



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

**Desarrollo de aplicación móvil y web para la detección de enfermedades
faciales mediante el uso de inteligencia artificial**

**VILLANO ESCOBAR DANIEL JAZMANY
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**CHAMBA SANCHEZ ANDY JOSEPH
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**MACHALA
2023**



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

Desarrollo de aplicación móvil y web para la detección de enfermedades faciales mediante el uso de inteligencia artificial

**VILLANO ESCOBAR DANIEL JAZMANY
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**CHAMBA SANCHEZ ANDY JOSEPH
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**MACHALA
2023**



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

PROPUESTAS TECNOLÓGICAS

Desarrollo de aplicación móvil y web para la detección de enfermedades faciales mediante el uso de inteligencia artificial

**VILLANO ESCOBAR DANIEL JAZMANY
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

**CHAMBA SANCHEZ ANDY JOSEPH
INGENIERO EN TECNOLOGIAS DE LA INFORMACION**

LOJA MORA NANCY MAGALY

**MACHALA
2023**

Chamba_Villano

por Nancy Loja Mora

Fecha de entrega: 18-feb-2024 07:50p.m. (UTC-0500)

Identificador de la entrega: 2298057772

Nombre del archivo: Proyecto_Integracion_Curricular_turnitin_Chamba.pdf (2.33M)

Total de palabras: 14465

Total de caracteres: 79468

Chamba_Villano

INFORME DE ORIGINALIDAD

6%

INDICE DE SIMILITUD

5%

FUENTES DE INTERNET

1%

PUBLICACIONES

1%

TRABAJOS DEL
ESTUDIANTE

FUENTES PRIMARIAS

1

healthlibrary.brighamandwomens.org

Fuente de Internet

<1 %

2

old.cisuc.uc.pt

Fuente de Internet

<1 %

3

www.openalfa.com

Fuente de Internet

<1 %

4

www.openvalley.es

Fuente de Internet

<1 %

5

catalonica.bnc.cat

Fuente de Internet

<1 %

6

engrxiv.org

Fuente de Internet

<1 %

7

helvia.uco.es

Fuente de Internet

<1 %

8

repositorio.upads.edu.pe

Fuente de Internet

<1 %

9

uvadoc.uva.es

Fuente de Internet

<1 %

CLÁUSULA DE CESIÓN DE DERECHO DE PUBLICACIÓN EN EL REPOSITORIO DIGITAL INSTITUCIONAL

Los que suscriben, VILLANO ESCOBAR DANIEL JAZMANY y CHAMBA SANCHEZ ANDY JOSEPH, en calidad de autores del siguiente trabajo escrito titulado Desarrollo de aplicación móvil y web para la detección de enfermedades faciales mediante el uso de inteligencia artificial, otorgan a la Universidad Técnica de Machala, de forma gratuita y no exclusiva, los derechos de reproducción, distribución y comunicación pública de la obra, que constituye un trabajo de autoría propia, sobre la cual tienen potestad para otorgar los derechos contenidos en esta licencia.

Los autores declaran que el contenido que se publicará es de carácter académico y se enmarca en las disposiciones definidas por la Universidad Técnica de Machala.

Se autoriza a transformar la obra, únicamente cuando sea necesario, y a realizar las adaptaciones pertinentes para permitir su preservación, distribución y publicación en el Repositorio Digital Institucional de la Universidad Técnica de Machala.

Los autores como garantes de la autoría de la obra y en relación a la misma, declaran que la universidad se encuentra libre de todo tipo de responsabilidad sobre el contenido de la obra y que asumen la responsabilidad frente a cualquier reclamo o demanda por parte de terceros de manera exclusiva.

Aceptando esta licencia, se cede a la Universidad Técnica de Machala el derecho exclusivo de archivar, reproducir, convertir, comunicar y/o distribuir la obra mundialmente en formato electrónico y digital a través de su Repositorio Digital Institucional, siempre y cuando no se lo haga para obtener beneficio económico.



VILLANO ESCOBAR DANIEL JAZMANY

0705778868

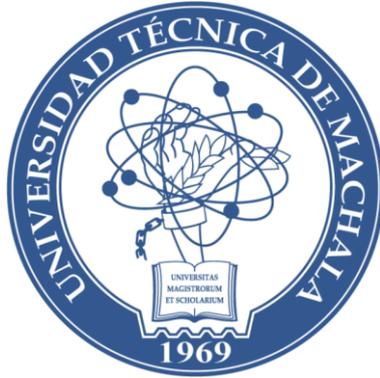


CHAMBA SANCHEZ ANDY JOSEPH

0751017989



UNIVERSITAS
MAGISTRORUM
ET SCHOLARIUM



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

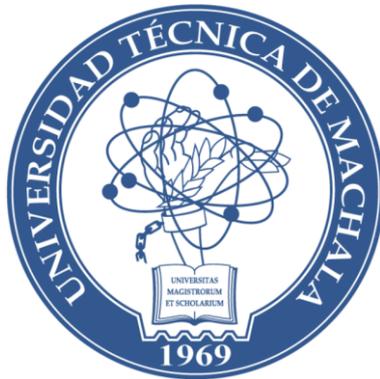
DESARROLLO DE APLICACIÓN MÓVIL Y WEB PARA LA
DETECCIÓN DE ENFERMEDADES FACIALES MEDIANTE EL USO
DE INTELIGENCIA ARTIFICIAL

CHAMBA SÁNCHEZ ANDY JOSEPH
INGENIERO EN TECNOLOGÍAS DE LA INFORMACIÓN

VILLANO ESCOBAR DANIEL JAZMANY
INGENIERO EN TECNOLOGÍAS DE LA INFORMACIÓN

MACHALA

2023



UTMACH

FACULTAD DE INGENIERÍA CIVIL

CARRERA DE TECNOLOGÍAS DE LA INFORMACIÓN

**DESARROLLO DE APLICACIÓN MÓVIL Y WEB PARA LA
DETECCIÓN DE ENFERMEDADES FACIALES MEDIANTE EL USO
DE INTELIGENCIA ARTIFICIAL**

**CHAMBA SÁNCHEZ ANDY JOSEPH
INGENIERO EN TECNOLOGÍAS DE LA INFORMACIÓN**

**VILLANO ESCOBAR DANIEL JAZMANY
INGENIERO EN TECNOLOGÍAS DE LA INFORMACIÓN**

MACHALA

2023

DEDICATORIA

A mis padres, quienes han sido mi mayor inspiración y sostén a lo largo de esta travesía académica. Su amor incondicional, su apoyo constante y el sacrificio inigualable que han hecho por mí son la razón principal de este logro. A través de su ejemplo de perseverancia y dedicación, han sembrado en mí las semillas del éxito y el compromiso.

A mi familia, cuyo apoyo inquebrantable y comprensión han sido pilares fundamentales en este viaje. Sus palabras de aliento, sus abrazos reconfortantes y su fe en mí han sido mi roca en los momentos de duda y dificultad. Su presencia constante ha iluminado mi camino y me ha dado la fuerza para seguir adelante, incluso en los momentos más desafiantes. Este logro no solo es mío, sino también de ustedes, quienes han estado a mi lado en cada paso del camino.

Chamba Sánchez Andy Joseph

Dedico este trabajo de titulación a mi amada madre y a mis queridos abuelos, cuyo amor incondicional y constante apoyo han sido mi mayor fortaleza a lo largo de este arduo proceso. Cada página escrita, cada desafío superado en este camino hacia mi título de Ingeniero en Tecnologías de la Información, es un tributo a su dedicación y sacrificio. Su aliento y apoyo incondicional han sido fundamentales en este logro

Villano Escobar Daniel Jazmany

AGRADECIMIENTO

Quiero expresar mi más sincero agradecimiento a mi tutora de tesis, Ing. Loja Mora Nancy Magaly, por su orientación experta, paciencia y dedicación a lo largo de este proyecto. Su mentoría ha sido fundamental para alcanzar este hito académico.

Agradezco profundamente a todos los profesores y profesionales que contribuyeron con su conocimiento y consejos en el desarrollo de este trabajo. Sus aportes han enriquecido enormemente mi investigación.

Agradezco a mis compañeros de clase y colegas por sus discusiones estimulantes, colaboración y amistad durante este viaje académico.

Andy Joseph Chamba Sánchez

Deseo expresar mi sincero agradecimiento al Ing. Loja Mora Nancy Magaly, por su incansable orientación y asesoramiento durante el desarrollo de esta tesis. Su experiencia y apoyo fueron fundamentales para alcanzar este logro.

Asimismo, agradezco al Ing. Sist. Rivas Asanza Wilmer Braulio, PhD, por su valiosa contribución como cotutor de este trabajo. Sus conocimientos y consejos han enriquecido significativamente la calidad de esta investigación.

Agradezco también a mis compañeros de equipo, Chamba Andy, cuya colaboración y dedicación fueron esenciales para el éxito de este proyecto.

Este logro no hubiera sido posible sin el apoyo de mi familia, mis amigos y todas las personas que de una forma u otra han formado parte de este camino. A todos ustedes, les debo mi más profundo agradecimiento y reconocimiento.

Daniel Jazmany Villano Escobar

RESUMEN

Las enfermedades faciales representan un desafío diagnóstico significativo en el ámbito médico, y su detección temprana es crucial para un tratamiento efectivo. Este proyecto aborda la necesidad de una detección confiable y accesible de estas enfermedades por lo cual se definió como objetivo general el desarrollar una aplicación móvil y web mediante el uso de inteligencia artificial, para la detección de enfermedades faciales. Se adoptó un enfoque cuantitativo, que es especialmente apropiado para probar la hipótesis y manejar el gran volumen de datos que se utilizarán para entrenar el modelo. Mediante una revisión sistemática, se buscó entender primero las tecnologías de aprendizaje profundo y redes neuronales convolucionales. Luego, del conjunto de imágenes de entrenamiento, se extrajeron características principales de las enfermedades faciales. La investigación tuvo un diseño cuasiexperimental, apropiado para evaluar posteriormente la funcionalidad y eficacia diagnóstica del aplicativo desarrollado. Para el desarrollo del modelo de red neuronal, se usó la metodología CRISP-DM, que ofrece una estructura metodológica sólida y bien definida. Para el desarrollo de la aplicación móvil y web, se adoptó la metodología EXTREME PROGRAMMING (XP), la cual consta de cuatro fases bien definidas en las cuales se definieron los requisitos e historias de usuarios para el aplicativo web y móvil. Bajo la misma metodología se evaluó el aplicativo mediante pruebas de aceptación que demostraron el correcto funcionamiento y el cumplimiento de las historias de usuario. Por otra parte, el modelo de red neuronal se evaluó mediante el uso de una matriz de confusión con una data de evaluación que se encontraba fuera de la data de entrenamiento dando como resultado un 88% de índice de precisión en la detección; luego se concluyó que la hipótesis donde se planteaba que el índice de precisión mínimo sería del 70% ha sido corroborada con éxito al superar el umbral definido.

PALABRAS CLAVE

Aprendizaje profundo, Enfermedades faciales, Red neuronal convolucional, Aplicación móvil, Inteligencia artificial.

SUMMARY

Facial diseases represent a significant diagnostic challenge in the medical field, and their early detection is crucial for effective treatment. This project addresses the need for a reliable and accessible detection of these diseases, so it was defined as a general objective to develop a mobile and web application using artificial intelligence for the recognition of facial diseases. A quantitative approach was adopted, which is particularly appropriate for testing the hypothesis and handling the large volume of data that will be used to train the model. Through a systematic review, we first sought to understand deep learning technologies and convolutional neural networks. Then, from the set of training images, main features of facial diseases were extracted. The research had a quasi-experimental design, appropriate to subsequently evaluate the functionality and diagnostic efficacy of the developed application. For the development of the model, the CRISP-DM methodology was applied, which offers a solid and well-defined methodological structure. For the development of the user interfaces, the EXTREME PROGRAMMING (XP) methodology was adopted, which consists of four well-defined phases in which the requirements and user stories for the web and mobile application were defined. Under the same methodology, the application was evaluated by means of acceptance tests that demonstrated the correct operation and compliance with the established requirements. On the other hand, the neural network model was evaluated through the use of a confusion matrix with an evaluation data that was outside the training data resulting in an 88% accuracy rate in detection; then it was concluded that the hypothesis where it was stated that the minimum accuracy rate would be 70% has been successfully corroborated by exceeding the defined threshold.

KEYWORDS

Deep learning, Facial diseases, Convolutional neural network, Mobile application, Artificial intelligence

ÍNDICE DE CONTENIDO

DEDICATORIA.....	iv
AGRADECIMIENTO.....	v
RESUMEN.....	vi
PALABRAS CLAVE.....	vi
SUMMARY	vii
ÍNDICE DE CONTENIDO.....	viii
ÍNDICE DE TABLAS	xi
GLOSARIO.....	xiii
INTRODUCCIÓN	1
i. Declaración y formulación del Problema.....	1
ii. Objeto de estudio y Campo de acción.....	3
iii. Objetivos.....	3
iv. Hipótesis y variables o Preguntas de investigación.....	4
v. Justificación.....	4
vi. Organización del documento	6
CAPÍTULO I. MARCO TEÓRICO.....	6
1.1. Antecedentes de la investigación.....	6
1.2. Antecedentes históricos	10
1.3. Antecedentes Teóricos.....	12
1.3.1. Inteligencia artificial y aprendizaje automático	12
1.3.2. Procesamiento de imágenes	14
1.3.3. Redes Neuronales Artificiales.....	16
1.3.4. Inteligencia artificial en la detección de enfermedades	19
1.3.4.2. Enfermedades comunes en el Rostro	21
1.3.5. Programas de desarrollo de Inteligencia Artificial	22
1.4. Antecedentes contextuales.....	24

1.4.1.	Ámbito de aplicación	24
1.4.2.	Establecimiento de requerimientos	24
CAPÍTULO II. DESARROLLO DEL PROTOTIPO		26
2.1.	Definición del prototipo.....	26
2.2.	Metodología de desarrollo del prototipo	26
2.2.1.	Enfoque, alcance y diseño de investigación	26
2.2.2.	Unidades de análisis.....	27
2.2.3.	Técnicas e instrumentos de recopilación de datos.	27
2.2.4.	Técnicas de procesamiento de datos para la obtención de resultados	27
2.2.5.	Metodología o métodos específicos.....	28
2.2.6.	Herramientas y/o Materiales	29
2.3.	Desarrollo del prototipo.....	30
2.3.1.	Metodología CRISP-DM	30
2.3.2.	Metodología XP.....	34
2.4.	Ejecución del prototipo.....	50
CAPÍTULO III. EVALUACIÓN DEL PROTOTIPO		56
3.1.	Plan de evaluación	56
3.1.1.	Pruebas de red neuronal	58
3.1.2.	Matriz de confusión.....	58
3.1.3.	Pruebas de aceptación de la metodología XP.....	58
3.2.	Resultados de la evaluación.....	61
3.2.1.	Resultados de evaluación del modelo de red neuronal	61
3.2.2.	Resultados de las pruebas de aceptación de la metodología XP.....	62
CONCLUSIONES		65
RECOMENDACIONES		66
REFERENCIAS BIBLIOGRÁFICAS		67
ANEXOS.....		73

Anexo 1: Matriz de consistencia	73
Anexo 2: Tutorías de titulación	75
Anexo 3: Evaluación del modelo.....	76

ÍNDICE DE FIGURAS

Figura 1: Espina de pescado	2
Figura 2: Proceso de búsqueda	9
Figura 3: Cantidad de artículos seleccionados por año.....	10
Figura 4: Mapa de antecedentes teóricos.	12
Figura 5: Establecimiento del prototipo.....	26
Figura 6: Fases de la metodología CRISP-DM.....	28
Figura 7: Clases etiquetas	32
Figura 8: Modelo de la red neuronal convolucional	33
Figura 9: Distribución de los datos	33
Figura 10: Entrenamiento de la red neuronal convolucional	34
Figura 11: Modelo relacional de la base de datos.....	38
Figura 12: Página de inicio de sesión.....	38
Figura 13: Modulo de enfermedades	39
Figura 14: Ejemplo de asignación de tratamiento a enfermedad	39
Figura 15: Modulo de productos	40
Figura 16: Modulo de dermatólogos.....	40
Figura 17: Acceso a la carga de archivos.....	41
Figura 18: Acceso a la cámara	41
Figura 19: Modulo de selección de dermatólogos	42
Figura 20: Modulo de ayuda	42
Figura 21: Ventana principal	43
Figura 22: Drawer	43
Figura 23: Interfaz de Ayuda	44
Figura 24: Interfaz de Dermatólogos	44
Figura 25: Interfaz de Recorte.....	45
Figura 26: Interfaz de Informe	46
Figura 27: Prueba del prototipo.....	52
Figura 28: Cámara del dispositivo.	53

Figura 29: Selección de la galería.....	53
Figura 30: Interfaz de Recorte.....	54
Figura 31: Modal de Aviso.....	54
Figura 32: Interfaz de Informe.....	55
Figura 33: Información adicional.....	55
Figura 34: Tutorial virtual con tutor académico.....	75
Figura 35: Tutoría con cotutor académico.....	75
Figura 36: Resultado de evaluación de la red neuronal.....	76
Figura 37: Código de evaluación del modelo.....	76

ÍNDICE DE TABLAS

Tabla 1: Definición de variables y dimensionamiento.....	4
Tabla 2: Preguntas de investigación.....	7
Tabla 3: Criterios de inclusión y exclusión.....	8
Tabla 4: Ejemplos de inteligencia artificial para la detección de enfermedades.....	20
Tabla 5: Establecimiento de requerimientos.....	24
Tabla 6: Datos de la data set entrenamiento y pruebas.....	27
Tabla 7: Técnicas e instrumentos de recopilación de datos.....	27
Tabla 8: Herramientas y/o Materiales.....	29
Tabla 9: Descripción de Enfermedades.....	31
Tabla 10: Roles del quipo XP.....	35
Tabla 11: Historia de usuario creación de base de datos.....	36
Tabla 12: Historia de usuario Aplicación web Administrativa.....	36
Tabla 13: Historia de usuario Plataforma móvil de Consulta.....	36
Tabla 14: Historia de usuario Plataforma Web de Consulta.....	37
Tabla 15: Plan de Entrega.....	37
Tabla 16: Plantilla de tarea de Ingeniería.....	46
Tabla 17: Tarea 1 de Historia de usuario 1.....	47
Tabla 18: Tarea 2 de Historia de usuario 1.....	47
Tabla 19: Tarea 3 de Historia de Usuario 1.....	47
Tabla 20: Tarea 1 de Historia de Usuario 2.....	47
Tabla 21: Tarea 2 de Historia de Usuario 2.....	47

Tabla 22: Tarea 3 de Historia de Usuario 2	48
Tabla 23: Tarea 4 de Historia de Usuario 2.....	48
Tabla 24: Tarea 1 de Historia de Usuario 3	48
Tabla 25: Tarea 2 de Historia de Usuario 3	48
Tabla 26: Tarea 3 de Historia de Usuario 3	48
Tabla 27: Tarea 4 de Historia de Usuario 3	49
Tabla 28: Tarea 5 de Historia de Usuario 3	49
Tabla 29: Tarea 1 de Historia de Usuario 4	49
Tabla 30: Tarea 2 de Historia de Usuario 4	49
Tabla 31: Tarea 3 de Historia de Usuario 4	49
Tabla 32: Tarea 4 de Historia de Usuario 4	50
Tabla 33: Tarea 5 de Historia de Usuario 4	50
Tabla 34: Tarea 6 de Historia de Usuario 4	50
Tabla 35: Plataforma administrativa	50
Tabla 36: Cronograma de actividades del plan de evaluación	57
Tabla 37: Tabla de métricas	58
Tabla 38: Matriz de confusión	58
Tabla 39: Pruebas de aceptación	59
Tabla 40: Plantilla de pruebas de aceptación	60
Tabla 41: Valores de la matriz de confusión.....	61
Tabla 42: Reporte de los resultados de la clasificación	61
Tabla 43: Prueba de Acceso a la base de datos	63
Tabla 44: Prueba de Inserción de datos.....	63
Tabla 45: Prueba de Crear datos desde la Web.....	64
Tabla 46: Prueba de Consulta desde el móvil	64
Tabla 47: Prueba de Consulta desde la Web	65

GLOSARIO

Convolución: Operación matemática que combina dos conjuntos de información para producir una tercera forma que representa cómo cambia uno en función del otro.

Pooling: Proceso de reducción de dimensiones o submuestreo de un mapa de características para disminuir la complejidad computacional y evitar el sobreajuste.

Capa de Convolución: La capa en una CNN donde se realiza la operación de convolución. Es la responsable de la detección de características como bordes, texturas y más en la imagen de entrada.

Función de Activación: Función matemática aplicada a la salida de una neurona en la red. La función ReLU (Rectified Linear Unit) es comúnmente utilizada en CNNs.

Backpropagation: Algoritmo utilizado para minimizar el error en la salida de la red ajustando los pesos durante el entrenamiento.

Matriz de Confusión: Tabla que muestra las clasificaciones reales y las predicciones del modelo, permitiendo calcular diversas métricas de evaluación.

Flatten: Capa que aplanar la estructura de sus entradas, convirtiendo datos multidimensionales en un vector unidimensional.

INTRODUCCIÓN

La prevalencia de enfermedades faciales como el eczema, acné, Hiperpigmentación, melanoma malignos y benignos representan un problema de salud pública de gran envergadura a nivel global. Estas afecciones, cuyas causas son multifactoriales—que van desde la exposición a la radiación ultravioleta del sol hasta factores genéticos, ambientales y niveles de estrés—, no solo afectan la calidad de vida de los individuos, sino que también pueden tener implicaciones psicosociales y económicas significativas. Ante este escenario, se hace imperante la necesidad de desarrollar soluciones tecnológicas eficaces y accesibles que permitan la detección temprana y confiable de estas enfermedades. En este contexto, la inteligencia artificial (IA), en combinación con técnicas de aprendizaje automático y reconocimiento facial, emerge como una herramienta potencialmente revolucionaria. La aplicación de redes neuronales convolucionales en el análisis de imágenes faciales puede identificar patrones y características asociadas con diversas enfermedades cutáneas, permitiendo así intervenciones más tempranas y precisas. En este marco, nuestra contribución se centra en el desarrollo de una aplicación móvil y web que utiliza IA para la detección automatizada de enfermedades faciales, ofreciendo una solución innovadora y práctica a un problema de salud apremiante.

i. Declaración y formulación del Problema

Las causas de las diferentes enfermedades faciales como eczema, acné, Hiperpigmentación, lunares malignos y benignos son producto de la exposición a la radiación ultravioleta del sol, factores genéticos, ambientales, estrés, entre otros, de esta manera, impactando a la salud de una gran cantidad de individuos a nivel global.

En Ecuador y el mundo se ha evidenciado un alto nivel de hiperpigmentación o melasma en mujeres embarazadas, específicamente en un 56% de estas, de igual forma esta enfermedad afecta en un 46% a personas que usan anticonceptivos orales y solo un 10% de los afectados por esta enfermedad son hombres. De igual forma, tiene un gran impacto en la calidad de vida de las personas que la sufren. [1]

Actualmente, el diagnóstico temprano y preciso de enfermedades faciales es un desafío para los expertos de la salud como aquellos que reciben atención médica. La detección manual de enfermedades faciales requiere experiencia y conocimientos especializados, lo que limita su

accesibilidad y aumenta el riesgo de diagnósticos incorrectos o tardíos. Además, el proceso de evaluación facial puede ser subjetivo y variar según la habilidad del profesional.

Se establece una necesidad apremiante de desarrollar una solución tecnológica que permita la detección automatizada y confiable de enfermedades faciales utilizando inteligencia artificial. La inteligencia artificial, combinada con técnicas de aprendizaje automático y reconocimiento facial, ofrece un potencial prometedor para analizar imágenes faciales e identificar patrones asociados con diferentes enfermedades. En la Figura 1, se presenta el problema, sus causas y efectos identificados.

