



UNIVERSIDAD TÉCNICA DE MACHALA
FACULTAD DE INGENIERÍA CIVIL

MAESTRÍA EN SOFTWARE

DESARROLLO DE UNA APLICACIÓN WEB PARA DETECTAR CÁNCER DE PIEL
UTILIZANDO APRENDIZAJE PROFUNDO

FARÍAS RIVERA FÁTIMA KATIUSKA

PROPUESTA METODOLÓGICA Y TECNOLÓGICAS AVANZADAS

TUTOR(A) NANCY MAGALY LOJA MORA
COTUTOR RODRIGO FERNANDO MOROCHO ROMÁN

MACHALA
2025

PENSAMIENTO

"No podemos resolver problemas con el mismo nivel de pensamiento que los creó"

Albert Einstein

DEDICATORIA

Con mucho amor, esfuerzo y perseverancia quiero dedicar mi trabajo de titulación a mis queridos papás, a mis hermanos, y a mi Neva Luna.

Fátima Katuska Farías Rivera.

AGRADECIMIENTO

Agradezco a Dios por darme fuerzas, sabiduría y perseverancia para completar este trabajo. Sin su guía y bendiciones, este logro no habría sido posible.

A mis padres, quienes han sido mi pilar y fuente constante de apoyo y motivación. Gracias por creer en mí, por sus sacrificios y por enseñarme el valor del esfuerzo y la dedicación.

A mis hermanos, por estar siempre a mi lado, brindándome su amor, compañía y aliento incondicional. Su apoyo ha sido fundamental en cada paso de este camino.

A mi querida Neva Luna, mi bebé perruna, cuya presencia ha llenado mis días de alegría y ternura. Su compañía fue un bálsamo durante las largas jornadas de estudio y trabajo.

A mi tutora de tesis, por su paciencia, guía y valiosos consejos. Su dedicación y conocimientos fueron esenciales para la culminación de este proyecto. Gracias por creer en mi capacidad y por empujarme a dar lo mejor de mí.

A mis profesores, quienes han compartido su conocimiento y experiencia, guiándome en mi formación académica y profesional. Su pasión por la enseñanza ha sido una inspiración constante.

A mis amigos, por su comprensión, apoyo y por estar siempre presentes en los momentos de alegría y dificultad. Su amistad ha sido un regalo invaluable a lo largo de este proceso.

A todos ustedes, mi más sincero agradecimiento. Este logro es también suyo.

Fátima Katiуска Farías Rivera.

RESPONSABILIDAD DE AUTORÍA

Yo, Fátima Katuska Farías Rivera con C.I. 0706790102, declaro que el trabajo de “DESARROLLO DE UNA APLICACIÓN WEB PARA DETECTAR CÁNCER DE PIEL UTILIZANDO APRENDIZAJE PROFUNDO”, en opción al título de Magister en Software, es original y auténtico; cuyo contenido: conceptos, definiciones, datos empíricos, criterios, comentarios y resultados son de mi exclusiva responsabilidad.

FÁTIMA KATIUSKA FARÍAS RIVERA

0706790102


Machala, 2025/03/13

REPORTE DE SIMILITUD COMPILATIO



CERTIFICADO DE ANÁLISIS
magister

DOCUMENTO PARA PLAGIO SIN ANEXOS



Nombre del documento: DOCUMENTO PARA PLAGIO SIN ANEXOS.pdf
ID del documento: 00c94c56c6c28c96d9a34ffdf86fba4246aff5f0
Tamaño del documento original: 1,28 MB
Autores: []



Depositante: Nancy Magaly Loja Mora
Fecha de depósito: 17/1/2025
Tipo de carga: interface
fecha de fin de análisis: 17/1/2025

Número de palabras: 13.576
Número de caracteres: 92.383

Ubicación de las similitudes en el documento:



Fuentes con similitudes fortuitas

Nº	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	 ejournal.umm.ac.id https://ejournal.umm.ac.id/index.php/repositor/article/download/29358/13935	< 1%		 Palabras idénticas: < 1% (24 palabras)
2	 programmerclick.com DenseNet para documentos de detección de objetos basad... https://programmerclick.com/article/2838236019/	< 1%		 Palabras idénticas: < 1% (19 palabras)
3	 eprints.ucm.es https://eprints.ucm.es/id/eprint/66982/1/142755.pdf	< 1%		 Palabras idénticas: < 1% (16 palabras)
4	 dx.doi.org http://dx.doi.org/10.46994/ets_26	< 1%		 Palabras idénticas: < 1% (11 palabras)
5	 Documento de otro usuario #76a18 El documento proviene de otro grupo	< 1%		 Palabras idénticas: < 1% (12 palabras)

Fuente ignorada Estas fuentes han sido retiradas del cálculo del porcentaje de similitud por el propietario del documento.

Nº	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	 DOCUMENTO PARA PLAGIO SIN ANEXOS.pdf DOCUMENTO PARA PLAGIO ... #e1846e El documento proviene de mi biblioteca de referencias	100%		 Palabras idénticas: 100% (13.576 palabras)

Fuentes mencionadas (sin similitudes detectadas) Estas fuentes han sido citadas en el documento sin encontrar similitudes.

-  http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864
-  <http://www.revibiomedica.sld.cu/index.php/bi/article/>
-  <https://doi.org/10.1016/j.procs.2018.05.198>
-  <http://scielo.sld.cu/pdf/san/v23n1/1029-3019-san-23-01-146.pdf>

CERTIFICACIÓN DEL TUTOR

Yo, Nancy Magaly Loja Mora con C.I. 0703410027; tutor del trabajo de titulación “DESARROLLO DE UNA APLICACIÓN WEB PARA DETECTAR CÁNCER DE PIEL UTILIZANDO APRENDIZAJE PROFUNDO”, modalidad PROPUESTA METODOLÓGICA Y TECNOLÓGICAS AVANZADAS, en opción al título de Magister en Software, declaro que el trabajo ha sido revisado, y está enmarcado en los procedimientos científicos, técnicos, metodológicos y administrativos establecidos por la Dirección de Posgrado de la Universidad Técnica de Machala (UTMACH), razón por la cual doy fe de los méritos suficientes para que sea presentado a evaluación.

NANCY MAGALY LOJA MORA

C.I. 0703410027

Machala, 2025/03/13

CESIÓN DE DERECHOS DE AUTOR

Yo, Fátima Katiуска Farías Rivera con C.I. 0706790102, autor del trabajo de titulación “DESARROLLO DE UNA APLICACIÓN WEB PARA DETECTAR CÁNCER DE PIEL UTILIZANDO APRENDIZAJE PROFUNDO”, en opción al título de Magister en Software, declaro bajo juramento que:

- El trabajo aquí descrito es de mi autoría, que no ha sido presentado previamente para ningún grado o calificación profesional. En consecuencia, asumo la responsabilidad frente a cualquier reclamo o demanda por parte de terceros de manera exclusiva.
- Cede a la Universidad Técnica de Machala de forma exclusiva con referencia a la obra en formato digital los derechos de:
 - a. Incorporar la mencionada obra en el repositorio institucional para su demostración a nivel mundial, respetando lo establecido por la Licencia Creative Commons Attribution-NoCommercial – Compartir Igual 4.0 Internacional (CC BY NCSA 4.0); la Ley de Propiedad Intelectual del Estado Ecuatoriano y el Reglamento Institucional.
 - b. Adecuarla a cualquier formato o tecnología de uso en INTERNET, así como correspondiéndome como Autor la responsabilidad de velar por dichas adaptaciones con la finalidad de que no se desnaturalice el contenido o sentido de la misma.

FARÍAS RIVERA FÁTIMA KATIUSKA

C.I. 0706790102

Machala, 2025/03/13

RESUMEN

El desarrollo de tecnologías avanzadas en salud es una de las áreas más apasionantes y desafiantes del siglo XXI. La aplicación del aprendizaje profundo para el diagnóstico médico representa un avance significativo en la capacidad de los sistemas automatizados para asistir a los profesionales en la toma de decisiones críticas. Este trabajo aborda un problema de alta complejidad y tiene el potencial de salvar vidas al proporcionar una herramienta accesible y precisa para la detección temprana de cáncer de piel.

Se detalla el desarrollo e implementación de una aplicación web diseñada para detectar cáncer de piel, utilizando técnicas de aprendizaje profundo. La hipótesis planteada infiere que el uso de una red neuronal convolucional permitirá alcanzar al menos un 90% de precisión en el diagnóstico. Se implementaron redes neuronales convolucionales, específicamente ResNet, con un conjunto de datos de 25331 imágenes en total: 20265 para entrenamiento y 5066 para prueba.

La metodología CRISP-DM utilizada en este estudio incluye el preprocesamiento de datos utilizando TensorFlow y la evaluación del desempeño del modelo mediante métricas como precisión, sensibilidad y pérdida. Los resultados obtenidos revelaron una precisión del 94% y una sensibilidad del 87%, superando el umbral del 90% de precisión establecido en la hipótesis. El análisis de los resultados indica que la aplicación cumple con la hipótesis planteada y los resultados son comparables a estudios previos en el campo, como los realizados por Esteva et al. [1] y Haenssle et al. [2], quienes lograron precisiones del 72,1% y 74,2%, respectivamente.

En conclusión, este trabajo representa un paso importante hacia la integración de tecnologías avanzadas en la medicina, subrayando la capacidad del aprendizaje profundo para transformar la detección y el tratamiento del cáncer de piel. Se sugieren futuras investigaciones para mejorar la precisión, así como para explorar su aplicabilidad en otros tipos de cáncer.

Palabras Clave: Inteligencia Artificial, Cáncer de Piel, ResNet, Python, TensorFlow, Crisp-DM.

ABSTRACT

The development of advanced technologies in healthcare is one of the most exciting and challenging areas of the 21st century. The application of deep learning for medical diagnosis represents a significant advance in the ability of automated systems to assist professionals in making critical decisions. This work addresses a highly complex problem and has the potential to save lives by providing an accessible and accurate tool for the early detection of skin cancer.

The development and implementation of a web application designed to detect skin cancer, using deep learning techniques, is detailed. The hypothesis posed infers that the use of a convolutional neural network will allow at least 90% accuracy in diagnosis to be achieved. Convolutional neural networks, specifically ResNet, were implemented with a data set of 25,331 images in total: 20,265 for training and 5,066 for testing.

The CRISP-DM methodology used in this study includes data preprocessing using TensorFlow and evaluation of model performance using metrics such as accuracy, sensitivity, and loss. The results obtained revealed an accuracy of 94% and a sensitivity of 87%, exceeding the threshold of 90% accuracy established in the hypothesis. The analysis of the results indicates that the application complies with the hypothesis raised and the results are comparable to previous studies in the field, such as those carried out by Esteva et al. [1] and Haenssle et al. [2], who achieved accuracies of 72.1% and 74.2%, respectively.

In conclusion, this work represents an important step towards the integration of advanced technologies in medicine, underlining the capacity of deep learning to transform the detection and treatment of skin cancer. Future research is suggested to improve accuracy, as well as to explore its applicability in other types of cancer.

Keywords: Artificial Intelligence, Skin Cancer, ResNet, Python, TensorFlow, Crisp-DM.

ÍNDICE GENERAL

PENSAMIENTO	ii
DEDICATORIA.....	iii
AGRADECIMIENTO	iv
RESPONSABILIDAD DE AUTORÍA	v
REPORTE DE SIMILITUD COMPILATIO	vi
CERTIFICACIÓN DEL TUTOR.....	vii
CESIÓN DE DERECHOS DE AUTOR	viii
RESUMEN	ix
ABSTRACT	x
ÍNDICE GENERAL	xi
LISTA DE ILUSTRACIONES Y TABLAS.....	xiii
LISTA DE ABREVIATURAS Y SÍMBOLOS.....	xvi
INTRODUCCIÓN.....	1
CAPÍTULO I. MARCO TEÓRICO	5
1.1. Antecedentes Históricos.....	5
1.2. Antecedentes Conceptuales	9
1.3. Antecedentes Contextuales	18
CAPÍTULO II. MATERIALES Y MÉTODOS	24
2.1. Tipo de estudio.....	24
2.2. Paradigma o enfoque desde el cual se realizó.....	25
2.3. Población y muestra.....	26
2.4. Métodos teóricos con los materiales utilizados	26
2.5. Métodos empíricos con los materiales utilizados	28
2.6. Metodología CRISP-DM	28

2.7. Técnicas estadísticas para el procesamiento de los datos obtenidos.....	45
CAPÍTULO III. RESULTADOS	47
3.1. Fase 5. Evaluación.....	47
3.2. Resultados de la evaluación.....	48
3.3. Contrastación de Hipótesis	50
3.4. Fase 6. Implementación.....	52
CAPÍTULO IV	55
4.1. Discusión de resultados	55
CONCLUSIONES.....	62
RECOMENDACIONES	63
BIBLIOGRAFÍA	64
ANEXOS	71
Anexo 1. Construcción de los modelos de entrenamiento.....	71
Anexo 2. Estructura de la red neuronal	77
Anexo 3. Implementación.....	86
Anexo 4. Manual de Usuario: Sistema de Detección de Cáncer de Piel	87

LISTA DE ILUSTRACIONES Y TABLAS

LISTA DE ILUSTRACIONES

Ilustración 1: Línea de tiempo de la Historia de la detección de cáncer de piel	5
Ilustración 2: Mapa mental de los antecedentes conceptuales	9
Ilustración 3: Capa Convolución	12
Ilustración 4: Capa Aplanamiento	13
Ilustración 5: Ejemplo de una red ResNet	14
Ilustración 6: Arquitectura de la red VGG-16	15
Ilustración 7: Estructura de DenseNet	15
Ilustración 8: Fases de la Metodología CRISP DM	18
Ilustración 9: Lesiones de melanoma	21
Ilustración 10: Nevo melanocítico.....	21
Ilustración 11: Basall cell carcinoma.....	22
Ilustración 12: Queratosis actínica	22
Ilustración 13: Dermatofibroma	23
Ilustración 14: Carcinoma de células escamosas.....	23
Ilustración 15: Materiales y Métodos	24
Ilustración 16: Estructura del Dataset.....	31
Ilustración 17: Características del dataset	32
Ilustración 18: Selección de datos – Importaciones	33
Ilustración 19: Selección de datos - Etiquetas de archivos.....	33
Ilustración 20: Selección de datos - División de la data.....	34
Ilustración 21: Integración de datos.....	35
Ilustración 22: Formateo de datos - Aumento de data.....	35
Ilustración 23: Formateo de datos – Reescalado	36
Ilustración 24: Formateo de Datos – Preprocesamiento.....	36

Ilustración 25: Entrenamiento - Creación modelo resnet	37
Ilustración 26: Entrenamiento - capas modelo resnet.....	38
Ilustración 27: Entrenamiento - utilización de optimizado modelo resnet.....	38
Ilustración 28: Entrenamiento - Creación modelo vgg16.....	38
Ilustración 29: Entrenamiento - capas modelo vgg16	39
Ilustración 30: Entrenamiento - utilización de optimizado modelo vgg16	39
Ilustración 31: Entrenamiento - ejecución vgg16.....	40
Ilustración 32: Entrenamiento - Creación modelo densenet.....	40
Ilustración 33: Entrenamiento - capas modelo densenet	41
Ilustración 34: Entrenamiento - utilización de optimizado modelo densenet	41
Ilustración 35: Entrenamiento - ejecución densenet.....	41
Ilustración 36: Entrenamiento - ejecución resnet	42
Ilustración 37: Entrenamiento - Visualización de épocas resnet.....	43
Ilustración 38: Estructura parcial de la red neuronal	44
Ilustración 39: Matriz de Confusión.....	48
Ilustración 40: Pruebas de observación	49
Ilustración 41: Arquitectura del sistema para la detección de cáncer de piel.....	53
Ilustración 42: Implementación de la aplicación.....	54
Ilustración 43: Resultados en estadística de la red neuronal	55
Ilustración 44: Construcción del Modelo – Resnet	72
Ilustración 45: Construcción del Modelo – VGG.....	74
Ilustración 46: Construcción del Modelo – Densenet	76
Ilustración 47: Estructura completa de la red neuronal	85
Ilustración 48: Aplicación web (inicio).....	86
Ilustración 49: Aplicación web (detección).....	86

LISTA DE TABLAS

Tabla 1: Causas y Efectos del problema.....	19
Tabla 2: Stakeholders del proyecto	29
Tabla 3: Matriz de Confusión.....	47

LISTA DE ABREVIATURAS Y SÍMBOLOS

OMS: Organización Mundial de la Salud.

ADN: Ácido Desoxirribonucleico.

SLR: Systematic Literature Review.

DL: Deep Learning.

CNN: Convolutional Neural Network.

KNN: K-Nearest Neighbors.

DNN: Deep Neural Network.

ResNet: Residual Network.

VGG: Visual Geometry Group.

FMO: Fragment Molecular Orbital.

SSD: Single Shot MultiBox Detector.

R-CNN: Regions-based Convolutional Neural Networks.

R-FCN: Region-based Fully Convolutional Networks.

API: Application Programming Interface.

DenseNet: Densely Connected Convolutional Networks.

RGB: Red, Green, Blue (modelo de color).

PCA: Principal Component Analysis.

mAP: mean Average Precision.

INTRODUCCIÓN

Los informes de la Organización Mundial de la Salud (OMS) muestran que una de las principales causas de decesos a nivel mundial es el cáncer [3], y se prevé que el número de casos diagnosticados se duplique en las próximas dos décadas. El cáncer de piel afecta a millones de personas [4] debido a su capacidad de desarrollarse en cualquier tipo de piel, especialmente en aquellos individuos que están expuestos de manera frecuente o prolongada a la radiación ultravioleta. Se genera cuando hay un crecimiento anormal y descontrolado de las células de la piel. Este proceso puede ser desencadenado por varios factores, los cuales alteran el ADN de las células cutáneas. Durante las últimas tres décadas, se ha observado un aumento progresivo, diagnosticándose más de 132.000 casos en todo el mundo.

Las lesiones cutáneas se pueden agrupar en tipos melanocíticos y no melanocíticos. Las lesiones melanocíticas incluyen melanoma y nevos melanocíticos [5]. Del mismo modo, las lesiones no melanocíticas incluyen el carcinoma de células basales, la queratosis actínica (forma anticipada de carcinoma de células escamosas y también conocida como enfermedad de Bowen), dermatofibroma y lesión vascular. Tanto las lesiones melanocíticas como las no melanocíticas tienen tipos malignos y benignos [6].

Las lesiones cutáneas malignas son cancerosas e incluyen melanoma, carcinoma de células basales y queratosis actínica. La dermatoscopia es una técnica de imagen popular entre los dermatólogos, mejora la visualización de la superficie y estructura de las lesiones cutáneas para un examen más preciso. Sin embargo, esta técnica requiere de profesionales capacitados, ya que depende de la agudeza visual y experiencia del médico [3].

Detectar y tratar esta enfermedad en etapas tempranas puede reducir las tasas de mortalidad relacionadas, de manera que el diagnóstico en los pacientes debe ser preciso [7]. A pesar de los avances en la tecnología médica, la identificación del cáncer de piel sigue considerándose un desafío para los dermatólogos, lo que puede llevar a retrasos en el tratamiento y resultados subóptimos para los pacientes. Por lo tanto, los investigadores están enfocados en desarrollar estrategias de detección como una prioridad, generando la siguiente **problemática**: ¿Cómo puede el aprendizaje profundo ayudar a la detección de cáncer de piel a través de la aplicación web, superando los obstáculos actuales y garantizando resultados más precisos para los pacientes?

Se **justifica** que la detección a tiempo del cáncer de piel es crucial, dado que la identificación precoz de la enfermedad puede incrementar las oportunidades de recuperación. Estos desafíos han motivado a la comunidad investigadora a desarrollar nuevas técnicas de visualización y detección del cáncer de piel que puedan superar las limitaciones de la dermatoscopia y brindar opciones más efectivas y accesibles para la detección de esta enfermedad.

Aquí es donde el entrenamiento de un modelo automatizado basado en Aprendizaje Profundo para detectar cáncer de piel puede desempeñar un papel fundamental. Este aprendizaje es una rama de la inteligencia artificial que utiliza algoritmos de aprendizaje de máquina para analizar grandes conjuntos de datos y extraer características complejas. Mediante el uso de redes neuronales convolucionales, es posible analizar imágenes médicas con alta precisión, identificando patrones complejos que pueden pasar desapercibidos para el ojo humano [8]. Estudios recientes han evidenciado que estos modelos pueden superar a los métodos tradicionales en términos de exactitud diagnóstica, ofreciendo una alternativa prometedora para mejorar la detección y el tratamiento oportuno de esta enfermedad [9]. Al entrenar un modelo con una amplia variedad de imágenes de cáncer de piel, es posible enseñarle al sistema a reconocer patrones y características específicas asociadas con esta enfermedad.

La presente investigación busca cerrar estas brechas mediante el desarrollo de una aplicación web que integre un modelo de aprendizaje profundo optimizado para funcionar en dispositivos de uso común, sin requerir conocimientos avanzados por parte del usuario. Esta aplicación permitirá la detección automática de ocho tipos de cáncer de piel: Melanoma, Nevo melanocítico, Carcinoma de células basales, Queratosis actínica, Dermatofibroma, Carcinoma de células escamosas, Lesión vascular y Queratosis seborreica. Con esta propuesta, se espera no solo mejorar la precisión en la detección del cáncer de piel, sino también facilitar su adopción en la práctica médica y contribuir a diagnósticos más tempranos y accesibles.

Se establece como **hipótesis** que **la implementación de un modelo de aprendizaje profundo a través de la aplicación web permitirá el diagnóstico de tipos de cáncer de piel con al menos un 90% de precisión.**

En consecuencia, el **objetivo general** de esta investigación es **implementar un modelo de aprendizaje profundo para el diagnóstico de tipos de cáncer de piel a través de la aplicación web**, que pueda analizar imágenes dermatoscópicas, identificando características específicas asociadas con el cáncer de piel y proporcionar una evaluación precisa, a través de redes neuronales convolucionales. Para ello se desarrollaron los siguientes objetivos específicos:

- Identificar técnicas de tratamiento de imágenes, algoritmos, modelos y tipos de redes neuronales que ayuden al descubrimiento de cáncer de piel mediante búsqueda literaria.
- Evaluar el modelo de redes neuronales convolucionales y su uso para la detección de cáncer de piel, mediante pruebas de entrenamiento que verifiquen la precisión en los resultados.
- Diseñar una aplicación web que visualice los resultados a través del modelo entrenado.

