



UNIVERSIDAD TÉCNICA DE AMBATO

**FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E
INDUSTRIAL**

CARRERA DE TELECOMUNICACIONES

Tema:

**RENDERIZADO DE COLORACIÓN CAPILAR UTILIZANDO
INTELIGENCIA ARTIFICIAL**

Trabajo de titulación modalidad: Proyecto de Investigación, presentado previo a la
obtención del título de Ingeniera en Telecomunicaciones

ÁREA: Comunicaciones

LÍNEA DE INVESTIGACIÓN: Tecnología de la información y Sistemas de
control

AUTOR: Johanna Elizabeth Balladares Armendariz

TUTOR: Ing. Víctor Santiago Manzano Villafuerte, Mg

Ambato – Ecuador

agosto - 2023

APROBACIÓN DEL TUTOR

En calidad de tutor del trabajo de titulación con el tema: **RENDERIZADO DE COLORACIÓN CAPILAR UTILIZANDO INTELIGENCIA ARTIFICIAL**, desarrollado bajo la modalidad Proyecto de Investigación por la señorita Johanna Elizabeth Balladares Armendariz, estudiante de la Carrera de Telecomunicaciones, de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, de la Universidad Técnica de Ambato, me permito indicar que la estudiante ha sido tutorada durante todo el desarrollo del trabajo hasta su conclusión, de acuerdo a lo dispuesto en el Artículo 17 del Reglamento para la Titulación de grado en la Universidad Técnica de Ambato y el numeral 6.3 del instructivo del reglamento referido.

Ambato, agosto 2023.

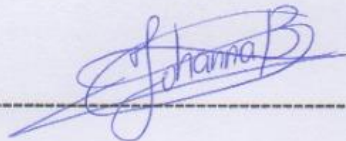
Ing. Víctor Santiago Manzano Villafuerte, Mg

TUTOR

AUTORÍA

El presente trabajo de titulación titulado: RENDERIZADO DE COLORACIÓN CAPILAR UTILIZANDO INTELIGENCIA ARTIFICIAL es absolutamente original, auténtico y personal y ha observado los preceptos establecidos en la Disposición General Quinta del Reglamento para la Titulación de Grado en la Universidad Técnica de Ambato. En tal virtud, el contenido, efectos legales y académicos que se desprenden del mismo son de exclusiva responsabilidad del autor.

Ambato, agosto 2023



Johanna Elizabeth Balladares Armendariz

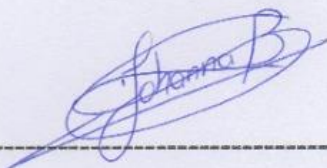
CC. 1850091511

AUTOR

DERECHOS DE AUTOR

Autorizo a la Universidad Técnica de Ambato, para que reproduzca total o parcialmente este trabajo de titulación dentro de las regulaciones legales e institucionales correspondientes. Además, cedo todos mis derechos de autor a favor de la institución con el propósito de su difusión pública, por lo tanto, autorizo su publicación en el repositorio virtual institucional como un documento disponible para la lectura y uso con fines académicos e investigativos de acuerdo con la Disposición General Cuarta del Reglamento para la Titulación de Grado en la Universidad Técnica de Ambato.

Ambato, agosto 2023.



Johanna Elizabeth Balladares Armendariz

CC. 1850091511

AUTOR

APROBACIÓN DEL TRIBUNAL DE GRADO

En calidad de par calificador del informe final del trabajo de titulación presentado por la señorita Johanna Elizabeth Balladares Armendariz , estudiante de la Carrera de Telecomunicaciones, de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, bajo la Modalidad Proyecto de Investigación titulado RENDERIZADO DE COLORACIÓN CAPILAR UTILIZANDO INTELIGENCIA ARTIFICIAL, nos permitimos informar que el trabajo ha sido revisado y calificado de acuerdo al Artículo 19 del Reglamento para la Titulación de Grado en la Universidad Técnica de Ambato y el numeral 6.4 del instructivo del reglamento referido. Para cuya constancia suscribimos, conjuntamente con la señora Presidente del Tribunal.

Ambato, agosto 2023.