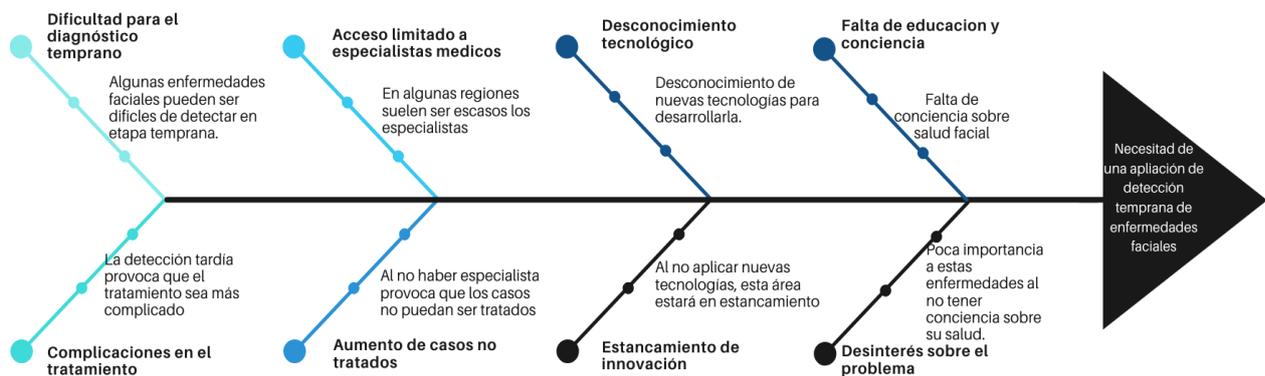


Figura 1: Espina de pescado

Formulación del problema

Problema principal:

- ¿Cómo apoyar a la detección enfermedades faciales mediante el uso de la inteligencia artificial?

Problemas específicos:

- ¿Cómo entrenar y calibrar los algoritmos de inteligencia artificial para detectar enfermedades faciales?
- ¿Cuáles son las características y patrones faciales relevantes para el diagnóstico de enfermedades faciales mediante inteligencia artificial?
- ¿Cómo se puede evaluar y validar la precisión y eficacia de la aplicación móvil y web en comparación con los diagnósticos realizados por profesionales de la salud en un entorno clínico?

- ¿Cuál es la viabilidad técnica y económica de desarrollar y mantener una aplicación móvil y web para la detección de enfermedades faciales basada en inteligencia artificial?

ii. Objeto de estudio y Campo de acción

Objeto de estudio

- Aplicación para detectar enfermedades faciales mediante inteligencia artificial.

Campo de acción

- Redes neuronales convolucionales aplicado al reconocimiento de imágenes.

iii. Objetivos

Objetivo General

- Desarrollar una aplicación móvil y web mediante el uso de inteligencia artificial, para la detección de enfermedades faciales.

Objetivos específicos

- Realizar una investigación bibliográfica para la construcción del estado del arte y marco teórico correspondiente.
- Contemplar los aspectos estructurales y funcionales necesarios para la implementación de un modelo de red neuronal.
- Establecer el conjunto de enfermedades con criterios claros y específicos que serán objeto de estudio.
- Realizar una búsqueda detallada de imágenes en alta calidad donde evidencien las enfermedades mencionadas previamente para el entrenamiento del modelo.
- Establecer funcionalidades y requisitos específicos que serán implementados en la aplicación móvil y web.
- Realizar pruebas de aceptación del aplicativo web y móvil para la validación de su correcto funcionamiento.
- Evaluar los resultados de la detección del modelo de red neuronal previamente entrenado.

iv. Hipótesis y variables o Preguntas de investigación

Hipótesis principal (o preguntas de investigación)

El desarrollo de aplicación móvil y web que integre inteligencia artificial permitirá la detección de afecciones faciales, entre ellas: Acné, Eczema, Hiperpigmentación, Lunares benignos y malignos con una precisión estimada del 70%.

Variables y dimensionamiento (o categorización)

Tabla 1: Definición de variables y dimensionamiento

Variabes	Categorías	Indicadores	Técnicas
Independiente Aplicación móvil y web que utilice inteligencia artificial	Procesamiento de imágenes	Aprendizaje automático y entrenamiento.	Redes neuronales convolucionales como arquitectura para el procesamiento de imágenes por IA.
		Conjunto de datos.	Dataset de imágenes de muestra junto con sus etiquetas.
		Potencia de cálculo y recursos.	Sistemas de computación en la nube para un procesamiento y entrenamiento eficiente.
	Desarrollo móvil y web	Diseño de la interfaz de usuario.	Programas como Figma y AdobeXD.
		Desarrollo del Backend	Lenguajes de programación Python y JavaScript.
		Desarrollo del FrontEnd	Lenguajes de programación Dart y JavaScript.
		Pruebas y depuración	Uso de la aplicación en un diagnóstico.
Dependiente Detección de enfermedades faciales	Enfermedades Faciales	Acné, Eczema, Hiperpigmentación, Lunares benignos y Malignos	Entrenamiento de la red neuronal convolucional con las imágenes etiquetadas y realizar el diagnóstico.

v. Justificación

La inteligencia artificial ha estado mucho más activa en estos últimos tiempos, realizando distintas tareas que facilitan el trabajo de las personas en diferentes áreas, el proyecto contribuirá en el proceso de integración de la Inteligencia Artificial dentro del área de salud, trayendo consigo beneficios tanto para los pacientes como para el personal de esta área.

El cuidado de la piel es una de las actividades principales que deben realizar las personas, especialmente del rostro, que es el principal atractivo, en él aparecen enfermedades que pueden ser difíciles de detectar para la persona común, por lo que recurren a especialistas cuando la enfermedad ya está muy avanzada. Debido a esto, la aplicación se centrará en la detección de dichas enfermedades, lo que ayudará a las personas a buscar ayuda profesional en una etapa temprana del problema, pudiendo solucionarlo sin mayores represalias.

Este proyecto facilita la detección temprana de enfermedades, es esencial para aumentar las tasas de supervivencia y mejorar los resultados de tratamiento. Sin embargo, en muchos casos, las enfermedades faciales pueden pasar desapercibidas o ser mal diagnosticadas. Al desarrollar una aplicación móvil y web que utilice inteligencia artificial para analizar imágenes faciales y detectar patrones o características asociadas con enfermedades, se podrían identificar problemas de salud en etapas más tempranas, lo que permitiría una intervención médica oportuna y un mejor pronóstico para los pacientes.

En la actualidad el acceso a atención médica de calidad es un desafío en muchas partes del mundo, especialmente en áreas rurales o remotas, por ende, el desarrollo de una aplicación móvil y web para la detección de enfermedades faciales podría superar algunas de las barreras geográficas y socioeconómicas al proporcionar a las personas una herramienta accesible para evaluar su estado de salud facial. Esto permitiría a las personas buscar atención médica temprana, incluso en ausencia de recursos médicos tradicionales, y obtener una evaluación preliminar de su condición.

La implementación de una aplicación móvil y web para la detección de enfermedades faciales podría ayudar a reducir la carga sobre los sistemas de salud al disminuir la necesidad de consultas médicas innecesarias o visitas a especialistas. Muchas veces, las preocupaciones menores relacionadas con la piel o los sistemas faciales pueden resolverse mediante una simple evaluación y asesoramiento. Al proporcionar a los usuarios una herramienta de detección preliminar, se podría filtrar a aquellos que necesitan una atención médica más especializada, al tiempo que se aliviaría la carga del sistema de salud.

Una aplicación móvil y web para la detección de enfermedades faciales podría ser una valiosa herramienta educativa para el público en general. Al mostrar ejemplos visuales y explicaciones sobre diferentes enfermedades faciales, la aplicación podría ayudar a crear conciencia sobre los signos y síntomas, así como fomentar la prevención y la adopción de hábitos de vida saludables.

Además, también podría proporcionar recomendaciones generales para el cuidado de la piel y la salud facial, promoviendo así la salud en general.

En el Anexo 1, se puede observar un resumen de todos los objetivos, e información relevante respecto al trabajo de titulación.

vi. Organización del documento

El presente escrito se encuentra dividido en tres capítulos donde se detallan las tareas desarrolladas en el transcurso del proceso de titulación, a continuación, se describe brevemente el contenido de cada capítulo.

Capítulo I: En este capítulo se encuentra la fundamentación teórica del trabajo con relación a las tecnologías usadas e información relevante, se compone de antecedentes de la investigación, históricos, teóricos y contextuales.

Capítulo II: Este capítulo describe el desarrollo del prototipo y contiene la definición, metodologías de desarrollo, elaboración y la ejecución prototipo.

Capítulo III: Por último, en este capítulo se realizan pruebas al prototipo, consta de un plan de evaluación y análisis de los resultados obtenidos.

CAPÍTULO I. MARCO TEÓRICO

1.1. Antecedentes de la investigación

Para la revisión bibliográfica de la investigación se realizó usando la metodología de Revisión Sistemática de la Literatura (SRL: Systematic Review of the Literature).

El propósito de la metodología SLR es recopilar toda la evidencia, información, publicaciones y documentos relevantes sobre el tema de investigación con los criterios de elegibilidad predefinidos para responder a las interrogantes de la investigación y la correcta estructura en la redacción del informe [2].

a) Preguntas de investigación

Las preguntas de investigación que se plantearon para realizar la búsqueda de información sobre la creación de una aplicación móvil y web para la detección de enfermedades faciales utilizando inteligencia artificial son las siguientes:

Tabla 2: Preguntas de investigación

Pregunta	Descripción y motivación
¿Qué características faciales específicas son más relevantes para la detección de enfermedades?	Esta pregunta nos permite definir la precisión y rendimiento del modelo a partir de la selección de datos de utilizamos para su entrenamiento.
¿Cuáles arquitecturas se utilizan para la implementación de una red neuronal en una aplicación móvil y web?	Esta pregunta pretende la búsqueda de lenguajes, tecnologías u herramientas que nos permitan la implementación de una aplicación móvil y web con inteligencia artificial.
¿Qué métricas de rendimiento me permitirán demostrar una alta disponibilidad de la aplicación?	Esta pregunta pretende la búsqueda de métricas para verificar la alta disponibilidad de la aplicación.
¿Cuál es el impacto potencial de una detección temprana de enfermedades faciales en la prevención de complicaciones y en la eficacia del tratamiento?	Esta pregunta pretende definir el impacto que tendría el desarrollo de una aplicación móvil y web que integre inteligencia artificial para la detección de enfermedades.
¿Qué tipos de enfermedades faciales son más susceptibles de detección temprana?	Esta pregunta nos permite limitar la selección de enfermedades para nuestro modelo para obtener un mejor rendimiento del mismo.

b) Palabras claves y Cadena(s) de búsqueda.

En cuanto a la estrategia de búsqueda utilizada en el presente trabajo, se utilizó una búsqueda manual en las diferentes bases de datos científicas como lo son: IEEE Explorer, Scopus, entre otros, haciendo uso de una cadena de búsqueda conformada por palabras clave que consideran y utilizan los principales términos que intervienen en nuestra investigación (Reconocimiento de enfermedades, inteligencia artificial, redes neuronales), con el fin de encontrar artículos al buscar en palabras clave, sus títulos, resúmenes, y el contenido en general de la publicación.

Cadena de búsqueda en español:

("redes neuronales convolucionales")

AND

("Detección de enfermedades" OR "Detección facial")

Cadena de búsqueda en Ingles:

("Convolutional Networks")

AND

("disease detection" OR "facial detection")

c) Criterios de inclusión y exclusión

Tabla 3: Criterios de inclusión y exclusión.

#	Criterio de Inclusión
1	Estudios primarios
2	Estudios publicados a partir del año 2019.
3	Estudios relacionados a arquitectura de redes neuronales artificiales
4	Estudios relacionados a inteligencia artificial y clasificación de imágenes.
5	Estudios relacionados a aplicaciones con inteligencia artificial.
6	Estudios relacionados a evaluación de redes neuronales artificiales.
7	Estudios relacionados a la detección de enfermedades con IA.
#	Criterios de Exclusión
1	Estudios secundarios
2	Estudios de poca relevancia en base a las preguntas de investigación.
3	Estudios publicados antes del 2019.
4	Estudios cortos con menos de tres paginas
5	Estudios duplicados
6	Estudios que no estén redactados en inglés o español
7	Estudios cuyo contenido no se encuentre disponible de manera gratuita.
8	Estudios cuya orientación no este alineada a nuestras palabras clave.

d) Proceso y resultados de la búsqueda

Proceso de búsqueda

El proceso de búsqueda se realizó mediante el uso de las palabras claves y cadenas de búsqueda en las diferentes bases de datos bibliográficas, las cuales son: Web of Science, IEEE Digital Library, Science Direct, Scopus. En la figura 2 se detalla los pasos del proceso de búsqueda.

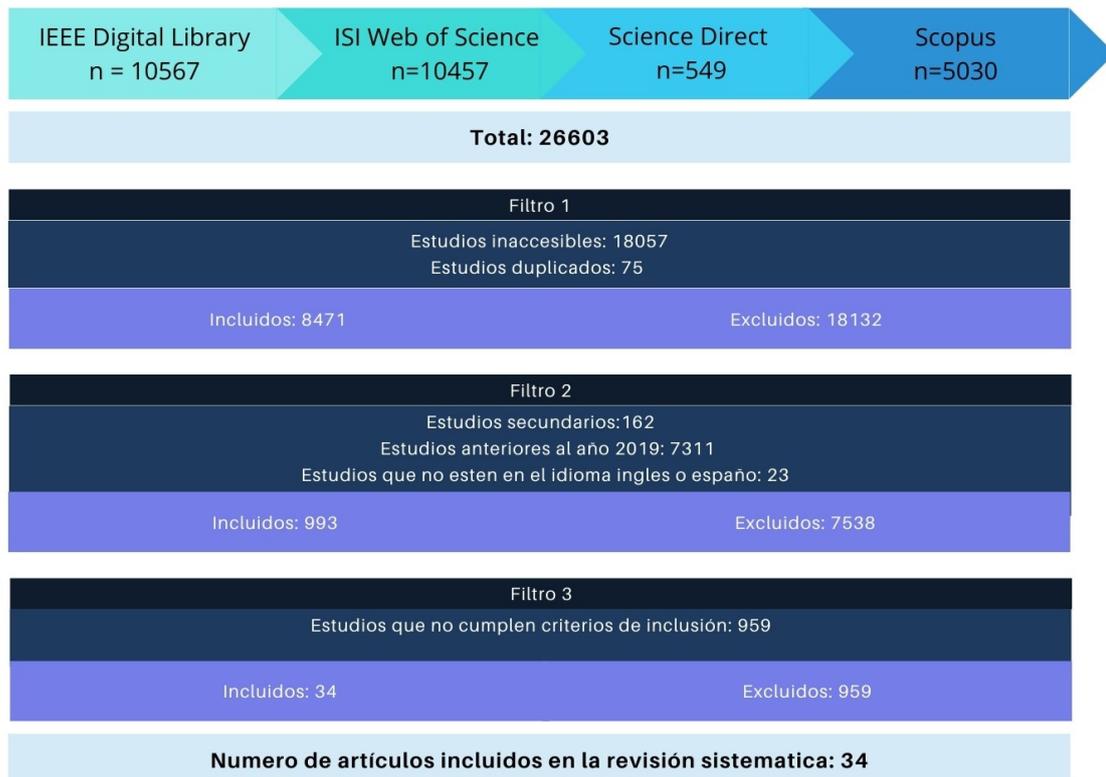


Figura 2: Proceso de búsqueda

En la **Figura 2.** se muestra en detalle el proceso y los resultados de la búsqueda bibliográfica realizada para el presente proyecto de investigación. Se utilizaron varias bases bibliográficas, entre las que se destacan Scopus, Web Of Science, Science Direct Y IEEE Digital Library. A través de una revisión exhaustiva, clasificación y aplicación de filtros, se obtuvo un total de 25 artículos relevantes.

Resultados de búsqueda

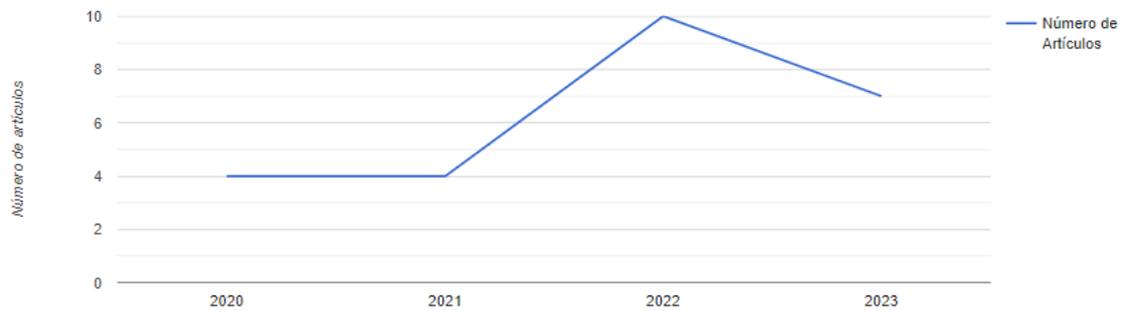


Figura 3: Cantidad de artículos seleccionados por año

Fuente: Parsifal

En la **Figura 3**. Se evidencia la cantidad de trabajos publicados por un rango específico de años, para ser examinados y analizados para el proyecto de investigación. La recolección se basó en el rango de 2019 a 2023 dentro de las diferentes bases electrónicas.

1.2. Antecedentes históricos

Las redes neuronales convolucionales (CNN) emergieron como un paradigma revolucionario en el ámbito de la visión por computadora, inspiradas por la estructura y funcionalidad del córtex visual biológico. Inicialmente conceptualizadas en la década de 1980 por Yann LeCun, estas arquitecturas emplearon el algoritmo de retro propagación para optimizar el reconocimiento de dígitos manuscritos, culminando en el desarrollo del modelo LeNet-5. Este avance seminal no solo estableció un precedente para la aplicación de CNN en tareas de clasificación de imágenes, sino que también inauguró un nuevo capítulo en el aprendizaje profundo, aunque su adopción inicial fue limitada debido a las restricciones computacionales de la época [3].

La inteligencia artificial ha experimentado una evolución notable a lo largo del tiempo. En sus inicios, se limitaba al desarrollo de sistemas expertos y reglas codificadas manualmente. Sin embargo, en la década de 1980, surgió una herramienta revolucionaria: las redes neuronales artificiales. Estas redes, inspiradas en la organización del sistema visual del cerebro, destacaron por su capacidad para procesar datos y reconocer patrones, especialmente en tareas de visión por computadora [4].

Con el paso del tiempo, las redes convolucionales se han convertido en un campo significativo dentro de la inteligencia artificial, dejando una huella profunda en diversas áreas como la medicina,

la robótica y el procesamiento del lenguaje natural. Gracias a su aplicación en el desarrollo de tecnologías innovadoras, han provocado una transformación significativa en nuestra sociedad. Las redes convolucionales, al permitir el avance en diferentes campos, han sentado las bases para el desarrollo de nuevas y poderosas herramientas tecnológicas que seguirán impactando positivamente en nuestra vida cotidiana [5].

Desde hace algún tiempo considerable ya se han planteado temas investigativos sobre el análisis de enfermedades utilizando inteligencia artificial, las investigaciones se realizaron con el objetivo de analizar y proponer alternativas de prevención y control para diversas enfermedades. A continuación, se toma como ejemplo el artículo del 2021 donde se presentó una solución para el control de enfermedades en las hojas de pimiento. El objetivo era utilizar redes neuronales convolucionales debido a su alta precisión de validación y rápida tasa de convergencia. Después de ajustar y evaluar el modelo, se obtuvo un índice de precisión del 96% durante las pruebas utilizando un conjunto de datos. Se consideró su aplicación para detectar, identificar y clasificar enfermedades en las plantas de pimiento [6].

En el trabajo de Imran Iqbal et al [7], se describe el desarrollo de un modelo de redes neuronales convolucionales profunda para la clasificación de anomalías gastrointestinales humanas, esta solución ofrece un diagnóstico mucho más acelerado permitiendo la reducción de costos de los procedimientos de investigación, esta red fue desarrollada a partir del diseño de múltiples rutas, varias resoluciones de imagen y diversas capas convolucionales para mejorar la eficacia y el rendimiento, obteniendo un coeficiente de correlación de Matthews (CCM) de 0.9743, es utilizado para ayudar a gastroenterólogos a clasificar anomalías del tracto gastrointestinal.

En el artículo de 2023 donde se describe el desarrollo de una red convolucional profunda basada en DenseNet-201 llamada "MonkeyNet". Este modelo fue creado con el propósito de ayudar a los médicos en la realización de diagnósticos tempranos-precisos de la viruela del mono, así como para prevenir su propagación. La red neuronal fue desarrollada mediante la recopilación de imágenes de la enfermedad y la aplicación de técnicas de aprendizaje, lo que permite su detección y clasificación. MonkeyNet logra un índice de precisión que oscila entre el 94.04% y el 99.85% en el conjunto de datos original y en el conjunto de datos aumentado [8].

1.3. Antecedentes Teóricos

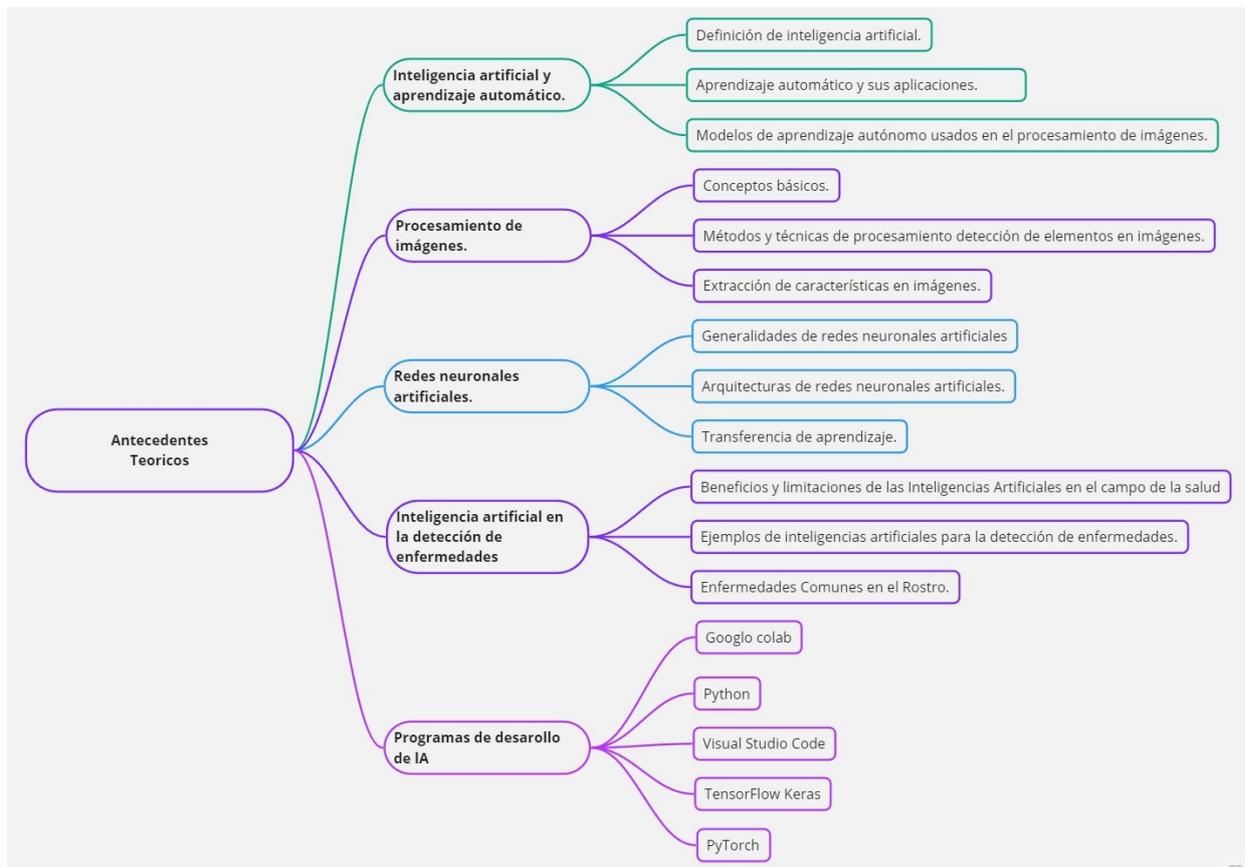


Figura 4: Mapa de antecedentes teóricos.