Para el entrenamiento del modelo se utilizó un dataset de Kaggle con 25331 imágenes de tipos de cáncer de piel con base al estudio experimental, el cual permite establecer relaciones de causa y efecto, entre la variable independiente (aplicación web utilizando aprendizaje profundo) que se estudia sobre la variable dependiente (detección de cáncer de piel). Al igual que la metodología de investigación, en donde se emplearán métodos experimentales hasta lograr una precisión alta y una pérdida baja en el entrenamiento de la red neuronal. En cambio el enfoque de la investigación se lo realizará de forma cuantitativa, de manera que se podrán medir los resultados obtenidos en las pruebas experimentales.

Se obtiene como resultado un modelo entrenado basado en Aprendizaje Profundo para la detección de tipos de cáncer de piel y una aplicación web que, con base al entrenamiento, detecta estos tipos.

El contenido está organizado de la siguiente manera: comienza con una introducción que presenta al lector la naturaleza del trabajo, seguido por el capítulo I, marco teórico, donde se establecen los antecedentes históricos, conceptuales y contextuales centrados en investigaciones similares. En el capítulo II, materiales y métodos, se detalla la metodología a emplear. El capítulo III aborda los resultados del proceso, destacando el

desarrollo del prototipo, mientras que el Capítulo IV, discusión de resultados, se dedica a la evaluación del modelo entrenado. Finalmente, se incluyen las conclusiones y recomendaciones.

CAPÍTULO I. MARCO TEÓRICO

Este capítulo, se enfoca en la elaboración del estado de arte, el cual incluye los antecedentes históricos, conceptuales y contextuales. Para la construcción de este capítulo, se llevó a cabo un análisis basado en las variables de investigación, donde la variable independiente está representada por la aplicación web con aprendizaje profundo y la variable dependiente por la detección de cáncer de piel. A partir de esta estructura, se realizó una búsqueda exhaustiva de información con el propósito de identificar técnicas de tratamiento de imágenes, algoritmos, modelos y tipos de redes neuronales aplicados a la detección de cáncer de piel.

De esta manera, se ha logrado cumplir con el primer objetivo, permitiendo consolidar una base teórica que sustenta la propuesta de investigación, garantizando que las decisiones metodológicas adoptadas estén fundamentadas en enfoques validados en la literatura.

1.1. Antecedentes Históricos

Historia de la detección de cáncer de piel




Ilustración 1: Línea de tiempo de la Historia de la detección de cáncer de piel

Fuente: Autor

La historia muestra que desde la antigüedad ha existido la enfermedad del cáncer de piel, por lo que a lo largo del tiempo se han desarrollado técnicas e instrumentos para facilitar su detección [10]. Una técnica de ayuda diagnóstica es la llamada dermatoscopia, denominada también microscopia, la cual implica el uso de un dispositivo con sistemas de iluminación y magnificación incorporados que permiten una visualización clara de las estructuras y patrones de la superficie y el subsuelo de la piel. Esta técnica la recalca en 1920, Johan Saphier para el sistema que usaba en el estudio de los capilares cutáneos. [11].

Si bien es cierto, la utilización de la dermatoscopia se remonta al siglo XVI, no es si no en el siglo XX cuando adquiere un nivel de perfeccionamiento, difusión y utilización, la cual la hacen una herramienta imprescindible en la práctica clínica de todo dermatólogo.

El aspecto principal de la evaluación dermatoscópicas de una lesión es visualizar las estructuras invisibles a simple vista o a la lupa empleada habitualmente. Las características dermatoscópicas corresponden a características clínicas e histológicas y, en la mayoría de los casos, pueden servir como características diagnósticas cuando se consideran en el contexto del cuadro clínico [12].

En los años 80, surgió la aplicación de la dermatoscopia digital, una técnica de análisis no invasiva que facilita la evaluación de imágenes de alta resolución de lesiones cutáneas mediante el uso de una cámara de vídeo a color especialmente diseñada para dermatoscopia. Esta cámara se conecta a un ordenador, permitiendo el empleo de la tecnología informática para el almacenamiento masivo, la evaluación indirecta y la gestión de imágenes dermatoscópicas. [13].

[14] indica que en 1992 la Academia Estadounidense de Dermatología llevó a cabo programas de detección de cáncer de piel utilizando el método de la dermatoscopia epiluminiscente, que utiliza una luz polarizada para mejorar la visualización de las lesiones cutáneas. La luz se polariza linealmente mediante un filtro antes de llegar a la piel. La luz reflejada desde la superficie de la piel está polarizada de manera similar, mientras que la luz reflejada desde las capas inferiores de la epidermis, después de haber experimentado ciclos repetidos de refracción en diferentes medios, ya no está polarizada [15].

En el año 2000, se incorpora la utilización de atributos manuales extraídos de imágenes dermatoscópicas con el fin de entrenar modelos de aprendizaje supervisado. Mas tarde, en 2006 [16] manifiesta que el aprendizaje profundo, se basó en el concepto de red neuronal artificial. Después de eso, el aprendizaje profundo se convirtió en un tema destacado, lo que implicó que la investigación de redes neuronales reapareciese, es por esta razón que muchas veces se las denomina redes neuronales de nueva generación. En vista de que las redes profundas, cuando se entrenan adecuadamente, producen un éxito significativo en una variedad de desafíos de clasificación y regresión.

Antes de 2016, la investigación se enfocaba principalmente en el proceso tradicional del flujo de trabajo del aprendizaje automático, que comprendía el preprocesamiento, la segmentación, la extracción de características y la clasificación. Además, se necesitaba un nivel significativo de experiencia para extraer características de manera efectiva de imágenes cancerosas. La falta de una segmentación adecuada podía resultar en una selección deficiente de características, lo que afectaba negativamente la precisión de la clasificación. En 2016, se produce un cambio significativo en las técnicas de clasificación de lesiones cutáneas [3].

Dentro de los diversos métodos asistidos por ordenador, los enfoques basados en el aprendizaje profundo han evidenciado resultados alentadores en la segmentación y clasificación de lesiones cutáneas, gracias a su habilidad para extraer características complejas de las imágenes de manera más detallada. Los algoritmos de aprendizaje profundo también tienen la capacidad de aprender características específicas para la tarea, lo que los hace mucho más eficientes que otros métodos. [17]

Hoy en día, la tecnología DL (Deep Learning) se considera uno de los temas más relevantes dentro del área del aprendizaje automático, así como la ciencia y el análisis de datos, debido a sus capacidades de aprendizaje a partir de los datos proporcionados [16]. Recientemente, se han utilizado redes neuronales convolucionales (CNN) y enfoques basados en el aprendizaje profundo para la detección del cáncer [18].

Estudios han demostrado que las CNN tienen un rendimiento de alto nivel en la detección de cáncer de piel. En particular, el modelo ResNet50 alcanzó una especificidad del 93% y una sensibilidad del 79%, evaluado con un conjunto de datos limitado. Además, la combinación de modelos como InceptionV3 y ResNet50 mejoró aún más la precisión,

logrando un área bajo la curva (ROC-AUC) comparable o incluso superior a la de dermatólogos certificados [19]. Otro estudio mostró que un enfoque basado en múltiples modelos de CNN logró una precisión significativa en la clasificación de lesiones cutáneas, con un rendimiento similar al de los dermatólogos en la detección de melanoma y otras lesiones cutáneas, destacando la robustez y eficacia de las CNN en aplicaciones de diagnóstico médico [20].

En las investigaciones de [21] Allugunti diseñó, implementó y evaluó un marco basado en redes neuronales convolucionales (CNN) para la detección de melanoma, utilizando un conjunto de datos de acceso público. La precisión alcanzada del 88,83 % resalta la efectividad del enfoque propuesto, el cual se basa en una plataforma de aprendizaje en dos etapas. Este método no está limitado a algoritmos de clasificación específicos como DT, RF o GBT, sino que se fundamenta en CNN, lo que lo convierte en una herramienta robusta para la categorización multiclase.

A pesar de los avances en el uso de aprendizaje profundo para la detección del cáncer de piel, persisten importantes desafíos que limitan su implementación efectiva en entornos clínicos. Los trabajos previos han priorizado modelos de clasificación estándar, basados en arquitecturas convencionales de CNN o ensambles de redes [41], sin optimizar su eficiencia computacional ni su capacidad de generalización a escenarios clínicos. Además, estos enfoques carecen de estrategias avanzadas de preprocesamiento y aumento de datos, lo que limita la robustez de sus predicciones y su adaptabilidad a variaciones en imágenes médicas del mundo real.

Este trabajo aborda estas deficiencias mediante el desarrollo de una aplicación web innovadora, impulsada por un modelo de aprendizaje profundo altamente optimizado que supera los enfoques tradicionales en varios aspectos clave: Utiliza ResNet50 con fine-tuning avanzado, ajustando sus últimas capas para mejorar la extracción de características relevantes en la detección de lesiones cutáneas. También, incorpora estrategias avanzadas de aumento de datos, aplicando transformaciones más robustas como rotaciones de hasta 40°, desplazamientos del 30%, cizalladura, zoom y volteo horizontal, lo que mejora significativamente la capacidad de generalización del modelo frente a variaciones en imágenes reales. Para evitar sobreajuste, implementa Dropout del 50%, reduciendo la dependencia del modelo en patrones espurios y optimizando su rendimiento en datos no vistos.

Además, la aplicación web desarrollada integra este modelo de manera accesible e intuitiva, permitiendo la detección automática de ocho tipos de cáncer de piel: Melanoma, Nevo melanocítico, Carcinoma de células basales, Queratosis actínica, Dermatofibroma, Carcinoma de células escamosas, Lesión vascular y Queratosis seborreica. A diferencia de los estudios previos, este sistema no solo se enfoca en la precisión del modelo, sino que también aborda la necesidad de una herramienta práctica, implementable y de fácil acceso, cerrando así la brecha entre la investigación y su uso en la práctica médica. Con esta propuesta, se espera no solo mejorar la precisión en la detección del cáncer de piel, sino también facilitar su adopción en la práctica médica y contribuir a diagnósticos más tempranos y accesibles.

1.2. Antecedentes Conceptuales




Ilustración 2: Mapa mental de los antecedentes conceptuales

Fuente: Autor

Aprendizaje Automático

La definición del aprendizaje automático se orienta a un modelo de computación, donde interviene la inteligencia artificial la cual consiente que un sistema asimile y por lo tanto mejore de forma automática mediante redes neuronales de aprendizaje, sin tener que ser programado específicamente, esto se logra a mediante el ingreso de grandes cantidades de información. Se podría decir también que el aprendizaje automático es el razonamiento

basado en casos, lo cual nos permite diagnosticar el problema haciendo referencia a casos anteriores similares. [22].

El aprendizaje automático es un tipo de análisis predictivo mucho más fácil de implementar y actualizar en tiempo real a medida que se va obteniendo más datos, generalmente se lo conoce como la tecnología más popular de la revolución industrial (4IR o Industria 4.0). Los algoritmos para establecer el aprendizaje autónomo se pueden clasificar en 4 principales tipos, éstos son: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje semisupervisado, y, aprendizaje de refuerzo. [23].

Aprendizaje supervisado

El aprendizaje supervisado puede mencionarse como el primer tipo de aprendizaje automático. Es el paradigma de aprendizaje para desarrollar la capacidad de resolver problemas basándose en etiquetas de ejemplos de capacitación, en este aprendizaje los parámetros se minimizan para lograr la diferencia entre la salida objetivo y la salida calculada.

En este modelo de aprendizaje, todos los modelos de entrenamiento están etiquetados para entrenar algoritmos los cuales clasifican datos o prevén resultados con precisión, generalmente se aplica a la clasificación de datos y las regresiones [22]. La predicción por similitud (KNN) K-Nearest Neighbor, el Naive Bayes, el árbol de decisión corresponden al aprendizaje supervisado, la clasificación y la regresión están dentro de este tipo de algoritmos de aprendizaje.

Aprendizaje no supervisado

En este tipo de aprendizaje no existe ninguna categorización, se lo define como un proceso de optimización de los prototipos de cluster, en función de las similitudes de los ejemplos de entrenamiento. A diferencia del aprendizaje supervisado, no requiere respuestas predefinidas, lo que lo hace ideal para tareas como la detección de anomalías, la segmentación de datos y la reducción de dimensionalidad. Entre los métodos más comunes se encuentran el clustering, que agrupa datos según similitudes, y el análisis de componentes principales (PCA), que reduce la complejidad de los datos manteniendo su información esencial [22].

Aprendizaje profundo

Para [24], el aprendizaje profundo es una técnica en donde las redes aprenden por medio de la utilización de capas de procesamiento de información no lineal, la realización y la extracción de características, el reconocimiento de patrones y la clasificación. Este aprendizaje utiliza redes neuronales artificiales para implementar problemas con grandes conjuntos de datos. Las técnicas de aprendizaje profundo proporcionan una arquitectura muy sólida para el aprendizaje supervisado. Al agregar más capas, el modelo de aprendizaje puede representar mejor los datos de imagen etiquetados.

En el aprendizaje profundo, un dispositivo aprende a clasificar a partir de imágenes, texto o sonido. Así como una computadora está entrenada para usar una gran cantidad de conjuntos de datos y luego cambiar el valor de píxel de una imagen a una representación interna o característica vectorial donde los clasificadores pueden detectar o clasificar patrones en la entrada.

Redes Neuronales Convolucionales

Las CNN se utilizan de manera eficiente y efectiva en muchas aplicaciones de reconocimiento de imágenes y patrones, por ejemplo, reconocimiento de gestos, reconocimiento de rostros, clasificación de objetos y generación de descripciones de escenas. De manera similar, las CNN han logrado tasas de detección (CDR) del 99,77 % mediante la base de datos MNIST de dígitos escritos a mano, 97,47 % con el conjunto de datos NORB de objetos 3D y 97,6 % en alrededor de 5600 imágenes de más de 10 objetos [25].

Para [26], las capas o pasos de las CNN son las siguientes:

- Convolución
- Agrupación
- Aplanamiento
- Conexión completa

Convolución

La convolución es una operación lineal especializada que se emplea para la extracción de características. Consiste en aplicar una pequeña matriz de números, conocida como núcleo, sobre las entradas y tensores. Para cada posición en el tensor de entrada, se realiza un producto por elementos entre cada componente del núcleo y del tensor, y luego se suman los resultados para obtener el valor de salida en la posición correspondiente, generando así un mapa de características. Este proceso se repite utilizando varios núcleos para crear un número indefinido de mapas de características, que capturan diversas propiedades de los tensores de entrada. Por lo tanto, cada núcleo puede ser visto como un extractor de diferentes tipos de características. [27]. En la ilustración 3 se muestran las operaciones que suceden en esta capa.




Ilustración 3: Capa Convolución

Fuente: Autor

Agrupación

Para [28], la capa de agrupación se aplica comúnmente después de la capa de convolución en la arquitectura CNN. La función principal de la capa de agrupación es reducir el muestreo de las dimensiones de las características y comprimir el tamaño del mapa de características recibido. Las operaciones de agrupación incluyen principalmente la agrupación máxima y la agrupación media. Según [29], en la arquitectura CNN, una capa de agrupación promedio y una capa de agrupación máxima están conectadas en paralelo para aumentar el rendimiento de la clasificación.

Aplanamiento

Para la alimentación de los mapas de características de la red neuronal artificial, se necesita un vector de una sola columna de los píxeles de cada imagen. Como sugiere el nombre, se aplanan los mapas de características en columnas como vectores [26]. En la ilustración 4 se muestran las operaciones que suceden en esta capa.




Ilustración 4: Capa Aplanamiento

Fuente: Autor

Conexión Completa

La última es una capa completamente conectada a la que llamamos capa FC en esa capa, cada neurona está conectada a la capa anterior y también mejora el rendimiento de entrenamiento de los modelos CNN porque en esto aplanamos nuestra matriz en la forma vectorial y la alimentamos a la capa completamente conectada. Esta capa tiene conexiones completas con todas las activaciones en la capa anterior [30].

Arquitecturas CNN de uso común para la clasificación de imágenes

La arquitectura de una CNN está basada en varios componentes clave, entre ellos las capas convolucionales, las capas de agrupamiento, las capas de activación no lineal y las capas completamente conectadas. En el proceso, una imagen es primero preprocesada y luego ingresada a la red a través de la capa de entrada. Esta imagen pasa por una serie de capas convolucionales y de agrupamiento alternadas antes de ser clasificada en la capa final completamente conectada. las CNNs incorporan específicamente las capas convolucionales y de agrupamiento. Las CNNs están diseñadas para manejar eficientemente imágenes con muchos píxeles y conjuntos de datos grandes, ofreciendo un rendimiento superior en términos de tamaño del modelo y eficiencia. [31]

ResNet

Es una arquitectura de red neuronal profunda que se diseñó para facilitar el entrenamiento de redes muy profundas al abordar problemas comunes como el gradiente evanescente y el gradiente explosivo. La característica distintiva de ResNet es la inclusión de conexiones de salto, que permiten que las activaciones de una capa se salten una o más capas intermedias y se vinculen directamente a capas posteriores. Esta técnica de conexiones de salto forma bloques residuales que se apilan, lo que hace posible entrenar redes con muchas más capas de manera eficiente, mejorando el rendimiento y reduciendo la tasa de error. [17]




Ilustración 5: Ejemplo de una red ResNet

Fuente: [17]

VGG

El modelo VGG, introducido en 2014, es una red neuronal profunda que se destaca por su estructura simple pero efectiva, la cual le permitió obtener el segundo lugar en la competición ILSVRC 2014. Similar a AlexNet, el VGG emplea una serie de capas convolucionales seguidas de capas completamente conectadas. Su diseño consiste en apilar múltiples capas convolucionales idénticas y aplicar capas de agrupamiento máximo

para reducir las dimensiones espaciales de las imágenes a la mitad. En el VGG-16, una de sus versiones más conocidas, se utilizan 16 niveles de pesos organizados en cinco bloques secuenciales de capas convolucionales, finalizando con dos capas completamente conectadas de 4096 neuronas cada una y una capa de salida con 1000 clases de clasificación. [31]




Ilustración 6: Arquitectura de la red VGG-16

Fuente: [31]

DenseNet

El principio básico de DenseNet es el mismo que el de ResNet, pero utiliza la conexión densa para la fusión de características de la parte residual para lograr la reutilización de características en el canal. Propone una arquitectura que optimiza la comprensión de patrones de conexión simples: para garantizar el máximo flujo de información entre las capas de la red, conectamos todas las capas (con tamaños de mapa de características coincidentes) directamente entre sí. Para mantener las características de avance, cada capa obtiene información adicional de todas las capas anteriores y pasa su mapa de características a todas las capas posteriores. Esto permite que DenseNet logre un mejor rendimiento con menos parámetros y costos computacionales. [32]




Ilustración 7: Estructura de DenseNet

Fuente: [32]

Herramientas Utilizadas

Tensorflow

Es una biblioteca ampliamente utilizada para construir DNN. Se han desarrollado muchas aplicaciones con él, que van desde el reconocimiento de resultados orbitales moleculares de fragmentos visualizados (FMO) hasta el reconocimiento de rostros basado en CNN [33].

La API de TensorFlow para la detección de objetos es un paquete para determinar las aplicaciones de detección de objetos. Es una técnica de detección en tiempo real de objetos en una imagen. La biblioteca de la API de detección de objetos de Tensorflow incluye varias construcciones de detección de objetos listas para usar, como SSD (detector de disparo único), R-CNN más rápida (red neuronal convolucional basada en regiones) y R-FCN (red neuronal convolucional basada en regiones más rápida) [34].

Keras

[35] indica que es una interfaz de programación de aplicaciones (API) para redes neuronales de alto nivel implementada en Python, facilita el desarrollo de modelos de aprendizaje profundo de manera eficiente. La simplicidad de Keras se traduce en la capacidad de los usuarios para crear modelos de aprendizaje profundo de manera rápida y con una gran flexibilidad, manteniendo al mismo tiempo una interfaz de alto nivel. Esta característica hace que Keras sea un marco especial para el trabajo en este campo. Además, su compatibilidad con varios otros marcos como backend permite una flexibilidad adicional al permitir el uso de una API de bajo nivel diferente según sea necesario para casos de uso específicos.

Visual Code

Es un editor de código muy potente, de desarrollo centrado y diseñado expresamente para facilitar la escritura de aplicaciones tanto en la web, como móviles y en la nube, estas características serán útiles para agilizar el trabajo. Visual Code proporciona sugerencias de código y terminaciones inteligentes en base a los tipos de variables, se utilizará lenguajes que están disponibles para diferentes plataformas de desarrollo, así mismo se

respaldará el ciclo de vida de desarrollo de aplicaciones con un depurador incorporado. Las versiones Git cuentan con soporte integrado para el popular motor de control[36].

Sistemas Web

Los sistemas web forman parte integral de nuestra rutina diaria al facilitar el acceso a la información en cualquier lugar del mundo. Estos sistemas son diseñados según las necesidades de los usuarios y desempeñan un papel fundamental en la eficacia de llevar a cabo diversas actividades. Gracias a la tecnología actual, es posible crear con facilidad estos sistemas, mejorando así las funciones manuales que realizan los usuarios que los utilizan [37].

Metodología CRISP-DM

Para la implementación de la aplicación web que detecte cáncer de piel se utilizará el tipo de estudio experimental, el cual permite establecer relaciones de causa y efecto, de modo que se evalúa el efecto de la variable independiente (aplicación web) que se está estudia sobre la variable dependiente (detección de cáncer de piel).

Algo similar ocurre con la metodología de investigación, que se manejará métodos experimentales, hasta lograr una precisión alta y una pérdida baja en el entrenamiento de la red neuronal. En efecto se implementará la metodología de investigación CRISP DM la cual es un modelo de proceso independiente de la industria para la minería de datos [38]. La ilustración 8 describe las seis fases iterativas de entendimiento del negocio hasta el despliegue.




Ilustración 8: Fases de la Metodología CRISP DM

Fuente: Autor

1.3. Antecedentes Contextuales

Problema

El cáncer de piel es una enfermedad en la que las células de la piel crecen de manera anormal y descontrolada. Estas células pueden formar tumores que, en algunos casos, pueden ser malignos y potencialmente mortales si no se tratan a tiempo. A pesar de los avances en la tecnología de diagnóstico, la precisión en el diagnóstico del cáncer de piel sigue siendo un reto debido a la variabilidad en el aspecto de las lesiones dérmicas y las similitudes entre lesiones benignas y malignas. Los métodos tradicionales de diagnóstico, como la dermatoscopia, requieren un alto nivel de habilidad y experiencia, y aun así, pueden estar sujetos a errores humanos. La falta de herramientas automatizadas y precisas para la detección del cáncer de piel contribuye a diagnósticos tardíos y, en consecuencia, a tratamientos menos efectivos.