Ing. Elsa Pilar Urrutia Urrutia, Mg
PRESIDENTE DEL TRIBUNAL

Ing. Juan Pablo Pallo Noroña, Mg
PROFESOR CALIFICADOR

PhD. Martha Esperanza Sevilla Abarca
PROFESOR CALIFICADOR

DEDICATORIA

A mi Niño Dios, porque además de brindarme vida y salud siempre me dio fortaleza para salir adelante.

Con gran amor a mis papitos Norma y Adán, su bendición a lo largo de mi vida me protegerá, esto es por y para ustedes, los amo.

A mi familia, amigos y más personas que estuvieron a mi lado brindándome su apoyo.

A mis ángeles del cielo, que me cuidan y ayudan a cumplir todos mis propósitos para ser feliz.

A mi personita favorita y a la vez especial, por ser testimonio de mi dedicación, este es un logro tan mío como suyo. Su mirada llena de orgullo y su amor incondicional me recuerda porqué tanto esfuerzo valió la pena. Dieguito, somos un gran equipo. ☺

Papitos, ¡Lo Logramos!

Joha

AGRADECIMIENTO

A mi Niño Dios, para que bendiga siempre a mis papitos y a cada persona que estuvo para mí siempre que lo necesité.

Un agradecimiento profundo va dedicado a mis padres “el motor de mi vida”, todo se los debo a ellos porque me enseñaron valores y a luchar por lo que quiero.

He logrado grandes amistades hasta llegar a esta etapa de mi vida y es grato para mí agradecer cada una de las sonrisas y momentos que he compartido con todas ellas.

A mis maestros por su bonita amistad y sus consejos: Ing. Juan Pablo, Ing. Marco, Ing. Jaime, Ing. Patricio, Ing. Freddy, y en especial a mi tutor Ing. Santiago, fue un gusto compartir mi carrera universitaria con ustedes.

May y Edd, amiguitos mil gracias por su amistad incondicional. ¡Son extraordinarios!

Mil gracias a todo el mundo.

Los quiero.

Joha

ÍNDICE GENERAL DE CONTENIDOS

APROBACIÓN DEL TUTOR	ii
AUTORÍA	iii
DERECHOS DE AUTOR	iv
APROBACIÓN DEL TRIBUNAL DE GRADO	v
DEDICATORIA	vi
AGRADECIMIENTO	vii
RESUMEN EJECUTIVO	xv
ABSTRACT	xvi
CAPÍTULO I	1
MARCO TEÓRICO	1
1.1. Tema de investigación.....	1
1.1.1. Planteamiento del problema.....	1
1.2. Antecedentes investigativos	2
1.3. Fundamentación teórica	4
1.3.1. Cosmética Capilar	4
1.3.1.1. Tendencias en cosmetología capilar	5
1.3.1.2. Moda en cosmetología capilar	5
1.3.2. Cosmetología Capilar.....	6
1.3.2.1. Colorimetría Capilar	6
Leyes de la colorimetría	6
1.3.2.2. Predicción de color	6
Color de cabello según piel, ojos y cabello	7
1.3.2.3. Coloración Capilar.....	9
Definición	9
Principios básicos	10
Tipos	11
Colores en tendencia	11
1.3.3. Procesamiento digital de imágenes	12
1.3.3.1. Segmentación de imágenes.....	12
1.3.3.2. Técnicas de Segmentación de imágenes.....	13
1.3.4. Inteligencia Artificial	15

