Si
46	No melanoma	No melanoma	Si
47	Posible melanoma	Melanoma	Si
48	Posible melanoma	Melanoma	Si
49	No melanoma	No melanoma	Si
50	No melanoma	No melanoma	Si
51	Posible melanoma	Melanoma	Si
52	No melanoma	No melanoma	Si
53	No melanoma	Melanoma	No
54	No melanoma	Melanoma	No
55	No melanoma	No melanoma	Si
56	No melanoma	No melanoma	Si
57	Posible melanoma	No melanoma	No
58	No melanoma	No melanoma	Si
59	Posible melanoma	Melanoma	Si
60	No melanoma	No melanoma	Si
61	No melanoma	No melanoma	Si

62	Possible melanoma	Melanoma	Si
63	No melanoma	No melanoma	Si
64	No melanoma	Melanoma	No
65	No melanoma	No melanoma	Si
66	No melanoma	No melanoma	Si
67	No melanoma	No melanoma	Si
68	Possible melanoma	Melanoma	Si
69	Possible melanoma	Melanoma	Si
70	Possible melanoma	No melanoma	No
71	No melanoma	No melanoma	Si
72	No melanoma	No melanoma	Si
73	Possible melanoma	Melanoma	Si
74	No melanoma	No melanoma	Si
75	Possible melanoma	Melanoma	Si
76	No melanoma	No melanoma	Si
77	Possible melanoma	Melanoma	Si
78	Possible melanoma	Melanoma	Si
79	No melanoma	No melanoma	Si
80	Possible melanoma	Melanoma	Si
81	No melanoma	No melanoma	Si
82	Possible melanoma	Melanoma	Si
83	No melanoma	No melanoma	Si
84	Possible melanoma	Melanoma	Si
85	No melanoma	No melanoma	Si

86	No melanoma	No melanoma	Si
87	No melanoma	No melanoma	Si
88	Posible melanoma	Melanoma	Si
89	No melanoma	No melanoma	Si
90	No melanoma	No melanoma	Si
91	Posible melanoma	Melanoma	Si
92	No melanoma	No melanoma	Si
93	No melanoma	No melanoma	Si
94	No melanoma	No melanoma	Si
95	Posible melanoma	Melanoma	Si
96	Posible melanoma	Melanoma	Si
97	No melanoma	No melanoma	Si
98	No melanoma	Melanoma	No
99	No melanoma	No melanoma	Si
100	No melanoma	No melanoma	Si

Nota. En la siguiente tabla se identifica los aciertos y errores al prediagnosticar 100 muestras de 600 utilizadas en las pruebas de campo del sistema. Fuente: El Autor.

ANEXO F.- Evidencia de pruebas externas

Las pruebas externas han sido realizadas en personas adultas mayores de la parroquia San Pablo del Lago, cantón Otavalo, provincia de Imbabura el día 9 de noviembre del 2024. A continuación, se muestra la imagen de la toma de la muestra seguido del resultado obtenido en sistema.

Figura 96


Prueba 1 – Adulto mayor (Mujer 78 años)



Fuente: El Autor.

Figura 97

Resultado 1 – Adulto mayor (Mujer 78 años)



Fuente: El Autor.

Figura 98

Prueba 2 – Adulto mayor (Mujer 92 años)



Fuente: El Autor.

Figura 99

Resultado 2 – Adulto mayor (Mujer 92 años)

DETECTOR DE MELANOMAS
Desarrollador: Yacelga Cañarejo Jorge Luis
WhatsApp: (+593) 969 909 220

ACCIONES

- Examinar
- Procesar
- Parametrizar
- Prediagnosticar
- Limpiar
- Generar Informe
- Info Desarrollador

IMAGEN ORIGINAL **IMAGEN OPTIMIZADA**

IMAGEN ESCALA DE GRISES **IMAGEN SEGMENTADA**

PARÁMETROS

Contraste	Correlación	Energía	Homogeneidad	Media
701.6221	0.85395	0.00014374	0.15507	135.2158

PREDIAGNÓSTICO: Melanoma no detectado **PRECISIÓN:** 97.3084 Salir

Fuente: El Autor.

Figura 100

Prueba 3 – Adulto mayor (Mujer 83 años)



Fuente: El Autor.

Figura 101

Resultado 3 – Adulto mayor (Mujer 83 años)

DETECTOR DE MELANOMAS
Desarrollador: Yaelga Caiñarejo-Jorge Luis
WhatsApp: (+503) 969 909 300

ACCIONES

- Examinar
- Procesar
- Parametrizar
- Prediagnosticar
- Limpiar
- Generar Informe
- Info Desarrollador

IMAGEN ORIGINAL IMAGEN OPTIMIZADA

IMAGEN ESCALA DE GRISES IMAGEN SEGMENTADA

PARÁMETROS

Contraste	Correlación	Energía	Homogeneidad	Media
506.6905	0.91289	0.00012184	0.16112	151.1546

PREDIAGNÓSTICO: **Posible Melanoma** PRECISIÓN: 64.0595

Salir

Fuente: El Autor.

Figura 102

Prueba 4 – Adulto mayor (Hombre 86 años)



Fuente: El Autor.

Figura 103

Resultado 4 – Adulto mayor (Hombre 86 años)

DETECTOR DE MELANOMAS
Desarrollador: Yacelga Cañarejo Jorge Luis
WhatsApp: (+592) 969 909 220

ACCIONES

- Examinar
- Procesar
- Parametrizar
- Prediagnosticar**
- Limpiar
- Generar Informe
- Info Desarrollador

IMAGEN ORIGINAL **IMAGEN OPTIMIZADA**

IMAGEN ESCALA DE GRISES **IMAGEN SEGMENTADA**

PARÁMETROS

Contraste	Correlación	Energía	Homogeneidad	Media
470.6143	0.93813	0.00011044	0.17222	152.0745

PREDIAGNÓSTICO: **Posible Melanoma** **PRECISIÓN:** 81.8945

Salir

Fuente: El Autor.