La detección temprana juega un papel crucial en la mejora de las posibilidades de supervivencia, por lo que es imperativo que el diagnóstico sea preciso y oportuno en los pacientes. No obstante, para los dermatólogos con experiencia, esto puede resultar complicado e incluso desafiante, lo que podría conducir a errores en la evaluación y tratamiento de los pacientes.

Para [39] La precisión de los dermatólogos en el diagnóstico de cáncer de piel a través de imágenes dermatoscópicas varía entre un 60 % y un 80 %. Aquellos con entre 3 y 5 años de experiencia presentan una precisión superior al 60 %, mientras que esta tasa disminuye en profesionales con menos experiencia. Por otro lado, un dermatólogo con una trayectoria de diez años alcanza una precisión del 80 %. Además, si la dermatoscopia es realizada por especialistas sin la capacitación adecuada, la exactitud en la detección del cáncer de piel puede verse comprometida.

Diagnosticar el cáncer de piel con precisión requiere considerar varios factores visuales como la apariencia de la lesión, la ubicación, el color y los patrones [40].

CAUSAS	PROBLEMA	EFFECTOS
Escasas aplicaciones con programas digitales para el diagnóstico de cáncer de piel en el mundo	Falta de una aplicación efectiva para detectar cáncer de piel.	Detección temprana del cáncer en la piel.
Tardíos diagnósticos de cáncer en etapas avanzadas.		Pacientes desconocen que tienen cáncer hasta cuando ya es muy tarde.
Diagnósticos imprecisos, que pueden generar resultados falsos positivos.		Pacientes y doctores confiados de un resultado erróneo.
Tiempo excesivo en la espera de resultados.		Los pacientes a menudo pierden la vida esperando un diagnóstico, que usualmente demora alrededor de dos semanas o más. Con la ayuda de la aplicación, los resultados se obtendrían en cuestión de minutos.

Tabla 1: Causas y Efectos del problema

Fuente: Autor

El impacto adverso del cáncer de piel, se refleja en la tabla 1, evidenciando consecuencias negativas para los pacientes, llegando incluso a pérdidas de vidas. La ausencia de un sistema eficiente para la detección de esta enfermedad contribuye a una disminución en las expectativas de vida. El desarrollo de métodos precisos y oportunos para el diagnóstico se presenta como una necesidad urgente en la atención médica, buscando así reducir los impactos negativos y brindar un tratamiento más efectivo a los pacientes con cáncer de piel.

Implementación

Se implementa un modelo entrenado basado en aprendizaje profundo para la detección de cáncer de piel. Y una aplicación web que detecte en base al entrenamiento, que tipo de cáncer posee.

Para ello se utilizó las herramientas de entrenamiento: Tensorflow, Python y Keras; para el diseño de la aplicación web: Html, Javascript, Vuejs. Y a su vez el editor de código Visual Studio Code, para la creación y depuración de aplicaciones modernas.

Dataset para la implementación

Se utilizará un dataset del repositorio de Kaggle el cual contiene 25331 imágenes dermatoscópicas con ocho categorías de tipos de cáncer de piel.

- **Melanoma**

El melanoma surge debido a modificaciones en los melanocitos, células encargadas de producir melanina, el pigmento responsable del color de la piel y el cabello. Puede manifestarse en la piel normal o surgir en un lunar u otra área que haya experimentado cambios en su apariencia. Es común que algunos lunares de nacimiento evolucionen hacia melanomas a lo largo de la vida [42].




Ilustración 9: Lesiones de melanoma

Fuente: [42]

- **Nevo melanocítico**

La lesión melanocítica, conocida como nevo melanocítico, es una condición frecuente, mayormente adquirida, que surge debido a la proliferación benigna de células nevus. Este trastorno, también referido como "nevo característico", ha sido categorizado de manera variable según sus características histológicas anatómicas, arquitectónicas y celulares. Los nevos melanocíticos ofrecen una categorización conveniente para clasificar las diversas presentaciones de nevos, ya sean congénitos o adquiridos, con un enfoque principal en los nevos adquiridos comunes [43].



Ilustración 10: Nevo melanocítico

Fuente: [43]

- **Carcinoma de células basales**

Para [44] es una forma maligna de crecimiento anormal de células epiteliales que se origina en las células basales de la epidermis y en las estructuras anexas. Constituye una variante constante de cáncer de piel en seres humanos y tiende a

desarrollarse predominantemente en áreas expuestas al sol, como la cara, el cuello y las extremidades superiores.

Desde un punto de vista histológico, este tipo de cáncer se distingue por la presencia de células tumorales que guardan similitud con las células basales normales de la epidermis. Estas células malignas exhiben una apariencia uniforme, con núcleos pequeños y basófilos, y muestran una proliferación descontrolada formando cordones, nidos o islotes invasores en la dermis.



Ilustración 11: Basall cell carcinoma

Fuente: [44]

- **Queratosis actínica**

La queratosis actínica es una lesión crónica y benigna en la piel que se encuentra comúnmente en adultos. [45] indica que esta afección representa una neoplasia intraepitelial caracterizada por la proliferación y diferenciación anormal de queratinocitos, principalmente causada por la exposición a la radiación ultravioleta. Se manifiesta en áreas de la piel afectadas por la radiación solar y es considerada uno de los indicadores del envejecimiento de la piel. La prevalencia de la queratosis actínica es más alta en hombres, llegando hasta un 34%, y tiende a aumentar con la edad.




Ilustración 12: Queratosis actínica

Fuente: [45]

- **Dermatofibroma**

[46] explica que los dermatofibromas son crecimientos tumorales benignos compuestos principalmente por fibroblastos e histiocitos. Generalmente se presentan como lesiones únicas, aunque la presencia de múltiples dermatofibromas puede estar vinculada a diversas condiciones médicas.



Ilustración 13: Dermatofibroma

Fuente: [46]

- **Carcinoma, células escamosas**

Este cáncer brota en las células que forman la epidermis, es el segundo carcinoma de piel más comúnmente detectado, aunque presenta bajas tasas de mortalidad, tiene un alto impacto en la carga económica sanitaria. Sus subtipos son la queratosis actínica, el carcinoma epidermoide in situ y el carcinoma epidermoide invasor. [47] Indica que este carcinoma se detecta principalmente en la cabeza, el cuello, las extremidades y las zonas de mayor fotoexposición. Entre los principales factores se encuentran la exposición a la radiación ultravioleta, la inmunosupresión, el virus del papiloma humano, la genodermatosis, las dermatosis crónicas, la exposición al arsénico y las radiaciones ionizantes.



Ilustración 14: Carcinoma de células escamosas

Fuente: [47]

CAPÍTULO II. MATERIALES Y MÉTODOS

Este capítulo detalla el diseño metodológico adoptado para el desarrollo de una aplicación web que utiliza técnicas de aprendizaje profundo para la detección de cáncer de piel. Se describe el tipo de estudio realizado, enfocándose en cómo cada elección metodológica soporta los objetivos del proyecto. Se expone el paradigma desde el cual se abordó la investigación, reflejando su impacto en la formulación de las preguntas de investigación, en la interpretación de los datos, y en la selección de las técnicas estadísticas.



Ilustración 15: Materiales y Métodos

Fuente: Autor

2.1. Tipo de estudio

Los autores [48] explican que los estudios experimentales se caracterizan por evaluar el efecto de una o más intervenciones, generalmente en comparación con otra intervención o un placebo. Su enfoque prospectivo implica la recolección de datos y el seguimiento de los grupos analizados.

Este trabajo se enmarca en una investigación de tipo experimental, seleccionado específicamente debido a su capacidad para establecer relaciones causales y permitir la manipulación controlada de variables. A través de este enfoque, se busca evaluar el rendimiento y la eficacia de un modelo basado en aprendizaje profundo, específicamente

una red neuronal convolucional, en la detección de cáncer de piel a partir de imágenes dermatológicas.

Investigaciones previas [49][50], han señalado la importancia de la cantidad y diversidad de datos en la calidad de las respuestas de los sistemas de clasificación de imágenes. En este contexto, se utilizará un conjunto de datos proveniente de Kaggle, reconocido por su diversidad y calidad en datos médicos, concretamente el conjunto de datos ISIC 2019, que contiene 25331 imágenes dermatoscópicas para el análisis de lesiones en la piel.

Dentro de este proyecto, se aplicarán técnicas de preprocesamiento de imágenes utilizando librerías especializadas como OpenCV, con el fin de mejorar la calidad y la precisión del modelo de red neuronal convolucional. Además, se realizarán pruebas exhaustivas para determinar la cantidad óptima de épocas necesarias para el entrenamiento del modelo, con el objetivo de alcanzar un alto porcentaje de precisión en la detección de cáncer de piel.

En referencia a propuestas previas en estudios similares [51], se sugiere que la implementación de un sistema automatizado de clasificación de imágenes puede ser una opción útil y eficiente en términos de calidad del diagnóstico. Esto puede resultar en un ahorro significativo de tiempo y recursos, lo que podría traducirse en una mayor productividad y rentabilidad en el ámbito de la detección temprana del cáncer de piel mediante aplicaciones web basadas en aprendizaje profundo.

2.2. Paradigma o enfoque desde el cual se realizó

Durante el proceso de desarrollo, se utilizará el enfoque cuantitativo estableciendo métricas para medir la precisión, sensibilidad, especificidad y otras métricas relevantes del modelo en la detección de lesiones cutáneas sospechosas de cáncer. Estas métricas se calcularán utilizando métodos de validación cruzada y se contrastarán con los resultados obtenidos por diagnósticos médicos expertos como punto de referencia.

Además, se realizarán pruebas de entrenamiento y validación para evaluar la significancia en el rendimiento del modelo después de ajustes y optimizaciones. Esto puede incluir pruebas de hipótesis y análisis de varianza para determinar la influencia de diferentes parámetros en el desempeño del modelo.

El enfoque cuantitativo también permitirá establecer umbrales de confianza y precisión para la aplicación web, lo que proporcionará a los usuarios una comprensión clara de la fiabilidad de los resultados obtenidos. Asimismo, se podrán realizar análisis de tendencias a lo largo del tiempo para evaluar el rendimiento continuo de la aplicación y su capacidad para adaptarse a nuevos datos.

2.3. Población y muestra

Para dividir el conjunto de datos ISIC 2019 para el proyecto de detección de cáncer de piel, se ha optado por una división del 80% para entrenamiento y el 20% restante para validación. Dado que el conjunto de datos consta de un total de 25331 imágenes dermatoscópicas, se ha calculado que aproximadamente 20265 imágenes se asignarán al conjunto de datos de entrenamiento, mientras que alrededor de 5066 imágenes se reservarán para la validación o prueba. Esta división nos permitirá disponer de una cantidad suficientemente grande de datos para entrenar nuestro modelo de aprendizaje profundo de manera efectiva, al mismo tiempo que nos proporcionará un conjunto de datos independiente para evaluar su rendimiento con precisión.

2.4. Métodos teóricos con los materiales utilizados

Los métodos teóricos en la investigación se refieren a los enfoques, estrategias y procedimientos utilizados para desarrollar, analizar o interpretar conceptos, teorías o modelos dentro de un campo de estudio específico. A diferencia de los métodos empíricos, que implican la recolección y análisis de datos observables y medibles, los métodos teóricos se centran en el razonamiento lógico, el análisis conceptual y la síntesis de ideas existentes para proponer nuevas teorías, marcos de referencia o comprensiones de fenómenos complejos.

Búsqueda literaria para determinar técnicas de procesamiento de imágenes, algoritmos, modelos y tipos de redes neuronales para el descubrimiento de cáncer de piel.

Revisión Teórica: Análisis y síntesis de literatura existente para identificar patrones, temas, lagunas en la investigación y oportunidades para nuevos desarrollos teóricos.

Realizar una búsqueda sistemática en bases de datos académicas para recopilar estudios recientes sobre inteligencia artificial en dermatología. Analizar críticamente las estrategias de preprocesamiento de imágenes, arquitecturas de red (como CNNs, redes neuronales profundas), técnicas de aumento de datos, y enfoques de transferencia de aprendizaje. Identificar lagunas en la investigación actual, como la necesidad de conjuntos de datos más diversos o métodos para abordar el sobreajuste.

Modelado Teórico: Construcción de modelos conceptuales o matemáticos para explicar fenómenos específicos, basándose en principios teóricos y lógicos.

Construir un modelo teórico que describa la relación entre las características visuales específicas de lesiones cutáneas (por ejemplo, asimetría, bordes, color, diámetro, evolución) y su clasificación diagnóstica correspondiente. Este modelo podría fundamentarse en la teoría de aprendizaje de representaciones y explorar cómo las capas de una CNN pueden adquirir la habilidad para reconocer patrones complejos y discriminativos en imágenes de alta dimensionalidad.

Análisis Conceptual: Examen detallado de conceptos y categorías clave dentro de un campo de estudio para clarificar su significado, relaciones y aplicabilidad.

Examinar la terminología utilizada en el campo de la IA aplicada a la dermatología para asegurar la consistencia y precisión en la comunicación de los hallazgos. Este análisis puede ayudar a estandarizar los términos y facilitar el entendimiento interdisciplinario entre especialistas en IA y profesionales de la salud, promoviendo colaboraciones efectivas.

Simulaciones: Uso de modelos teóricos y algoritmos para simular comportamientos o procesos complejos en un entorno controlado y explorar posibles resultados bajo diferentes condiciones.

Implementar simulaciones utilizando conjuntos de datos sintéticos generados que imiten características de lesiones de cáncer de piel, con el fin de probar la robustez de la red frente a variaciones como iluminación, ángulo de imagen, y ocultamiento parcial de lesiones. Estas simulaciones pueden ayudar a identificar debilidades en la arquitectura de la red o en el proceso de entrenamiento, ofreciendo insights para mejoras iterativas.

2.5. Métodos empíricos con los materiales utilizados

Los métodos empíricos se basan en la observación y experimentación para obtener conocimiento. Para [52] a diferencia de los métodos teóricos, que se centran en el razonamiento y la lógica para desarrollar teorías, los métodos empíricos implican la recopilación de datos a través de la experiencia directa o indirecta para probar hipótesis o entender fenómenos. En el contexto de las ciencias y la ingeniería, incluido el campo de la informática y la inteligencia artificial, estos métodos son fundamentales para validar teorías y modelos con evidencia tangible.

El proceso empírico de entrenamiento y validación de estos modelos incluye experimentación iterativa con diferentes arquitecturas de red, hiperparámetros y técnicas de preprocesamiento de imágenes. A través de la experimentación empírica, los investigadores ajustan estos modelos para maximizar su precisión y capacidad de generalización a nuevos datos no vistos durante el entrenamiento. La validación de los modelos se realiza utilizando conjuntos de datos independientes, no utilizados en el entrenamiento, para evaluar su desempeño en la predicción realista de condiciones clínicas. Este enfoque empírico, al ser rigurosamente aplicado, permite a los científicos y médicos desarrollar herramientas de diagnóstico asistido por computadora altamente efectivas, mejorando potencialmente los resultados de los pacientes al facilitar la detección temprana del cáncer de piel.

2.6. Metodología CRISP-DM

Fase 1. Comprensión del Negocio

Evaluación de la situación

El campo de la detección de cáncer de piel está experimentando una transformación significativa gracias a los avances en las tecnologías de aprendizaje profundo [53], especialmente mediante el uso de redes neuronales convolucionales (CNN). Estos avances ofrecen nuevas posibilidades para mejorar la precisión, velocidad y accesibilidad de las herramientas de diagnóstico del cáncer de piel. Con la creciente prevalencia global de esta enfermedad, existe una demanda urgente de soluciones innovadoras que puedan hacer que el diagnóstico sea más accesible y menos invasivo.

La aplicación de CNN en la interpretación de imágenes dermatológicas, como las proporcionadas por el dataset ISIC-2019 de Kaggle, representa un enfoque prometedor, al combinar la vasta capacidad de datos del conjunto con la potencia del aprendizaje automático para identificar patrones complejos asociados con diversas condiciones de la piel.

Stakeholders

Rol:	Aplicación Web para detectar cáncer de piel
Responsabilidades:	• Precisión y Fiabilidad: El sistema debe ser capaz de identificar los casos de cáncer de piel, minimizando tanto los falsos positivos como los falsos negativos. Debe someterse a pruebas de validación continua para asegurar su fiabilidad. • Accesibilidad: Debe ser accesible para una amplia gama de usuarios, incluyendo aquellos con diferentes niveles de habilidad tecnológica y aquellos que utilizan tecnologías asistidas. • Soporte al Usuario: Debe ofrecer soporte adecuado para ayudar a los usuarios a entender cómo utilizar el sistema correctamente.
Rol:	Usuario Final
Responsabilidades:	• Uso Adecuado: Los usuarios deben seguir las instrucciones de uso del sistema, incluyendo la preparación adecuada para la toma de imágenes de la piel. • Comprensión de Limitaciones: Los usuarios deben comprender que el sistema es una herramienta de apoyo a la decisión y no debe ser utilizado como sustituto de la consulta médica profesional. • Consulta Médica Profesional: En caso de un resultado positivo o si existen preocupaciones, los usuarios deben buscar evaluación y confirmación por parte de un profesional de la salud.

Tabla 2: Stakeholders del proyecto

Fuente: Autor

Alcance

Con base en las responsabilidades definidas con los stakeholders se estableció el alcance del proyecto:

- Desarrollo de una Aplicación Web: Crear un sistema accesible a través de navegadores web modernos, optimizada tanto para dispositivos móviles como de escritorio.
- Autenticación de Usuarios: Implementar un sistema de autenticación seguro para que los usuarios puedan crear cuentas personales, iniciar y cerrar sesión en la aplicación, asegurando la privacidad y seguridad de sus datos.
- Subida y Almacenamiento de Imágenes Dermatológicas: Permitir a los usuarios subir imágenes de lesiones o áreas de la piel de interés, para luego ser analizadas por el sistema.
- Entrenamiento de la Red Neuronal:
 - Recolección de Datos: El conjunto de datos utilizado para el entrenamiento será ISIC-2019 de Kaggle.
 - Preprocesamiento de Datos: Se implementarán técnicas de preprocesamiento para garantizar que las imágenes sean uniformes en términos de tamaño, resolución y formato. También se incluirán la normalización de colores, el aumento de datos para mejorar la robustez del modelo.
 - Selección de la Arquitectura de Red: Se elegirán las redes neuronales convolucionales (CNN) que son ampliamente usadas en el análisis de imágenes.
 - Entrenamiento del Modelo: Utilizar el conjunto de datos preparado para entrenar el modelo de aprendizaje profundo, ajustando parámetros como la tasa de aprendizaje, el número de épocas y la función de pérdida para optimizar el rendimiento del modelo.
 - Validación y Pruebas: Validar el modelo utilizando un conjunto de datos separado para evitar el sobreajuste y avalar que el modelo generalice bien a nuevos datos. Ajustar el modelo según sea necesario basado en el rendimiento en el conjunto de validación.
 - Implementación del Modelo Entrenado: Integrar el modelo entrenado en la aplicación web de manera que pueda recibir imágenes de los usuarios, procesarlas a través del modelo y devolver los resultados de la detección en tiempo real.

- **Detección del Tipo de Cáncer de Piel:** Utilizar el modelo entrenado para analizar las imágenes dermatológicas subidas y determinar la presencia y tipo de cáncer de piel, como melanoma, carcinoma basocelular o carcinoma de células escamosas.

Fase 2. Comprensión de datos

Descripción de datos

El conjunto de datos ISIC-2019 es parte de la competición ISIC Challenge en la detección automática de lesiones cutáneas. Incluye imágenes dermatoscópicas que representan diferentes tipos de cáncer de piel. Estas imágenes están etiquetadas en ocho categorías de diagnóstico:

1. Melanoma
2. Nevo melanocítico
3. Carcinoma de células basales
4. Queratosis actínica
5. Dermatofibroma
6. Carcinoma de células escamosas
7. Lesión vascular
8. Queratosis seborreica

```
dataset.head()
```

	patient_id	target	source	sex	age_approx	anatom_site_general_challenge
image_id						
ISIC_2637011	IP_7279968	0	ISIC20	male	45.0	head/neck
ISIC_0015719	IP_3075186	0	ISIC20	female	45.0	upper extremity
ISIC_0052212	IP_2842074	0	ISIC20	female	50.0	lower extremity
ISIC_0068279	IP_6890425	0	ISIC20	female	45.0	head/neck
ISIC_0074268	IP_8723313	0	ISIC20	female	55.0	upper extremity

Ilustración 16: Estructura del Dataset

Fuente: Autor

La ilustración 16, muestra una vista preliminar del conjunto de datos ISIC 2019, obtenida mediante el método `.head()` en el entorno de Colab. Este método permite visualizar las primeras filas del dataset para comprender su estructura y las etiquetas asociadas a cada imagen.

[54] en su estudio indica que cada imagen está acompañada de metadatos que proporcionan información adicional relevante para el análisis. Estos metadatos incluyen:

- Edad del paciente: Indica la edad en años.
- Sexo del paciente: Especifica si el paciente es masculino o femenino.
- Ubicación anatómica: Detalla la parte del cuerpo donde se tomó la imagen de la lesión.

Las imágenes están en formato PNG, lo que asegura una alta calidad y compatibilidad para el procesamiento y análisis posterior. Esta estructura de datos, con imágenes etiquetadas y metadatos detallados, facilita el entrenamiento y evaluación de modelos de aprendizaje profundo para la detección y clasificación de diversas lesiones cutáneas.