1.3.1. Inteligencia artificial y aprendizaje automático

1.3.1.1. Definición de Inteligencia artificial

Autores como [9] definen a la Inteligencia artificial como un intento por parte de las máquinas de replicar la inteligencia de las personas, o al menos los procesos de esta para realizar diversas tareas propias de un ser humano como reconocer voces, ayuda en la toma de decisiones, el procesamiento del lenguaje o la identificación de imágenes y clasificación de las mismas.

Los sistemas de Inteligencia artificial resultan útiles y son beneficiosos ya que replican el procesamiento del cerebro de las personas en tareas aparentemente simples, como lo menciona [10], siendo capaz de llegar a una conclusión y armar su propia solución, encontrando un algoritmo para una tarea que una persona consideraría complicada. El resultado que se obtendrá del sistema dependerá de las entradas que le demos, ya que, en base a estas, el sistema será capaz de armar un algoritmo capaz de resolver lo que se le plantea.

1.3.1.2. Aprendizaje autónomo y sus aplicaciones

El aprendizaje autónomo es la capacidad que tiene un sistema de aprender y adaptarse a los nuevos conocimientos sin intervención de un tercero, los autores de [10] lo definen como técnicas que se basan en modelos explícitos o implícitos previamente establecidos que le permiten al sistema poder encontrar patrones y caracterizarlos mediante un análisis de los datos que se le proporcionan al modelo.

Estas técnicas son muy aplicadas por los sistemas de inteligencia artificial para poder lograr aprender, lo indispensable en estas técnicas es tener listos los datos con los que se van a entrenar al modelo, [11] nos dice que estos datos deben estar etiquetados correctamente para que se pueda realizar un buen entrenamiento, lo que conlleva muchos recursos.

El aprendizaje autónomo es aplicado en el desarrollo de varias nuevas tecnologías, [10] nos comenta que el uso más importante se ha visto en el desarrollo de:

- Redes Bayesianas.
- Modelos de Markov.
- Redes Neuronales.
- Técnicas de lógica difusa.
- Algoritmos genéticos.
- Agrupamiento y detección de outlier.

1.3.1.3. Modelos de aprendizaje autónomo usados en el procesamiento de imágenes.

Los modelos de aprendizaje profundo, que es un subcampo del aprendizaje autónomo según [12] y estos resultan ser los más eficientes al momento de trabajar con imágenes, ya que [13] nos dice que muestran una eficiencia relativa cuando se realizan trabajos de clasificación basados en datos e imágenes, ya que estos presentan características útiles en la tarea como:

- Adaptabilidad ante el cambio
- Identificación automática de características en datos de entrada.
- Identificación de patrones de datos no expuestos.

Dentro de modelo de aprendizaje profundo encontramos también técnicas de aprendizaje profundo, las cuales son el aprendizaje supervisado, el aprendizaje semi supervisado y por último

el aprendizaje no supervisado [14], cada una de estas técnicas posee modelos y algoritmos que pueden ser usados en el procesamiento de imágenes siendo aprendizaje supervisado el más usado, ya que cuenta con algoritmos como perceptrón multicapa y las famosas redes neuronales convolucionales.

Otro algoritmo con enfoque en el aprendizaje automático supervisado es el conjunto de algoritmos de Naive Bayes, los cuales dependen del teorema propuesto por nave bayes, estos algoritmos siguen el principio de que cada par de pronósticos va a ser independiente del otro. Este es uno de los enfoques de aprendizaje automático supervisado. Aunque este algoritmo es más usado en la predicción, ya que asume características que brindan un impacto equivalente e independiente si se incluyen una gran dimensión de datos a la predicción, obteniendo unos resultados mucho más precisos [15].

1.3.2. Procesamiento de imágenes

1.3.2.1. Conceptos básicos

El procesamiento de imágenes es un grupo de técnicas que se encuentran dentro del área de las matemáticas aplicadas, el cual se encarga de analizar y tratar de manipular los elementos que están contenidos en una imagen digital haciendo uso de un procesador [16], en otras palabras, es un conjunto de técnicas usadas por un procesador para manipular imágenes digitales, este sistema tiene como datos de entrada imágenes digitales y de igual forma obtiene una nueva imagen como salida del proceso.

Las imágenes obtenidas de manera digital regularmente se encuentran sujetas a problemas como ruido, distracciones o problemas de calidad. El procesamiento de imágenes se encarga de realizar una limpieza de la misma para que puedan ser usadas y vistas por el ojo humano, o aplicarlo en otras áreas. En [16] nos comenta que el procesamiento de imágenes tiene aplicaciones en distintas áreas de interés como:

- Satélites.
- Medicina.
- Agricultura.
- Telecomunicaciones.
- Procesos Industriales.

1.3.2.2. Métodos y técnicas de procesamiento y detección de elementos en imágenes.

Como ya vimos en [16] el procesamiento de imágenes es aplicado en varios campos y mediante estos podemos obtener datos sobre las mismas, podemos identificar características recurrentes en imágenes que estén relacionadas y de esta forma aplicarlo de distintas formas en las distintas áreas.

En [17] se propone una técnica de identificación de enfermedades en cultivos, donde se hizo uso de un modelo de identificación con red neuronal convolucional, además se propuso una técnica en la cual usaban módulos de inyección y convolución dilatada, con los cuales lograron identificar características de varias enfermedades que afectan a los cultivos en diferentes escalas.

La técnica de detección de imagen de novela simple es otra técnica aplicada en el procesamiento de imágenes, propuesta por [18], que, junto a las redes neuronales convolucionales, pretende mejorar la precisión al momento de detectar enfermedades. Esta técnica es un algoritmo que es capaz de calcular la densidad de píxeles que están presentes en las imágenes que se dan como entrada, esta densidad se usa para lograr transformar la imagen en una escala de grises, con lo cual el algoritmo podrá clasificar las imágenes de salida en función de dicha escala de grises de la entrada.

1.3.2.3. Extracción de características en imágenes.

Una parte importante dentro del procesamiento de imágenes es la capacidad de poder extraer características de las imágenes, con las cuales podemos clasificarlas u detectar objetos dentro de las mismas. Una vez que se extraen esas características, los distintos investigadores podrán hacer uso de estas para sus propios objetivos de investigación, de modo que, el esencial saber la forma en la que se extraen esas características de las imágenes.

Las imágenes actuales están conformadas por píxeles RGB, los cuales se mezclan para lograr obtener todos los colores, una de las técnicas para extraer características en imágenes es transformarlo a escala de grises. Para el sistema de procesamiento le es más fácil trabajar con escalas de grises, ya que así los datos de entrada son menos voluminosos, porque el sistema transforma estos colores en la escala de grises a datos numéricos para puedan ser procesados, mejorando la eficiencia del sistema [18].

1.3.3. Redes Neuronales Artificiales

1.3.3.1. Generalidades de las redes neuronales artificiales

Dentro del mundo animal, el proceso para obtener información es a través de las redes neuronales que poseemos en nuestro cerebro, este es capaz de realizar procesos con todos los datos de entrada que obtenemos a través de nuestros cinco sentidos. Este sistema fue la inspiración para crear las redes neuronales artificiales, las cuales básicamente son neuronas artificiales creadas por el ser humano que están interconectadas [19].

Este campo abarca un sin número de arquitecturas de redes neuronales artificiales capaces de realizar tareas sumamente complejas, pero [19] postula que esta se inició como una forma para procesar imágenes, debido a que el perceptrón fue el primer modelo que se creó de redes neuronales, este modelo se puso a prueba teniendo la tarea de detectar caracteres ópticos, es decir que de cierta forma estaba procesando una imagen para saber que carácter se presentaba en la imagen.

Con el avance en esta área, las redes neuronales artificiales profundas fueron aumentando la precisión en el procesamiento de imágenes significativamente, siendo capaces de lograr la clasificación en estas, aunque una red neuronal artificial básica conformada por una capa conectada, otra capa de softmax y por último una de salida puede realizar tareas de clasificación, aunque esta sería menos eficiente que los modelos y arquitecturas que hay actualmente [20] [21].

1.3.3.2. Arquitecturas de redes neuronales artificiales.

En lo que va del tiempo, el área de las redes neuronales artificiales se ha extendido a varias áreas trayendo consigo la creación de varias arquitecturas de redes neuronales que son aplicables en casos de uso específicos, o simplemente son mejores que sus predecesoras en cierta área, el autor [18] nos comenta que dentro del área de procesamiento de imágenes se han utilizado las siguientes arquitecturas de redes neuronales artificiales:

- **Teoría de resonancia adaptativa o “ART”:** este es un modelo de red neuronal medianamente simple que según [22] es principalmente utilizada en el reconocimiento de patrones de diversas fuentes, es por eso que se aplican en el desarrollo de sonares, radares o artefactos del mismo tipo.

En cuanto a este modelo, [22] define a este modelo como sofisticado, a pesar de ello, es poco utilizada debido a ciertos problemas que tiene al momento de implementarla en un proyecto como: es sensible a la traslación, también es sensible a la distorsión y al cambio de escala.

- **Red neuronal Convolutiva o “CNN”:** Dentro del área de procesamiento de imágenes, tiene la tarea de poder clasificar y distinguir entre los distintos elementos u objetos presentes en una imagen. Es una arquitectura compuesta por múltiples neuronas artificiales, pero principalmente está conformada por tres capas las cuales son: capas de convolución y capas de reducción, las cuales se encargan de realizar la tarea de extraer las características, y por último las capas densas que se encargan de la tarea de clasificar [23].

Debido a su gran usabilidad es que se han visto utilizadas en diversos trabajos investigativos e implementada como herramienta para detectar enfermedades en cultivos de arroz, plantas de maíz, hojas de tomate, hojas de trigo, en la planta capsicum y en la papa [24] [25] [26] [27] [28]. De igual forma se la utilizado para tareas de clasificación automática en distintas plantas como: en las hojas de caupí, plátanos maduros y crudos, la madurez de la composta y en las enfermedades de la papa [29] [30] [31] [28].

Podemos notar la popularidad de esta arquitectura al realizar la investigación de trabajos de procesamiento de imágenes y notar que la mayoría usan la arquitectura de redes neuronales convolucionales, también [23] propone que la popularidad de esta arquitectura se incrementó gracias a que ImageNet logro la victoria en una competencia sobre reconocimiento visual en gran escala en el año 2012.

- **Perceptrón Multicapa o “MLP”:** La estructura de este modelo de red neuronal esta principalmente compuesta por una capa de entrada, una capa oculta de elementos donde se procesan la información o también llamado neuronas y una capa de salida donde se obtienen los resultados [32].

En base a [32], se puede decir que lo más difícil en esta metodología es determinar cuántas neuronas se pondrán en cada capa del modelo. Además, [32] propone un ejemplo básico donde se aplica este modelo es en un algoritmo de propagación hacia atrás o Back Propagation, el cual es un algoritmo matemático para minimizar la suma de errores, con lo que se puede modificar la dirección que tomara la red al cambiar el vector de pesos y así disminuir la cantidad de errores que la red cometa.

- **Red neuronal Pulso Acoplada o “PCNN”:** Este modelo de red se puede definir según [33] como una red de neuronas que se encuentran integradas y de encendido lateral en una sola capa que es bidimensional, la cual no necesita ser entrenada y que las imágenes de salida presentan algunos segmentos de las imágenes que fueron sus entradas en distintas iteraciones.

Este modelo es bueno para procesar imágenes igual que los modelos anteriores, pero [33] nos dice que también es aplicada en otros campos, y es por eso que en la década del 2000 ha experimentado un desarrollo acelerado al ser utilizado en grandes cantidades de trabajos sobre el tema en ese tiempo.

1.3.3.3. Transferencia de aprendizaje

La transferencia de aprendizaje es un concepto que según [34] trata sobre mejorar a un individuo en un ámbito mediante la transferencia de información de otro ámbito relacionado con el fin de aprovechar el conocimiento adquirido. Por lo que este concepto se puede aplicar a las redes neuronales al ser tomadas estas como individuos y a las tareas como ámbitos.

Por lo que, podemos definir a la transferencia de aprendizaje en redes neuronales como el utilizar información y conocimientos obtenidos por una red neuronal ya entrenada en realizar una tarea, para incrementar el rendimiento en otra tarea relacionada pero diferente.

Con esta técnica se logra aprovechar el conocimiento y proceso de aprendizaje que se obtiene entrenando redes neuronales artificiales para facilitar el entrenamiento de nuevas redes neuronales en nuevas tareas.

En [34] se pueden identificar varias aplicaciones que se la ha dado al aprendizaje por transferencia que principalmente se encuentran relacionados con los trabajos de procesamiento del lenguaje natural, pero también en:

- Clasificación de sentimientos.
- Clasificación de texto.
- Detección de correo electrónico indeseable.
- Clasificación de texto en distintos idiomas.

1.3.4. Inteligencia artificial en la detección de enfermedades

1.3.4.1. Beneficios y limitaciones de la Inteligencia artificial en el campo de la medicina.

Es bien conocido que la inteligencia artificial y las redes neuronales necesitan de una gran cantidad de datos para que puedan aprender de estos y así lograr encontrar patrones y poder definir un algoritmo que resuelva el problema relacionado a estos datos. Es por eso que uno de los beneficios que se han identificado es la facilidad de obtención de datos e información sobre ciertas enfermedades.

Por ejemplo, se logra observar que la obtención de los datos ha sido relativamente sencilla y la cantidad de datos obtenidos ha sido voluminosa en ciertos proyectos, debido principalmente a que estos datos son mucho más comunes y fáciles de obtener como:

- Imágenes de rayos – X para detectar covid y tuberculosis [35] [36].
- Imágenes de resonancia magnética en detección de tumores cerebrales [37].
- Imágenes de micro anatomía de osteosarcoma teñido con hematoxilina y eosina (H y E) en la detección de cáncer de hueso [38].
- Imágenes de colposcopia digital en la detección de enfermedades cervicales [39].
- Imágenes microscópicas de células sanguíneas en el diagnóstico de la malaria [40].
- Tomografías de coherencia optima en la clasificación de enfermedades de retinianas [41].
- Imágenes de pacientes en la detección de la viruela del mono [8].

Aunque esta también puede ser una limitación en ciertos casos, ya que algunas instituciones se niegan a compartir esta información por diversas causas, que como resultado se obtienen pocos datos para entrenar el modelo, lo que reducirá la eficiencia del resultado, como se presenta en [42] donde el entrenamiento del modelo se realizó con un conjunto de datos pequeño en comparación con los otros trabajos, pero se complementó con la transferencia de aprendizaje de la que hablamos anteriormente.

1.3.4.1. Ejemplos de inteligencia artificial para la detección de enfermedades.

El área de la salud y de la Inteligencia artificial se han estado acercando cada vez más, gracias al progreso que tiene la inteligencia artificial en la resolución de problemas, en la revisión sistemática de la literatura se han logrado encontrar varios trabajos en los que se ha utilizado la inteligencia

artificial en la detección de diversas enfermedades del ser humano, como se puede observar en la **Tabla 4**, donde podemos observar lo más relevante de cada uno de estos trabajos.

Tabla 4: Ejemplos de inteligencia artificial para la detección de enfermedades

Tecnología usada	Propósito	Conclusión	Referencia
Redes convolucionales profundas y cambio de espacio regular.	Clasificación de lesiones cutáneas.	Los resultados experimentales demostraron que este modelo es mejor que otros en un 9% conjuntamente.	[43]
Función de pérdida, lógica equilibrada y aumento de imagen en tiempo real.	Mejorar la clasificación de enfermedades en la piel.	El modelo logro un porcentaje de precisión del 89,97%.	[44]
Redes neuronales convolucionales.	Detectar Nistagmo.	El modelo demuestra que los métodos son capaces de identificar períodos de nistagmo con un modesto grado de precisión.	[45]
Red Movilnet V2.	Clasificación de imágenes de melanoma.	El método propuesto puede brindar una alta precisión, hasta un 85 %, en comparación con otras redes.	[46]
Redes neuronales convolucionales grupales y Transición de Equivalencia.	Clasificación del cáncer de Mama.	Se logró un alto rendimiento computacional y se mejoró la generalización de la inferencia con una precisión del 94,84%.	[47]
Máquina vectorial de soporte y redes neuronales convolucionales.	Categorización de lesiones cutáneas comunes.	Los resultados demostraron que los métodos propuestos son una herramienta para la tarea propuesta.	[48]
Aprendizaje profundo.	Clasificación de psoriasis.	Las precisiones finales que se obtuvieron fueron de un 84.2% lo que es relativamente bueno.	[49]

Tabla 4: Ejemplos de inteligencia artificial para la detección de enfermedades

Tecnología usada	Propósito	Conclusión	Referencia
Redes neuronales convolucionales.	Reconocimiento de enfermedades en los bordes de las cuerdas vocales.	Los resultados demostraron que las inferencias del modelo fueron consistentes con los exámenes clínicos realizados.	[50]
Redes neuronales convolucionales y aprendizaje de transferencia.	Clasificación automática de lesiones periapicales.	El sistema desarrollado logro una precisión del alrededor del 70%.	[51]

1.3.4.2. Enfermedades comunes en el Rostro

En artículos como [52] mencionan que las enfermedades y afecciones que afectan la cara tienen el potencial de generar dolor y modificar su apariencia, llegando a repercutir en la visión, el habla, la capacidad de respirar y la capacidad de tragar. Además de enfermedades, también nos habla de las lesiones faciales más frecuentes, como las fracturas óseas, particularmente en los huesos de la nariz, las mejillas y la mandíbula.

Autores como [53] comentan que existen varios tipos de trastornos que varían tanto sus síntomas como su gravedad, además menciona una lista de enfermedades comunes que se presentan en la piel, entre esta lista se seleccionó las enfermedades las cuales son analizadas por el sistema.

A continuación, se describen estas enfermedades según [53]:

- **Acné:** Esta es una afección que principalmente se encuentra en el rostro, pero también suele aparecer en lugares como el cuello, los hombros, el pecho y la espalda alta. Se caracteriza por ser brotes que surgen en la piel como espinillas, puntos negros y blancos, quistes, y nódulos. Si este problema no se trata con precaución, se llegan a tener repercusiones como cicatrices o manchas en la piel.
- **Eczema:** Esta enfermedad se caracteriza por el surgimiento de manchas escamosas que con el tiempo se descascaran, estas manchas de color amarillo o blanco suelen estar acompañadas por enrojecimiento, la picazón, engrasamiento y pérdida del cabello del área afectada.

- **Melanoma:** Esta enfermedad es una forma del cáncer de piel, la cual es mucho mas frecuente en personas con un tono de piel claro. Se presenta como un tipo de lunar en cualquier en la cara o el cuerpo, presenta bordes irregulares y asimétricos de distintos colores. Estos pueden cambiar de color o crecer con el tiempo.
- **Hiperpigmentación:** Esta es una enfermedad común que se presenta en el rostro y partes del cuello, pecho o brazos, aunque es menos común en estas zonas. Esta afección es más común en mujeres embarazadas y personas con un tono de piel oscuro y que se exponen frecuentemente a la luz del sol. Sus únicos síntomas son la decoloración de la piel, presentes como manchas en la piel.

Lunares benignos: Además de las enfermedades presentadas previamente, existen otras que también se presentan en el rostro, pero también pueden presentarse en otras partes del cuerpo, una de estas son los lunares benignos. En [54] se definen a estos como masas benignas de piel, y estos suelen confundirse mucho con el melanoma, en el mismo artículo se definen aspectos a tener en cuenta al momento de diferenciarlos como:

- **Asimetría:** Cuando las mitades del lunar son distintas.
- **Borde:** Cuando los bordes de la masa son distintos y no uniformes.
- **Color:** Cuando el lunar no es todo del mismo color.
- **Evolución:** Cuando el lunar cambia conforme avanza el tiempo.

1.3.5. Programas de desarrollo de Inteligencia Artificial

1.3.5.1. Google Colab

Google Colab es una plataforma gratuita de Google que proporciona un entorno basado en la nube para ejecutar y utilizar bibliotecas de código Python. Con acceso a recursos de hardware, como CPU y GPU, además de la opción de trabajo colaborativo, se convierte en una herramienta ideal para proyectos relacionados con análisis de datos, aprendizaje automático y visualización. [55]

1.3.5.2. Python

Python es lenguaje de alto nivel, se considera un lenguaje multiparadigma, es decir, soporta diversos estilos de programación como: orientado a objetos, imperativa y funcional, cuenta con un

tipado dinámico y a diferencia de otros lenguajes no realiza compilación, es muy popular en el área de analítica de datos y machine learning. [56]

1.3.5.3. Visual Studio Code

Visual Studio Code es un editor de código extremadamente popular, apreciado por su sencillez y versatilidad. Ofrece soporte para una amplia variedad de lenguajes de programación y su rendimiento es óptimo. La integración de extensiones es una de sus características más destacadas, lo que agiliza significativamente el proceso de codificación. En la actualidad, se ha convertido en la opción preferida para muchos desarrolladores dentro del ámbito del desarrollo de software. [57]

1.3.5.4. TensorFlow

TensorFlow, originalmente desarrollado por Google, es una biblioteca open source multiplataforma. Ofrece una variedad de herramientas para crear y entrenar modelos de aprendizaje automático, lo que facilita el desarrollo de soluciones inteligentes. Además, la incorporación de TensorBoard en TensorFlow permite una visualización clara y detallada de información relevante del modelo, lo que ayuda a comprender y mejorar el proceso de entrenamiento. Otro aspecto destacado es su capacidad para distribuir la carga de trabajo en múltiples dispositivos, aprovechando al máximo el rendimiento de la CPU, GPU o TPU, lo que permite el procesamiento eficiente de grandes conjuntos de datos y el escalamiento para aplicaciones a gran escala. [58]

1.3.5.5. Keras

Keras es una biblioteca de código abierto utilizada para el aprendizaje de redes neuronales artificiales, escrita en Python. Su API permite la creación y composición modular de modelos de diversas arquitecturas, facilitando la construcción eficiente de capas y reduciendo la curva de aprendizaje, maneja una simplicidad y versatilidad que se ha convertido en una opción popular para aquellos que desean desarrollar y entrenar modelos de aprendizaje profundo con facilidad y efectividad. Su enfoque intuitivo y la capacidad de utilizar diferentes motores de backend, como TensorFlow. [59]

1.3.5.6. Pytorch

Pytorch es una biblioteca open source enfocada a la preparación de redes neuronales convolucionales en Python, sus características más notables son: Realización de cálculos en

estructuras tensoriales, aceleración a través de GPUs, implementación de redes neuronales en un entorno de integración automatizada, redes neuronales adaptables con derivación automática en modo inverso, permitiendo así manipular de forma arbitraria el comportamiento de la red neuronal. [60]

1.4. Antecedentes contextuales

El consultorio dermatológico objetivo es una institución privada, que tiene como misión brindar un servicio de protección y cuidado para la piel mejorando la calidad vida de las personas.

Este trabajo de titulación está centrado en desarrollo de una aplicación móvil y web para la detección de enfermedades faciales, utilizando redes neuronales convolucionales en esta entidad.

1.4.1. Ámbito de aplicación

Algunas personas no toman en cuenta la posibilidad de solicitar consultas médicas cuando experimentan molestias en la piel, debido a diversos motivos como la falta de tiempo, costos elevados o simplemente no perciben la necesidad de hacerlo.

Por este motivo, se ha desarrollado una aplicación móvil y web que ofrece la detección automatizada de ciertas enfermedades cutáneas. Para su prueba y validación, se ha seleccionado un consultorio dermatológico de la ciudad de Machala, utilizando algunos de sus casos como punto principal de análisis.