1.3.4.1.	Definición	15
1.3.4.2.	Inteligencia Artificial, Machine Learning y Deep Learning.....	16
1.3.4.3.	Algoritmos y técnicas	16
	Machine Learning.....	16
	Deep Learning	17
1.3.4.4.	Frameworks para aplicaciones con inteligencia artificial.....	19
1.3.4.5.	Machine Learning	19
	Definición	19
	Aprendizaje supervisado	20
	Lenguajes de Programación orientados a Machine Learning.....	20
	Tipos de bases de datos utilizadas en Machine Learning	22
1.3.4.6.	Deep Learning.....	23
	Redes Neuronales Convolucionales o CNN.....	23
	Clasificación de las Redes Neuronales Convolucionales	24
	DeepLabv3	25
	Métricas de calidad para evaluar del modelo DeepLabv3.....	27
1.1.1.	Aplicación Web.....	28
1.3.5.	Arquitectura de una Aplicación Web	28
1.4.	Objetivos	29
	1.4.1. Objetivo General.....	29
	1.4.2. Objetivos Específicos	29
	CAPÍTULO II	30
	METODOLOGÍA	30
2.1.	Materiales.....	30
2.2.	Métodos	30
	2.2.1. Modalidad de investigación	30
	2.2.2. Recolección de información	30
	2.2.3. Procesamiento y análisis de datos.....	31
	2.2.4. Desarrollo del Proyecto	31
	CAPÍTULO III.....	32
	RESULTADOS Y DISCUSIÓN	32
3.1.	Análisis y discusión de los resultados.....	32
3.2.	Desarrollo de la propuesta	32

3.2.1. Consideraciones para el desarrollo del proyecto	32
3.2.2. Arquitectura general del sistema.....	34
3.2.3. Etapa recolección de características	35
3.2.4. Etapa procesamiento	36
3.2.4.1. Creación de la base de datos	36
Pasos para crear una base de datos con phpMyAdmin	37
Creación de tablas en la base de datos.....	37
3.2.4.2. Selección del algoritmo de Machine Learning	39
Acondicionamiento de la Base de Datos	39
Adecuación del dataset	39
Acondicionamiento del dataframe.....	40
Construcción del algoritmo	40
Entrenamiento algoritmo	41
3.2.5. Etapa de renderizado.....	43
3.2.5.1. Programación del modelo Deep Learning de Segmentación	43
Acondicionamiento de la base de datos.....	43
Adecuación del dataset.....	43
Acondicionamiento del dataframe.....	44
Construcción modelo.....	45
Entrenamiento modelo	46
Validación modelo	47
3.2.6. Etapa coloración	48
3.2.6.1. Programación de la coloración capilar.....	48
3.2.6.2. Sugerencia	53
3.2.7. Desarrollo de la aplicación	53
3.2.7.1. Creación de la interfaz gráfica	54
3.2.8. Pruebas de funcionamiento.....	55
3.2.8.1. Especificaciones para las pruebas de funcionamiento	55
3.2.8.2. Comprobación del funcionamiento de la base de datos	55
3.2.8.3. Pruebas de funcionamiento de la aplicación	56
3.2.9. Presupuesto del proyecto	68
CAPÍTULO IV	70
CONCLUSIONES Y RECOMENDACIONES.....	70
4.1. Conclusiones	70

4.2. Recomendaciones.....	71
BIBLIOGRAFÍA	72
ANEXOS.....	78
Anexo 1: Evaluación de algoritmos para Aprendizaje Supervisado.....	78
Anexo 2: Funciones de procesamiento de imágenes para entrenamiento del modelo.	78
Anexo 3: Pruebas de funcionamiento al capturar la imagen en tiempo real.....	79
Anexo 4: Manual de Usuario	80
Anexo 5: Mensajes de alerta de los procesos y botones.	83

ÍNDICE DE TABLAS

Tabla 1: Frameworks para desarrollo de aplicaciones con inteligencia artificial	19
Tabla 2: Lenguajes de programación orientados a Machine Learning	21
Tabla 3: Tipos de bases de datos utilizadas en Machine Learning	22
Tabla 4: Clasificación de las redes neuronales convolucionales	24
Tabla 5: Requisitos mínimos y recomendados de los dispositivos.	33
Tabla 6: Opciones para datos de ingreso.....	39
Tabla 7 Datos para entrenamiento de predicción de color.	40
Tabla 8: Tonos de tintes de la marca Nouvelle y colores RGB.	48
Tabla 9: Especificaciones para pruebas de funcionamiento	55
Tabla 10: Pruebas de funcionamiento de la aplicación.....	57
Tabla 11: Presupuesto del proyecto	68