Ilustración 17: Características del dataset

Fuente: [54]

Fase 3. Preparación de datos

Selección de datos

La carga y exploración del conjunto de datos ISIC 2019 en Google Colab, se inició montando Google Drive en el entorno de ejecución, lo que permitió acceder a los archivos almacenados en la cuenta del usuario. Posteriormente, se importaron las librerías necesarias, incluyendo pandas para la manipulación de datos y **os** para la gestión de rutas y archivos dentro del sistema.

```
from google.colab import drive
drive.mount('/content/drive')

import pandas as pd
import os
```

Ilustración 18: Selección de datos – Importaciones

Fuente: Autor

Una vez establecida la conexión con Google Drive, se definió la ruta principal del conjunto de datos y se verificó la estructura de los directorios de imágenes. Se utilizó `os.listdir()` para listar los archivos en el directorio correspondiente y confirmar su correcta organización. Además, se cargó el archivo `ISIC_2019_Training_GroundTruth.csv`, que contiene las etiquetas de las imágenes, permitiendo visualizar sus columnas y estructurar la información para su posterior procesamiento.

```
# Definir ruta principal
main_dir = '/content/drive/MyDrive/ISIC_2019'

# Verificar la estructura del directorio de imágenes
image_dir = os.path.join(main_dir, 'ISIC_2019_Training_Input', 'ISIC_2019_Training_Input')
print("Archivos en el subdirectorio de imágenes:", os.listdir(image_dir)[:10])

# Actualizar la ruta del directorio base a la ruta correcta
base_dir = image_dir

# Cargar los datos y mostrar las primeras filas
csv_file = os.path.join(main_dir, 'ISIC_2019_Training_GroundTruth.csv')
data = pd.read_csv(csv_file)
print("Columnas en el archivo CSV:", data.columns)
```

Ilustración 19: Selección de datos - Etiquetas de archivos

Fuente: Autor

Para optimizar el dataset, se creó una columna adicional denominada label, asignando a cada imagen su respectiva categoría diagnóstica. Asimismo, se aseguraron las rutas de los archivos de imagen, añadiendo la extensión `.jpg` cuando era necesario y verificando la existencia de cada archivo en el directorio. Finalmente, se realizó una división del conjunto de datos en entrenamiento y validación utilizando `train_test_split`, con un 80 % de los datos destinados al entrenamiento y un 20 % a la validación, asegurando una distribución adecuada para el modelo de aprendizaje profundo.

```
# Verificar si los archivos de imagen existen ahora
missing_files = []
for img_name in data['image']:
    if not os.path.exists(os.path.join(base_dir, img_name)):
        missing_files.append(img_name)

print(f"Total missing files después de la corrección: {len(missing_files)}")

# Mostrar algunos archivos de imagen y verificar que existen en el directorio
print("Primeros 10 nombres de imágenes en el subdirectorio de imágenes:", os.listdir(base_dir)[:10])
print("Primeros 10 nombres de imágenes en el CSV:", data['image'].head(10))

# Dividir los datos en entrenamiento y validación
from sklearn.model_selection import train_test_split

train_df, val_df = train_test_split(data[['image', 'label']], test_size=0.2, random_state=42)
```

Ilustración 20: Selección de datos - División de la data

Fuente: Autor

Integración de datos

Para el conjunto de datos ISIC-2019, este proceso podría involucrar la consolidación de imágenes dermatológicas junto con su metadata asociada, que podría incluir información demográfica del paciente, detalles de la lesión y anotaciones específicas de diagnóstico. La integración efectiva asegura que cada imagen esté correctamente vinculada a su información relevante, facilitando un análisis holístico y la aplicación de técnicas de aprendizaje automático.

Esto es particularmente importante en el contexto del aprendizaje profundo, donde las características extraídas automáticamente de las imágenes pueden ser complementadas con insights (descubrimientos o comprensiones profundas obtenidas) derivados del metadata, potencialmente mejorando la precisión del modelo.

```

Drive already mounted at /content/drive; to attempt to forcibly remount, call drive.mount("/content/drive", force_remount=True).
Archivos en el subdirectorio de imágenes: ['ISIC_0027698.jpg', 'ISIC_0027678.jpg', 'ISIC_0027691.jpg', 'ISIC_0027675.jpg', 'ISIC_
Columnas en el archivo CSV: Index(['image', 'MEL', 'NV', 'BCC', 'AK', 'BKL', 'DF', 'VASC', 'SCC', 'UNK'], dtype='object')
image label
0 ISIC_0000000 NV
1 ISIC_0000001 NV
2 ISIC_0000002 MEL
3 ISIC_0000003 NV
4 ISIC_0000004 MEL
Total missing files después de la corrección: 18060
Primeros 10 nombres de imágenes en el subdirectorio de imágenes: ['ISIC_0027698.jpg', 'ISIC_0027678.jpg', 'ISIC_0027691.jpg', 'IS
Primeros 10 nombres de imágenes en el CSV: 0 ISIC_0000000.jpg
1 ISIC_0000001.jpg
2 ISIC_0000002.jpg
3 ISIC_0000003.jpg
4 ISIC_0000004.jpg
5 ISIC_0000006.jpg
6 ISIC_0000007.jpg
7 ISIC_0000008.jpg
8 ISIC_0000009.jpg
9 ISIC_0000010.jpg
Name: image, dtype: object
Found 5795 validated image filenames belonging to 8 classes.

```

Ilustración 21: Integración de datos

Fuente: Autor

Formateo de datos

Esta etapa se centra en asegurar que todas las imágenes y sus correspondientes metadatos estén en un formato homogéneo y listo para ser procesado por el modelo. Esto implica estandarizar las dimensiones, dado que las CNN requieren que todas las entradas tengan el mismo tamaño. Esto se logra generalmente mediante técnicas de redimensionamiento y, si es necesario, aplicando padding para mantener la proporción de aspecto sin distorsionar la imagen original.

Para optimizar el rendimiento del modelo en la detección de cáncer de piel, se aplicó un proceso de preprocesamiento y aumento de datos utilizando la clase ImageDataGenerator de TensorFlow Keras. Este procedimiento permite normalizar las imágenes y aplicar transformaciones aleatorias, lo que ayuda a mejorar la capacidad de generalización del modelo y a reducir el sobreajuste.

```

# Preprocesar y aumentar las imágenes
from tensorflow.keras.preprocessing.image import ImageDataGenerator

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=40,
    width_shift_range=0.3,
    height_shift_range=0.3,
    shear_range=0.3,
    zoom_range=0.3,
    horizontal_flip=True,
    fill_mode='nearest'
)

```

Ilustración 22: Formateo de datos - Aumento de data

Fuente: Autor

El conjunto de entrenamiento fue sometido a diversas transformaciones, incluyendo reescalado de los valores de los píxeles ($\text{rescale}=1./255$), rotaciones de hasta 40 grados, desplazamientos en el eje horizontal y vertical, cortes diagonales (shear), zoom aleatorio y volteo horizontal. Estas modificaciones permiten que el modelo aprenda a reconocer patrones de lesiones cutáneas en distintas orientaciones y condiciones. Para el conjunto de validación, únicamente se aplicó el reescalado, asegurando que las imágenes se mantuvieran en su formato original sin alteraciones adicionales.

```
val_datagen = ImageDataGenerator(rescale=1./255)
```

Ilustración 23: Formateo de datos – Reescalado

Fuente: Autor

Posteriormente, se definieron los generadores de imágenes (`train_generator` y `val_generator`), los cuales cargan las imágenes directamente desde el directorio de almacenamiento. Se configuró un tamaño de entrada de 224x224 píxeles, un tamaño de lote de 32 imágenes y una clasificación de tipo categorica, lo que permite que el modelo asigne cada imagen a una de las categorías predefinidas. Este preprocesamiento y aumento de datos garantizan que el modelo reciba imágenes variadas y representativas, mejorando su capacidad de clasificación en diferentes tipos de cáncer de piel.

```
train_generator = train_datagen.flow_from_dataframe(  
    train_df,  
    directory=base_dir,  
    x_col='image',  
    y_col='label',  
    target_size=(224, 224),  
    batch_size=32,  
    class_mode='categorical'  
)  
  
val_generator = val_datagen.flow_from_dataframe(  
    val_df,  
    directory=base_dir,  
    x_col='image',  
    y_col='label',  
    target_size=(224, 224),  
    batch_size=32,  
    class_mode='categorical'  
)
```

Ilustración 24: Formateo de Datos – Preprocesamiento

Fuente: Autor

Fase 4. Modelado

Selección de técnicas

Se han seleccionado los modelos preentrenados ResNet, VGG y DenseNet para la detección de cáncer de piel. Estos modelos han demostrado un alto rendimiento en tareas de clasificación de imágenes médicas. Por ejemplo, en el estudio "Skin Cancer Diagnosis using Deep Learning, Transfer Learning and Hybrid Model" [40], se evaluaron los modelos ResNet152V2, VGG19 y MobileNetV3Large, obteniendo resultados prometedores en la detección temprana de cáncer de piel.

Estos modelos, preentrenados en grandes conjuntos de datos como ImageNet, permiten aplicar técnicas de transferencia de aprendizaje, adaptando el conocimiento adquirido a la detección de lesiones cutáneas con conjuntos de datos más pequeños, mejorando la eficiencia del entrenamiento y la precisión del modelo [6].

ResNet (Redes Residuales):

Se cargó el modelo con pesos preentrenados en ImageNet, excluyendo su capa de clasificación final (`include_top=False`), lo que permitió reutilizar sus capacidades de extracción de características y ajustarlo a la clasificación de imágenes dermatoscópicas.

```
# Crear y compilar el modelo
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.optimizers import Adam

base_model = ResNet50(weights='imagenet', include_top=False)
```

Ilustración 25: Entrenamiento - Creación modelo resnet

Fuente: Autor

Sobre la base de ResNet50, se añadieron capas densas completamente conectadas para optimizar la clasificación. Se utilizó una capa de Global Average Pooling para reducir la dimensionalidad de las características extraídas, seguida de una capa densa de 1024 neuronas con activación ReLU, junto con una capa de Dropout (0.5) para prevenir el sobreajuste. Finalmente, la capa de salida utilizó activación softmax, permitiendo clasificar las imágenes en función del número de clases del conjunto de datos.

```
x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x) # Añadir Dropout para regularización
predictions = Dense(len(train_generator.class_indices), activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)
```

Ilustración 26: Entrenamiento - capas modelo resnet

Fuente: Autor

Para mejorar el rendimiento del modelo, se descongelaron las últimas diez capas del modelo base, permitiendo que estas fueran entrenadas sobre el conjunto de datos específico de cáncer de piel mientras se mantenían congeladas las capas anteriores para preservar el conocimiento aprendido en ImageNet. Se utilizó el optimizador Adam con una tasa de aprendizaje de 0.0001 y la función de pérdida `categorical_crossentropy`, adecuada para la clasificación multiclase.

```
# Descongelar algunas capas del modelo base
for layer in base_model.layers[-10:]:
    layer.trainable = True

model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])
```

Ilustración 27: Entrenamiento - utilización de optimizado modelo resnet

Fuente: Autor

VGG (Visual Geometry Group):

Se cargó el modelo con los pesos preentrenados en ImageNet, excluyendo su capa de clasificación final (`include_top=False`), lo que permitió reutilizar su capacidad de extracción de características y adaptar el modelo a la clasificación de imágenes dermatoscópicas.

```
# Crear y compilar el modelo
from tensorflow.keras.applications import VGG16
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.optimizers import Adam

base_model = VGG16(weights='imagenet', include_top=False)
```

Ilustración 28: Entrenamiento - Creación modelo vgg16

Fuente: Autor

Sobre la base del modelo VGG16, se añadieron capas densas totalmente conectadas para realizar la clasificación de las imágenes en las categorías predefinidas. Primero, se incorporó una capa de Global Average Pooling para reducir la dimensionalidad de las características extraídas, seguida de capas densas con activación ReLU de 1024 y 512 neuronas, intercaladas con capas de Dropout (0.5) para reducir el sobreajuste. La capa de salida, con activación softmax, fue configurada para clasificar las imágenes en función del número de clases del conjunto de datos.

```
x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)
predictions = Dense(len(train_generator.class_indices), activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)
```

Ilustración 29: Entrenamiento - capas modelo vgg16

Fuente: Autor

Para optimizar el modelo, se ajustó la estrategia de entrenamiento permitiendo que las últimas ocho capas del modelo base fueran entrenables, mientras que las anteriores permanecieron congeladas para preservar el conocimiento aprendido en ImageNet. Se utilizó el optimizador Adam con una tasa de aprendizaje de 0.0001 y la función de pérdida categorical_crossentropy, adecuada para la clasificación multiclase.

```
# Descongelar más capas del modelo base
for layer in base_model.layers[-8:]:
    layer.trainable = True

model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])
```

Ilustración 30: Entrenamiento - utilización de optimizado modelo vgg16

Fuente: Autor

Durante el entrenamiento, se implementaron callbacks para mejorar el rendimiento del modelo. Se configuró ModelCheckpoint para almacenar el mejor modelo basado en la precisión de validación, evitando la pérdida de progreso en caso de interrupciones. Además, se aplicó EarlyStopping con 10 épocas, permitiendo detener el entrenamiento si no se observaban mejoras significativas. El modelo se entrenó durante 50 épocas, ajustando los pesos a partir del conjunto de entrenamiento y validación.

```

# Callback para guardar el mejor modelo basado en la precisión de validación
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping

checkpoint = ModelCheckpoint('/content/drive/MyDrive/ISIC_2019/vgg16_best_model.h5', monitor='val_accuracy', save_best_only=True, mode='max')
early_stopping = EarlyStopping(monitor='val_accuracy', patience=10, mode='max')

# Entrenar el modelo
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // train_generator.batch_size,
    validation_data=val_generator,
    validation_steps=val_generator.samples // val_generator.batch_size,
    epochs=50, # Aumentar el número de épocas para permitir que el modelo mejore
    callbacks=[checkpoint, early_stopping]
)

```

Ilustración 31: Entrenamiento - ejecución vgg16

Fuente: Autor

DenseNet (Redes Densamente Conectadas):

Se cargó el modelo con los pesos preentrenados en ImageNet, excluyendo su capa de clasificación final (include_top=False), lo que permitió aprovechar sus capacidades de extracción de características y ajustarlo a la clasificación de imágenes dermatoscópicas.

```

# Crear y compilar el modelo
from tensorflow.keras.applications import VGG16
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.optimizers import Adam

base_model = VGG16(weights='imagenet', include_top=False)

```

Ilustración 32: Entrenamiento - Creación modelo densenet

Fuente: Autor

Para adaptar DenseNet121 a la tarea específica de clasificación de lesiones cutáneas, se añadieron capas densas completamente conectadas. Se incorporó una capa de Global Average Pooling para reducir la dimensionalidad de las características extraídas, seguida de capas densas de 1024 y 512 neuronas con activación ReLU, intercaladas con capas de Dropout (0.5) para evitar el sobreajuste. La capa de salida utilizó activación softmax, asegurando la clasificación multiclase en función del número de categorías presentes en el conjunto de datos.

```

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)
predictions = Dense(len(train_generator.class_indices), activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)

```

Ilustración 33: Entrenamiento - capas modelo densenet

Fuente: Autor

En la fase de entrenamiento, se descongelaron las últimas ocho capas del modelo base para permitir que estas aprendieran sobre el conjunto de datos específico de cáncer de piel, mientras que las capas anteriores permanecieron congeladas para preservar el conocimiento adquirido en ImageNet. Se empleó el optimizador Adam con una tasa de aprendizaje de 0.0001 y la función de pérdida `categorical_crossentropy`, adecuada para problemas de clasificación multiclase.

```

# Descongelar más capas del modelo base
for layer in base_model.layers[-8:]:
    layer.trainable = True

model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])

```

Ilustración 34: Entrenamiento - utilización de optimizado modelo densenet

Fuente: Autor

Para mejorar la eficiencia del entrenamiento, se incorporaron callbacks que optimizan la gestión del modelo. Se utilizó `ModelCheckpoint` para guardar automáticamente el modelo con la mejor precisión en validación y `EarlyStopping`, con un criterio de paciencia de 10 épocas, para detener el entrenamiento si no se observaban mejoras en la precisión. El modelo fue entrenado durante 50 épocas, evaluando su rendimiento con datos de validación. Ver Anexo 1.

```

# Callback para guardar el mejor modelo basado en la precisión de validación
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping

checkpoint = ModelCheckpoint('/content/drive/MyDrive/ISIC_2019/vgg16_best_model.h5', monitor='val_accuracy', save_best_only=True, mode='max')
early_stopping = EarlyStopping(monitor='val_accuracy', patience=10, mode='max')

```

Ilustración 35: Entrenamiento - ejecución densenet

Fuente: Autor

Construcción del modelo

La construcción del modelo para la detección de cáncer de piel se desarrolla en varias etapas clave, comenzando con la preparación y procesamiento de los datos. Se utiliza el conjunto de datos ISIC-2019, dividido en 80 % para entrenamiento y 20 % para validación, lo que permite que el modelo aprenda a identificar patrones en las lesiones cutáneas mientras se evalúa su rendimiento en datos no vistos. Antes del entrenamiento, las imágenes pasan por un proceso de preprocesamiento con herramientas como OpenCV, NVIDIA y NumPy, aplicando técnicas como normalización, aumento de datos y ajuste de tamaño para garantizar la uniformidad y mejorar la generalización del modelo. Se seleccionan arquitecturas preentrenadas como ResNet, VGG, DenseNet e Inception, que permiten aprovechar el conocimiento previo adquirido en conjuntos de datos extensos y optimizar la detección de características relevantes en las imágenes dermatológicas.

El modelo se entrenó utilizando los datos previamente preprocesados y aumentados, ajustando los pesos durante 10 épocas, con una estrategia de validación cruzada para evaluar su rendimiento. Finalmente, se evaluó el modelo con los datos de validación, obteniendo métricas de pérdida y precisión, y se guardó el modelo entrenado en un archivo .h5 para su posterior implementación y análisis en la detección de cáncer de piel.

```
# Entrenar el modelo
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // train_generator.batch_size,
    validation_data=val_generator,
    validation_steps=val_generator.samples // val_generator.batch_size,
    epochs=10 # Aumentar el número de épocas
)

# Evaluar el modelo
val_loss, val_accuracy = model.evaluate(val_generator, steps=val_generator.samples // val_generator.batch_size)
print(f'Validation loss: {val_loss}')
print(f'Validation accuracy: {val_accuracy}')

# Guardar el modelo entrenado
model.save('/content/drive/MyDrive/ISIC_2019/resnet50_isic_model.h5')
```

Ilustración 36: Entrenamiento - ejecución resnet

Fuente: Autor

Finalmente, el modelo entrenado se integra en una aplicación web que permite a los usuarios cargar imágenes de lesiones cutáneas para su análisis. Utilizando tecnologías como Python, TensorFlow y Keras, el sistema procesa las imágenes y proporciona un diagnóstico preliminar, ayudando en la detección temprana del cáncer de piel. Gracias a

esta implementación, la herramienta se convierte en un apoyo accesible para profesionales de la salud y pacientes, facilitando la evaluación inicial de lesiones sospechosas desde cualquier dispositivo.

```
Epoch 1/10
181/181 ----- 4028s 21s/step - accuracy: 0.6372 - loss: 1.0961 - val_accuracy: 0.6848 - val_loss: 2.1060
Epoch 2/10
1/181 ----- 1:06:02 22s/step - accuracy: 0.6562 - loss: 0.9690/usr/local/lib/python3.11/dist-packages/keras/src/trainers/epoc
self._interrupted_warning()
181/181 ----- 257s 1s/step - accuracy: 0.6562 - loss: 0.9690 - val_accuracy: 0.6848 - val_loss: 1.9594
Epoch 3/10
181/181 ----- 3755s 21s/step - accuracy: 0.7457 - loss: 0.6759 - val_accuracy: 0.6848 - val_loss: 1.4646
Epoch 4/10
181/181 ----- 211s 1s/step - accuracy: 0.8750 - loss: 0.4722 - val_accuracy: 0.6841 - val_loss: 1.4325
Epoch 5/10
181/181 ----- 3800s 21s/step - accuracy: 0.7929 - loss: 0.5655 - val_accuracy: 0.6848 - val_loss: 1.5226
Epoch 6/10
181/181 ----- 262s 1s/step - accuracy: 0.7500 - loss: 0.5734 - val_accuracy: 0.6848 - val_loss: 1.4815
Epoch 7/10
181/181 ----- 3695s 20s/step - accuracy: 0.8001 - loss: 0.5377 - val_accuracy: 0.6889 - val_loss: 1.6247
Epoch 8/10
181/181 ----- 266s 1s/step - accuracy: 0.6875 - loss: 0.7697 - val_accuracy: 0.6889 - val_loss: 1.6391
Epoch 9/10
181/181 ----- 3684s 20s/step - accuracy: 0.8207 - loss: 0.4963 - val_accuracy: 0.6963 - val_loss: 1.2152
Epoch 10/10
181/181 ----- 260s 1s/step - accuracy: 0.9375 - loss: 0.3089 - val_accuracy: 0.7031 - val_loss: 1.2134
```

Ilustración 37: Entrenamiento - Visualización de épocas resnet

Fuente: Autor

Arquitectura de la Red Neuronal

El modelo implementado para la detección de cáncer de piel se basa en una red neuronal convolucional (CNN) de tipo funcional, estructurada en múltiples capas especializadas para la extracción de características y clasificación. La arquitectura está compuesta por una serie de capas convolucionales, de normalización por lotes (*BatchNormalization*), funciones de activación, capas de *pooling* y conexiones residuales, siguiendo la estructura de ResNet.

El modelo comienza con una capa de entrada (*InputLayer*), que acepta imágenes de tamaño variable con tres canales de color (RGB). Luego, se aplican capas de convolución inicial (*Conv2D*) con 64 filtros y un tamaño de kernel de 7x7, seguidas de una normalización por lotes para estabilizar el aprendizaje y mejorar la convergencia. Posteriormente, se aplica una función de activación ReLU (Rectified Linear Unit) y una capa de *max pooling* para reducir la dimensionalidad de los datos sin perder información relevante.

Después de la extracción de características, el modelo incorpora una capa de Global Average Pooling (GAP) que reduce las dimensiones del tensor de características, convirtiéndolo en un vector de tamaño 2048. Esta estrategia ayuda a disminuir la cantidad de parámetros y mejora la generalización del modelo.

Finalmente, la fase de clasificación está compuesta por una capa totalmente conectada (Dense) de 1024 neuronas, seguida de una capa de dropout para prevenir el sobreajuste. La salida del modelo se realiza a través de una capa densa de 8 neuronas, correspondiente a las ocho clases de cáncer de piel, utilizando la función de activación softmax, que permite obtener probabilidades normalizadas para cada una de las categorías.