1.4.2. Establecimiento de requerimientos

En la **Tabla 5** se mencionan los requerimientos y su funcionalidad dentro de la aplicación

Tabla 5: Establecimiento de requerimientos

Requerimientos	Funcionalidades	Alcance
Modelo de Red Neuronal Convolutacional.	Clasificar imágenes de enfermedades	Crear un modelo de red neuronal convolutacional que logre clasificar enfermedades faciales.
Dataset de Imágenes	Definir un dataset de imágenes representativo	Diseñar el dataset de manera que sea compatible con algoritmos de aprendizaje automático y técnicas de visión por computadora.

Tabla 5: Establecimiento de requerimientos

Requerimientos	Funcionalidades	Alcance
Base de datos	Almacenamiento en tiempo real	Diseñar una base de datos relacionar para el almacenamiento de datos sobre enfermedades, tratamientos, recomendaciones, productos y dermatólogos.
Aplicación web Administrativa	Gestión de Contenido	Procedimientos para crear, editar y eliminar.
Plataforma móvil/web de Consulta.	Acceso a la Cámara del Dispositivo	Requerir el permiso del usuario para acceder a la cámara de su dispositivo.
	Acceso a la galería	Requerir el permiso del usuario para acceder a la galería de imágenes de su dispositivo.
	Generación de Informe de Resultados	Desarrollar una pantalla donde se presente la información que se obtuvo del api del modelo sobre la predicción de la enfermedad.
	Pantalla de información adicional.	Obtener los datos adicionales como recomendaciones, tratamientos y productos de la base de datos, y presentarlos en la aplicación móvil y web.
	Contactos con profesionales	Crear un apartado donde el usuario podrá revisar los distintos dermatólogos registrados en la base de datos, y ponerse en contacto con ellos si lo desea.
	Vista de ayuda	Crear una pantalla de ayuda a los usuarios donde se le dará consejos sobre cómo tomar una buena foto para obtener buenas predicciones.
Plataforma móvil/web de Consulta.	Recorte de Imagen	Crear un apartado donde se recorte la imagen seleccionada ya sea de la cámara o de la galería antes de enviarla a consulta.
Documentación	Documentación técnica	Crear documentación técnica dirigida a desarrolladores, abordando aspectos como la estructura del código, la elección de tecnologías y los patrones de diseño utilizados.

CAPÍTULO II. DESARROLLO DEL PROTOTIPO

2.1. Definición del prototipo

La tecnología empleada en el desarrollo del prototipo se ve representada en la **Figura 5**, donde se describe el funcionamiento del mismo.

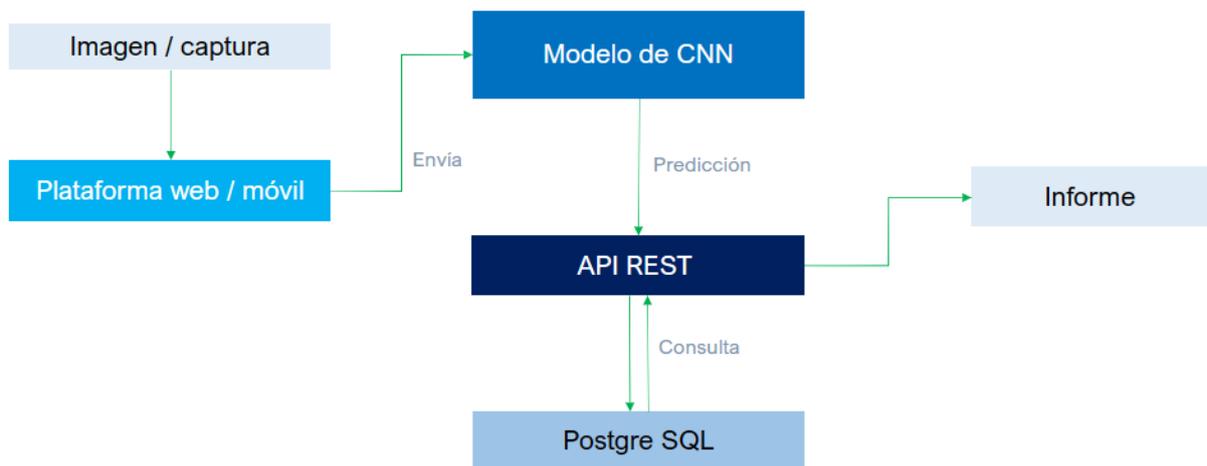


Figura 5: Establecimiento del prototipo

La aplicación actúa como un sistema de diagnóstico especializado en la identificación de patologías dermatológicas faciales. Utiliza como variable de entrada una imagen digital del área facial, la cual es sometida a un análisis mediante un modelo de red neuronal convolucional. Posteriormente, el sistema genera un informe analítico que encapsula los resultados del análisis, proporcionando así información relevante.

2.2. Metodología de desarrollo del prototipo

2.2.1. Enfoque, alcance y diseño de investigación

El enfoque elegido para este trabajo fue un enfoque cuantitativo, el cual es apropiado para este tipo de trabajo, ya que mediante este podemos realizar la prueba de la hipótesis planteada y trabajar con el gran número de datos recolectados que usamos para entrenar al modelo de red neuronal convolucional elegido y de esta forma pueda ser capaz de detectar eficazmente las enfermedades de la piel que se le presenten.

En relación al alcance, iniciamos con un alcance exploratorio, debido a que, en este trabajo, empezamos realizando una revisión sistemática de la literatura en bases de datos académicas de

gran impacto sobre las principales tecnologías que fueron usadas en nuestro proyecto como lo son las redes neuronales convolucionales, el aprendizaje profundo y la detección de enfermedades por inteligencia artificial. Posteriormente, se incorporó un alcance descriptivo, por el cual pudimos comprobar que la aplicación es capaz de reconocer una enfermedad facial en base a las características de la misma presentada en forma de imagen de manera eficiente.

El diseño de investigación implementado será Cuasi-Experimental debido a que el trabajo ha sido probado con un grupo predefinido de imágenes de evaluación, los cuales determinaran el nivel de efectividad y precisión de la detección.

2.2.2. Unidades de análisis

Se consideró como muestra las imágenes que se utilizaran para la construcción del modelo, considerando un total 34833 imágenes correspondientes al 100% para el entrenamiento se consideró el 80% y la validación un 20%, en la siguiente tabla se desglosa la información.

Tabla 6: Datos de la data set entrenamiento y pruebas

	Cantidad de imágenes	Porcentaje
Entrenamiento	30910	80%
Validación	3923	20%
Total	34833	100

2.2.3. Técnicas e instrumentos de recopilación de datos.

Para esta investigación, se hará uso de las técnicas e instrumentos de recopilación de datos especificadas en la siguiente tabla:

Tabla 7: Técnicas e instrumentos de recopilación de datos

Técnica	Instrumento
Análisis de Datos	Guía de análisis del conjunto de imágenes o datos.

2.2.4. Técnicas de procesamiento de datos para la obtención de resultados

La técnica de procesamiento y análisis para la obtención de resultados aplicada en la investigación fue Deep Learning, la cual nos permitió entrenar un modelo de red neuronal artificial

convolucional capaz de detectar enfermedades de la piel en la cara, por lo que se necesita de un conjunto de imágenes debidamente etiquetadas en base a las distintas enfermedades que se pretende detectar.

2.2.5. Metodología o métodos específicos

En el proceso de desarrollo de la red neuronal convolucional, se empleó el modelo de proceso estándar CRISP-DM. Este modelo proporciona una estructura sólida y bien definida, descrita a continuación.

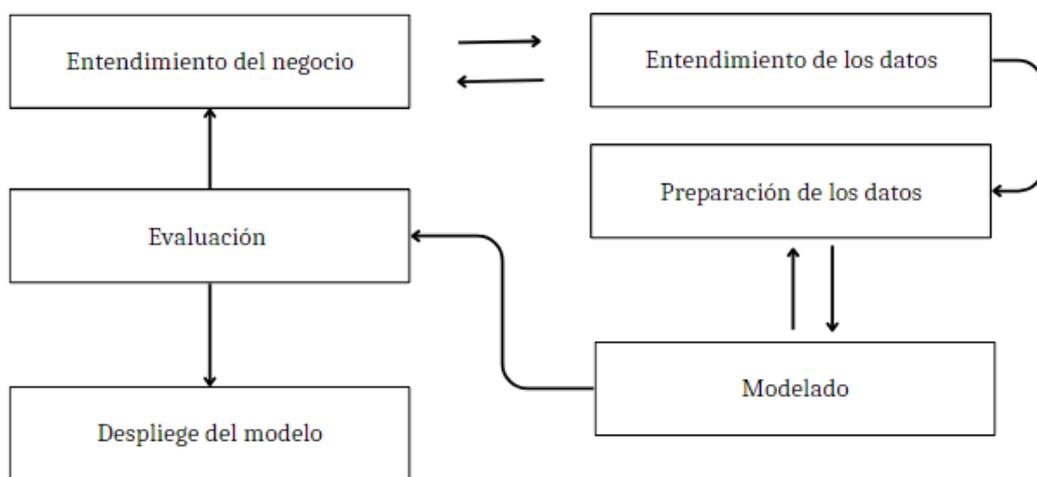


Figura 6: Fases de la metodología CRISP-DM

Para el desarrollo de la aplicación móvil y web hemos optado por la metodología EXTREME PROGRAMMING (XP), la cual, según está enfocada a implementar las buenas prácticas en el desarrollo ágil de la aplicación, esta metodología cuenta con cuatro fases codependientes las cuales se describen a continuación:

- **Fase de Planeación:** en esta fase el equipo trabaja conjuntamente con el usuario para definir historias del usuario, se establecen tiempos a cada tarea e igualmente se determina los elementos a incluir en la aplicación.
- **Fase de Diseño:** en esta fase se realizan los primeros diseños de la aplicación, enfatizando en diseños simples y funcionales enfocadas a tareas puntuales, entregando un primer prototipo del diseño de la aplicación.

- **Fase de Desarrollo:** en esta fase se empieza el desarrollo de la aplicación, en esta metodología es común realizar la codificación en parejas, cada uno interpretando un rol. Los desarrolladores integran los avances y cambios en el repositorio compartido varias veces al día, cumpliendo con la integración continua.
- **Fase de pruebas:** en esta fase los desarrolladores someten la aplicación o un módulo de ella a pruebas automatizadas que garantizan que la aplicación funcione correctamente y ayuda a detectar errores en una etapa temprana del proceso. Una vez pasada esta fase con buenos resultados, la aplicación esta lista para su lanzamiento.

2.2.6. Herramientas y/o Materiales

Las herramientas y materiales que se usaron tanto para el desarrollo de la red neuronal convolucional como para el desarrollo de la aplicación móvil y web que la implementará se especifican en la siguiente tabla:

Tabla 8: Herramientas y/o Materiales

Clasificación	Herramienta y/o Material
Software	<ul style="list-style-type: none"> • Google Colab. • TensorFlow. • Keras. • Visual Studio Code. • Android Studio.
Hardware	<ul style="list-style-type: none"> • Computadora personal. • Teléfono móvil personal.
Datos	<ul style="list-style-type: none"> • Dataset de imágenes de las distintas enfermedades faciales.
Lenguajes	<ul style="list-style-type: none"> • Dart • Python • JavaScript.

2.3. Desarrollo del prototipo

2.3.1. Metodología CRISP-DM

2.3.1.1. Comprensión del problema

Identificación del problema

A pesar de los avances en la medicina, el diagnóstico de enfermedades faciales todavía depende en gran medida de la evaluación visual realizada por dermatólogos. Este enfoque es subjetivo y puede llevar a diagnósticos tardíos. Además, el acceso a dermatólogos especializados puede ser limitado en áreas rurales o en países en desarrollo.

Determinar objetivos

- Identificar y recopilar un conjunto de datos diverso y representativo de imágenes de enfermedades faciales, que incluya diferentes tipos de piel, etapas de la enfermedad y grados de severidad.
- Preprocesar las imágenes para normalizar el tamaño, la iluminación y el color, y realizar aumentos de datos para mejorar la robustez del modelo.

Evaluación de la situación actual

El consultorio dermatológico actualmente carece de un sistema de software especializado para la clasificación automatizada de enfermedades faciales. Para abordar esta brecha tecnológica, proponemos el desarrollo de una aplicación móvil y web. Esta aplicación utilizará como entrada imágenes del tejido cutáneo que requiere análisis, y en respuesta, generará un diagnóstico preliminar acompañado de recomendaciones pertinentes.

2.3.1.2. Compresión de los datos

Recolección de los datos

Se recurrió a múltiples fuentes públicas para compilar el conjunto de datos que se empleará en el entrenamiento del modelo. A continuación en la **Tabla 11**, se detallan las características específicas de las enfermedades faciales que se pretenden clasificar:

Tabla 9: Descripción de Enfermedades

Nombre	Descripción	Imagen
Acné	Se suele manifestar como una combinación de comedones (puntos negros y blancos), pústulas y, en casos más severos, quistes o nódulos. Las áreas afectadas suelen presentar enrojecimiento e inflamación.	
Eczema	Se caracteriza por áreas de piel inflamada, enrojecida y con picazón. Puede presentar vesículas llenas de líquido que, cuando se rompen, forman costras. Las áreas afectadas pueden mostrar descamación y, en casos crónicos, la piel puede engrosarse.	
Melanoma	Esta enfermedad es una forma del cáncer de piel. Se presenta como un tipo de lunar en cualquier en la cara o el cuerpo, presenta bordes irregulares y asimétricos de distintos colores. Estos pueden cambiar de color o crecer con el tiempo.	
Hiperpigmentación	Esta afección es más común en mujeres embarazadas y personas con un tono de piel oscuro y que se exponen frecuentemente a la luz del sol. Sus únicos síntomas son la decoloración de la piel, presentes como manchas en la piel.	
Lunares benignos	En [54] se definen a estos como masas benignas de piel, y estos suelen confundirse mucho con el melanoma	

Descripción de los datos

Se han recopilado un total de 4,355 imágenes, que, aunque son altamente representativas, se planea ampliar la base de datos para mejorar la precisión del modelo. Cabe señalar que un conjunto de datos más extenso podría incrementar el tiempo requerido para el entrenamiento del modelo. Las imágenes actuales varían en tamaño, pero se consideran lo suficientemente representativas para capturar las características esenciales de las enfermedades faciales en cuestión.

2.3.1.3. Preparación de los datos

Limpieza de datos

Se llevaron a cabo las siguientes etapas en el proceso de limpieza y preparación de los datos:

- a. Eliminación de Imágenes No Adecuadas: Se descartaron aquellas imágenes que no cumplían con los criterios específicos para representar las enfermedades en estudio, así como imágenes erróneas o de baja calidad.
- b. Tratamiento Avanzado de Datos: Para las imágenes seleccionadas, se implementaron las siguientes técnicas de procesamiento:

Redimensionamiento: Todas las imágenes fueron ajustadas a un tamaño uniforme de 299x299 píxeles para garantizar la consistencia en el entrenamiento del modelo.

Optimización del Contraste y Calidad: Se empleó la ecualización adaptativa para mejorar el contraste y la calidad visual de cada imagen, útil para resaltar características específicas de las enfermedades faciales.

Estas etapas aseguran que el conjunto de datos esté optimizado para el entrenamiento del modelo, mejorando así las posibilidades de un diagnóstico preciso y eficaz.

Creación de indicadores

Los datos fueron organizados en directorios, estableciendo así cinco categorías distintas, cada una correspondiente al nombre de una enfermedad específica. Esta estructura de clasificación se ilustra en la **Figura 7**.

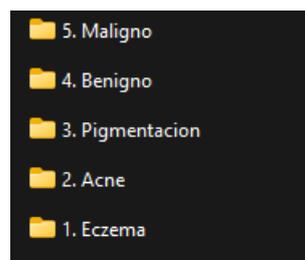


Figura 7: Clases etiquetas

2.3.1.4. Modelado

Selección de técnica de modelado

Se utilizó la arquitectura Xception pre entrenada como base. El modelo se compone de capas de Global Average Pooling, capas Flatten y capas densas (fully connected) con funciones de activación ReLU. El modelo se compila con el optimizador SGD, el código se muestra en la **Figura 8**.

```
addModel = tf.keras.applications.Xception(
    include_top=False,
    weights=None, # Establece los pesos en None porque los estamos cargando manualmente
    input_shape=(299, 299, 3)
)
addModel.load_weights('/kaggle/input/xception/xception_weights_tf_dim_ordering_tf_kernels_notop.h5')

model = Sequential()
model.add(addModel)
model.add(GlobalAveragePooling2D())
model.add(Flatten())
model.add(Dense(1024, activation="relu"))
model.add(Dense(512, activation="relu"))
model.add(Dense(5, activation="softmax", name="classification"))
```

Figura 8: Modelo de la red neuronal convolucional

Distribución de los datos

El conjunto de datos se distribuyó, equitativamente entre las clases de la data set, mediante un algoritmo de equilibrio, se muestra en la **Figura 9**.

```
train_df length: 30910
5. Benign      10888
6. Malign     6783
1. Enfeksiyonel 6000
2. Ekzama     4070
3. Akne       2149
4. Pigment    1020
Name: labels, dtype: int64
train_df length: 3923
5. Benign      1361
6. Malign     847
1. Enfeksiyonel 750
2. Ekzama     508
3. Akne       322
4. Pigment    135
Name: labels, dtype: int64
train_df length: 3928
5. Benign      1361
6. Malign     849
1. Enfeksiyonel 750
2. Ekzama     510
3. Akne       322
4. Pigment    136
Name: labels, dtype: int64
```

Figura 9: Distribución de los datos

Obtención del modelo

Mediante el uso de la plataforma kaggle, se obtuvo el modelo de red neuronal convolucional. Como resultado, obtuvimos el modelo en un archivo con extensión (.h5), en la **Figura 10** se evidencia su entrenamiento:

```
history = model.fit(train_gen , validation_data = valid_gen , epochs = 25)

Epoch 1/25
938/938 [=====] - 555s 565ms/step - loss: 1.0665 - accuracy: 0.5973 - val_loss: 0.8218 - val_accuracy: 0.6811
Epoch 2/25
938/938 [=====] - 475s 506ms/step - loss: 0.7124 - accuracy: 0.7244 - val_loss: 0.6706 - val_accuracy: 0.7469
Epoch 3/25
938/938 [=====] - 472s 503ms/step - loss: 0.5765 - accuracy: 0.7818 - val_loss: 0.6034 - val_accuracy: 0.7742
Epoch 4/25
938/938 [=====] - 473s 504ms/step - loss: 0.4725 - accuracy: 0.8270 - val_loss: 0.5516 - val_accuracy: 0.7971
Epoch 5/25
938/938 [=====] - 472s 503ms/step - loss: 0.3829 - accuracy: 0.8609 - val_loss: 0.5221 - val_accuracy: 0.8132
Epoch 6/25
938/938 [=====] - 469s 500ms/step - loss: 0.2995 - accuracy: 0.8947 - val_loss: 0.4929 - val_accuracy: 0.8300
Epoch 7/25
938/938 [=====] - 472s 503ms/step - loss: 0.2306 - accuracy: 0.9192 - val_loss: 0.4357 - val_accuracy: 0.8534
Epoch 8/25
938/938 [=====] - 472s 503ms/step - loss: 0.1773 - accuracy: 0.9408 - val_loss: 0.4258 - val_accuracy: 0.8621
Epoch 9/25
938/938 [=====] - 472s 503ms/step - loss: 0.1312 - accuracy: 0.9573 - val_loss: 0.4315 - val_accuracy: 0.8659
Epoch 10/25
938/938 [=====] - 473s 504ms/step - loss: 0.1004 - accuracy: 0.9680 - val_loss: 0.4744 - val_accuracy: 0.8550
Epoch 11/25
938/938 [=====] - 472s 503ms/step - loss: 0.0764 - accuracy: 0.9766 - val_loss: 0.4563 - val_accuracy: 0.8718
Epoch 12/25
938/938 [=====] - 471s 502ms/step - loss: 0.0599 - accuracy: 0.9822 - val_loss: 0.4812 - val_accuracy: 0.8766
Epoch 13/25
...
Epoch 24/25
938/938 [=====] - 473s 504ms/step - loss: 0.0170 - accuracy: 0.9949 - val_loss: 0.5515 - val_accuracy: 0.8866
```

Figura 10: Entrenamiento de la red neuronal convolucional

2.3.2. Metodología XP

2.3.2.1. Fase 1: Planificación

En esta fase el equipo trabaja conjuntamente con el usuario para definir historias del usuario, se establecen tiempos a cada tarea e igualmente se determina los elementos a incluir en la aplicación. Para esto es importante definir los roles del equipo XP, en la **Tabla 10** se definen los seis roles que contienen un equipo XP para que se obtenga una mejor productividad.

Tabla 10: Roles del quipo XP

Rol	Tarea	Representante
El cliente	Es el que se encarga de realizar las historias de usuario, y definir la prioridad de cada una.	Persona Natural.
El programador	Es un miembro que se encarga de escribir el código y realizar las tareas que conforman el proyecto.	Andy Chamba. Daniel Villano.
El entrenador	Es la persona que se encarga de vigilar el trabajo del resto.	Ing. Nancy Lojan.
El rastreador	Es la persona que monitorea como avanza el progreso del proyecto.	Ing. Nancy Lojan.
El probador	Es el que se encarga de la prueba del producto.	Andy Chamba. Daniel Villano.
El pronosticador	Es la que se encarga de rastrear los posibles riesgos del proyecto.	Andy Chamba. Daniel Villano.

Una vez definidos los roles se puede continuar con la comunicación entre el cliente y el desarrollador para la creación de las historias de usuarios. En este caso al ser una aplicación para la persona natural, se definieron los requerimientos entre los mismos miembros del equipo de desarrollo, y al final se obtuvieron los siguientes requerimientos:

- Base de Datos
- Aplicación web Administrativa.
- Plataforma Web de Consulta
- Plataforma móvil de consulta.
- Documentación de las plataformas web y móvil.

Historias de Usuario

Para la realización de las historias de usuario se ha utilizado un modelo de historia de usuario. Con una estructura ya definida podemos proceder a realizar las historias de usuario que se van a realizar en el trabajo, en total se ha definido las siguientes historias de usuario:

Tabla 11: Historia de usuario creación de base de datos

HISTORIA DE USUARIO	
ID: H1	Usuario: Administrador
Nombre: Creación de la base de datos	
Prioridad: Alta.	Riesgo: Media
Duración estimada: 1 semana.	Numero de Iteración: 1 iteración.
Programador responsable: Daniel Villano	
Descripción: Diseñar una base de datos relacionar para el almacenamiento de datos sobre enfermedades, tratamientos, recomendaciones, productos y dermatólogos.	

Tabla 12: Historia de usuario Aplicación web Administrativa

HISTORIA DE USUARIO	
ID: H2	Usuario: Administrador
Nombre: Aplicación web Administrativa	
Prioridad: Alta.	Riesgo: Media
Duración estimada: 3 semanas	Numero de Iteración: 2 iteración.
Programador responsable: Daniel Villano	
Descripción: Procedimientos para crear, editar y eliminar los datos de la base de datos.	

Tabla 13: Historia de usuario Plataforma móvil de Consulta.

HISTORIA DE USUARIO	
ID: H3	Usuario: Persona Natural.
Nombre: Plataforma móvil de consulta.	
Prioridad: Alta.	Riesgo: Alta
Duración estimada: 4 semanas	Numero de Iteración: 3 iteración.
Programador responsable: Andy Chamba	
Descripción: Crear una aplicación móvil con la cual consultar si se detecta alguna enfermedad en el rostro.	

Tabla 14: Historia de usuario Plataforma Web de Consulta.

HISTORIA DE USUARIO	
ID: H4	Usuario: Persona Natural.
Nombre: Plataforma web de consulta.	
Prioridad: Alta.	Riesgo: Alta
Duración estimada: 4 semanas	Numero de Iteración: 3 iteración.
Programador responsable: Daniel Villano.	
Descripción: Crear una aplicación web con la cual consultar si se detecta alguna enfermedad en el rostro.	