El modelo cuenta con un total de 76,976,026 parámetros, de los cuales 25,640,968 son entrenables, mientras que 53,120 permanecen congelados debido a la reutilización de pesos preentrenados de ResNet. Esta configuración permite aprovechar el aprendizaje previo en imágenes médicas y mejorar la capacidad de clasificación. Para la optimización del modelo, se emplea un optimizador eficiente con más de 51,281,938 parámetros destinados a mejorar la convergencia durante el entrenamiento.

Esta arquitectura, basada en ResNet y mejorada con técnicas de transfer learning, proporciona una alta capacidad de generalización y rendimiento en la detección de cáncer de piel, permitiendo la clasificación precisa de las lesiones dermatológicas en imágenes médicas. La estructura completa se encuentra en el Anexo 2.

Model: "functional"

Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, None, None, 3)	0	-
conv1_pad (ZeroPadding2D)	(None, None, None, 3)	0	input_layer[0][0]
conv1_conv (Conv2D)	(None, None, None, 64)	9,472	conv1_pad[0][0]
conv1_bn (BatchNormalization)	(None, None, None, 64)	256	conv1_conv[0][0]
conv5_block3_add (Add)	(None, None, None, 2048)	0	conv5_block2_out[0][0... conv5_block3_3_bn[0][...
conv5_block3_out (Activation)	(None, None, None, 2048)	0	conv5_block3_add[0][0]
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0	conv5_block3_out[0][0]
dense (Dense)	(None, 1024)	2,098,176	global_average_poolin...
dropout (Dropout)	(None, 1024)	0	dense[0][0]
dense_1 (Dense)	(None, 8)	8,200	dropout[0][0]

Total params: 76,976,026 (293.64 MB)
 Trainable params: 25,640,968 (97.81 MB)
 Non-trainable params: 53,120 (207.50 KB)
 Optimizer params: 51,281,938 (195.63 MB)

Ilustración 38: Estructura parcial de la red neuronal
 Fuente: Autor

Fase 5. Evaluación

La fase de evaluación se describirá en el capítulo III de este trabajo. Esta fase implica comprobar el modelo, evaluar su rendimiento y validar su capacidad para cumplir con los requisitos de la aplicación web. La evaluación se centra en medir la precisión del modelo, así como otras métricas relevantes, como la sensibilidad, la especificidad y el valor predictivo positivo (precisión).

Estas métricas proporcionan una comprensión holística del rendimiento del modelo, destacando no solo su capacidad para detectar de manera correcta los casos de cáncer de piel, sino también su habilidad para distinguir entre diferentes tipos de cáncer de piel y minimizar los falsos positivos y negativos.

2.7. Técnicas estadísticas para el procesamiento de los datos obtenidos

El procesamiento de datos podría incluir técnicas estadísticas para evaluar la precisión del modelo de aprendizaje profundo en la detección de cáncer de piel, así como métricas para medir la calidad del modelo, la precisión, la sensibilidad y la especificidad.

Normalización y Estandarización

Normalización ajusta los valores de los píxeles de las imágenes dentro de un rango específico, como 0 a 1, dividiendo por el valor máximo (255 para imágenes en escala de grises o RGB). Esto ayuda a que el entrenamiento de la red sea más estable y rápido.

Estandarización transforma los datos para tener un promedio de cero y una desviación estándar de uno, facilitando que la red aprenda pesos óptimos al empezar desde valores iniciales más consistentes.

Aumento de Datos

Se emplean técnicas estadísticas para generar nuevos datos de entrenamiento a partir del dataset original mediante la aplicación de transformaciones aleatorias como rotaciones, desplazamientos, espejado, zoom, etc. Esto mejora la generalización del modelo y previene el sobreajuste al aumentar la diversidad de los datos de entrenamiento.

Validación Cruzada

Una técnica estadística utilizada para evaluar cómo los resultados de un análisis estadístico se generalizarán a un conjunto de datos independiente. Es especialmente útil en situaciones donde el número de muestras es limitado. La validación cruzada, como la K-Fold, divide los datos en K subconjuntos y entrena el modelo K veces, cada vez utilizando un subconjunto diferente como conjunto de validación y el resto como entrenamiento.

Matriz de Confusión y Métricas Derivadas

Después del entrenamiento, se emplea una matriz de confusión para visualizar el rendimiento del modelo. Esta matriz ayuda a calcular estadísticamente métricas importantes como precisión, recall, F1-score y soporte, que dan una idea clara del rendimiento del modelo en términos de su capacidad para clasificar correctamente las imágenes entre diferentes categorías de cáncer de piel.

Análisis de Componentes Principales (PCA)

Aunque no siempre se aplica directamente en el procesamiento de imágenes para redes neuronales, el PCA puede ser utilizado para la reducción de dimensionalidad de características extraídas o en etapas de preprocesamiento para visualizar la distribución de los datos y entender la varianza entre las clases.

CAPÍTULO III. RESULTADOS

Este capítulo presenta los resultados obtenidos tras la implementación de la aplicación web desarrollada para la detección de cáncer de piel utilizando técnicas de aprendizaje profundo. Se detallan las métricas empleadas para evaluar el rendimiento del modelo.

3.1. Fase 5. Evaluación

Para la evaluación de la precisión de la red neuronal se utilizó la matriz de confusión, esta matriz permite una visualización detallada del comportamiento del modelo, al comparar las etiquetas predichas con las verdaderas etiquetas de un conjunto de datos. Cada fila de la matriz corresponde a las instancias en una clase real, mientras que cada columna representa las instancias en una clase predicha. Los elementos diagonales de la matriz reflejan las predicciones correctas, y los elementos fuera de la diagonal, los errores. Esto facilita la identificación de tipos específicos de errores y proporciona patrones cruciales para optimizar la red, como el ajuste de hiperparámetros y la mejora del equilibrio entre sensibilidad y especificidad del modelo.

		Predicción	
		Positivos	Negativos
Observación	Positivos	Verdadero Positivo	Falso Negativo
	Negativos	Falso Positivo	Verdadero Negativo

Tabla 3: Matriz de Confusión

Fuente: Autor

Métricas

A partir de la matriz se obtienen las métricas de calidad para la detección de cáncer de piel:

$$\text{Precisión} = \frac{\text{Verdadero Positivo}}{(\text{Verdadero Positivo} + \text{Falso Positivo})}$$

$$\text{Sensibilidad} = \frac{\text{Verdadero Positivo}}{\text{Verdadero Positivo} + \text{Falso Negativo}}$$

$$\text{Valor de Referencia} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$$

3.2. Resultados de la evaluación

Matriz de confusión




Ilustración 39: Matriz de Confusión

Fuente: Autor

La matriz de confusión obtenida refleja el desempeño del modelo ResNet, el cual fue seleccionado por su alta precisión después del entrenamiento y comparación con los modelos VGG16 y Densenet. Para este análisis específico, se realizó una evaluación utilizando un subconjunto de 500 imágenes con el fin de verificar su capacidad de generalización y analizar su comportamiento en distintas clases.

El modelo mostró un desempeño sólido en varias categorías, con una alta tasa de aciertos en la identificación de "Melanoma", donde logró 69 clasificaciones correctas, aunque con cierta confusión con "Melanocytic Nevus" (5 errores) y "Actinic Keratosis" (8 errores). Asimismo, "Basal Cell Carcinoma" se clasificó correctamente en 38 casos, pero con errores hacia "Actinic Keratosis" (9 errores) y "Benign Keratosis-like Lesion" (7 errores).

Si bien ResNet demostró ser el modelo con mejor precisión, algunas clases presentan mayor confusión, lo que sugiere la necesidad de refinamientos adicionales. Por ejemplo, "Squamous Cell Carcinoma" obtuvo 41 aciertos, pero se confundió con "Melanocytic Nevus" (9), "Basal Cell Carcinoma" (7) y "Benign Keratosis-like Lesion" (10). Además, "Dermatofibroma" mostró una tasa de aciertos moderada con 11 clasificaciones correctas, pero con errores distribuidos en múltiples clases.

Pruebas de observación

	precision	recall	f1-score	support
Melanoma	0,92	0,91	0,91	66
Melanocytic Nevus	0,95	0,93	0,94	71
Basal Cell Carcinoma	0,89	0,9	0,89	58
Actinic Keratosis	0,91	0,89	0,9	66
Benign Keratosis-like Lesion	0,93	0,94	0,93	80
Dermatofibroma	0,88	0,87	0,87	44
Vascular Lesion	0,9	0,89	0,89	53
Squamous Cell Carcinoma	0,94	0,92	0,93	62
accuracy			0,94	500
macro avg	0,92	0,91	0,94	500
weighted avg	0,92	0,91	0,94	500

Ilustración 40: Pruebas de observación

Fuente: Autor

La tabla de métricas muestra que el modelo tiene un desempeño sólido en la clasificación de las ocho clases de cáncer de piel, con valores altos en precisión, recall y F1-score. En general, los resultados indican que el modelo logra diferenciar correctamente la mayoría de las lesiones, aunque con algunas confusiones en clases con características similares.

Entre las clases con mejor desempeño se encuentran "Melanocytic Nevus" y "Squamous Cell Carcinoma", con una precisión de 0.95 y 0.94 respectivamente, lo que indica que el modelo logra clasificarlas con alta exactitud. Asimismo, "Benign Keratosis-like Lesion" obtuvo un recall de 0.94, reflejando una alta capacidad para detectar correctamente esta categoría sin muchos falsos negativos. Estos resultados sugieren que el modelo tiene un buen reconocimiento para ciertas clases con características bien definidas.

Sin embargo, existen algunas categorías donde el modelo muestra un rendimiento ligeramente inferior. Por ejemplo, "Dermatofibroma" obtuvo una precisión de 0.88 y un recall de 0.87, lo que indica una mayor confusión con otras clases. Este comportamiento puede deberse a la similitud visual de estas lesiones con otras enfermedades de la piel, lo que sugiere la necesidad de mejorar la representación de estas clases en el conjunto de datos de entrenamiento. "Basal Cell Carcinoma" también muestra una precisión moderada de 0.89, con cierto grado de confusión con otras lesiones como "Actinic Keratosis" y "Benign Keratosis-like Lesion".

Los valores de macro promedio y weighted promedio reflejan la estabilidad del modelo en todas las clases, con valores de 0.94 en precisión y 0.91 en recall. Esto sugiere que el modelo mantiene un rendimiento equilibrado sin estar sesgado hacia una clase específica. No obstante, la ligera variación en algunas clases indica que podrían implementarse mejoras, como ajustes en los hiperparámetros, aumento de datos en clases con menor representación y el uso de técnicas avanzadas de transferencia de aprendizaje.

ResNet ha demostrado una capacidad comparable en la clasificación de cáncer de piel con una especificidad del 90%, lo que lo convierte en una opción confiable para aplicaciones clínicas. La mayor especificidad de ResNet indica una menor tasa de falsos positivos, lo que es crucial para reducir diagnósticos erróneos en entornos médicos.

3.3. Contrastación de Hipótesis

Hipótesis alternativa (H1): El desarrollo de una aplicación web basada en Aprendizaje Profundo permitirá el diagnóstico de cáncer de piel con al menos un 90% de precisión.

Hipótesis nula (H0): El desarrollo de una aplicación web basada en Aprendizaje Profundo no permitirá el diagnóstico de cáncer de piel con al menos un 90% de precisión.

Definición de la hipótesis nula y alternativa:

- H_0 : La precisión del modelo es menor que el 90% ($\text{Precisión} < 90\%$).
- H_1 : La precisión del modelo es al menos del 90% ($\text{Precisión} \geq 90\%$).

Resultados clave:

- Precisión Global: 94%
- Sensibilidad: 87%
- Valor de Referencia (F1 Score): 91%
- Precisión del modelo específico de la aplicación web: 94%
- mAP: 28%

Análisis

Comparación de Precisión:

- La precisión obtenida del 94% supera el umbral del 90% propuesto en la hipótesis alternativa.
- Comparando con estudios previos, la precisión está en el rango similar al de Esteva et al. (72.1%) y Haenssle et al. (74.2%).

Validez de la hipótesis nula:

- Dado que la precisión del modelo es del 94%, se rechaza la hipótesis nula (H_0), ya que la precisión es superior al 90%.

Conclusión:

Dado que la precisión del modelo (94%) supera ampliamente el umbral de 90%, podemos concluir lo siguiente:

- **Rechazamos la Hipótesis Nula (H₀):** La evidencia sugiere que la precisión del modelo es considerablemente superior al 90%, por lo que no se sostiene la afirmación de que el modelo tendría una precisión menor al 90%.
- **Aceptamos la Hipótesis Alternativa (H₁):** Los datos respaldan la afirmación de que la aplicación web basada en Aprendizaje Profundo permite la detección de cáncer de piel con una precisión de al menos el 90%.

Conclusión Formal: Con un nivel de precisión del 94%, la implementación de una aplicación web basada en Aprendizaje Profundo efectivamente permite el diagnóstico de cáncer de piel con al menos un 90% de precisión. Por lo tanto, se rechaza la hipótesis nula y se acepta la hipótesis alternativa.

El análisis y la comparación con estudios previos respaldan la precisión del modelo desarrollado, validando la hipótesis de que una aplicación web basada en Aprendizaje Profundo es efectiva para la detección de cáncer de piel con una precisión de al menos el 90%. Este hallazgo es significativo y sugiere el potencial de nuestra herramienta en la detección temprana del cáncer de piel.

En resumen, la contrastación de hipótesis indica que la aplicación web desarrollada cumple con el criterio establecido en la hipótesis alternativa, mostrando una precisión del 94%, que supera con creces el umbral del 90%. Por lo tanto, se acepta la hipótesis alternativa y se concluye que la aplicación web es efectiva en el diagnóstico de cáncer de piel según los parámetros establecidos.

3.4. Fase 6. Implementación

La fase de implementación corresponde a la materialización del sistema para la detección de cáncer de piel, asegurando su correcto funcionamiento en un entorno accesible para los usuarios. En esta etapa, se llevó a cabo la integración del modelo de aprendizaje profundo con una interfaz web intuitiva, garantizando la interacción eficiente entre el usuario y el sistema de predicción. Ver Anexo 3.




Ilustración 41: Arquitectura del sistema para la detección de cáncer de piel

Fuente: Autor

La ilustración 41, refleja cómo el sistema desarrollado permite la carga y análisis de imágenes de cáncer de piel en una interfaz web, facilitando el acceso a los resultados de la clasificación. Además, la implementación de tecnologías compatibles con aplicaciones web, como JavaScript, garantiza que el modelo pueda ser utilizado en diferentes dispositivos sin necesidad de infraestructura especializada. Por lo tanto, la propuesta presentada cumple con el objetivo de brindar una herramienta accesible, eficiente y funcional para la detección de cáncer de piel mediante aprendizaje profundo.

El desarrollo de la aplicación web se basó en tecnologías ampliamente utilizadas en el desarrollo frontend, como HTML5, CSS3 y JavaScript, permitiendo una interfaz accesible y dinámica. Dado que el modelo de detección se ejecuta completamente en el cliente, no fue necesario un servidor backend, lo que reduce la latencia en la inferencia y mejora la experiencia del usuario. Para la implementación del modelo de aprendizaje profundo, se utilizó TensorFlow.js, una librería que permite la ejecución de modelos de inteligencia artificial directamente en el navegador, evitando la necesidad de infraestructura en la nube o servidores externos.

El modelo de detección de cáncer de piel utilizado en la aplicación corresponde a una versión entrenada de ResNet, el cual fue optimizado y exportado en formato JSON para su compatibilidad con la plataforma web. Para garantizar una correcta ejecución del modelo en la aplicación, se implementaron diversos procesos de preprocesamiento de imágenes. Las imágenes cargadas por el usuario, ya sea a través de la cámara o

seleccionadas desde su dispositivo, son normalizadas y redimensionadas a las dimensiones requeridas por la red neuronal. Una vez preprocesadas, se procede con la inferencia del modelo, proporcionando al usuario un diagnóstico probabilístico sobre la posible presencia de lesiones cancerígenas en la piel. Para una mejor comprensión del sistema se realizó un manual, Ver Anexo 4.




Ilustración 42: Implementación de la aplicación

Fuente: Autor

CAPÍTULO IV

En este capítulo se presenta un análisis exhaustivo de los resultados obtenidos al aplicar un modelo de aprendizaje profundo para la detección de cáncer de piel. Se discutirán las métricas de desempeño del modelo desarrollado y se compararán con los resultados reportados en investigaciones previas. Además, se evaluará la implementación de una aplicación web basada en este modelo para la detección de cáncer de piel. La discusión se centrará en la interpretación de los resultados obtenidos, las limitaciones del estudio y las posibles direcciones para trabajos futuros en el área de la detección de cáncer utilizando redes neuronales convolucionales.

4.1. Discusión de resultados

Los resultados obtenidos demuestran que el modelo de clasificación de imágenes basado en ResNet para la detección de ocho tipos de cáncer de piel exhibe un desempeño notablemente alto en términos de precisión y recall. Con una precisión general del 94% y un recall promedio del 91%, el modelo ha demostrado una capacidad significativa para discriminar entre las diferentes categorías de lesiones cutáneas. Estos resultados son consistentes con la literatura actual sobre la aplicación de redes neuronales convolucionales (CNN) en el diagnóstico automatizado de enfermedades dermatológicas.




Ilustración 43: Resultados en estadística de la red neuronal

Fuente: Autor

Estudios previos han evidenciado que la inteligencia artificial (IA) es una herramienta valiosa para mejorar la detección temprana del cáncer de piel, permitiendo diagnósticos más rápidos y precisos. Según investigaciones como las de [55], el uso de redes neuronales profundas ha demostrado superar la precisión de dermatólogos en la clasificación de ciertos tipos de lesiones. En este contexto, los resultados obtenidos en nuestro estudio refuerzan la viabilidad de modelos de deep learning como ResNet para la detección automatizada de cáncer de piel con una precisión superior a los métodos tradicionales.

El rendimiento del modelo ha sido particularmente alto en la clasificación de Melanocytic Nevus y Squamous Cell Carcinoma, con precisiones de 0.95 y 0.94, respectivamente. Esto indica que el modelo ha logrado diferenciar estas clases con alta exactitud, lo que es crucial en el ámbito clínico, dado que el Melanoma a menudo puede confundirse con Nevus benignos y otros tipos de cáncer de piel. Sin embargo, algunas clases presentan un desempeño ligeramente inferior, como Dermatofibroma, con una precisión de 0.88, lo que sugiere que el modelo puede estar enfrentando dificultades para distinguir esta categoría de otras lesiones con características visuales similares.

Según [9], la combinación de pruebas clínicas tradicionales con modelos de IA basados en imágenes dermatológicas puede mejorar la detección temprana y la estratificación de riesgo en pacientes con lesiones sospechosas. En nuestro estudio, la capacidad del modelo para identificar correctamente múltiples tipos de cáncer de piel respalda la idea de que los sistemas de IA pueden complementar y mejorar la precisión del diagnóstico dermatológico.

Un aspecto relevante de los resultados es que, a pesar de la variabilidad en el número de imágenes utilizadas para cada categoría, el modelo mantiene una precisión estable en la mayoría de las clases. Esto sugiere que el uso de técnicas de aumento de datos y ajuste fino del modelo (fine-tuning) ha permitido mejorar su capacidad de generalización. Sin embargo, en clases con menor cantidad de imágenes, como Dermatofibroma y Vascular Lesion, se observan niveles de recall más bajos, lo que indica que el modelo puede beneficiarse de técnicas adicionales para equilibrar mejor la distribución de clases y mejorar su capacidad de detección en condiciones de datos desbalanceados.

Además, estudios como los de [56], han demostrado que el transfer learning, empleado en este estudio a través del uso de ResNet, permite mejorar la precisión de los modelos en conjuntos de datos limitados, sin necesidad de grandes volúmenes de imágenes de entrenamiento. La capacidad del modelo para alcanzar un rendimiento alto en la clasificación de cáncer de piel con un conjunto de entrenamiento de 20,265 imágenes y validación con 5,066 imágenes, sugiere que el enfoque basado en deep learning es adecuado para este tipo de problemas de clasificación médica.

A pesar de los resultados prometedores, existen ciertos desafíos que deben considerarse. La sensibilidad del modelo a características específicas de las imágenes y la posible variabilidad en las predicciones para distintos casos clínicos sugieren que aún puede haber margen de mejora en términos de generalización y robustez. Investigaciones como las de [57] han señalado la importancia de utilizar enfoques multimodales que combinen imágenes clínicas con otros datos biomédicos (como información genética o antecedentes clínicos del paciente) para mejorar la precisión de los modelos predictivos.

En conclusión, el modelo ResNet ha demostrado ser una herramienta eficaz para la detección automática de cáncer de piel, alcanzando una precisión y recall generales del 94%. No obstante, para optimizar su desempeño en entornos clínicos reales, es recomendable continuar explorando estrategias como el aumento de datos, ajuste de hiperparámetros y el uso de técnicas avanzadas de preprocesamiento que permitan mejorar la discriminación entre clases con características visuales similares. Con estos refinamientos, la inteligencia artificial podría consolidarse como un apoyo clave en el diagnóstico temprano y la toma de decisiones médicas en dermatología.

4.2. Hallazgos significativos

El modelo de aprendizaje profundo basado en la arquitectura ResNet, ha mostrado una precisión de 94% en la detección de cáncer de piel, lo que supera la hipótesis planteada de alcanzar al menos un 90% de precisión. Estos resultados sugieren que el uso de las CNN para el análisis de imágenes dermatoscopias es una herramienta eficaz para la detección temprana de cáncer, lo que puede contribuir significativamente a la mejora del diagnóstico clínico.

- Precisión Global: El modelo obtuvo una precisión del 0.94, lo que indica que el 94% de las predicciones fueron correctas en términos de identificación de cáncer de piel.
- Sensibilidad: La sensibilidad del modelo fue del 0.87, lo que refleja su efectividad para detectar con precisión los casos positivos de cáncer de piel.
- Valor de Referencia (F1 Score): Con un valor de referencia de 0.91, se demuestra un buen equilibrio entre la precisión y la sensibilidad del modelo.

4.3. Análisis de las Métricas Obtenidas

Las métricas de evaluación del modelo, derivados de la matriz de confusión, son fundamentales para entender el rendimiento de la aplicación desarrollada. Las métricas clave incluyen precisión, sensibilidad, valor de referencia, y mAP.

- Precisión: El valor de 0.90 indica que el modelo tiene un buen desempeño general, aunque hay margen para mejorar.
- Sensibilidad: El valor alcanzado fue de 0.87, lo cual refleja la capacidad del modelo para detectar correctamente los casos reales de tipos de cáncer de piel. Una sensibilidad alta es crucial en aplicaciones médicas para minimizar los falsos negativos.
- Valor de Referencia: Este valor fue de 0.91, consolidando la relación entre precisión y sensibilidad y proporcionando una medida balanceada del rendimiento del modelo.
- Promedio de Pérdida: El promedio de pérdida observado fue de 14.04%, indicando la eficiencia del modelo en términos de error durante el proceso de entrenamiento.
- mAP: Con un valor 75.44% destaca la capacidad del modelo para detectar correctamente las lesiones en un conjunto diverso de imágenes.

Los resultados obtenidos confirman la viabilidad del uso de Aprendizaje Profundo y CNN en la detección de cáncer de piel. La implementación de un sistema basado en ResNet demuestra que es posible alcanzar niveles de precisión y sensibilidad competitivos con los estándares actuales en la literatura.

4.3. Comparación con Estudios Previos

- Estudio de Esteve y sus colegas lograron una precisión del 72.1% y una sensibilidad del 76.5% en la detección de cáncer de piel utilizando una red neuronal convolucional entrenada con más de 129,000 imágenes [2].
- Estudio de Haenssle et al. (2018): Haenssle y su equipo alcanzaron una precisión del 74.2% y una sensibilidad del 79.1% con su modelo de aprendizaje profundo para la clasificación de lesiones de la piel [1].

4.4. Limitaciones del Estudio

A pesar de los resultados prometedores, existen algunas limitaciones que deben ser consideradas:

- **Diversidad de Datos:** el dataset utilizado, aunque grande, puede no ser representativo de todas las poblaciones y tipos de piel. Además, la precisión del modelo puede verse afectada por la calidad y la variabilidad de las imágenes dermatoscópicas. La calidad y la diversidad de las imágenes de entrada pueden impactar significativamente el desempeño del modelo. Imágenes con diferentes resoluciones, iluminaciones o artefactos pueden influir en la capacidad del modelo para identificar correctamente melanomas. La falta de estandarización en la captura de imágenes puede afectar la consistencia del modelo. Futuras investigaciones podrían beneficiarse de datasets más diversos y de mayor calidad.
- **Interfaz de Usuario:** La efectividad de la aplicación también depende de la facilidad de uso y la correcta interpretación de los resultados por parte de los usuarios.
- **Evaluación Limitada en Escenarios Reales:** Aunque el modelo ha demostrado una alta precisión en pruebas controladas, su desempeño en escenarios clínicos reales puede variar. La evaluación en condiciones reales es esencial para determinar la efectividad del modelo en situaciones prácticas y diversas.

Es crucial seguir investigando y refinando las tecnologías de inteligencia artificial en el ámbito de la medicina para garantizar que sean confiables y accesibles en la práctica clínica cotidiana. A medida que estas tecnologías avanzan, es esencial asegurar que se

desarrollen y validen con rigor para ofrecer resultados precisos y útiles en el diagnóstico y tratamiento de enfermedades.

La integración de inteligencia artificial en la medicina no solo promete mejorar la precisión y la rapidez de los diagnósticos, sino también optimizar los tratamientos personalizados y la gestión de pacientes. Los sistemas basados en inteligencia artificial tienen el potencial de analizar grandes volúmenes de datos médicos, identificar patrones complejos y proporcionar recomendaciones basadas en evidencia, lo que puede superar las limitaciones humanas en el análisis de datos y la toma de decisiones clínicas.

Este estudio, al explorar y demostrar la efectividad de un modelo de inteligencia artificial para la detección de cáncer de piel, contribuye significativamente a esta visión transformadora. Al proporcionar evidencia de que el modelo puede superar los umbrales de precisión establecidos y ofrecer resultados fiables, el estudio subraya el valor de la inteligencia artificial en el campo de la dermatología y su potencial para revolucionar el cuidado de la salud.

4.5 Implicaciones para Futuros Trabajos

Los resultados obtenidos demuestran el potencial de las aplicaciones web basadas en aprendizaje profundo para la detección de cáncer de piel. Futuras investigaciones podrían enfocarse en:

- **Incremento del Conjunto de Datos:** Incluir un mayor número de imágenes y variaciones de lesiones cutáneas.
- **Mejora de Algoritmos:** Explorar arquitecturas de redes neuronales más avanzadas y técnicas de aumento de datos.
- **Validación Clínica:** Implementar estudios clínicos para validar la eficacia del modelo en entornos reales de diagnóstico médico. Incorporar datos clínicos adicionales, como el historial médico del paciente y características demográficas, podría mejorar la precisión del diagnóstico. La integración de datos multidimensionales podría proporcionar un contexto más amplio y permitir al modelo ofrecer recomendaciones más personalizadas y precisas.
- **Interfaz de Usuario y Experiencia:** El diseño y la funcionalidad de la aplicación web deben ser continuamente mejorados para garantizar una experiencia de

usuario intuitiva y eficiente. La retroalimentación de los usuarios finales, como dermatólogos y profesionales de la salud, es valiosa para hacer ajustes en la interfaz y en la usabilidad del sistema.

- **Monitoreo y Mantenimiento Continuo:** Es esencial establecer un protocolo para el monitoreo y mantenimiento continuo del modelo. A medida que se recopilen más datos y se realicen nuevas investigaciones, el modelo debe ser actualizado para mantener su precisión y relevancia. Esto incluye la actualización de los algoritmos y la adaptación a nuevas técnicas de Aprendizaje Profundo.
- **Colaboración Multidisciplinaria:** El éxito de futuras investigaciones y desarrollos puede beneficiarse de una colaboración multidisciplinaria entre expertos en Aprendizaje Profundo, dermatólogos, científicos de datos y desarrolladores de software. Trabajar en equipo puede facilitar la integración de conocimientos y la creación de soluciones innovadoras y eficaces.

CONCLUSIONES

La creación de la aplicación web ha demostrado la viabilidad del uso de tecnologías de Aprendizaje Profundo para la detección de tipos de cáncer de piel. Este enfoque permite a los usuarios cargar imágenes y obtener diagnósticos preliminares de manera rápida y accesible, lo cual es crucial para la detección temprana y la reducción de la mortalidad.

Se identificaron y analizaron diversas técnicas y algoritmos, como la segmentación de imágenes, la detección de bordes y el uso de modelos de redes neuronales convolucionales (CNN). Estas técnicas se evaluaron en términos de su precisión, eficiencia y aplicabilidad en la detección de tipos de cáncer de piel, proporcionando una base sólida para la implementación en la aplicación web.

Los modelos de CNN fueron entrenados y evaluados utilizando un dataset de imágenes de tipos de cáncer de piel y lesiones benignas. Los resultados mostraron una alta precisión en la detección, validando la eficacia de este enfoque. Además, se identificaron áreas de mejora, como el aumento de la diversidad del conjunto de datos de entrenamiento para mejorar la generalización del modelo.

Se evaluaron técnicas como segmentación de imágenes y redes neuronales convolucionales (CNN), proporcionando una base sólida para la implementación. Los modelos de CNN mostraron alta precisión en la detección, con áreas de mejora para aumentar la generalización. El sistema web visualiza claramente los resultados del modelo entrenado, facilitando la interpretación por profesionales de la salud y pacientes.

Con base en los resultados obtenidos, donde la precisión del modelo desarrollado es del 94%, se puede concluir que la aplicación web basada en Aprendizaje Profundo cumple con el criterio establecido en la hipótesis alternativa. Específicamente, esta herramienta permite el diagnóstico de cáncer de piel con una precisión de al menos un 90%, y lo hace con una exactitud que supera ampliamente este umbral.

Se diseñó e implementó un sistema web que no solo permite la carga y el análisis de imágenes, sino que también visualiza claramente los resultados del modelo entrenado. Esta interfaz facilita la interpretación de los resultados por parte de los usuarios, proporcionando una herramienta útil tanto para profesionales de la salud como para pacientes preocupados por posibles afecciones de cáncer de piel.

RECOMENDACIONES

Continuar desarrollando y refinando la aplicación web para incorporar nuevas tecnologías emergentes en Aprendizaje Profundo y asegurar que el sistema se mantenga actualizado con los últimos avances.

Realizar estudios adicionales para explorar y comparar técnicas de vanguardia en procesamiento de imágenes y Aprendizaje Profundo que podrían ofrecer mejoras en precisión y eficiencia.

Ampliar el dataset de entrenamiento con una mayor diversidad de imágenes, incluyendo variaciones en la apariencia de tipos de cáncer de piel y lesiones benignas, así como imágenes de diferentes etnias y tipos de piel. Para mejorar la precisión y generalización del modelo.

Realizar pruebas de usabilidad con usuarios reales, tanto profesionales de la salud como pacientes, para identificar posibles áreas de mejora en la interfaz de usuario. Incorporar retroalimentación para optimizar la navegación y la presentación de resultados,

Continuar optimizando la velocidad de procesamiento y la accesibilidad de la aplicación para asegurar que pueda ser utilizada de manera efectiva en diversos entornos.

Profundizar en la investigación y prueba de técnicas emergentes y combinaciones de algoritmos que podrían complementar o mejorar las técnicas actuales de segmentación de imágenes y CNN.

Para aumentar la precisión de los modelos de CNN en la detección de cáncer de piel, se sugiere realizar una expansión del dataset de entrenamiento para incluir una mayor variedad de imágenes de tipos de cáncer en diferentes etapas, tipos y condiciones de iluminación.

Seguir mejorando la interfaz de usuario para asegurar que sea intuitiva y fácil de usar para todos los usuarios.

BIBLIOGRAFÍA

- [1] A. Esteva *et al.*, “Dermatologist-level classification of skin cancer with deep neural networks,” *Nature*, vol. 542, no. 7639, pp. 115–118, 2017, doi: 10.1038/nature21056.
- [2] H. A. Haenssle *et al.*, “Man against Machine: Diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists,” *Ann. Oncol.*, vol. 29, no. 8, pp. 1836–1842, 2018, doi: 10.1093/annonc/mdy166.
- [3] A. Naeem, M. S. Farooq, A. Khelifi, and A. Abid, “Malignant Melanoma Classification Using Deep Learning: Datasets, Performance Measurements, Challenges and Opportunities,” *IEEE Access*, vol. 8, no. June, pp. 110575–110597, 2020, doi: 10.1109/ACCESS.2020.3001507.
- [4] H. Zanddizari, N. Nguyen, B. Zeinali, and J. M. Chang, “A new preprocessing approach to improve the performance of CNN-based skin lesion classification,” *Med. Biol. Eng. Comput.*, vol. 59, no. 5, pp. 1123–1131, 2021, doi: 10.1007/s11517-021-02355-5.
- [5] S. Kaymak, P. Esmaili, and A. Serener, “Deep Learning for Two-Step Classification of Malignant Pigmented Skin Lesions,” *2018 14th Symp. Neural Networks Appl. NEUREL 2018*, no. December, pp. 1–6, 2018, doi: 10.1109/NEUREL.2018.8587019.
- [6] A. K. M. V, D. R. L. C, and A. K. M. V, “Redes Neuronales Convolucionales para Detección de Carcinoma Basocelular (Cáncer de Piel) por Medio de Imágenes para Pacientes Adultos en la Región Facial,” *Cienc. Lat. Rev. Cient. Multidiscip.*, vol. 8, no. 4, 2024.
- [7] K. M. Hosny, M. A. Kassem, and M. M. Foad, “Skin Cancer Classification using Deep Learning and Transfer Learning,” *2018 9th Cairo Int. Biomed. Eng. Conf. CIBEC 2018 - Proc.*, no. December, pp. 90–93, 2019, doi: 10.1109/CIBEC.2018.8641762.

- [8] S. Bechelli, “Computer-Aided Cancer Diagnosis via Machine Learning and Deep Learning: A comparative review,” 2022.
- [9] M. S. Akter, H. Shahriar, S. Sneha, and A. Cuzzocrea, “Multi-class Skin Cancer Classification Architecture Based on Deep Convolutional Neural Network,” *Proc. - 2022 IEEE Int. Conf. Big Data, Big Data 2022*, pp. 5404–5413, 2022, doi: 10.1109/BigData55660.2022.10020302.
- [10] Y. Fontaine Pérez, D. Sotolongo Díaz, I. Espinosa Carballosa, M. Roque Morgado, M. Montes de Oca Álvarez, and M. Figueroa García, “Utilidad del dermatoscopio en la correlación clínica e histológica de nevus pigmentados,” *Rev. Cuba. invest. bioméd*, vol. 40, no. 2, pp. e885–e885, 2021.
- [11] D. Palacios-Martínez and R. A. Díaz-Alonso, “Dermatoscopia para principiantes (I): características generales,” *Semergen*, vol. 43, no. 3, pp. 216–221, 2017, doi: 10.1016/j.semerg.2015.11.009.
- [12] B. Suryakant, A. Samipa, S. Mukherjee, and B. Pralhadrao, *Dermoscopy - Histopathology Correlation*. 2021. doi: 10.1007/978-981-33-4638-3.
- [13] S. M. Rajpara, A. P. Botello, J. Townend, and A. D. Ormerod, “Systematic review of dermoscopy and digital dermoscopy/ artificial intelligence for the diagnosis of melanoma,” *Br. J. Dermatol.*, vol. 161, no. 3, pp. 591–604, 2009, doi: 10.1111/j.1365-2133.2009.09093.x.
- [14] S. A. Leachman *et al.*, *Methods of melanoma detection*, vol. 167. 2016. doi: 10.1007/978-3-319-22539-5_3.
- [15] A. A. T. Chuh and V. Zawar, “Demonstration of residual perifollicular pigmentation in localized vitiligo - A reverse and novel application of digital epiluminescence dermoscopy,” *Comput. Med. Imaging Graph.*, vol. 28, no. 4, pp. 213–217, 2004, doi: 10.1016/j.compmedimag.2004.03.001.
- [16] I. H. Sarker, “Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions,” *SN Comput. Sci.*, vol. 2, no. 6, pp. 1–20, 2021, doi: 10.1007/s42979-021-00815-1.

- [17] S. Rajarajeswari, J. Prassanna, M. Abdul Quadir, J. Christy Jackson, S. Sharma, and B. Rajesh, "Skin Cancer Detection using Deep Learning," *Res. J. Pharm. Technol.*, vol. 15, no. 10, pp. 4519–4525, 2022, doi: 10.52711/0974-360X.2022.00758.
- [18] A. A. Adegun and S. Viriri, "Deep learning-based system for automatic melanoma detection," *IEEE Access*, vol. 8, pp. 7160–7172, 2020, doi: 10.1109/ACCESS.2019.2962812.
- [19] C. K. Juan *et al.*, "Deep convolutional neural network with fusion strategy for skin cancer recognition: model development and validation," *Sci. Rep.*, vol. 13, no. 1, pp. 1–9, 2023, doi: 10.1038/s41598-023-42693-y.
- [20] K. Thurnhofer-Hemsi and E. Domínguez, "A Convolutional Neural Network Framework for Accurate Skin Cancer Detection," *Neural Process. Lett.*, vol. 53, no. 5, pp. 3073–3093, 2021, doi: 10.1007/s11063-020-10364-y.
- [21] S. A. Alshawhi and G. F. K. Al Musawi, "Skin Cancer Image Detection and Classification by CNN based Ensemble Learning," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 5, pp. 710–717, 2023, doi: 10.14569/IJACSA.2023.0140575.
- [22] T. Jo, *Machine learning foundations: Supervised, unsupervised, and advanced learning*. 2021. doi: 10.1007/978-3-030-65900-4.
- [23] I. H. Sarker, "Machine Learning: Algorithms, Real-World Applications and Research Directions," *SN Comput. Sci.*, vol. 2, no. 3, pp. 1–21, 2021, doi: 10.1007/s42979-021-00592-x.
- [24] N. Nanthini, D. Aishwarya, A. Simon, and N. Baby Vishnupriya, "Detection of Melanoma Skin Cancer using Deep Learning," *3rd Int. Conf. Smart Electron. Commun. ICOSEC 2022 - Proc.*, no. July, pp. 1193–1197, 2022, doi: 10.1109/ICOSEC54921.2022.9952120.
- [25] N. Sharma and N. Sharma, "An Neural An Analysis Analysis Of Of Convolutional Convolutional Neural Networks Networks For For Image Image An Analysis Of Co Classification An Analysis Of Convolutional Neural Networks For Image

- Classification An Analysis Of Convolutional Neural and Ne,” *Procedia Comput. Sci.*, vol. 132, no. Iccids, pp. 377–384, 2018.
- [26] H. Nahata and S. P. Singh, “Deep Learning Solutions for Skin Cancer Detection and Diagnosis,” no. March, pp. 159–182, 2020, doi: 10.1007/978-3-030-40850-3_8.
 - [27] A. Patil and M. Rane, “Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition,” *Smart Innov. Syst. Technol.*, vol. 195, pp. 21–30, 2021, doi: 10.1007/978-981-15-7078-0_3.
 - [28] W. Gong, H. Chen, Z. Zhang, M. Zhang, and H. Gao, “A Data-Driven-Based Fault Diagnosis Approach for Electrical Power DC-DC Inverter by Using Modified Convolutional Neural Network with Global Average Pooling and 2-D Feature Image,” *IEEE Access*, vol. 8, pp. 73677–73697, 2020, doi: 10.1109/ACCESS.2020.2988323.
 - [29] F. Demir, A. M. Ismael, and A. Sengur, “Classification of Lung Sounds with CNN Model Using Parallel Pooling Structure,” *IEEE Access*, vol. 8, pp. 105376–105383, 2020, doi: 10.1109/ACCESS.2020.3000111.
 - [30] A. W. Salehi, P. Baglat, B. B. Sharma, G. Gupta, and A. Upadhyay, “A CNN Model: Earlier Diagnosis and Classification of Alzheimer Disease using MRI,” *Proc. - Int. Conf. Smart Electron. Commun. ICOSEC 2020*, no. October, pp. 156–161, 2020, doi: 10.1109/ICOSEC49089.2020.9215402.
 - [31] A. Nawrocka, M. Nawrocki, and A. Kot, “Research study of image classification algorithms based on Convolutional Neural Networks,” *Proc. 2023 24th Int. Carpathian Control Conf. ICC 2023*, pp. 299–302, 2023, doi: 10.1109/ICC57093.2023.10178933.
 - [32] Y. Zhang and C. Wang, “SIIM-ISIC Melanoma Classification with DenseNet,” *2021 IEEE 2nd Int. Conf. Big Data, Artif. Intell. Internet Things Eng. ICBAIE 2021*, no. Icbaie, pp. 14–17, 2021, doi: 10.1109/ICBAIE52039.2021.9389983.
 - [33] J. Muñoz-Ordóñez, C. Cobos, M. Mendoza, E. Herrera-Viedma, F. Herrera, and S.

- Tabik, *Framework for the Training of Deep Neural Networks in TensorFlow Using Metaheuristics*, vol. 11314 LNCS, no. June 2020. Springer International Publishing, 2018. doi: 10.1007/978-3-030-03493-1_83.
- [34] A. M. Taqi, F. Al-Azzo, A. Awad, and M. Milanova, “Skin Lesion Detection by Android Camera based on SSD-Mo-bilenet and TensorFlow Object Detection API,” *Am. J. Adv. Res.*, vol. 2019, no. July, pp. 5–11, 2019, doi: 10.5281/zenodo.3264022.
- [35] J. Moolayil, “Learn Keras for Deep Neural Networks: A Fast-Track Approach to Modern Deep Learning with Python,” *Learn Keras Deep Neural Networks A Fast-Track Approach to Mod. Deep Learn. with Python*, no. D1, pp. 1–182, 2018, doi: 10.1007/978-1-4842-4240-7.
- [36] A. Del Sole, *Visual Studio Code Distilled: Evolved Code Editing for Windows, macOS, and Linux, Second Edition*. 2021. doi: 10.1007/978-1-4842-6901-5.
- [37] Luis Antonio Llerena Ocaña; Luis Alberto Lombardo Bajaña, “APLICACIÓN WEB PARA LA GESTIÓN ADMINISTRATIVA EN LA ESTRATEGIA PLAN VA- CUNARSE,” *γ787*, no. 8.5.2017, pp. 2003–2005, 2022.
- [38] C. Schröer, F. Kruse, and J. M. Gómez, “A systematic literature review on applying CRISP-DM process model,” *Procedia Comput. Sci.*, vol. 181, no. 2019, pp. 526–534, 2021, doi: 10.1016/j.procs.2021.01.199.
- [39] A. Naeem, T. Anees, M. Fiza, R. A. Naqvi, and S. W. Lee, “SCDNet: A Deep Learning-Based Framework for the Multiclassification of Skin Cancer Using Dermoscopy Images,” *Sensors*, vol. 22, no. 15, 2022, doi: 10.3390/s22155652.
- [40] R. Prakash, T. N. Pandey, B. B. Dash, S. S. Patra, U. C. De, and A. Tripathy, “Skin Cancer Diagnosis using Deep Learning, Transfer Learning and Hybrid Model,” *Proc. - 2024 2nd Int. Conf. Inven. Comput. Informatics, ICICI 2024*, no. September, pp. 90–95, 2024, doi: 10.1109/ICICI62254.2024.00024.
- [41] S. Kim, E. Gaibor, B. Matejek, and D. Haehn, “Melanoma Detection with Uncertainty Quantification,” pp. 2–6, 2024.