Plan de entrega

A partir de las historias realizadas, se ha realizado el plan de entrega del proyecto donde se detallan las iteraciones en la siguiente tabla:

Tabla 15: Plan de Entrega

Historia	Iteración	Duración
H1	1	1 semana
H2	2	3 semanas
H3	3	4 semanas
H4	3	4 semanas

Notamos que en la primera iteración se ha asignado el desarrollo de la historia de usuario H1 en lapso de una semana. En la segunda iteración se ha asignado el desarrollo de la historia de usuario h2 en un lapso de 3 semanas, y en la última iteración se ha asignado el desarrollo de las historias de usuario h3 y h4 en un lapso de 4 semanas cada una.

2.3.2.2. Fase 2: Diseño

BASE DE DATOS

En la **Figura 11** se presenta el diagrama relacional de la base de datos, que ilustra las interconexiones entre las tablas de enfermedades, recomendaciones, productos y dermatólogos.

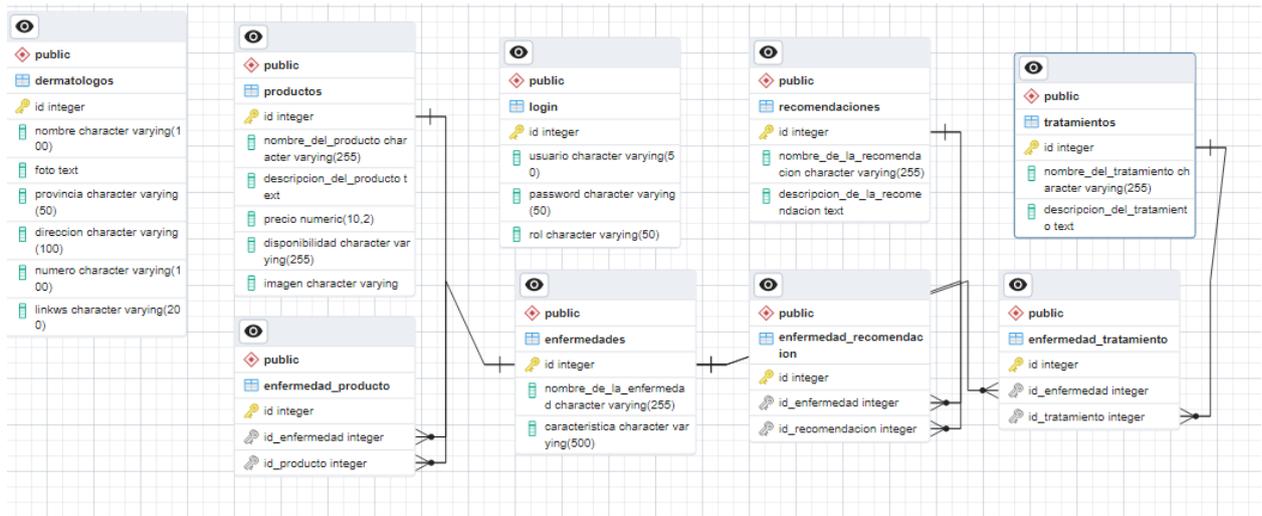


Figura 11: Modelo relacional de la base de datos

PLATAFORMA DE ADMINISTRACIÓN

En la **Figura 12** se muestra el módulo de inicio de sesión, donde inicia sesión el administrador del sistema.

The screenshot shows a login form with the following elements:

- Title: **Iniciar sesión en tu cuenta**
- Label: **Tu correo electrónico**
- Input field: nombre@empresa.com
- Label: **Contraseña**
- Input field:
- Checkbox: **Recuérdame**
- Button: **Iniciar sesión**

Figura 12: Página de inicio de sesión

En la **Figura 13** se exhibe el módulo de enfermedades, que incorpora un botón para la creación de nuevas enfermedades. Dentro de la tabla, se incluyen botones para editar y eliminar enfermedades. Además, se disponen opciones adicionales para asignar recomendaciones o productos a las enfermedades, se evidencia proceso en la **Figura 14**.

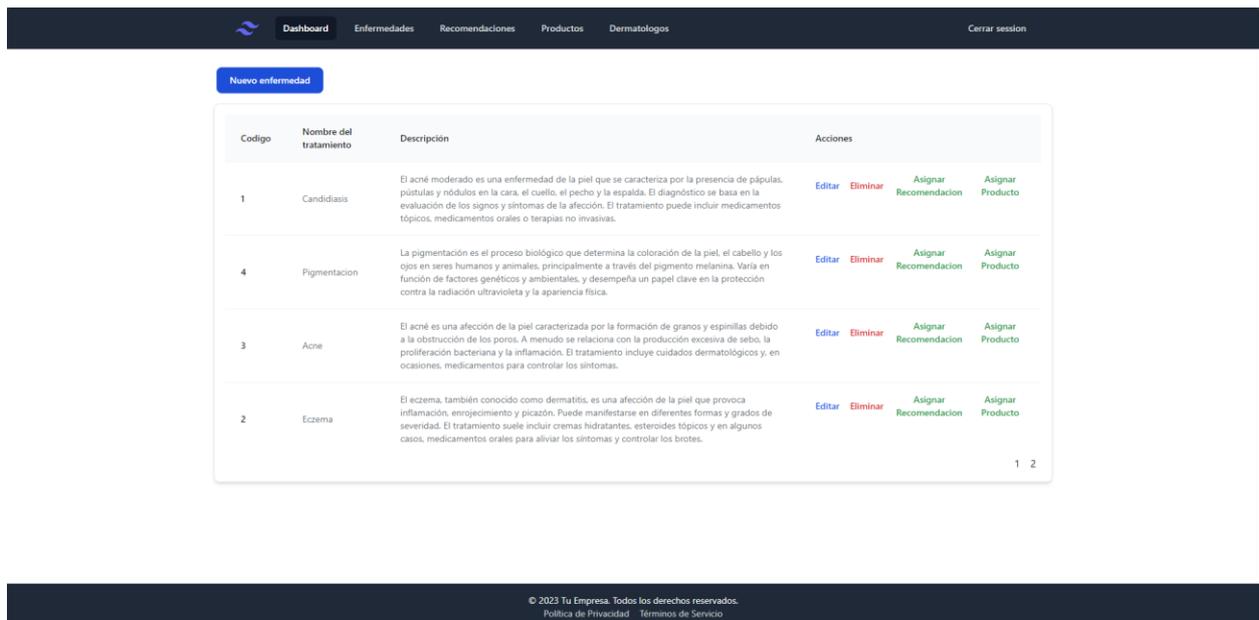


Figura 13: Modulo de enfermedades

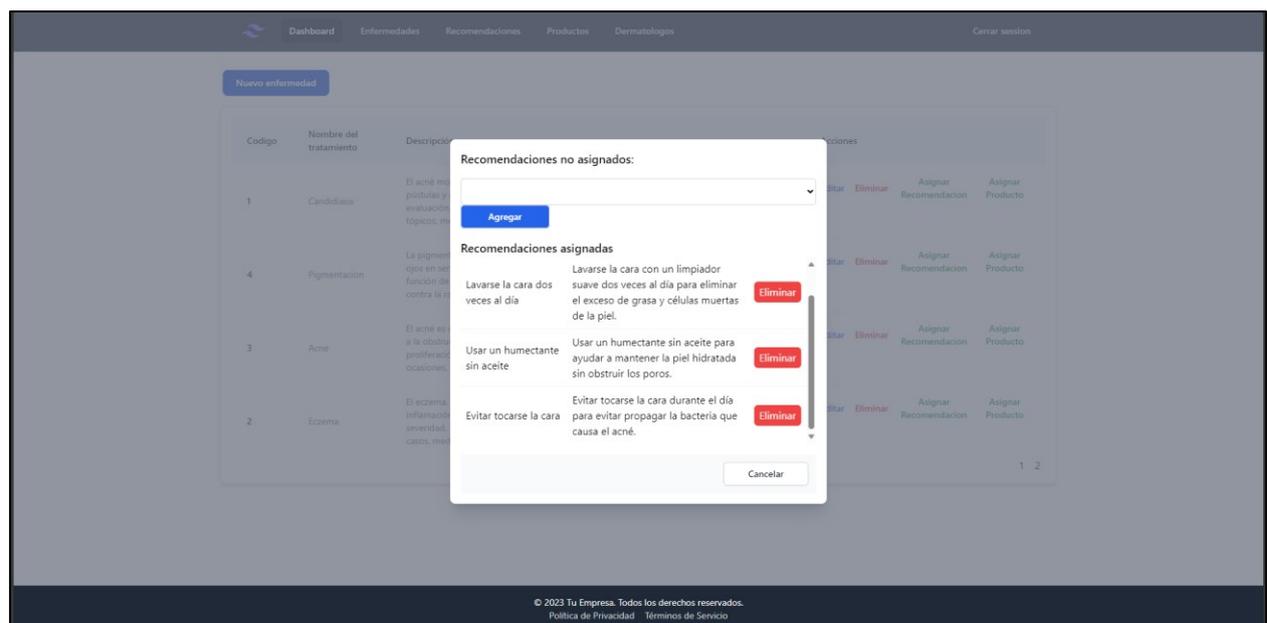


Figura 14: Ejemplo de asignación de tratamiento a enfermedad

En la **Figura 15** se evidencia el diseño del módulo de productos el cual permite el registro, modificación y eliminación de información referente a productos, además esta estructura se aplicará a otros módulos como el de recomendaciones.

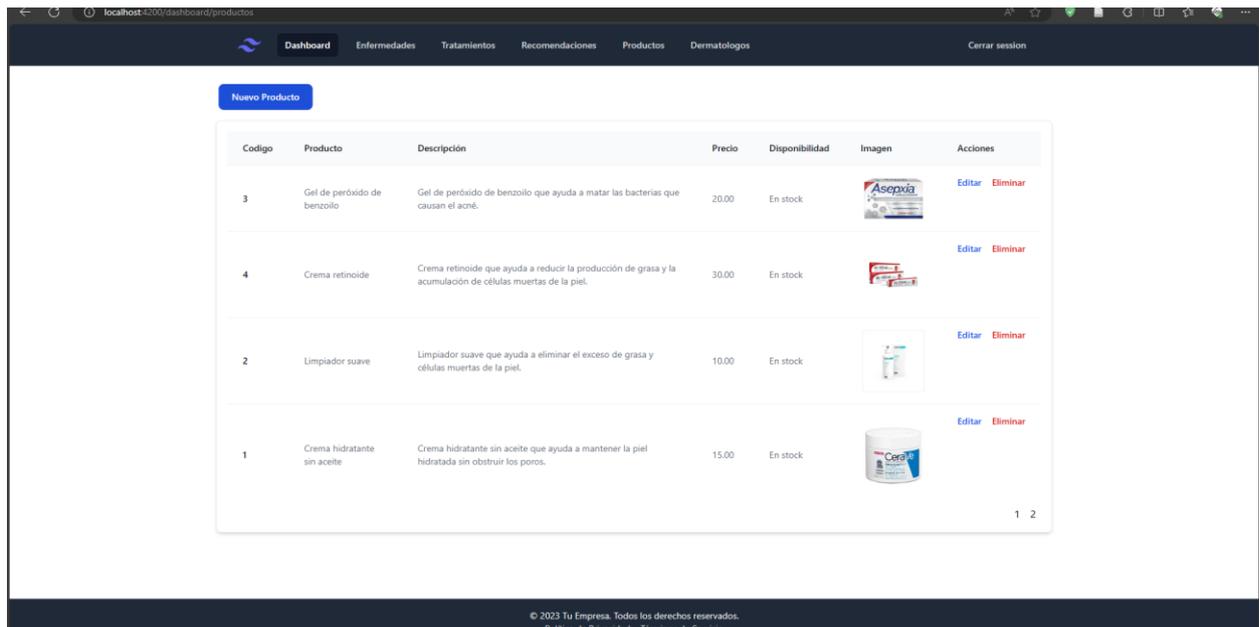


Figura 15: Modulo de productos

En la **Figura 16** se evidencia el módulo de dermatólogos el cual permite el registro, modificación y eliminación de información referente a dermatólogos.

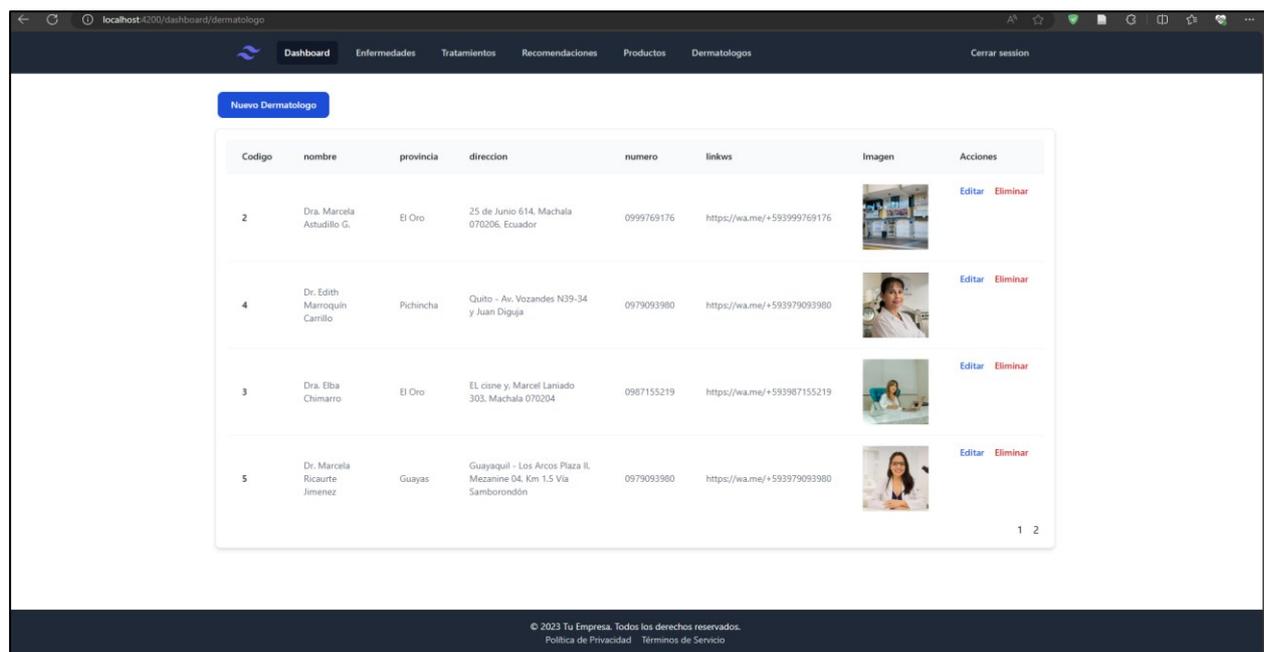


Figura 16: Modulo de dermatólogos

PLATAFORMA WEB DE CONSULTA

En esta plataforma, contamos con la opción de cargar archivos, como se muestra en la **Figura 17**, lo que nos permite subir una imagen para su análisis. Además, tenemos la posibilidad de acceder

a la cámara del dispositivo, como se evidencia en la **Figura 18**, para realizar análisis en tiempo real y obtener diversas opciones de resultados que pueden ser visualizadas a partir de los resultados de dicho análisis.

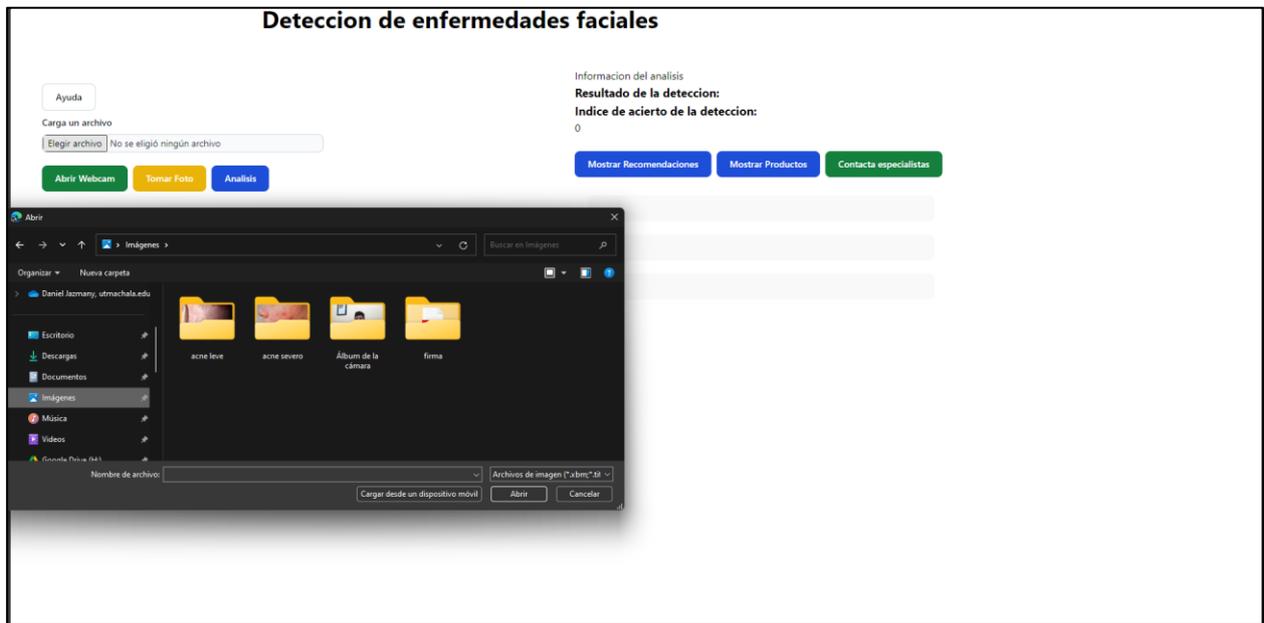


Figura 17: Acceso a la carga de archivos

En la **Figura 18** se muestra el acceso a la cámara del dispositivo



Figura 18: Acceso a la cámara

En la **Figura 19** se presenta el módulo de dermatólogos, el cual posibilita la selección de una provincia para visualizar los dermatólogos disponibles en dicha área.

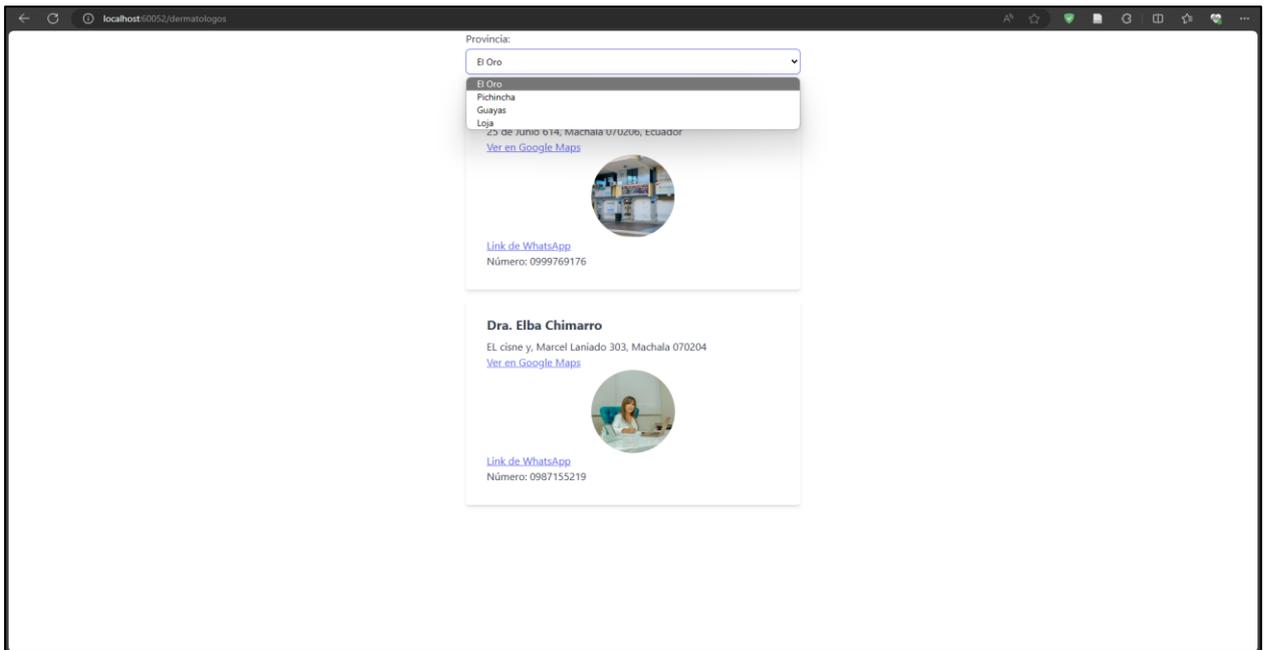


Figura 19: Modulo de selección de dermatólogos

En la **Figura 20** se evidencia el módulo de ayuda, el cual trae indicaciones de la aplicación para su correcto uso.

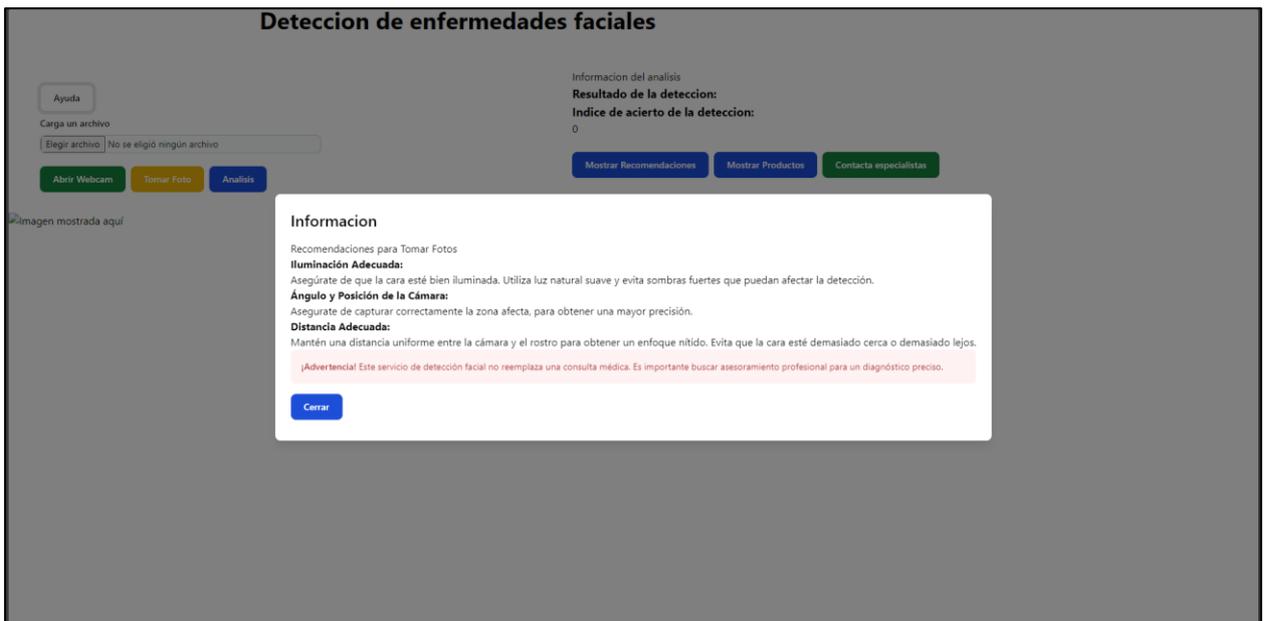


Figura 20: Modulo de ayuda

PLATAFORMA MÓVIL DE CONSULTA

En la **Figura 21** se muestra el diseño de la ventana principal del aplicativo móvil, donde destacan un botón para abrir el Drawer y una vista previa de lo que es la cámara del dispositivo con los controles de la misma como los botones para tomar foto, cambiar el modo de flash, cambiar de cámara y por último el botón para seleccionar una imagen desde la galería.

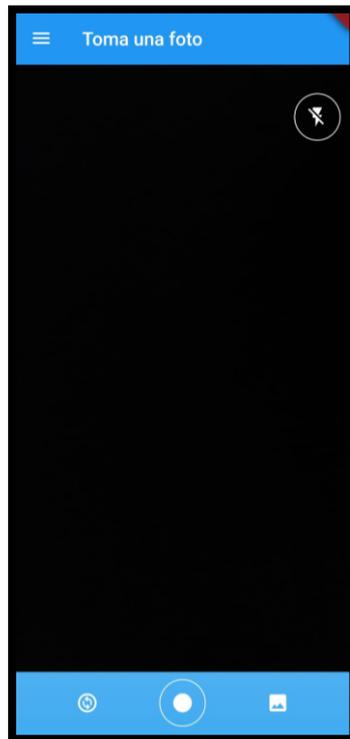


Figura 21: Ventana principal

En la **Figura 22** se muestra el diseño del drawer donde destacan la presentación de un menú de opciones las cuales llevan a distintas vistas, como lo es la vista de ayuda, la vista de dermatólogos y la vista de información adicional.

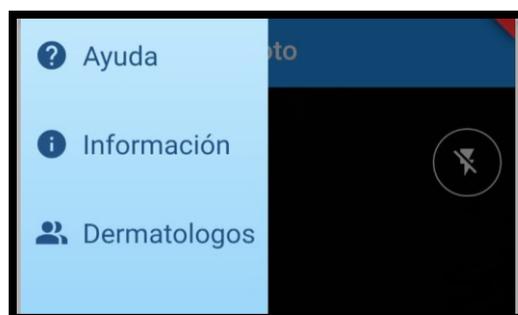


Figura 22: Drawer

En la **Figura 23** se puede observar el diseño de la vista de ayuda, donde notamos que se presenta una serie de consejos sobre cómo tomar correctamente la foto.

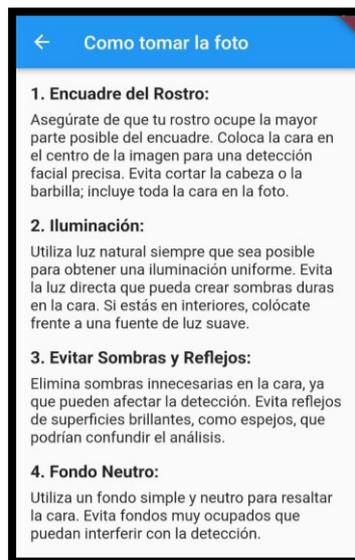


Figura 23: Interfaz de Ayuda

En la **Figura 24** se muestra el diseño de la interfaz de dermatólogos, el cual el usuario será capaz de filtrar los dermatólogos por provincia, y podrá revisar la información de contacto de cada uno y podrá seleccionar uno si desea.



Figura 24: Interfaz de Dermatólogos

En la **Figura 25** se muestra la interfaz de recorte del aplicativo, donde el usuario podrá seleccionar que parte de la imagen enviara a detección, aquí destacan los controles como los botones para la relación de aspecto, el marco de selección y los botones para aceptar y cancelar.

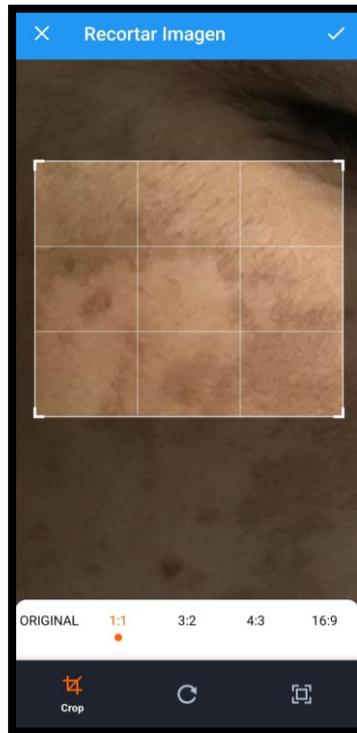


Figura 25:Interfaz de Recorte

En la **Figura 26** se muestra el diseño de la interfaz de informe de resultados, donde el usuario podrá apreciar los resultados que se han generado sobre la imagen que envió, aquí destacan la imagen que se envió, la predicción de la enfermedad, información sobre la enfermedad, e información adicional como consejos y productos. Además, se puede apreciar también un botón que nos lleva a la vista de dermatólogos.



Figura 26: Interfaz de Informe

2.3.2.3. Fase 3: Desarrollo

En esta fase se lleva a cabo lo descrito en las historias de usuario, en cada historia de usuario se definen unas tareas de ingeniería, las cuales describen las actividades que se realizarán en cada historia de usuario. En estas tareas se ponen a prueba para validar si el resultado es aceptable, la plantilla a usarse para las tareas se presenta en la **Tabla 16**.

Tabla 16: Plantilla de tarea de Ingeniería.

Tarea de Ingeniería	
Numero de tarea: Identificador de la tarea	Id de historia: Identificador de la historia a la que corresponde.
Nombre de la tarea: El nombre que lleva la tarea	
Tipo: El tipo de tarea que se realizará.	Duración: La duración estimada en días.
Programador responsable: La persona encargada de realizar la tarea.	
Descripción: Detallar la tarea a realizar.	

Una vez definida la plantilla, se procede a detallar las tareas realizadas por cada historia de usuario definida previamente.

Historia de Usuario H1: Creación de la Base de datos.

Tabla 17: Tarea 1 de Historia de usuario 1

Tarea de Ingeniería	
Numero de tarea: 1	Id de historia: H1
Nombre de la tarea: Diseño de la base de datos relacional.	
Tipo: Diseño.	Duración: 2
Programador responsable: Daniel Villano.	
Descripción: Realizar el diseño de la base de datos relacional.	

Tabla 18: Tarea 2 de Historia de usuario 1

Tarea de Ingeniería	
Numero de tarea: 2	Id de historia: H1
Nombre de la tarea: Creación de la base de datos relacional.	
Tipo: Desarrollo.	Duración: 3
Programador responsable: Daniel Villano.	
Descripción: Crear la base de datos del proyecto, con sus tablas y relaciones entre tablas.	

Tabla 19: Tarea 3 de Historia de Usuario 1

Tarea de Ingeniería	
Numero de tarea: 3	Id de historia: H1
Nombre de la tarea: Procedimientos almacenados.	
Tipo: Desarrollo.	Duración: 2
Programador responsable: Daniel Villano.	
Descripción: Desarrollo de modelos, controladores y rutas con Sequelize.	

Historia de Usuario H2: Aplicación web Administrativa.

Tabla 20: Tarea 1 de Historia de Usuario 2

Tarea de Ingeniería	
Numero de tarea: 4	Id de historia: H2
Nombre de la tarea: Creación de Servicios en Angular	
Tipo: Desarrollo – Investigación.	Duración: 7
Programador responsable: Daniel Villano.	
Descripción: Investigar y Desarrollar los servicios necesarios en Angular.	

Tabla 21: Tarea 2 de Historia de Usuario 2

Tarea de Ingeniería	
Numero de tarea: 5	Id de historia: H2
Nombre de la tarea: Creación de Procedimientos CRUD	
Tipo: Desarrollo.	Duración: 8
Programador responsable: Daniel Villano.	
Descripción: Desarrollo del módulo de creación (Create) y lectura (Read) de datos e Implementación de las operaciones de actualización (Update) y eliminación (Delete).	

Tabla 22: Tarea 3 de Historia de Usuario 2

Tarea de Ingeniería	
Numero de tarea: 6	Id de historia: H2
Nombre de la tarea: Módulo de relaciones	
Tipo: Desarrollo.	Duración: 3
Programador responsable: Daniel Villano.	
Descripción: Diseño e implementación del módulo de relaciones entre servicios y/o entidades.	

Tabla 23: Tarea 4 de Historia de Usuario 2

Tarea de Ingeniería	
Numero de tarea: 7	Id de historia: H2
Nombre de la tarea: Pruebas y Ajustes Finales.	
Tipo: Desarrollo.	Duración: 3
Programador responsable: Daniel Villano.	
Descripción: Desarrollo de ajustes finales y pruebas.	

Historia de Usuario H3: Plataforma Web de Consulta.

Tabla 24: Tarea 1 de Historia de Usuario 3

Tarea de Ingeniería	
Numero de tarea: 8	Id de historia: H3
Nombre de la tarea: Vista principal.	
Tipo: Desarrollo.	Duración: 10
Programador responsable: Daniel Villano.	
Descripción: Desarrollo de la ventana principal de la aplicación móvil, donde se pedirá el permiso sobre la cámara del dispositivo y el acceso a la galería del mismo.	

Tabla 25: Tarea 2 de Historia de Usuario 3

Tarea de Ingeniería	
Numero de tarea: 9	Id de historia: H3
Nombre de la tarea: Interfaz de Informe de resultados.	
Tipo: Desarrollo.	Duración: 5
Programador responsable: Daniel Villano	
Descripción: Desarrollo de la ventana de informe de resultados donde encontraremos la predicción de la enfermedad, la imagen, una descripción e información adicional sobre la enfermedad.	

Tabla 26: Tarea 3 de Historia de Usuario 3

Tarea de Ingeniería	
Numero de tarea: 10	Id de historia: H3
Nombre de la tarea: Interfaz de dermatólogos.	
Tipo: Desarrollo.	Duración: 5
Programador responsable: Daniel Villano.	
Descripción: Desarrollo de la interfaz donde aparecerá información de distintos dermatólogos, y donde se podrá filtrar por provincia, en la cual se podrá contactar directamente con los profesionales.	

Tabla 27: Tarea 4 de Historia de Usuario 3

Tarea de Ingeniería	
Numero de tarea: 11	Id de historia: H3
Nombre de la tarea: Interfaz de ayuda.	
Tipo: Desarrollo.	Duración: 4
Programador responsable: Daniel Villano.	
Descripción: Desarrollo de la ventana de ayuda, donde el usuario podrá acceder a consejos sobre como tomar una buena foto para enviar a detectar.	

Tabla 28: Tarea 5 de Historia de Usuario 3

Tarea de Ingeniería	
Numero de tarea: 12	Id de historia: H3
Nombre de la tarea: Interfaz de Información.	
Tipo: Desarrollo.	Duración: 5
Programador responsable: Daniel Villano.	
Descripción: Desarrollo de la ventana de información donde el usuario podrá acceder a información sobre las enfermedades que detecta la aplicación.	

Historia de Usuario H4: Plataforma Móvil de consulta.

Tabla 29: Tarea 1 de Historia de Usuario 4

Tarea de Ingeniería	
Numero de tarea: 13	Id de historia: H4
Nombre de la tarea: Vista principal.	
Tipo: Desarrollo.	Duración: 7
Programador responsable: Andy Chamba	
Descripción: Desarrollo de la ventana principal de la aplicación móvil, donde se pedirá el permiso sobre la cámara del dispositivo y el acceso a la galería del mismo.	

Tabla 30: Tarea 2 de Historia de Usuario 4

Tarea de Ingeniería	
Numero de tarea: 14	Id de historia: H4
Nombre de la tarea: Interfaz de Informe de resultados.	
Tipo: Desarrollo.	Duración: 7
Programador responsable: Andy Chamba	
Descripción: Desarrollo de la ventana de informe de resultados donde encontraremos la predicción de la enfermedad, la imagen, una descripción e información adicional sobre la enfermedad.	

Tabla 31: Tarea 3 de Historia de Usuario 4

Tarea de Ingeniería	
Numero de tarea: 15	Id de historia: H4
Nombre de la tarea: Interfaz de dermatólogos.	
Tipo: Desarrollo.	Duración: 5
Programador responsable: Andy Chamba	
Descripción: Desarrollo de la interfaz donde aparecerá información de distintos dermatólogos, y donde se podrá filtrar por provincia, en la cual se podrá contactar directamente con los profesionales.	

Tabla 32: Tarea 4 de Historia de Usuario 4

Tarea de Ingeniería	
Numero de tarea: 16	Id de historia: H4
Nombre de la tarea: Interfaz de ayuda.	
Tipo: Desarrollo.	Duración: 2
Programador responsable: Andy Chamba	
Descripción: Desarrollo de la ventana de ayuda, donde el usuario podrá acceder a consejos sobre cómo tomar una buena foto para enviar a detectar.	

Tabla 33: Tarea 5 de Historia de Usuario 4

Tarea de Ingeniería	
Numero de tarea: 17	Id de historia: H4
Nombre de la tarea: Interfaz de Información.	
Tipo: Desarrollo.	Duración: 2
Programador responsable: Andy Chamba	
Descripción: Desarrollo de la ventana de información donde el usuario podrá acceder a información sobre las enfermedades que detecta la aplicación.	

Tabla 34: Tarea 6 de Historia de Usuario 4

Tarea de Ingeniería	
Numero de tarea: 18	Id de historia: H4
Nombre de la tarea: Interfaz de Recorte.	
Tipo: Desarrollo.	Duración: 5
Programador responsable: Andy Chamba	
Descripción: Desarrollo de una interfaz de recorte en la cual el usuario podrá acceder a distintas funcionalidades para seleccionar la parte de la foto que quiere mandar a detectar.	

2.4. Ejecución del prototipo

PLATAFORMA ADMINISTRATIVA

Tabla 35: Plataforma administrativa

<p>Para el inicio de sesión ingresamos con nuestras credenciales, correo electrónico y contraseña</p>	
---	--

Tabla 35: Plataforma administrativa

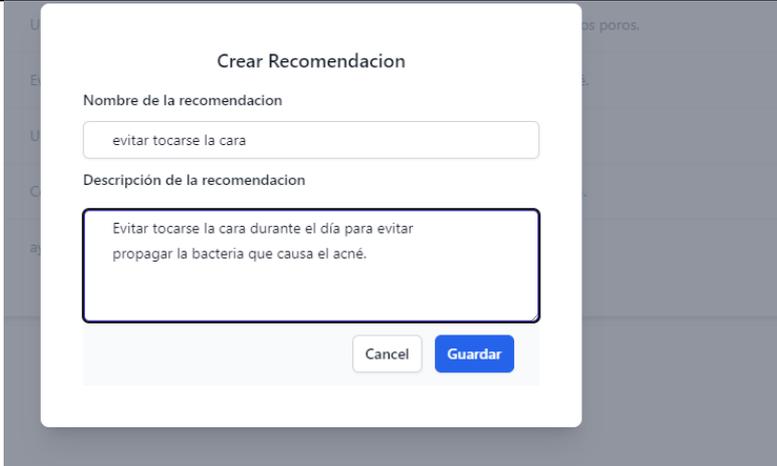
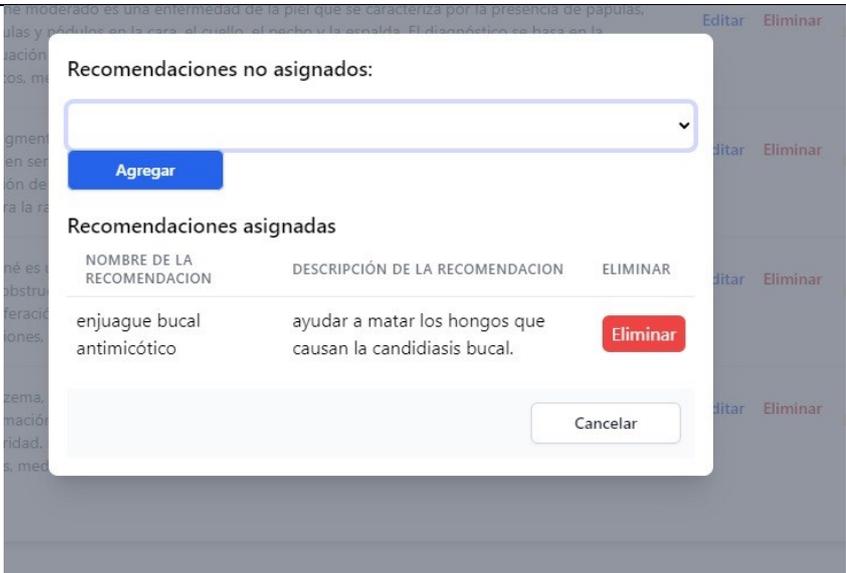
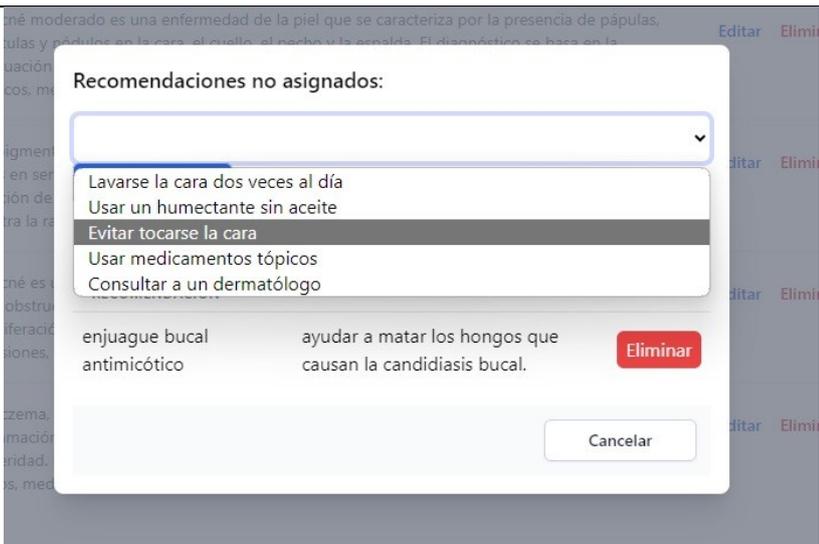
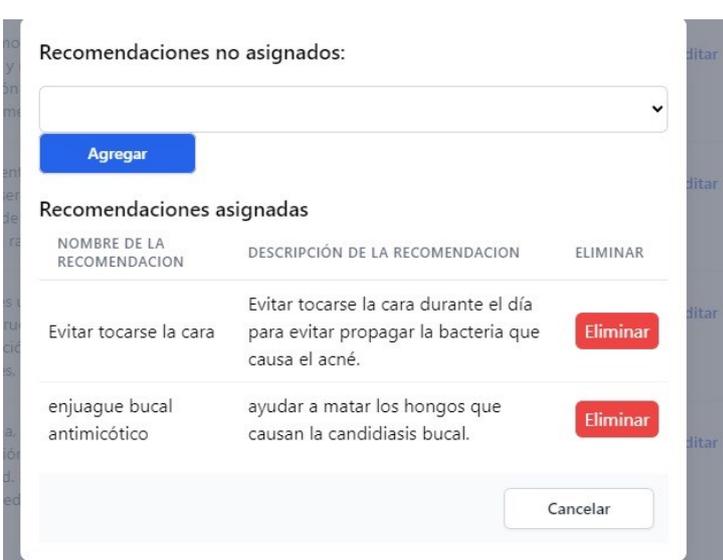
<p>Procedimiento para crear una nueva recomendación</p>	
<p>Ahora asignaremos la nueva recomendación registrado a una enfermedad, este proceso lo realizaremos en el módulo de enfermedad</p>	
<p>El modal cargara las recomendaciones no asignadas a la enfermedad en un combo box, y los asignados lo listara en una tabla.</p>	

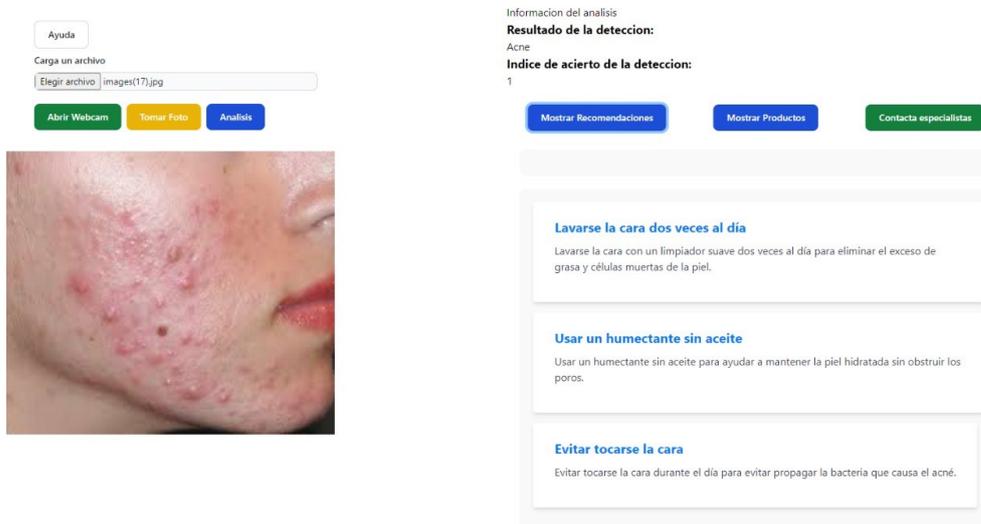
Tabla 35: Plataforma administrativa

<p>Lo seleccionamos y le damos al botón agregar, y este ya se encontrará asignado a esta enfermedad, una vez agregado, este ya no se encontrará en los tratamientos no asignados de esa enfermedad.</p>	 <p>Recomendaciones no asignados:</p> <p><input type="text"/></p> <p>Agregar</p> <p>Recomendaciones asignadas</p> <table border="1"> <thead> <tr> <th>NOMBRE DE LA RECOMENDACION</th> <th>DESCRIPCIÓN DE LA RECOMENDACION</th> <th>ELIMINAR</th> </tr> </thead> <tbody> <tr> <td>Evitar tocarse la cara</td> <td>Evitar tocarse la cara durante el día para evitar propagar la bacteria que causa el acné.</td> <td>Eliminar</td> </tr> <tr> <td>enjuague bucal antimicótico</td> <td>ayudar a matar los hongos que causan la candidiasis bucal.</td> <td>Eliminar</td> </tr> </tbody> </table> <p>Cancelar</p>	NOMBRE DE LA RECOMENDACION	DESCRIPCIÓN DE LA RECOMENDACION	ELIMINAR	Evitar tocarse la cara	Evitar tocarse la cara durante el día para evitar propagar la bacteria que causa el acné.	Eliminar	enjuague bucal antimicótico	ayudar a matar los hongos que causan la candidiasis bucal.	Eliminar
NOMBRE DE LA RECOMENDACION	DESCRIPCIÓN DE LA RECOMENDACION	ELIMINAR								
Evitar tocarse la cara	Evitar tocarse la cara durante el día para evitar propagar la bacteria que causa el acné.	Eliminar								
enjuague bucal antimicótico	ayudar a matar los hongos que causan la candidiasis bucal.	Eliminar								

PLATAFORMA WEB

Seleccionar o cargar la imagen, seguido de esto, empezamos el proceso de análisis, dando en el botón analizar, se evidencia en la **Figura 27**, los resultados de la detección y el índice de acierto, la información cargada por modulo tratamiento, recomendación o producto:

Deteccion de enfermedades faciales



Ayuda

Carga un archivo

Elegir archivo | images(17).jpg

Abrir Webcam **Tomar Foto** **Análisis**

Información del análisis

Resultado de la detección:
Acne

Índice de acierto de la detección:
1

Mostrar Recomendaciones **Mostrar Productos** **Contacta especialistas**

Lavarse la cara dos veces al día
Lavarse la cara con un limpiador suave dos veces al día para eliminar el exceso de grasa y células muertas de la piel.

Usar un humectante sin aceite
Usar un humectante sin aceite para ayudar a mantener la piel hidratada sin obstruir los poros.

Evitar tocarse la cara
Evitar tocarse la cara durante el día para evitar propagar la bacteria que causa el acné.

Figura 27: Prueba del prototipo

PLATAFORMA MÓVIL DE CONSULTA

En la pantalla principal, podemos tomar una foto con la cámara frontal o trasera, o podemos seleccionarla de la galería, este es el primer paso para la detección de la enfermedad, estos pasos se pueden apreciar en la **Figura 28** y **29**.

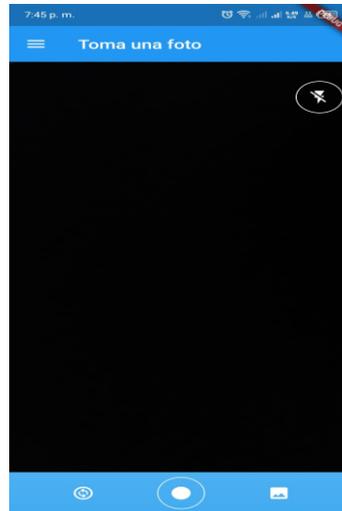


Figura 28: Cámara del dispositivo.