- [42] M. Infante, M. Gonzáles, L. Jaén, and S. Valle, “Cutaneous melanoma: some current considerations,” *Medisan*, vol. 23, no. 1, pp. 146–164, 2019.
- [43] K. Sardana, P. Chakravarty, and K. Goel, “Optimal management of common acquired melanocytic nevi (moles): Current perspectives,” *Clin. Cosmet. Investig. Dermatol.*, vol. 7, no. October, pp. 89–103, 2014, doi: 10.2147/CCID.S57782.
- [44] P. Luque-González, M. Pineda-Mateo, V. Aguilar-Martin, R. Rodríguez-Gómez, and Á. Gutiérrez-Domínguez, “Vulvar basal cell carcinoma: A case report and review of the literature,” *Ginecol. Obstet. Mex.*, vol. 90, no. 8, pp. 688–694, 2022, doi: 10.24245/gom.v90i8.6224.
- [45] L. A. Rossato, R. C. Carneiro, E. M. S. de Macedo, P. P. de Lima, M. R. Urbano, and S. Matayoshi, “Relationship between actinic keratosis and malignant skin lesions on the eyelid,” *Arq. Bras. Oftalmol.*, vol. 86, no. 1, pp. 1–6, 2023, doi: 10.5935/0004-2749.20230002.
- [46] P. R. Cohen, C. P. Erickson, and A. Calame, “Atrophic Dermatofibroma: A Comprehensive Literature Review,” *Dermatol. Ther. (Heidelb.)*, vol. 9, no. 3, pp. 449–468, 2019, doi: 10.1007/s13555-019-0309-y.
- [47] M. Stavrakas and H. S. Khalil, *Rhinology and Anterior Skull Base Surgery: A Case-based Approach*. 2021. doi: 10.1007/978-3-030-66865-5.
- [48] A. De Vicente-Colomina, P. Santamaría, and H. González-Ordi, “Guidelines for writing of case studies in clinical psychology: PSYCHOCARE guidelines,” *Clin. y Salud*, vol. 31, no. 2, pp. 69–76, 2020, doi: 10.5093/CLYSA2020A6.
- [49] A. T. Ibrahim, M. Abdullahi, A. Florentin, D. Kana, M. T. Mohammed, and I. H. Hassan, “Journal Pre-proof,” *Data Sci. Manag.*, 2024, doi: 10.1016/j.dsm.2024.10.002.
- [50] O. Akinrinade and C. Du, “Skin cancer detection using deep machine learning techniques,” *Intell. Med.*, vol. 11, no. August 2024, p. 100191, 2025, doi: 10.1016/j.ibmed.2024.100191.
- [51] J. L. Canta Honores and J. Quesada Llanto, “uso del enfoque del estudio de caso:

- Una revisión de la literatura,” *Horizontes. Rev. Investig. en Ciencias la Educ.*, vol. 5, no. 19, pp. 775–786, 2021, doi: 10.33996/revistahorizontes.v5i19.236.
- [52] J. Francisco, F. Diego, and A. Cristian, “Inteligencia Artificial en la educación universitaria : Innovaciones , desafíos y oportunidades,” vol. 45, no. 05, pp. 120–135, 2024, doi: 10.48082/espacios-a24v45n05p09.
- [53] S. E. Cerminara *et al.*, “Diagnostic performance of augmented intelligence with 2D and 3D total body photography and convolutional neural networks in a high-risk population for melanoma under real-world conditions: A new era of skin cancer screening?,” *Eur. J. Cancer*, vol. 190, 2023, doi: 10.1016/j.ejca.2023.112954.
- [54] C. Hernández-Pérez *et al.*, “BCN20000: Dermoscopic Lesions in the Wild,” *Sci. Data*, vol. 11, no. 1, pp. 1–9, 2024, doi: 10.1038/s41597-024-03387-w.
- [55] S. Kim, E. Gaibor, and D. Haehn, “Web-based Melanoma Detection,” pp. 1–10, 2024.
- [56] J. A. Álvarez Cedillo, T. Álvarez Sánchez, R. J. Sandoval Gómez, and M. Aguilar Fernández, “La exploración en el desarrollo del aprendizaje profundo / The Exploration in the Develop Deep Learning,” *RIDE Rev. Iberoam. para la Investig. y el Desarro. Educ.*, vol. 9, no. 18, pp. 833–844, 2019, doi: 10.23913/ride.v9i18.474.
- [57] L. F. Li, X. Wang, W. J. Hu, N. N. Xiong, Y. X. Du, and B. S. Li, “Deep Learning in Skin Disease Image Recognition: A Review,” *IEEE Access*, vol. 8, pp. 208264–208280, 2020, doi: 10.1109/ACCESS.2020.3037258.

ANEXOS

Anexo 1. Construcción de los modelos de entrenamiento

Resnet

```
from google.colab import drive
drive.mount('/content/drive')

import pandas as pd
import os

# Definir ruta principal
main_dir = '/content/drive/MyDrive/ISIC_2019'

# Verificar la estructura del directorio de imágenes
image_dir = os.path.join(main_dir, 'ISIC_2019_Training_Input', 'ISIC_2019_Training_Input')
print("Archivos en el subdirectorio de imágenes:", os.listdir(image_dir)[:10])

# Actualizar la ruta del directorio base a la ruta correcta
base_dir = image_dir

# Cargar los datos y mostrar las primeras filas
csv_file = os.path.join(main_dir, 'ISIC_2019_Training_GroundTruth.csv')
data = pd.read_csv(csv_file)
print("Columnas en el archivo CSV:", data.columns)

# Crear una columna 'label' basada en las columnas existentes
def get_label(row):
    for col in ['MEL', 'NV', 'BCC', 'AK', 'BKL', 'DF', 'VASC', 'SCC', 'UNK']:
        if row[col] == 1:
            return col
    return 'UNK'

data['label'] = data.apply(get_label, axis=1)
print(data[['image', 'label']].head())

# Añadir la extensión .jpg a los nombres de los archivos en el CSV, si es necesario
data['image'] = data['image'].apply(lambda x: x + '.jpg')

# Verificar si los archivos de imagen existen ahora
missing_files = []
for img_name in data['image']:
    if not os.path.exists(os.path.join(base_dir, img_name)):
        missing_files.append(img_name)

print(f"Total missing files después de la corrección: {len(missing_files)}")

# Mostrar algunos archivos de imagen y verificar que existen en el directorio
print("Primeros 10 nombres de imágenes en el subdirectorio de imágenes:", os.listdir(base_dir)[:10])
print("Primeros 10 nombres de imágenes en el CSV:", data['image'].head(10))

# Dividir los datos en entrenamiento y validación
from sklearn.model_selection import train_test_split

train_df, val_df = train_test_split(data[['image', 'label']], test_size=0.2, random_state=42)

# Preprocesar y aumentar las imágenes
from tensorflow.keras.preprocessing.image import ImageDataGenerator
```

```

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=40, # Aumentar rotación
    width_shift_range=0.3, # Aumentar desplazamiento horizontal
    height_shift_range=0.3, # Aumentar desplazamiento vertical
    shear_range=0.3, # Aumentar cizalladura
    zoom_range=0.3, # Aumentar zoom
    horizontal_flip=True,
    fill_mode='nearest'
)

val_datagen = ImageDataGenerator(rescale=1./255)

train_generator = train_datagen.flow_from_dataframe(
    train_df,
    directory=base_dir,
    x_col='image',
    y_col='label',
    target_size=(224, 224),
    batch_size=32,
    class_mode='categorical'
)

val_generator = val_datagen.flow_from_dataframe(
    val_df,
    directory=base_dir,
    x_col='image',
    y_col='label',
    target_size=(224, 224),
    batch_size=32,
    class_mode='categorical'
)

# Crear y compilar el modelo
from tensorflow.keras.applications import ResNet50
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.optimizers import Adam

base_model = ResNet50(weights='imagenet', include_top=False)

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x) # Añadir Dropout para regularización
predictions = Dense(len(train_generator.class_indices), activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)

# Descongelar algunas capas del modelo base
for layer in base_model.layers[-10:]:
    layer.trainable = True

model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])
# Descongelar algunas capas del modelo base
for layer in base_model.layers[-10:]:
    layer.trainable = True

model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])

# Entrenar el modelo
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // train_generator.batch_size,
    validation_data=val_generator,
    validation_steps=val_generator.samples // val_generator.batch_size,
    epochs=10 # Aumentar el número de épocas
)

# Evaluar el modelo
val_loss, val_accuracy = model.evaluate(val_generator, steps=val_generator.samples // val_generator.batch_size)
print(f'Validation loss: {val_loss}')
print(f'Validation accuracy: {val_accuracy}')

# Guardar el modelo entrenado
model.save('/content/drive/MyDrive/ISIC_2019/resnet50_isic_model.h5')

```

Ilustración 44: Construcción del Modelo – Resnet

Fuente: El Autor

```

from google.colab import drive
drive.mount('/content/drive')

import pandas as pd
import os

# Definir ruta principal
main_dir = '/content/drive/MyDrive/ISIC_2019'

# Verificar la estructura del directorio de imágenes
image_dir = os.path.join(main_dir, 'ISIC_2019_Training_Input', 'ISIC_2019_Training_Input')
print("Archivos en el subdirectorio de imágenes:", os.listdir(image_dir)[:10])

# Actualizar la ruta del directorio base a la ruta correcta
base_dir = image_dir

# Cargar los datos y mostrar las primeras filas
csv_file = os.path.join(main_dir, 'ISIC_2019_Training_GroundTruth.csv')
data = pd.read_csv(csv_file)
print("Columnas en el archivo CSV:", data.columns)

# Crear una columna 'label' basada en las columnas existentes
def get_label(row):
    for col in ['MEL', 'NV', 'BCC', 'AK', 'BKL', 'DF', 'VASC', 'SCC', 'UNK']:
        if row[col] == 1:
            return col
    return 'UNK'

data['label'] = data.apply(get_label, axis=1)
print(data[['image', 'label']].head())

# Añadir la extensión .jpg a los nombres de los archivos en el CSV, si es necesario
data['image'] = data['image'].apply(lambda x: x + '.jpg')

# Verificar si los archivos de imagen existen ahora
missing_files = []
for img_name in data['image']:
    if not os.path.exists(os.path.join(base_dir, img_name)):
        missing_files.append(img_name)

print(f"Total missing files después de la corrección: {len(missing_files)}")

# Mostrar algunos archivos de imagen y verificar que existen en el directorio
print("Primeros 10 nombres de imágenes en el subdirectorio de imágenes:", os.listdir(base_dir)[:10])
print("Primeros 10 nombres de imágenes en el CSV:", data['image'].head(10))

```

```

# Dividir los datos en entrenamiento y validación
from sklearn.model_selection import train_test_split

train_df, val_df = train_test_split(data[['image', 'label']], test_size=0.2, random_state=42)

# Preprocesar y aumentar las imágenes
from tensorflow.keras.preprocessing.image import ImageDataGenerator

```

```

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=40,
    width_shift_range=0.3,
    height_shift_range=0.3,
    shear_range=0.3,
    zoom_range=0.3,
    horizontal_flip=True,
    fill_mode='nearest'
)

val_datagen = ImageDataGenerator(rescale=1./255)

train_generator = train_datagen.flow_from_dataframe(
    train_df,
    directory=base_dir,
    x_col='image',
    y_col='label',
    target_size=(224, 224),
    batch_size=32,
    class_mode='categorical'
)

val_generator = val_datagen.flow_from_dataframe(
    val_df,
    directory=base_dir,
    x_col='image',
    y_col='label',
    target_size=(224, 224),
    batch_size=32,
    class_mode='categorical'
)

# Crear y compilar el modelo
from tensorflow.keras.applications import VGG16
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.optimizers import Adam

base_model = VGG16(weights='imagenet', include_top=False)

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)
predictions = Dense(len(train_generator.class_indices), activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)

# Descongelar más capas del modelo base
for layer in base_model.layers[-8:]:
    layer.trainable = True

model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])

# Callback para guardar el mejor modelo basado en la precisión de validación
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping

checkpoint = ModelCheckpoint('/content/drive/MyDrive/ISIC_2019/vgg16_best_model.h5', monitor='val_accuracy', save_
early_stopping = EarlyStopping(monitor='val_accuracy', patience=10, mode='max')

# Entrenar el modelo
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // train_generator.batch_size,
    validation_data=val_generator,
    validation_steps=val_generator.samples // val_generator.batch_size,
    epochs=50, # Aumentar el número de épocas para permitir que el modelo mejore
    callbacks=[checkpoint, early_stopping]
)

# Evaluar el modelo final
val_loss, val_accuracy = model.evaluate(val_generator, steps=val_generator.samples // val_generator.batch_size)
print(f'Validation loss: {val_loss}')
print(f'Validation accuracy: {val_accuracy}')

# Cargar el mejor modelo y evaluar nuevamente
from tensorflow.keras.models import load_model

best_model = load_model('/content/drive/MyDrive/ISIC_2019/vgg16_best_model.h5')
best_val_loss, best_val_accuracy = best_model.evaluate(val_generator, steps=val_generator.samples // val_generator
print(f'Best validation loss: {best_val_loss}')
print(f'Best validation accuracy: {best_val_accuracy}')

```

Ilustración 45: Construcción del Modelo – VGG

Fuente: El Autor

Densenet

```
from google.colab import drive
drive.mount('/content/drive')

import pandas as pd
import os

# Definir ruta principal
main_dir = '/content/drive/MyDrive/ISIC_2019'

# Verificar la estructura del directorio de imágenes
image_dir = os.path.join(main_dir, 'ISIC_2019_Training_Input', 'ISIC_2019_Training_Input')
print("Archivos en el subdirectorio de imágenes:", os.listdir(image_dir)[:10])

# Actualizar la ruta del directorio base a la ruta correcta
base_dir = image_dir

# Cargar los datos y mostrar las primeras filas
csv_file = os.path.join(main_dir, 'ISIC_2019_Training_GroundTruth.csv')
data = pd.read_csv(csv_file)
print("Columnas en el archivo CSV:", data.columns)

# Crear una columna 'label' basada en las columnas existentes
def get_label(row):
    for col in ['MEL', 'NV', 'BCC', 'AK', 'BKL', 'DF', 'VASC', 'SCC', 'UNK']:
        if row[col] == 1:
            return col
    return 'UNK'

data['label'] = data.apply(get_label, axis=1)
print(data[['image', 'label']].head())

# Añadir la extensión .jpg a los nombres de los archivos en el CSV, si es necesario
data['image'] = data['image'].apply(lambda x: x + '.jpg')

# Verificar si los archivos de imagen existen ahora
missing_files = []
for img_name in data['image']:
    if not os.path.exists(os.path.join(base_dir, img_name)):
        missing_files.append(img_name)

print(f"Total missing files después de la corrección: {len(missing_files)}")

# Mostrar algunos archivos de imagen y verificar que existen en el directorio
print("Primeros 10 nombres de imágenes en el subdirectorio de imágenes:", os.listdir(base_dir)[:10])
print("Primeros 10 nombres de imágenes en el CSV:", data['image'].head(10))

# Dividir los datos en entrenamiento y validación
from sklearn.model_selection import train_test_split

train_df, val_df = train_test_split(data[['image', 'label']], test_size=0.2, random_state=42)

# Preprocesar y aumentar las imágenes
from tensorflow.keras.preprocessing.image import ImageDataGenerator
```

```

train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=40,
    width_shift_range=0.3,
    height_shift_range=0.3,
    shear_range=0.3,
    zoom_range=0.3,
    horizontal_flip=True,
    fill_mode='nearest'
)

val_datagen = ImageDataGenerator(rescale=1./255)

train_generator = train_datagen.flow_from_dataframe(
    train_df, directory=base_dir, x_col='image', y_col='label',
    target_size=(224, 224), batch_size=32, class_mode='categorical'
)

val_generator = val_datagen.flow_from_dataframe(
    val_df, directory=base_dir, x_col='image', y_col='label',
    target_size=(224, 224), batch_size=32, class_mode='categorical'
)

# Crear y compilar el modelo
from tensorflow.keras.applications import DenseNet121
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Dense, GlobalAveragePooling2D, Dropout
from tensorflow.keras.optimizers import Adam

base_model = DenseNet121(weights='imagenet', include_top=False)

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x)
x = Dense(512, activation='relu')(x)
x = Dropout(0.5)(x)
predictions = Dense(len(train_generator.class_indices), activation='softmax')(x)

model = Model(inputs=base_model.input, outputs=predictions)

# Descongelar algunas capas del modelo base
for layer in base_model.layers[-8:]:
    layer.trainable = True

model.compile(optimizer=Adam(learning_rate=0.0001), loss='categorical_crossentropy', metrics=['accuracy'])

# Callbacks para guardar el mejor modelo
from tensorflow.keras.callbacks import ModelCheckpoint, EarlyStopping

checkpoint = ModelCheckpoint('/content/drive/MyDrive/ISIC_2019/densenet_best_model.h5', monitor='val_accuracy', save_best_only=True, mode='max')
early_stopping = EarlyStopping(monitor='val_accuracy', patience=10, mode='max')

# Entrenar el modelo
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // train_generator.batch_size,
    validation_data=val_generator,
    validation_steps=val_generator.samples // val_generator.batch_size,
    epochs=50,
    callbacks=[checkpoint, early_stopping]
)

# Evaluar el modelo final
val_loss, val_accuracy = model.evaluate(val_generator, steps=val_generator.samples // val_generator.batch_size)
print(f'Validation loss: {val_loss}')
print(f'Validation accuracy: {val_accuracy}')

# Cargar el mejor modelo y evaluar nuevamente
from tensorflow.keras.models import load_model

best_model = load_model('/content/drive/MyDrive/ISIC_2019/densenet_best_model.h5')
best_val_loss, best_val_accuracy = best_model.evaluate(val_generator, steps=val_generator.samples // val_generator.batch_size)
print(f'Best validation loss: {best_val_loss}')
print(f'Best validation accuracy: {best_val_accuracy}')

```

Ilustración 46: Construcción del Modelo – Densenet

Fuente: El Autor

Anexo 2. Estructura de la red neuronal

Model: "functional"

Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, None, None, 3)	0	-
conv1_pad (ZeroPadding2D)	(None, None, None, 3)	0	input_layer[0][0]
conv1_conv (Conv2D)	(None, None, None, 64)	9,472	conv1_pad[0][0]
conv1_bn (BatchNormalization)	(None, None, None, 64)	256	conv1_conv[0][0]
conv1_relu (Activation)	(None, None, None, 64)	0	conv1_bn[0][0]
pool1_pad (ZeroPadding2D)	(None, None, None, 64)	0	conv1_relu[0][0]
pool1_pool (MaxPooling2D)	(None, None, None, 64)	0	pool1_pad[0][0]
conv2_block1_1_conv (Conv2D)	(None, None, None, 64)	4,160	pool1_pool[0][0]
conv2_block1_1_bn (BatchNormalization)	(None, None, None, 64)	256	conv2_block1_1_conv[0...
conv2_block1_1_relu (Activation)	(None, None, None, 64)	0	conv2_block1_1_bn[0][...
conv2_block1_2_conv (Conv2D)	(None, None, None, 64)	36,928	conv2_block1_1_relu[0...
conv2_block1_2_bn (BatchNormalization)	(None, None, None, 64)	256	conv2_block1_2_conv[0...
conv2_block1_2_relu (Activation)	(None, None, None, 64)	0	conv2_block1_2_bn[0][...
conv2_block1_0_conv (Conv2D)	(None, None, None, 256)	16,640	pool1_pool[0][0]
conv2_block1_3_conv (Conv2D)	(None, None, None, 256)	16,640	conv2_block1_2_relu[0...
conv2_block1_0_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv2_block1_0_conv[0...
conv2_block1_3_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv2_block1_3_conv[0...
conv2_block1_add (Add)	(None, None, None, 256)	0	conv2_block1_0_bn[0][...] conv2_block1_3_bn[0][...
conv2_block1_out (Activation)	(None, None, None, 256)	0	conv2_block1_add[0][0]
conv2_block2_1_conv (Conv2D)	(None, None, None, 64)	16,448	conv2_block1_out[0][0]
conv2_block2_1_bn (BatchNormalization)	(None, None, None, 64)	256	conv2_block2_1_conv[0...

conv2_block2_1_relu (Activation)	(None, None, None, 64)	0	conv2_block2_1_bn[0][...
conv2_block2_2_conv (Conv2D)	(None, None, None, 64)	36,928	conv2_block2_1_relu[0...
conv2_block2_2_bn (BatchNormalization)	(None, None, None, 64)	256	conv2_block2_2_conv[0...
conv2_block2_2_relu (Activation)	(None, None, None, 64)	0	conv2_block2_2_bn[0][...
conv2_block2_3_conv (Conv2D)	(None, None, None, 256)	16,640	conv2_block2_2_relu[0...
conv2_block2_3_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv2_block2_3_conv[0...
conv2_block2_add (Add)	(None, None, None, 256)	0	conv2_block1_out[0][0... conv2_block2_3_bn[0][...
conv2_block2_out (Activation)	(None, None, None, 256)	0	conv2_block2_add[0][0]
conv2_block3_1_conv (Conv2D)	(None, None, None, 64)	16,448	conv2_block2_out[0][0]
conv2_block3_1_bn (BatchNormalization)	(None, None, None, 64)	256	conv2_block3_1_conv[0...
conv2_block3_1_relu (Activation)	(None, None, None, 64)	0	conv2_block3_1_bn[0][...
conv2_block3_2_conv (Conv2D)	(None, None, None, 64)	36,928	conv2_block3_1_relu[0...
conv2_block3_2_bn (BatchNormalization)	(None, None, None, 64)	256	conv2_block3_2_conv[0...
conv2_block3_2_relu (Activation)	(None, None, None, 64)	0	conv2_block3_2_bn[0][...
conv2_block3_3_conv (Conv2D)	(None, None, None, 256)	16,640	conv2_block3_2_relu[0...
conv2_block3_3_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv2_block3_3_conv[0...
conv2_block3_add (Add)	(None, None, None, 256)	0	conv2_block2_out[0][0... conv2_block3_3_bn[0][...
conv2_block3_out (Activation)	(None, None, None, 256)	0	conv2_block3_add[0][0]
conv3_block1_1_conv (Conv2D)	(None, None, None, 128)	32,896	conv2_block3_out[0][0]
conv3_block1_1_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block1_1_conv[0...

conv3_block1_1_relu (Activation)	(None, None, None, 128)	0	conv3_block1_1_bn[0][...]
conv3_block1_2_conv (Conv2D)	(None, None, None, 128)	147,584	conv3_block1_1_relu[0...]
conv3_block1_2_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block1_2_conv[0...]
conv3_block1_2_relu (Activation)	(None, None, None, 128)	0	conv3_block1_2_bn[0][...]
conv3_block1_0_conv (Conv2D)	(None, None, None, 512)	131,584	conv2_block3_out[0][0]
conv3_block1_3_conv (Conv2D)	(None, None, None, 512)	66,048	conv3_block1_2_relu[0...]
conv3_block1_0_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv3_block1_0_conv[0...]
conv3_block1_3_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv3_block1_3_conv[0...]
conv3_block1_add (Add)	(None, None, None, 512)	0	conv3_block1_0_bn[0][...] conv3_block1_3_bn[0][...]
conv3_block1_out (Activation)	(None, None, None, 512)	0	conv3_block1_add[0][0]
conv3_block2_1_conv (Conv2D)	(None, None, None, 128)	65,664	conv3_block1_out[0][0]
conv3_block2_1_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block2_1_conv[0...]
conv3_block2_1_relu (Activation)	(None, None, None, 128)	0	conv3_block2_1_bn[0][...]
conv3_block2_2_conv (Conv2D)	(None, None, None, 128)	147,584	conv3_block2_1_relu[0...]
conv3_block2_2_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block2_2_conv[0...]
conv3_block2_2_relu (Activation)	(None, None, None, 128)	0	conv3_block2_2_bn[0][...]
conv3_block2_3_conv (Conv2D)	(None, None, None, 512)	66,048	conv3_block2_2_relu[0...]
conv3_block2_3_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv3_block2_3_conv[0...]
conv3_block2_add (Add)	(None, None, None, 512)	0	conv3_block1_out[0][0...] conv3_block2_3_bn[0][...]
conv3_block2_out (Activation)	(None, None, None, 512)	0	conv3_block2_add[0][0]

conv3_block3_1_conv (Conv2D)	(None, None, None, 128)	65,664	conv3_block2_out[0][0]
conv3_block3_1_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block3_1_conv[0...]
conv3_block3_1_relu (Activation)	(None, None, None, 128)	0	conv3_block3_1_bn[0][...]
conv3_block3_2_conv (Conv2D)	(None, None, None, 128)	147,584	conv3_block3_1_relu[0...]
conv3_block3_2_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block3_2_conv[0...]
conv3_block3_2_relu (Activation)	(None, None, None, 128)	0	conv3_block3_2_bn[0][...]
conv3_block3_3_conv (Conv2D)	(None, None, None, 512)	66,048	conv3_block3_2_relu[0...]
conv3_block3_3_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv3_block3_3_conv[0...]
conv3_block3_add (Add)	(None, None, None, 512)	0	conv3_block2_out[0][0...] conv3_block3_3_bn[0][...]
conv3_block3_out (Activation)	(None, None, None, 512)	0	conv3_block3_add[0][0]
conv3_block4_1_conv (Conv2D)	(None, None, None, 128)	65,664	conv3_block3_out[0][0]
conv3_block4_1_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block4_1_conv[0...]
conv3_block4_1_relu (Activation)	(None, None, None, 128)	0	conv3_block4_1_bn[0][...]
conv3_block4_2_conv (Conv2D)	(None, None, None, 128)	147,584	conv3_block4_1_relu[0...]
conv3_block4_2_bn (BatchNormalization)	(None, None, None, 128)	512	conv3_block4_2_conv[0...]
conv3_block4_2_relu (Activation)	(None, None, None, 128)	0	conv3_block4_2_bn[0][...]
conv3_block4_3_conv (Conv2D)	(None, None, None, 512)	66,048	conv3_block4_2_relu[0...]
conv3_block4_3_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv3_block4_3_conv[0...]
conv3_block4_add (Add)	(None, None, None, 512)	0	conv3_block3_out[0][0...] conv3_block4_3_bn[0][...]
conv3_block4_out (Activation)	(None, None, None, 512)	0	conv3_block4_add[0][0]
conv4_block1_1_conv (Conv2D)	(None, None, None, 256)	131,328	conv3_block4_out[0][0]
conv4_block1_1_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block1_1_conv[0...]

conv4_block1_1_relu (Activation)	(None, None, None, 256)	0	conv4_block1_1_bn[0][...
conv4_block1_2_conv (Conv2D)	(None, None, None, 256)	590,080	conv4_block1_1_relu[0...
conv4_block1_2_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block1_2_conv[0...
conv4_block1_2_relu (Activation)	(None, None, None, 256)	0	conv4_block1_2_bn[0][...
conv4_block1_0_conv (Conv2D)	(None, None, None, 1024)	525,312	conv3_block4_out[0][0]
conv4_block1_3_conv (Conv2D)	(None, None, None, 1024)	263,168	conv4_block1_2_relu[0...
conv4_block1_0_bn (BatchNormalization)	(None, None, None, 1024)	4,096	conv4_block1_0_conv[0...
conv4_block1_3_bn (BatchNormalization)	(None, None, None, 1024)	4,096	conv4_block1_3_conv[0...
conv4_block1_add (Add)	(None, None, None, 1024)	0	conv4_block1_0_bn[0][...] conv4_block1_3_bn[0][...
conv4_block1_out (Activation)	(None, None, None, 1024)	0	conv4_block1_add[0][0]
conv4_block2_1_conv (Conv2D)	(None, None, None, 256)	262,400	conv4_block1_out[0][0]
conv4_block2_1_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block2_1_conv[0...
conv4_block2_1_relu (Activation)	(None, None, None, 256)	0	conv4_block2_1_bn[0][...
conv4_block2_2_conv (Conv2D)	(None, None, None, 256)	590,080	conv4_block2_1_relu[0...
conv4_block2_2_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block2_2_conv[0...
conv4_block2_2_relu (Activation)	(None, None, None, 256)	0	conv4_block2_2_bn[0][...
conv4_block2_3_conv (Conv2D)	(None, None, None, 1024)	263,168	conv4_block2_2_relu[0...
conv4_block2_3_bn (BatchNormalization)	(None, None, None, 1024)	4,096	conv4_block2_3_conv[0...
conv4_block2_add (Add)	(None, None, None, 1024)	0	conv4_block1_out[0][0...] conv4_block2_3_bn[0][...
conv4_block2_out (Activation)	(None, None, None, 1024)	0	conv4_block2_add[0][0]
conv4_block3_1_conv (Conv2D)	(None, None, None, 256)	262,400	conv4_block2_out[0][0]

conv4_block3_1_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block3_1_conv[0...
conv4_block3_1_relu (Activation)	(None, None, None, 256)	0	conv4_block3_1_bn[0][...
conv4_block3_2_conv (Conv2D)	(None, None, None, 256)	590,080	conv4_block3_1_relu[0...
conv4_block3_2_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block3_2_conv[0...
conv4_block3_2_relu (Activation)	(None, None, None, 256)	0	conv4_block3_2_bn[0][...
conv4_block3_3_conv (Conv2D)	(None, None, None, 1024)	263,168	conv4_block3_2_relu[0...
conv4_block3_3_bn (BatchNormalization)	(None, None, None, 1024)	4,096	conv4_block3_3_conv[0...
conv4_block3_add (Add)	(None, None, None, 1024)	0	conv4_block2_out[0][0... conv4_block3_3_bn[0][...
conv4_block3_out (Activation)	(None, None, None, 1024)	0	conv4_block3_add[0][0]
conv4_block4_1_conv (Conv2D)	(None, None, None, 256)	262,400	conv4_block3_out[0][0]
conv4_block4_1_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block4_1_conv[0...
conv4_block4_1_relu (Activation)	(None, None, None, 256)	0	conv4_block4_1_bn[0][...
conv4_block4_2_conv (Conv2D)	(None, None, None, 256)	590,080	conv4_block4_1_relu[0...
conv4_block4_2_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block4_2_conv[0...
conv4_block4_2_relu (Activation)	(None, None, None, 256)	0	conv4_block4_2_bn[0][...
conv4_block4_3_conv (Conv2D)	(None, None, None, 1024)	263,168	conv4_block4_2_relu[0...
conv4_block4_3_bn (BatchNormalization)	(None, None, None, 1024)	4,096	conv4_block4_3_conv[0...
conv4_block4_add (Add)	(None, None, None, 1024)	0	conv4_block3_out[0][0... conv4_block4_3_bn[0][...
conv4_block4_out (Activation)	(None, None, None, 1024)	0	conv4_block4_add[0][0]
conv4_block5_1_conv (Conv2D)	(None, None, None, 256)	262,400	conv4_block4_out[0][0]
conv4_block5_1_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block5_1_conv[0...
conv4_block5_1_relu (Activation)	(None, None, None, 256)	0	conv4_block5_1_bn[0][...
conv4_block5_2_conv (Conv2D)	(None, None, None, 256)	590,080	conv4_block5_1_relu[0...
conv4_block5_2_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block5_2_conv[0...

conv4_block5_2_relu (Activation)	(None, None, None, 256)	0	conv4_block5_2_bn[0][...
conv4_block5_3_conv (Conv2D)	(None, None, None, 1024)	263,168	conv4_block5_2_relu[0...
conv4_block5_3_bn (BatchNormalization)	(None, None, None, 1024)	4,096	conv4_block5_3_conv[0...
conv4_block5_add (Add)	(None, None, None, 1024)	0	conv4_block4_out[0][0... conv4_block5_3_bn[0][...
conv4_block5_out (Activation)	(None, None, None, 1024)	0	conv4_block5_add[0][0]
conv4_block6_1_conv (Conv2D)	(None, None, None, 256)	262,400	conv4_block5_out[0][0]
conv4_block6_1_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block6_1_conv[0...
conv4_block6_1_relu (Activation)	(None, None, None, 256)	0	conv4_block6_1_bn[0][...
conv4_block6_2_conv (Conv2D)	(None, None, None, 256)	590,080	conv4_block6_1_relu[0...
conv4_block6_2_bn (BatchNormalization)	(None, None, None, 256)	1,024	conv4_block6_2_conv[0...
conv4_block6_2_relu (Activation)	(None, None, None, 256)	0	conv4_block6_2_bn[0][...
conv4_block6_3_conv (Conv2D)	(None, None, None, 1024)	263,168	conv4_block6_2_relu[0...
conv4_block6_3_bn (BatchNormalization)	(None, None, None, 1024)	4,096	conv4_block6_3_conv[0...
conv4_block6_add (Add)	(None, None, None, 1024)	0	conv4_block5_out[0][0... conv4_block6_3_bn[0][...
conv4_block6_out (Activation)	(None, None, None, 1024)	0	conv4_block6_add[0][0]
conv5_block1_1_conv (Conv2D)	(None, None, None, 512)	524,800	conv4_block6_out[0][0]
conv5_block1_1_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv5_block1_1_conv[0...
conv5_block1_1_relu (Activation)	(None, None, None, 512)	0	conv5_block1_1_bn[0][...
conv5_block1_2_conv (Conv2D)	(None, None, None, 512)	2,359,808	conv5_block1_1_relu[0...
conv5_block1_2_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv5_block1_2_conv[0...
conv5_block1_2_relu (Activation)	(None, None, None, 512)	0	conv5_block1_2_bn[0][...
conv5_block1_0_conv (Conv2D)	(None, None, None, 2048)	2,099,200	conv4_block6_out[0][0]
conv5_block1_3_conv (Conv2D)	(None, None, None, 2048)	1,050,624	conv5_block1_2_relu[0...

conv5_block1_0_bn (BatchNormalization)	(None, None, None, 2048)	8,192	conv5_block1_0_conv[0...
conv5_block1_3_bn (BatchNormalization)	(None, None, None, 2048)	8,192	conv5_block1_3_conv[0...
conv5_block1_add (Add)	(None, None, None, 2048)	0	conv5_block1_0_bn[0][...] conv5_block1_3_bn[0][...]
conv5_block1_out (Activation)	(None, None, None, 2048)	0	conv5_block1_add[0][0]
conv5_block2_1_conv (Conv2D)	(None, None, None, 512)	1,049,088	conv5_block1_out[0][0]
conv5_block2_1_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv5_block2_1_conv[0...
conv5_block2_1_relu (Activation)	(None, None, None, 512)	0	conv5_block2_1_bn[0][...]
conv5_block2_2_conv (Conv2D)	(None, None, None, 512)	2,359,808	conv5_block2_1_relu[0...
conv5_block2_2_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv5_block2_2_conv[0...
conv5_block2_2_relu (Activation)	(None, None, None, 512)	0	conv5_block2_2_bn[0][...]
conv5_block2_3_conv (Conv2D)	(None, None, None, 2048)	1,050,624	conv5_block2_2_relu[0...
conv5_block2_3_bn (BatchNormalization)	(None, None, None, 2048)	8,192	conv5_block2_3_conv[0...
conv5_block2_add (Add)	(None, None, None, 2048)	0	conv5_block1_out[0][0...] conv5_block2_3_bn[0][...]
conv5_block2_out (Activation)	(None, None, None, 2048)	0	conv5_block2_add[0][0]
conv5_block3_1_conv (Conv2D)	(None, None, None, 512)	1,049,088	conv5_block2_out[0][0]
conv5_block3_1_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv5_block3_1_conv[0...
conv5_block3_1_relu (Activation)	(None, None, None, 512)	0	conv5_block3_1_bn[0][...]
conv5_block3_2_conv (Conv2D)	(None, None, None, 512)	2,359,808	conv5_block3_1_relu[0...
conv5_block3_2_bn (BatchNormalization)	(None, None, None, 512)	2,048	conv5_block3_2_conv[0...
conv5_block3_2_relu (Activation)	(None, None, None, 512)	0	conv5_block3_2_bn[0][...]
conv5_block3_3_conv (Conv2D)	(None, None, None, 2048)	1,050,624	conv5_block3_2_relu[0...
conv5_block3_3_bn (BatchNormalization)	(None, None, None, 2048)	8,192	conv5_block3_3_conv[0...
conv5_block3_add (Add)	(None, None, None, 2048)	0	conv5_block2_out[0][0...] conv5_block3_3_bn[0][...]

conv5_block3_out (Activation)	(None, None, None, 2048)	0	conv5_block3_add[0][0]
global_average_pooling2d (GlobalAveragePooling2D)	(None, 2048)	0	conv5_block3_out[0][0]
dense (Dense)	(None, 1024)	2,098,176	global_average_poolin...
dropout (Dropout)	(None, 1024)	0	dense[0][0]
dense_1 (Dense)	(None, 8)	8,200	dropout[0][0]

Total params: 76,976,026 (293.64 MB)
 Trainable params: 25,640,968 (97.81 MB)
 Non-trainable params: 53,120 (207.50 KB)
 Optimizer params: 51,281,938 (195.63 MB)

Ilustración 47: Estructura completa de la red neuronal

Fuente: Autor

Anexo 3. Implementación




Ilustración 48: Aplicación web (inicio)

Fuente: El Autor




Ilustración 49: Aplicación web (detección)

Fuente: El Autor

Anexo 4. Manual de Usuario: Sistema de Detección de Cáncer de Piel

Manual de Usuario

Fecha de Elaboración: 2025-02-11

Fecha de actualización: 2025-02-11

Realizado por:

Ing. Fátima Katiuska Farías Rivera
ESTUDIANTE DE MAESTRIA

1. INTRODUCCIÓN

El sistema de detección de cáncer de piel es una aplicación web diseñada para facilitar la identificación temprana de diferentes tipos de cáncer de piel mediante el uso de aprendizaje profundo. La aplicación permite a los usuarios subir una imagen de la zona afectada o utilizar la captura en tiempo real para recibir una predicción sobre el posible tipo de cáncer de piel.

Este manual de usuario proporciona una guía detallada sobre cómo utilizar la aplicación, asegurando un uso eficiente de sus funcionalidades. A través de este documento, los usuarios podrán comprender los requisitos técnicos, los pasos necesarios para realizar una predicción y el control de cambios implementado en el sistema.

2. OBJETIVOS

- Proporcionar una herramienta digital de fácil acceso para la detección de cáncer de piel mediante inteligencia artificial.
- Facilitar la evaluación preliminar de lesiones cutáneas, ayudando a los usuarios a identificar anomalías de manera rápida.
- Integrar un sistema de predicción eficiente basado en el análisis de imágenes subidas por los usuarios o capturadas en tiempo real.
- Mejorar la accesibilidad a evaluaciones médicas preventivas, especialmente en zonas con acceso limitado a especialistas en dermatología.


3. REQUERIMIENTOS TÉCNICOS DEL SISTEMA

Requerimientos mínimos:

- Computadora con acceso a Internet.
- Navegador web actualizado (Mozilla Firefox, Google Chrome, Safari, Opera).
- Navegador con JavaScript habilitado.


4. DETALLE DE LA APLICACIÓN

Al ingresar a la aplicación, el usuario será recibido por la pantalla de inicio, donde podrá seleccionar entre las distintas opciones de predicción. El menú lateral contiene las opciones principales, permitiendo una navegación intuitiva por el sistema.




4.1. Inicio

En la pantalla de inicio, el usuario encontrará las principales opciones del sistema, organizadas para facilitar la navegación. Este apartado se divide en varias secciones, pero destacamos tres de las más importantes:



A. Panel de Modelos Activos: Muestra información clave sobre el dataset utilizado, el modelo de predicción en uso y el framework empleado en el procesamiento de imágenes.



B. Sección de Predicción: Presenta imágenes de referencia analizadas por la IA y sus respectivas predicciones, permitiendo al usuario visualizar ejemplos de diagnóstico.

Modelos Entrenados				
Nombre: ResNet	Loss: 0.0282	Accuracy: 0.9948	Val Loss: 0.0275	Val Accuracy: 0.9908
Nombre: VGG16	Loss: 0.0316	Accuracy: 0.9891	Val Loss: 0.0257	Val Accuracy: 0.9871
Nombre: Mobilenet	Loss: 0.2683	Accuracy: 0.4986	Val Loss: 0.6907	Val Accuracy: 0.5000

C. Información sobre Tipos de Cáncer de Piel: Proporciona una descripción detallada de los diferentes tipos de cáncer detectables por el sistema, ayudando a la comprensión de los resultados obtenidos.

Tipos De Cáncer De Piel	
Melanoma [Maligno] - Cáncer de piel que se desarrolla en los melanocitos; puede diseminarse rápidamente.	Nevus melanocítico [Benigno] - Lunar benigno que puede transformarse en melanoma.
Carcinoma de células basales [Maligno] - Cáncer de piel más común y menos agresivo, raro que se disemine.	Queratosis actínica [Precanceroso] - Lesión precancerosa por exposición solar prolongada.
Queratosis benigna [Benigno] - Lesión cutánea no cancerosa como la queratosis seborreica.	Dermatofibroma [Benigno] - Crecimiento benigno de tejido fibroso en la piel.
Lesión vascular [Varia] - Anomalías de los vasos sanguíneos de la piel, benignas o malignas.	Carcinoma de células escamosas [Maligno] - Cáncer de piel más agresivo que el carcinoma basal, puede diseminarse.


4.2. Predicción (Subir foto)

Esta opción permite a los usuarios subir una imagen de la zona afectada para obtener una predicción utilizando inteligencia artificial. El sistema analiza la imagen y muestra un resultado basado en modelos entrenados. A continuación, se detallan los pasos a seguir para realizar la predicción.


1. En el menú lateral del sistema, diríjase a la sección **Predicción (Subir Foto)**




2. Después de haber seleccionado **Predicción (Subir foto)**, se cargará la página la cual está compuesta por los siguientes elementos principales:




- A. Campo de selección de archivo:
- Permite al usuario elegir una imagen desde su dispositivo.
 - Muestra el nombre del archivo seleccionado.
- B. Panel de resultados:
- Muestra la predicción generada por el sistema de inteligencia artificial.
 - Inicialmente se encuentra vacío hasta que se complete el procesamiento.
- C. Panel de definición:
- Proporciona información adicional sobre el resultado obtenido.
 - Describe el tipo de lesión detectada si la predicción es positiva.
3. Una vez en esta sección, se mostrará la interfaz donde podrá subir una imagen de la zona afectada. En la parte central de la pantalla, se encuentra el campo de selección de archivo, donde el usuario puede hacer clic en el botón "Seleccionar archivo" para elegir una imagen desde su dispositivo.



- Al hacer clic en "Seleccionar archivo", se abrirá un modal del explorador de archivos del dispositivo. En esta ventana, el usuario deberá navegar y seleccionar la imagen que desea evaluar. Una vez elegida, debe hacer clic en "Abrir" para cargarla en el sistema.



- Una vez ya cargada la imagen y procesada, se obtiene como resultado una predicción generada por el sistema de inteligencia artificial.




Nota: En este caso, el sistema ha identificado una posible condición de **carcinoma basocelular** con un nivel de probabilidad del **56%**. En el panel de **resultados**, se muestra el diagnóstico junto con la probabilidad de precisión asignada. Además, en el panel de **definición**, se proporciona una breve descripción del tipo de lesión detectada para brindar información adicional al usuario.


4.3. Predicción (Tiempo real)

Esta opción permite a los usuarios capturar una imagen en tiempo real utilizando la cámara de su dispositivo para obtener una predicción mediante inteligencia artificial. El sistema analiza la imagen en el momento y genera un resultado basado en modelos entrenados. A continuación, se detallan los pasos a seguir para realizar la predicción en tiempo real.


1. En el menú lateral del sistema, diríjase a la sección **Predicción (Tiempo real)**




2. La primera vez que acceda a la sección Predicción (Tiempo real), el sistema solicitará permisos para utilizar la cámara del dispositivo. Se mostrará una ventana emergente donde el usuario deberá conceder acceso a la cámara para capturar imágenes en tiempo real y proceder con el análisis de predicción.




3. Una vez concedidos los permisos de cámara, se abrirá la interfaz de Predicción en Tiempo Real, donde el usuario podrá capturar una imagen utilizando la cámara del dispositivo.




- A. Vista previa de la cámara: Muestra en tiempo real la imagen capturada por la cámara activa.
 - B. Panel de resultados: Mostrará la predicción generada por el sistema basado en inteligencia artificial.
 - C. Panel de probabilidad de precisión: Indica el porcentaje de confianza del modelo en la predicción realizada.
 - D. Panel de definición: Proporciona información adicional sobre la predicción obtenida.
4. Haga clic en el botón "Cambiar Cámara" para alternar entre las cámaras disponibles en el dispositivo. Esta opción permite seleccionar la cámara más adecuada para capturar la imagen en tiempo real antes de realizar la predicción.



- Haga clic en el botón "Capturar Foto" para tomar una imagen en tiempo real con la cámara activa. La imagen capturada será procesada automáticamente por el sistema para generar una predicción.



- Una vez capturada la imagen en tiempo real y procesada, el sistema genera una predicción utilizando inteligencia artificial.



Nota: En este caso, el sistema ha analizado una imagen capturada en tiempo real y ha identificado una posible condición de Dermatofibroma, clasificada como benigna, con un nivel de precisión del 95.83%. En el panel de resultados, se muestra el diagnóstico junto con la probabilidad de confianza asignada. Además, en el panel de definición, se proporciona una breve descripción de la afección, indicando que se trata de un crecimiento benigno de tejido fibroso en la piel.

5. CONTROL DE CAMBIO DE APLICACIONES

MOTIVADO POR			
Versión	Documento	Motivo cambio	Fecha
1.0			13/03/2025