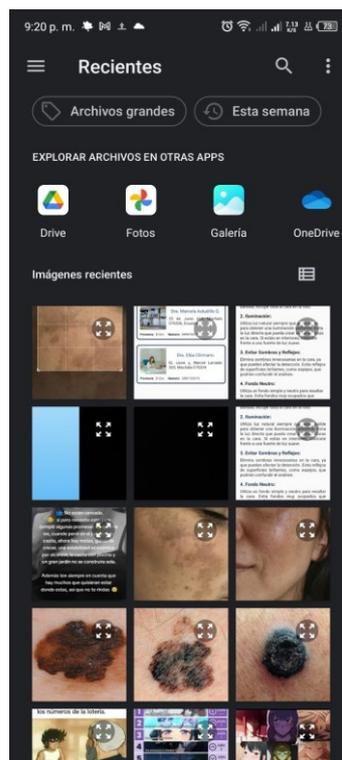


Figura 29: Selección de la galería.

El siguiente paso es seleccionar la parte de la foto que se quiere enviar a detectar, para esto está la interfaz de recorte, en la cual están distintas opciones para esta tarea. Este paso se muestra en la **Figura 30**.

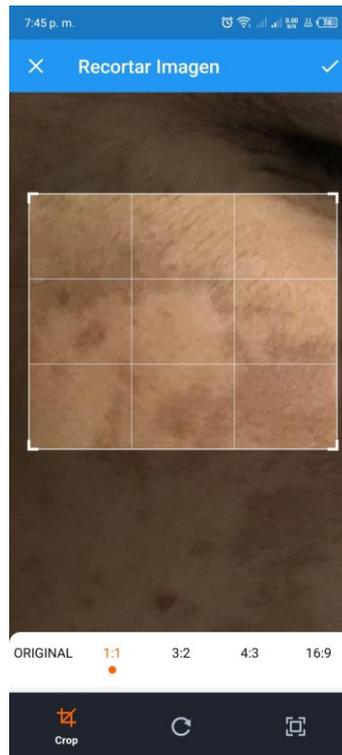


Figura 30: Interfaz de Recorte.

Una vez seleccionada la parte, se envía la imagen al api, la cual nos envía una predicción, con esta predicción accedemos a información adicional sobre ella y la mostramos en la interfaz de presentación de resultados, esto se puede apreciar en la **Figura 32**, adicionalmente se muestra información adicional que se aprecia en la **Figura 33**, y un aviso sobre esta información ya que esta es solo informativa y no se promueve el uso de dicha información sin consultar con un profesional primero, esto se aprecia en la **Figura 31**.

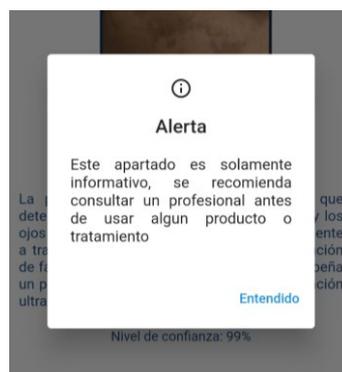


Figura 31: Modal de Aviso.



Figura 32: Interfaz de Informe



Figura 33: Información adicional.

CAPÍTULO III. EVALUACIÓN DEL PROTOTIPO

3.1. Plan de evaluación

Objetivo

- Evaluar el rendimiento de la red neuronal en términos de Precisión, Recall y F1-Score.

Desarrollo

En la elaboración del plan de evaluación, se tomó en cuenta realizar pruebas tanto para la red neuronal convolucional como para el aplicativo móvil y web. Para la evaluación del modelo entrenado se utilizarán métricas bajo la metodología CRISP-DM y su etapa de evaluación. En cuanto a las pruebas para evaluar la aplicación móvil y web, se realizarán bajo la etapa de evaluación determinada en la metodología Extreme Programming (XP). De este modo, se ha realizado un cronograma que incluye las actividades que se llevarán a cabo para ejecutar el plan de evaluación de este proyecto, detalladas en la siguiente **Tabla 36**.

Tabla 36: Cronograma de actividades del plan de evaluación

Cronograma									
Actividad	Tareas	Resultados	Semana						
			5	6	7	8	9	10	11
Elaboración del plan de evaluación.	<ul style="list-style-type: none"> - Definir objetivos - Crear el cronograma - Definir las métricas. 	Desarrollar una serie de pasos que guíen el proceso de evaluación de los objetivos y métricas propuestas del proyecto.							
Evaluación de rendimiento del modelo de red neuronal artificial mediante pruebas.	<ul style="list-style-type: none"> - Crear una matriz de confusión. - Emplear medidas de desempeño como F-Score, recall y Precisión. 	Lograr niveles de precisión que sean considerados satisfactorios.							
Ejecución de pruebas de aceptación bajo la metodología XP.	<ul style="list-style-type: none"> - Diseñar las pruebas de aceptación. - Realizar las pruebas de aceptación. - Recolectar datos de las pruebas. 	Obtención de información que ayudara a determinar la validez del proyecto.							
Presentación de los resultados provenientes de las pruebas.	<ul style="list-style-type: none"> - Tabular los resultados obtenidos. - Realizar gráficos estadísticos de los datos tabulados. - Anexar estos resultados en el informe del Proyecto. 	Obtener un punto de referencia para contrastar la hipótesis planteada.							

3.1.1. Pruebas de red neuronal

Se consideraron las siguientes métricas

Tabla 37: Tabla de métricas

Variable	Descripción
TP	muestras correctamente clasificadas como positivas
FP	muestras erróneamente clasificadas como positivas
FN	muestras erróneamente clasificadas como negativas
TN	Muestras correctamente clasificadas como negativas.

Precisión: La precisión es la proporción de muestras correctamente clasificadas. Se calcula como:

$$\text{Precisión} = TP / (TP + FP)$$

Recall: Es la proporción de muestras positivas correctamente clasificadas. Se calcula como:

$$\text{Recall} = TP / (TP + FN)$$

F1-Score: El F1-Score es una combinación de precisión y recall. Se calcula como:

$$F1 - Score = 2 * (\text{Precisión} * \text{Recall}) / (\text{Precisión} + \text{Recall})$$

3.1.2. Matriz de confusión

Tabla 38: Matriz de confusión

	Clase Real Positiva	Clase Real Negativa
Predicción Positiva	TP	FP
Predicción Negativa	FN	TN

3.1.3. Pruebas de aceptación de la metodología XP

Objetivo: Evaluar la calidad del aplicativo móvil y web de detección de enfermedades, mediante la aplicación de la metodología Extreme Programming para determinar el correcto funcionamiento del aplicativo.

Las pruebas de aceptación de la metodología XP se realizan en base a las historias de usuario, siendo el cliente quien debe definir el contexto o escenarios en los cuales se puede determinar que una historia de usuario ha sido realizada e implementada satisfactoriamente.

En el caso de nuestro proyecto, dirigido al público en general, hemos establecido que los pacientes de un consultorio dermatológico de la ciudad de Machala serán los usuarios que utilicen el aplicativo, proporcionando la retroalimentación necesaria para determinar si las funcionalidades definidas en las historias de usuario se han implementado eficazmente.

Estas pruebas de aceptación están programadas para la semana 6 y se realizarán con los pacientes de un consultorio dermatológico, documentándose y estructurándose con el fin de determinar el nivel de éxito de la aplicación.

En la tabla 4 se describen de manera general las pruebas de aceptación y su relación con las historias de usuario. La plantilla que se utilizará para la elaboración de estas pruebas, donde se detallan más aspectos, se muestra en la **Tabla 40**.

Tabla 39: Pruebas de aceptación

N°	Código	Nombre	Métricas
1	H1	Acceso a la base de datos.	<ul style="list-style-type: none"> - Correcto acceso a los datos de la base. - Tiempo de respuesta promedio para consultas comunes.
2	H1	Inserción de datos.	<ul style="list-style-type: none"> - Asegurar que se pueden insertar registros en cada tabla de la base de datos. - Validar la consistencia de los datos ingresados en las tablas. - Evaluar el rendimiento de la inserción de datos en términos de velocidad y eficiencia.
3	H2	Crear datos desde la aplicación web administrativa.	<ul style="list-style-type: none"> - Verificar que se pueden crear, editar y eliminar datos de la base de datos utilizando la interfaz web administrativa. - Evaluar la respuesta del sistema ante operaciones concurrentes de edición y eliminación. - Medir el tiempo necesario para completar cada operación desde la interfaz web.

Tabla 39: Pruebas de aceptación

Nº	Código	Nombre	Métricas
4	H3	Consulta de enfermedades en la aplicación móvil.	<ul style="list-style-type: none"> - Confirmar que la aplicación móvil puede realizar consultas a la base de datos y mostrar resultados relacionados con enfermedades detectadas en el rostro. - Evaluar la velocidad de respuesta de la aplicación móvil al realizar consultas. - Verificar la precisión de los resultados mostrados por la aplicación móvil.
5	H4	Consulta de enfermedades en la aplicación web.	<ul style="list-style-type: none"> - Verificar que la aplicación web puede realizar consultas a la base de datos y mostrar resultados relacionados con enfermedades detectadas en el rostro. - Evaluar la velocidad de carga de la página web al realizar consultas. - Validar la compatibilidad con diferentes navegadores y dispositivos.

Tabla 40: Plantilla de pruebas de aceptación

Prueba de Aceptación	
Numero: Numero Único que identifica la prueba.	Id Historia de Usuario: El id de la historia de usuario a la cual prueba.
Historia de Usuario: El nombre de la historia de usuario a la cual prueba.	
Nombre: El nombre que se le asigna a la prueba.	
Condiciones: Las condiciones que deben cumplirse antes de realizar la prueba.	
Pasos de ejecución: Pasos que deben seguir los usuarios para probar la funcionalidad que se está probando.	
Métricas: Las medidas que se utilizaran para evaluar la funcionalidad.	
Resultado Esperado: Lo que se espera obtener al realizar la funcionalidad.	
Evaluación de la prueba: El nivel de satisfacción que tuvo el usuario ante la respuesta de la funcionalidad. Sus valores son: Aprobado y No Aprobado.	

3.2. Resultados de la evaluación

3.2.1. Resultados de evaluación del modelo de red neuronal

Para la evaluación del modelo de red neuronal se preparó un conjunto de evaluación el cual constaba de un grupo reducido de imágenes por clase las cuales no pertenecen al conjunto de entrenamiento, y mediante el uso de la librería “DataImagenGenerator”, se establecieron un conjunto de 3133 imágenes.

Para la evaluación se aplicó una matriz de confusión la cual define:

- Las filas representan las clases reales.
- Las columnas representan las clases predichas.

Los valores en la matriz indican la cantidad de instancias en las que la clase real y la clase predicha coinciden.

Tabla 41: Valores de la matriz de confusión

Clases	Eczema	Acné	Pigmentación	Benigno	Maligno
Eczema	456	3	4	4	4
Acné	1	301	5	4	4
Pigmentación	5	4	98	7	6
Benigno	9	5	7	1209	94
Maligno	8	3	8	69	738

Reporte de clasificación

Tabla 42: Reporte de los resultados de la clasificación

Clase	Precisión	Recall	F1-Score	Support
Eczema	0.86	0.9	0.88	508
Acné	0.93	0.93	0.93	322
Pigmentación	0.77	0.73	0.75	135
Benigno	0.93	0.89	0.91	1361
Maligno	0.87	0.87	0.87	847
Accuracy	0.88			3173
Macro Avg	0.86	0.86	0.87	3173
Weighted Avg	0.88	0.88	0.88	3173

Análisis de resultados

La matriz de confusión revela la cantidad de instancias clasificadas correctamente e incorrectamente para cada clase. Observamos que el modelo muestra una tendencia general de aciertos, pero también hay algunas confusiones notables, especialmente en la clase "Pigmentación".

Reporte de Clasificación:

El reporte de clasificación proporciona métricas detalladas para cada clase, incluyendo precisión, recall y F1-Score. Destacamos algunos puntos clave:

- **Eczema:** Precisión y recall son satisfactorios, pero aún hay margen para mejorar.
- **Acné:** Muestra un rendimiento excepcional, con alta precisión y recall.
- **Pigmentación:** Precisión y recall más bajos, debido a un conjunto de datos de entrenamiento reducido.
- **Benigno y Maligno:** Ambas clases tienen un rendimiento sólido, pero hay algunos falsos negativos en "Benigno" que podrían mejorarse.

Métricas Globales:

Accuracy:

El modelo logra una precisión global del 88%, indicando un rendimiento sólido en la clasificación general.

Macro Avg y Weighted Avg:

Ambas métricas macro y ponderada son altas, sugiriendo que el modelo es consistente en todas las clases y tiene un buen rendimiento global.

3.2.2. Resultados de las pruebas de aceptación de la metodología XP

La evaluación funcional del prototipo resultó en un total de cinco pruebas de aceptación que se especificaron previamente en el plan de evaluación, teniendo un resultado satisfactorio en cuanto a lo que se planteó en las historias de usuario que se especificaron anteriormente, con lo cual se ha verificado que los sistemas prototipo cumplen con lo requerido en cuanto a funcionalidad. A continuación, se especifican las pruebas de aceptación que se realizaron:

Tabla 43: Prueba de Acceso a la base de datos

Prueba de Aceptación	
Numero: 1	Id Historia de Usuario: H1
Historia de Usuario: Creación de la Base de Datos	
Nombre: Acceso a la base de datos.	
Condiciones: Acceso a las credenciales de la base de datos.	
Pasos de ejecución: <ol style="list-style-type: none"> 1. Desde un gestor como postgres, ingresar las credenciales para acceder a la bd. 2. Realizar consultas comunes como “SELECT”. 3. Revisar las relaciones entre las tablas. 	
Métricas: <ul style="list-style-type: none"> - Correcto acceso a los datos de la base. - Tiempo de respuesta promedio para consultas comunes. - Evaluar la integridad referencial para garantizar que las relaciones entre las tablas sean correctas. 	
Resultado Esperado: <ul style="list-style-type: none"> - Acceso a toda la base de datos. - Tiempo de respuesta máximo de 1 segundos. - Coherencia en las relaciones de las tablas. 	
Evaluación de la prueba: Aprobado.	

Tabla 44: Prueba de Inserción de datos

Prueba de Aceptación	
Numero: 2	Id Historia de Usuario: H1
Historia de Usuario: Creación de la Base de Datos	
Nombre: Inserción de datos.	
Condiciones: Acceso a la base de datos.	
Pasos de ejecución: <ol style="list-style-type: none"> 1. Desde un gestor como postgres, realizar el ingreso de datos en las tablas creadas. 	
Métricas: <ul style="list-style-type: none"> - Asegurar que se pueden insertar registros en cada tabla de la base de datos. - Validar la consistencia de los datos ingresados en las tablas. - Evaluar el rendimiento de la inserción de datos en términos de velocidad y eficiencia. 	
Resultado Esperado: <ul style="list-style-type: none"> - Inserción correcta de los datos con sus relaciones. - Tiempo de respuesta máximo de 500 milisegundos. 	
Evaluación de la prueba: Aprobado.	

Tabla 45: Prueba de Crear datos desde la Web

Prueba de Aceptación	
Numero: 3	Id Historia de Usuario: H2
Historia de Usuario: Aplicación web Administrativa	
Nombre: Crear datos desde la aplicación web administrativa.	
Condiciones: Acceso a las credenciales de administrador.	
Pasos de ejecución: <ol style="list-style-type: none"> 1. Desde la página web administrativa ingresar con los datos del usuario administrador. 2. Realizar las acciones CRUD en las diversas entidades. 	
Métricas: <ul style="list-style-type: none"> - Verificar que se pueden crear, editar y eliminar datos de la base de datos utilizando la interfaz web administrativa. - Evaluar la respuesta del sistema ante operaciones concurrentes de edición y eliminación. - Medir el tiempo necesario para completar cada operación desde la interfaz web. 	
Resultado Esperado: <ul style="list-style-type: none"> - Realización de las acciones CRUD sin problemas. - Tiempo de respuesta de cada acción máximo de 2 segundos. 	
Evaluación de la prueba: Aprobado.	

Tabla 46: Prueba de Consulta desde el móvil

Prueba de Aceptación	
Numero: 4	Id Historia de Usuario: H3
Historia de Usuario: Plataforma móvil de consulta.	
Nombre: Consulta de enfermedades en la aplicación móvil.	
Condiciones: Acceso a las credenciales de administrador.	
Pasos de ejecución: <ol style="list-style-type: none"> 1. En la aplicación, tomamos una foto en la pantalla principal. 2. Recortamos la foto para mejorar la respuesta. 3. Enviamos la foto y esperamos la respuesta. 	
Métricas: <ul style="list-style-type: none"> - Confirmar que la aplicación móvil puede realizar consultas a la base de datos y mostrar resultados relacionados con enfermedades detectadas en el rostro. - Evaluar la velocidad de respuesta de la aplicación móvil al realizar consultas. 	
Resultado Esperado: <ul style="list-style-type: none"> - Concordancia de los datos provenientes de la base de datos con la enfermedad predicha por el servicio. - Tiempo de respuesta máximo de 10 segundos. 	
Evaluación de la prueba: Aprobado.	

Tabla 47: Prueba de Consulta desde la Web

Prueba de Aceptación	
Numero: 5	Id Historia de Usuario: H4
Historia de Usuario: Plataforma web de consulta.	
Nombre: Consulta de enfermedades en la aplicación web.	
Condiciones: Acceso a las credenciales de administrador.	
Pasos de ejecución: <ol style="list-style-type: none"> 4. En la aplicación, tomamos una foto en la pantalla principal. 5. Recortamos la foto para mejorar la respuesta. 6. Enviamos la foto y esperamos la respuesta. 	
Métricas: <ul style="list-style-type: none"> - Verificar que la aplicación web puede realizar consultas a la base de datos y mostrar resultados relacionados con enfermedades detectadas en el rostro. - Evaluar la velocidad de carga de la página web al realizar consultas. - Validar la compatibilidad con diferentes navegadores y dispositivos. 	
Resultado Esperado: <ul style="list-style-type: none"> - Concordancia de los datos provenientes de la base de datos con la enfermedad predicha por el servicio. - Tiempo de respuesta máximo de 10 segundos. - Accesible en navegadores más usados (Chrome, Firefox, Edge y Opera). 	
Evaluación de la prueba: <u>Aprobado.</u>	

CONCLUSIONES

Se ha logrado con éxito el desarrollo de una aplicación móvil y web que integre inteligencia artificial para la detección de enfermedades faciales cumpliendo con los requisitos establecidos para cada una.

Se realizó una investigación bibliográfica exhaustiva de los temas que intervienen en el desarrollo del prototipo para el cual se revisaron trabajos de investigación de diferentes autores y fuentes en los que se identificaron las principales técnicas y algoritmos usados en este campo.

Tras el análisis de los diferentes tipos de redes neuronales que podrían usarse para la detección de enfermedades faciales, se logró seleccionar e implementar el modelo xcepción tras considerar que sus aspectos estructurales y funcionales son adecuados para el objetivo del prototipo.

Se establecieron eficazmente el conjunto de enfermedades faciales que fueron objeto de estudio por la aplicación, considerando enfermedades comunes y disponibles en bases de datos publicas

Se realizó la búsqueda de un Dataset de imágenes donde se evidencien las enfermedades seleccionadas en diferentes fuentes como bases de datos públicas, sitios web, entre otros. Al final se seleccionó una data del repositorio de Kaggle.

Se establecieron las funcionalidades y requisitos específicos que fueron implementados en la aplicación web y móvil considerando facilidad de uso para el usuario.

El aplicativo web y móvil fueron validados exitosamente tras realizar las pruebas de aceptación propuestas por la metodología XP donde se verificó que se cumple con los requisitos propuestos.

Tras evaluar el modelo de red neuronal previamente entrenado mediante el análisis de una matriz de confusión y un conjunto de imágenes de evaluación, se obtuvo un índice de acierto promedio de 0.88 en todas las clases. Este resultado respalda de manera concluyente la hipótesis inicial, la cual sugería que el índice de precisión mínimo sería del 70%. La exitosa superación del umbral establecido en la hipótesis confirma la validez y eficacia del modelo, respaldando así la solidez de la investigación y la calidad del trabajo desarrollado.

RECOMENDACIONES

Se recomienda utilizar fuentes en otros idiomas relevantes para tu área de estudio, para ampliar la diversidad y perspectivas.

En el apartado de la estructura del modelo, se aconseja revisar y analizar las arquitecturas más actualizadas, considerando las necesidades específicas de tu proyecto, incluyendo el entorno de ejecución y su disponibilidad.

Al preparar el conjunto de datos (Dataset) para el entrenamiento, se sugiere considerar aspectos cruciales como una cantidad significativa de imágenes, asegurándote de que las clases cuenten con representaciones visuales adecuadas, y ajustando el tamaño de las imágenes de acuerdo con la arquitectura del modelo que planeas utilizar.

En relación con las funcionalidades de la aplicación, se recomienda mantener una documentación personalizada de los módulos y códigos del programa.

Considera realizar pruebas de estrés en el modelo de red neuronal para evaluar su rendimiento bajo cargas extremas o condiciones adversas.

Dentro de la evaluación de resultados, se sugiere establecer métricas específicas que contemplen aspectos clave del modelo, tales como precisión y eficacia.

REFERENCIAS BIBLIOGRÁFICAS

- [1] carmensantamaria.dra@gmail.com, «Melasma, conocido como “paño”», Dermatóloga Quito. Accedido: 11 de enero de 2024. [En línea]. Disponible en: <https://dracarmensantamaria.com/melasma-conocido-como-pano/>
- [2] B. Perdomo, O. G. Martínez, y I. B. Barreto, «Competencias digitales en docentes universitarios: una revisión sistemática de la literatura», *EDMETIC*, vol. 9, n.º 2, Art. n.º 2, jul. 2020, doi: 10.21071/edmetic.v9i2.12796.
- [3] Y. Lecun, L. Bottou, Y. Bengio, y P. Haffner, «Gradient-based learning applied to document recognition», *Proc. IEEE*, vol. 86, n.º 11, pp. 2278-2324, nov. 1998, doi: 10.1109/5.726791.
- [4] A. Abeliuk y C. Gutiérrez, «Historia y evolución de la inteligencia artificial», *Rev. Bits Cienc.*, n.º 21, Art. n.º 21, ago. 2021.
- [5] L. E. P. V, A. E. Rico-Carrillo, y A. Hernández-Arango, «Del ábaco a las redes neuronales o la breve historia de la inteligencia artificial en salud», *Medicina (Mex.)*, vol. 43, n.º 4, Art. n.º 4, 2021, doi: 10.56050/01205498.1641.
- [6] H. Pant, M. C. Lohani, J. Pant, y P. Petshali, «Capsicum Plant Leaves Disease Detection Using Convolution Neural Networks», *Int. J. Curr. Res. Rev.*, vol. 13, n.º 07, pp. 185-190, 2021, doi: 10.31782/IJCRR.2021.13704.
- [7] I. Iqbal, K. Walayat, M. U. Kakar, y J. Ma, «Automated identification of human gastrointestinal tract abnormalities based on deep convolutional neural network with endoscopic images», *Intell. Syst. Appl.*, vol. 16, p. 200149, nov. 2022, doi: 10.1016/j.iswa.2022.200149.
- [8] D. Bala *et al.*, «MonkeyNet: A robust deep convolutional neural network for monkeypox disease detection and classification», *Neural Netw.*, vol. 161, pp. 757-775, abr. 2023, doi: 10.1016/j.neunet.2023.02.022.
- [9] C. A. Cuervo Sánchez, «Efectos de la inteligencia artificial en las estrategias de marketing: revisión de literatura», *Adres. Rev. Int. Investig. En Comun.*, n.º 24 (enero-junio), pp. 26-41, 2021.
- [10] W. Siłka, M. Wiczorek, J. Siłka, y M. Woźniak, «Malaria Detection Using Advanced Deep Learning Architecture», *Sensors*, vol. 23, n.º 3, Art. n.º 3, ene. 2023, doi: 10.3390/s23031501.
- [11] R. Pérez y J. Luis, «Técnicas de aprendizaje automático para la detección de intrusos en redes de computadoras», *Rev. Cuba. Cienc. Informáticas*, vol. 8, n.º 4, pp. 52-73, dic. 2014.

- [12] J. Díaz-Ramírez, «Aprendizaje Automático y Aprendizaje Profundo», *Ingeniare Rev. Chil. Ing.*, vol. 29, n.º 2, pp. 180-181, jun. 2021, doi: 10.4067/S0718-33052021000200180.
- [13] P. N. Srinivasu, J. G. SivaSai, M. F. Ijaz, A. K. Bhoi, W. Kim, y J. J. Kang, «Classification of Skin Disease Using Deep Learning Neural Networks with MobileNet V2 and LSTM», *Sensors*, vol. 21, n.º 8, Art. n.º 8, ene. 2021, doi: 10.3390/s21082852.
- [14] D. I. Q. Yagual, C. C. Yagual, y I. C. Suárez, «Una revisión del Aprendizaje profundo aplicado a la ciberseguridad», *Rev. Científica Tecnológica UPSE*, vol. 9, n.º 1, Art. n.º 1, jun. 2022, doi: 10.26423/rctu.v9i1.671.
- [15] S. A. Prabhu y V. Parthipan, «A Novel Approach for Prediction of Human Disease using Symptoms by Multilayer Perceptron Algorithm to Improve the Accuracy and Compared with Gaussian Naïve Bayes Algorithm», *J. Pharm. Negat. Results*, pp. 845-850, sep. 2022, doi: 10.47750/pnr.2022.13.S04.099.
- [16] A. L. Batallas, J. Bermeo Paucar, J. Paredes Quevedo, y H. Torres Ordoñez, «Una revisión de las métricas aplicadas en el procesamiento de imágenes», *RECIMUNDO Rev. Científica Investig. El Conoc.*, vol. 4, n.º 3, pp. 267-273, 2020.
- [17] L. Wang, J. Sun, X. Wu, J. Shen, B. Lu, y W. Tan, «Identification of crop diseases using improved convolutional neural networks», *IET Comput. Vis.*, vol. 14, n.º 7, pp. 538-545, 2020, doi: 10.1049/iet-cvi.2019.0136.
- [18] R. Mukesh y K. Jaisharma, «Prediction of Plant Diseases using Simple Novel Image Detection Technique with Improved Accuracy and Compared with Convolutional Neural Network», *J. Pharm. Negat. Results*, pp. 825-830, sep. 2022, doi: 10.47750/pnr.2022.13.S04.095.
- [19] J. D. Ramírez Sánchez, «Regularización de redes neuronales artificiales para la clasificación de imágenes de retinopatía diabética», Trabajo de grado - Maestría, Universidad Nacional de Colombia, 2022. Accedido: 11 de agosto de 2023. [En línea]. Disponible en: <https://repositorio.unal.edu.co/handle/unal/81945>
- [20] S. Barburiceanu, S. Meza, B. Orza, R. Malutan, y R. Terebes, «Convolutional Neural Networks for Texture Feature Extraction. Applications to Leaf Disease Classification in Precision Agriculture», *IEEE Access*, vol. 9, pp. 160085-160103, 2021, doi: 10.1109/ACCESS.2021.3131002.
- [21] M. Agarwal, A. Singh, S. Arjaria, A. Sinha, y S. Gupta, «ToLeD: Tomato Leaf Disease Detection using Convolution Neural Network», *Procedia Comput. Sci.*, vol. 167, pp. 293-301, ene. 2020, doi: 10.1016/j.procs.2020.03.225.

- [22] G. A. Figueredo-Ávila y J. A. Ballesteros-Ricaurte, «Identificación del estado de madurez de las frutas con redes neuronales artificiales, una revisión», *Cienc. Agric.*, vol. 13, n.º 1, Art. n.º 1, ene. 2016, doi: 10.19053/01228420.4811.
- [23] F. Lubinus Badillo, C. A. Rueda Hernández, B. Marconi Narváez, y Y. E. Arias Trillos, «Redes neuronales convolucionales: un modelo de Deep Learning en imágenes diagnósticas. Revisión de tema», *Rev Colomb Radiol*, pp. 5591-5599, 2021.
- [24] S. P. Singh, K. Pritamdas, K. J. Devi, y S. D. Devi, «Custom Convolutional Neural Network for Detection and Classification of Rice Plant Diseases», *Procedia Comput. Sci.*, vol. 218, pp. 2026-2040, ene. 2023, doi: 10.1016/j.procs.2023.01.179.
- [25] S. Jasrotia, J. Yadav, N. Rajpal, M. Arora, y J. Chaudhary, «Convolutional Neural Network Based Maize Plant Disease Identification», *Procedia Comput. Sci.*, vol. 218, pp. 1712-1721, ene. 2023, doi: 10.1016/j.procs.2023.01.149.
- [26] Md. R. Islam, Md. A. M. T. Siddique, M. Amiruzzaman, M. Abdullah-Al-Wadud, S. M. R. A. Masud, y A. K. Saha, «An Efficient Technique for Recognizing Tomato Leaf Disease Based on the Most Effective Deep CNN Hyperparameters», *Ann. Emerg. Technol. Comput.*, vol. 7, n.º 1, pp. 1-14, ene. 2023, doi: 10.33166/AETiC.2023.01.001.
- [27] J. Jiang *et al.*, «Evaluation of Diverse Convolutional Neural Networks and Training Strategies for Wheat Leaf Disease Identification with Field-Acquired Photographs», *Remote Sens.*, vol. 14, n.º 14, Art. n.º 14, ene. 2022, doi: 10.3390/rs14143446.
- [28] A. Arshaghi, M. Ashourin, y L. Ghabeli, «Detection and Classification of Potato Diseases Using a New Convolution Neural Network Architecture», *Trait. Signal*, vol. 38, pp. 1783-1791, dic. 2021, doi: 10.18280/ts.380622.
- [29] V. Choudhary, P. Guha, G. Pau, R. K. Dhanaraj, y S. Mishra, «Automatic classification of cowpea leaves using deep convolutional neural network», *Smart Agric. Technol.*, vol. 4, p. 100209, ago. 2023, doi: 10.1016/j.atech.2023.100209.
- [30] A. Upadhyay, S. Singh, y S. Kanojiya, «Segregation of Ripe and Raw Bananas Using Convolutional Neural Network», *Procedia Comput. Sci.*, vol. 218, pp. 461-468, 2023, doi: 10.1016/j.procs.2023.01.028.
- [31] S. Kujawa, J. Mazurkiewicz, y W. Czekala, «Using convolutional neural networks to classify the maturity of compost based on sewage sludge and rapeseed straw», *J. Clean. Prod.*, vol. 258, p. 120814, jun. 2020, doi: 10.1016/j.jclepro.2020.120814.

- [32] K. Przybył y K. Koszela, «Applications MLP and Other Methods in Artificial Intelligence of Fruit and Vegetable in Convective and Spray Drying», *Appl. Sci.*, vol. 13, n.º 5, Art. n.º 5, ene. 2023, doi: 10.3390/app13052965.
- [33] Z. Wang, Y. Ma, F. Cheng, y L. Yang, «Review of pulse-coupled neural networks», *Image Vis. Comput.*, vol. 28, n.º 1, pp. 5-13, ene. 2010, doi: 10.1016/j.imavis.2009.06.007.
- [34] K. Weiss, T. M. Khoshgoftaar, y D. Wang, «A survey of transfer learning», *J. Big Data*, vol. 3, n.º 1, p. 9, may 2016, doi: 10.1186/s40537-016-0043-6.
- [35] M. Rahimzadeh y A. Attar, «A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2», *Inform. Med. Unlocked*, vol. 19, p. 100360, ene. 2020, doi: 10.1016/j.imu.2020.100360.
- [36] T. Xu y Z. Yuan, «Convolution Neural Network With Coordinate Attention for the Automatic Detection of Pulmonary Tuberculosis Images on Chest X-Rays», *IEEE Access*, vol. 10, pp. 86710-86717, 2022, doi: 10.1109/ACCESS.2022.3199419.
- [37] A. S. Musallam, A. S. Sherif, y M. K. Hussein, «A New Convolutional Neural Network Architecture for Automatic Detection of Brain Tumors in Magnetic Resonance Imaging Images», *IEEE Access*, vol. 10, pp. 2775-2782, 2022, doi: 10.1109/ACCESS.2022.3140289.
- [38] S. Gawade, A. Bhansali, K. Patil, y D. Shaikh, «Application of the convolutional neural networks and supervised deep-learning methods for osteosarcoma bone cancer detection», *Healthc. Anal.*, vol. 3, p. 100153, nov. 2023, doi: 10.1016/j.health.2023.100153.
- [39] N. Younezade, M. Marjani, y S. K. Ray, «A Predictive Model to Detect Cervical Diseases Using Convolutional Neural Network Algorithms and Digital Colposcopy Images», *IEEE Access*, vol. 11, pp. 59882-59898, 2023, doi: 10.1109/ACCESS.2023.3285409.
- [40] G. Marques, A. Ferreras, y I. de la Torre-Diez, «An ensemble-based approach for automated medical diagnosis of malaria using EfficientNet», *Multimed. Tools Appl.*, vol. 81, n.º 19, pp. 28061-28078, ago. 2022, doi: 10.1007/s11042-022-12624-6.
- [41] M. Stanojevic, D. Draškovic, y B. Nikolic, «Retinal disease classification based on optical coherence tomography images using convolutional neural networks», *J. Electron. Imaging*, vol. 32, n.º 3, p. 032004, nov. 2022, doi: 10.1117/1.JEI.32.3.032004.
- [42] M. Nieniewski, L. J. Chmielewski, S. Patrzyk, y A. Woźniacka, «Studies in differentiating psoriasis from other dermatoses using small data set and transfer learning», *EURASIP J. Image Video Process.*, vol. 2023, n.º 1, p. 7, may 2023, doi: 10.1186/s13640-023-00607-y.

- [43] K. Thurnhofer-Hemsi, E. López-Rubio, E. Domínguez, y D. A. Elizondo, «Skin Lesion Classification by Ensembles of Deep Convolutional Networks and Regularly Spaced Shifting», *IEEE Access*, vol. 9, pp. 112193-112205, 2021, doi: 10.1109/ACCESS.2021.3103410.
- [44] T.-C. Pham, A. Doucet, C.-M. Luong, C.-T. Tran, y V.-D. Hoang, «Improving Skin-Disease Classification Based on Customized Loss Function Combined With Balanced Mini-Batch Logic and Real-Time Image Augmentation», *IEEE Access*, vol. 8, pp. 150725-150737, 2020, doi: 10.1109/ACCESS.2020.3016653.
- [45] J. L. Newman, J. S. Phillips, y S. J. Cox, «1D Convolutional Neural Networks for Detecting Nystagmus», *IEEE J. Biomed. Health Inform.*, vol. 25, n.º 5, pp. 1814-1823, may 2021, doi: 10.1109/JBHI.2020.3025381.
- [46] R. Indraswari, R. Rokhana, y W. Herulambang, «Melanoma image classification based on MobileNetV2 network», *Procedia Comput. Sci.*, vol. 197, pp. 198-207, ene. 2022, doi: 10.1016/j.procs.2021.12.132.
- [47] Z. Sani, R. Prasad, y E. K. M. Hashim, «Breast Cancer Classification Using Equivariance Transition in Group Convolutional Neural Networks», *IEEE Access*, vol. 11, pp. 28454-28465, 2023, doi: 10.1109/ACCESS.2023.3253640.
- [48] P. K. Sethy, S. K. Behera, y N. Kannan, «Categorization of Common Pigmented Skin Lesions (CPSL) using Multi-Deep Features and Support Vector Machine», *J. Digit. Imaging*, vol. 35, n.º 5, pp. 1207-1216, oct. 2022, doi: 10.1007/s10278-022-00632-9.
- [49] S. F. Aijaz, S. J. Khan, F. Azim, C. S. Shakeel, y U. Hassan, «Deep Learning Application for Effective Classification of Different Types of Psoriasis», *J. Healthc. Eng.*, vol. 2022, p. e7541583, ene. 2022, doi: 10.1155/2022/7541583.
- [50] C.-K. Tsung y Y.-A. Tso, «Recognizing Edge-Based Diseases of Vocal Cords by Using Convolutional Neural Networks», *IEEE Access*, vol. 10, pp. 120383-120397, 2022, doi: 10.1109/ACCESS.2022.3221457.
- [51] M. A. A. Calazans, F. A. B. S. Ferreira, M. de L. M. G. Alcoforado, A. dos Santos, A. dos A. Pontual, y F. Madeiro, «Automatic Classification System for Periapical Lesions in Cone-Beam Computed Tomography», *Sensors*, vol. 22, n.º 17, Art. n.º 17, ene. 2022, doi: 10.3390/s22176481.
- [52] «Lesiones y enfermedades de la cara». Accedido: 19 de septiembre de 2023. [En línea]. Disponible en: <https://medlineplus.gov/spanish/facialinjuriesanddisorders.html>

- [53] «Problemas de la piel: fotos, causas, síntomas y tratamientos», Healthline. Accedido: 19 de septiembre de 2023. [En línea]. Disponible en: <https://www.healthline.com/health/es/enfermedades-de-la-piel>
- [54] «Masas benignas en la piel». Accedido: 3 de diciembre de 2023. [En línea]. Disponible en: <http://healthlibrary.brighamandwomens.org/Spanish/RelatedItems/85,p03420>
- [55] M. Alnajjar, «Image-Based Detection Using Deep Learning and Google Colab», vol. 5, n.º 1, 2021.
- [56] I. Challenger-Pérez, Y. Díaz-Ricardo, y R. A. Becerra-García, «El lenguaje de programación Python», *Cienc. Holguín*, vol. XX, n.º 2, pp. 1-13, 2014.
- [57] «Setting up Visual Studio Code». Accedido: 11 de agosto de 2023. [En línea]. Disponible en: <https://code.visualstudio.com/docs/setup/setup-overview>
- [58] J. S. Vivanco Castro, «Implementación de algoritmos de clasificación con Deep Learning a través del uso de la librería TensorFlow», bachelorThesis, 2018. Accedido: 11 de agosto de 2023. [En línea]. Disponible en: <http://dspace.utpl.edu.ec/handle/20.500.11962/23604>
- [59] J. D. García O., S. M. Hurtado G., y M. I. Vidal C, «Revisión de la Literatura: Método Automatizado De Reconocimiento Facial Basado En Algoritmos De Aprendizaje - ProQuest», *Revisión de la Literatura: Método Automatizado De Reconocimiento Facial Basado En Algoritmos De Aprendizaje*. Accedido: 11 de agosto de 2023. [En línea]. Disponible en: <https://www.proquest.com/openview/bb8394516455cda03d7ddb46c18cb161/1.pdf?pq-origsite=gscholar&cbl=1006393>
- [60] J. Benito Picazo, K. Thurnhofer Hemi, M. Á. Molina-Cabello, y E. Domínguez, «Comparación de marcos de trabajo de Aprendizaje Profundo para la detección de objetos», nov. 2018, Accedido: 11 de agosto de 2023. [En línea]. Disponible en: <https://riuma.uma.es/xmlui/handle/10630/16817>

ANEXOS

Anexo 1: Matriz de consistencia

Problema, objeto y campo	Objetivo	Marco Teórico	Hipótesis	Variabes	Metodología
<p>Problema:</p> <p>¿Cómo apoyar a la detección confiable de diferentes enfermedades faciales y brindar información relevante en base al procesamiento y análisis de imágenes?</p> <p>Problemas específicos Opcional):</p> <p>¿Cómo entrenar y calibrar los algoritmos de inteligencia artificial para detectar enfermedades faciales?</p> <p>¿Cuáles son las características y patrones faciales relevantes para el diagnóstico de enfermedades faciales mediante inteligencia artificial?</p>	<p>Objetivo General:</p> <ul style="list-style-type: none"> - Desarrollar una aplicación móvil y web mediante el uso de inteligencia artificial, para detectar enfermedades faciales. <p>Objetivos Específicos:</p> <ul style="list-style-type: none"> - Realizar una investigación bibliográfica para construir el estado del arte y marco teórico correspondiente. - Contemplar los aspectos estructurales y funcionales necesarios para la implementación de un modelo de red neuronal. 	<p>Antecedentes históricos a nivel internacional y nacional del objeto, campo:</p> <ul style="list-style-type: none"> - Inicios de la inteligencia artificial. - Inicios de las redes neuronales convolucionales. - Estudios de redes neuronales para la detección de enfermedades <p>Fundamentos Teóricos de objeto, campo y variables:</p> <ul style="list-style-type: none"> - Inteligencia artificial - Aprendizaje autónomo. - Procesamiento de Imágenes - Redes neuronales artificiales - Inteligencia artificial en la detección de enfermedades 	<p>Hipótesis General:</p> <ul style="list-style-type: none"> - El desarrollo de aplicación móvil y web que utilice inteligencia artificial permitirá la detección de afecciones faciales como: acné, queratosis actínica, eczema y rosácea. 	<p>Variable 1 / Independiente:</p> <ul style="list-style-type: none"> - Aplicación móvil y web que utilice inteligencia artificial. <p>Dimensiones o categorías:</p> <ul style="list-style-type: none"> - Procesamiento de imágenes. - Desarrollo móvil. <p>Variable 2/ Dependiente:</p> <ul style="list-style-type: none"> - Detección de enfermedades faciales. <p>Dimensiones o categorías:</p> <ul style="list-style-type: none"> - Enfermedades Faciales 	<p>Enfoque:</p> <p>Enfoque cuantitativo</p> <p>Alcance:</p> <p>Alcance exploratorio y descriptivo.</p> <p>Diseño:</p> <p>Diseño Cuasi-Experimental.</p> <p>Unidades de análisis:</p> <p>Población:</p> <p>Se estima un total de 31 pacientes atendidos en los últimos 5 meses.</p>

<p>¿Cómo se puede evaluar y validar la precisión y eficacia de la aplicación móvil y web en comparación con los diagnósticos realizados por profesionales de la salud en un entorno clínico?</p> <p>Objeto de estudio:</p> <p>Aplicación para detectar enfermedades faciales mediante inteligencia artificial.</p> <p>Campo de Acción:</p> <p>Redes neuronales convolucionales aplicado al reconocimiento de imágenes.</p>	<ul style="list-style-type: none"> - Establecer el conjunto de enfermedades con criterios claros y específicos que serán objeto de estudio. - Realizar una búsqueda detallada de imágenes en alta calidad donde evidencien las enfermedades mencionadas previamente para entrenar el modelo. - Establecer funcionalidades y requisitos específicos que serán implementados en la aplicación móvil y web. - Realizar pruebas y depuración del sistema para identificación y la corrección posibles errores. 	<ul style="list-style-type: none"> - Programas de desarrollo de IA. 			<p>Muestra:</p> <p>Se obtuvo un tamaño de muestra de 28 personas.</p> <p>Técnicas e instrumentos de recolección de datos:</p> <p>Técnica:</p> <p>Análisis de datos</p> <p>Instrumento:</p> <p>Guía de análisis del conjunto de imágenes.</p> <p>Técnicas de procesamiento de datos:</p> <p>Técnica Deep Learning.</p>
--	--	--	--	--	--

Anexo 2: Tutorías de titulación

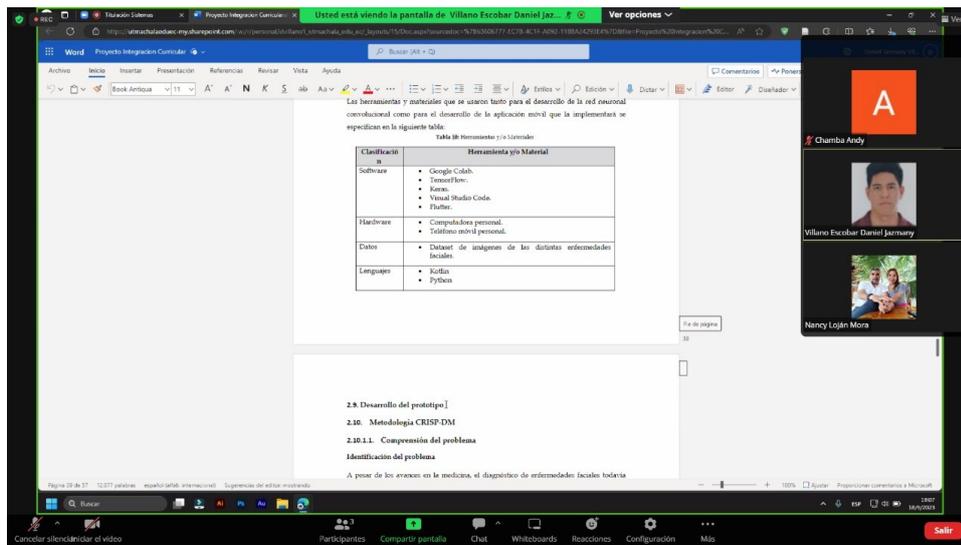


Figura 34: Tutorial virtual con tutor académico



Figura 35: Tutoría con cotutor académico

Anexo 3: Evaluación del modelo

```
Found 3923 validated image filenames belonging to 6 classes.
50/75 [=====>.....] - ETA: 22sWARNING:tensorflow:Your input ran out
75/75 [=====] - 46s 598ms/step
Confusion Matrix:
[[ 669  50  7  5  14  5]
 [ 37 456  3  4  4  4]
 [ 7  1 301  5  4  4]
 [ 15  5  4 98  7  6]
 [ 37  9  5  7 1209 94]
 [ 21  8  3  8  69 738]]
Classification Report:
              precision    recall  f1-score   support

 Candidiasis      0.85      0.89      0.87       750
  Eczema          0.86      0.90      0.88       508
   Acne           0.93      0.93      0.93       322
Pigmentación     0.77      0.73      0.75       135
  Benigno         0.93      0.89      0.91      1361
  Maligno         0.87      0.87      0.87       847

 accuracy              0.88      3923
 macro avg              0.87      0.87      0.87      3923
 weighted avg          0.89      0.88      0.88      3923
```

Figura 36: Resultado de evaluación de la red neuronal

```
## Equilibrar las clases en el conjunto de validación
max_samples = 1000 # Puedes ajustar este valor según sea necesario
min_samples = 0
column = 'labels'
working_dir = '/content/drive/MyDrive/enfermedades_red'
img_size = (299, 299)
#balanced_valid_df = balance(test_df, max_samples, min_samples, column, working_dir, img_size)

## Tamaño del lote de prueba
#length = len(balanced_valid_df)
test_batch_size = sorted([int(length/n) for n in range(1, length+1) if length % n == 0 and length/n <= 80], reverse=True)[0]
test_steps = int(length / test_batch_size)

def load_skin_model(model_path):
    model = load_model(model_path)
    return model

# Cargar el modelo preentrenado
model_path = '/content/drive/MyDrive/enfermedades_red/skinect_model.h5'
skin_model = load_skin_model(model_path)

# Preparar datos de validación
valid_gen = tvgen.flow_from_dataframe(test_df, x_col='filepaths', y_col='labels', target_size=img_size,
                                     class_mode='categorical', color_mode='rgb', shuffle=False, batch_size=test_batch_size)

# Resetear el generador para asegurarse de que comience desde el principio
valid_gen.reset()

# Obtener predicciones en el conjunto de validación
predictions = skin_model.predict(valid_gen, steps=test_steps, verbose=1)

# Obtener etiquetas reales del generador de flujo de datos
true_labels = valid_gen.classes

# Generar la matriz de confusión
cm = confusion_matrix(true_labels, np.argmax(predictions, axis=1))

# Imprimir la matriz de confusión
print("Confusion Matrix:")
print(cm)

# Obtener nombres de clases desde el generador de flujo de datos
class_names = list(valid_gen.class_indices.keys())

# Generar e imprimir el informe de clasificación
clr = classification_report(true_labels, np.argmax(predictions, axis=1), target_names=class_names)
print("Classification Report:")
print(clr)
```

Figura 37: Código de evaluación del modelo