ÍNDICE DE FIGURAS

Figura 1: Aspectos de la cosmetología capilar	5
Figura 2: Leyes de colorimetría	6
Figura 3: Según el color de ojos	8
Figura 4: Según el tono de piel	8
Figura 5: Según el color de cabello actual	9
Figura 6: Primer principio básico de la coloración capilar.	10
Figura 7: Segundo principio básico de la coloración capilar.	10
Figura 8: Clasificación de la coloración del cabello	11
Figura 9: Colores de cabello en tendencia del año 2023	12
Figura 10: Segmentación de una imagen	13
Figura 11: Ejemplo de búsqueda de umbral mediante histograma de la imagen.....	13
Figura 12: Ejemplo de segmentación orientada a regiones	14
Figura 13: Detección de bordes en escala de grises.....	14
Figura 14: Imagen y píxeles etiquetados	14
Figura 15: Red neuronal de convolución completa para tareas de predicción densas	15
Figura 16: Inteligencia Artificial, Machine Learning y Deep Learning	16
Figura 17: Estructura Machine Learning	20
Figura 18: Estructura de redes neuronales convolucionales	24
Figura 19: Arquitectura DeepLabv3	26
Figura 20: Arquitectura DeepLabv3+	27
Figura 21 Arquitectura de una aplicación Web.....	29
Figura 22: Arquitectura general del sistema	34
Figura 23: Base de datos MySQL con phpMyAdmin	38
Figura 24: Conexión con la base de datos	39
Figura 25: Algoritmos de Machine Learning.....	41
Figura 26: Gráfica de barras sobre entrenamiento del algoritmo	42
Figura 27: Resultados de entrenamiento del algoritmo SVM.....	43
Figura 28: Imágenes y máscaras de cabello.....	44
Figura 29: Procesamiento de la base de datos de las imágenes	44
Figura 30: Ejemplos para el procesamiento de la base de datos de las imágenes	45

Figura 31: Código fuente para cargar el modelo DeepLabv3.....	46
Figura 32: División de datos de entrenamiento y prueba	46
Figura 33: Ruta para imágenes de entrenamiento del modelo.....	46
Figura 34: Resultados del entrenamiento para la validación del modelo, (a) imagen y máscara para el entrenamiento, (b) resultados del modelo DeepLabv3.....	47
Figura 35: Métricas de calidad para el modelo DeepLabv3	47
Figura 36: Colores RGB para la máscara de color	53
Figura 37: Ajuste de transparencia de la imagen	53
Figura 38: Diagrama de secuencias del desarrollo de la aplicación	54
Figura 39: Diagrama secuencial del funcionamiento de la aplicación	54
Figura 40: Ingreso de datos para prueba de funcionamiento de la base de datos	56
Figura 41: Confirmación de ingreso en la base de datos en el código fuente.....	56
Figura 42: Registro en la base de datos phpMyAdmin.....	56
Figura 43: Almacenamiento en la base de datos.....	67

RESUMEN EJECUTIVO

La importancia en el mundo de teñirse el cabello se ha convertido en tendencia y las personas que deciden cambiar su color de cabello asisten a una estética en donde por lo general piden recomendaciones sin conocer el resultado final.

El propósito de crear una aplicación de renderizado de coloración capilar es brindar una herramienta digital que muestre recomendaciones de color mediante un proceso de colorimetría capilar previsualizando un tono de cabello de manera virtual.

La aplicación recolecta tres características físicas: color de ojos, piel y cabello que son almacenadas en una base de datos MySQL. El algoritmo Máquina de Vectores Soporte utiliza las librerías Tensor Flow y Keras para el proceso de colorimetría capilar con la finalidad de predecir el color de cabello. El modelo DeepLabv3 segmenta el cabello de una imagen cargada dando como resultado una máscara. Por último, se aplica un proceso que acopla los resultados de los algoritmos anteriores para mostrar el color de cabello personalizado mediante el modelo RGB.

La evaluación del algoritmo de colorimetría capilar usa la validación cruzada y obtiene un valor de 0.78 en entrenamiento y testeo siendo capaz de predecir el color adecuadamente. Las métricas de calidad para el modelo DeepLabv3 presentan un promedio de resultados: recall 98%, Dice Coeficiente 98% y IoU 97%, considerando que el modelo posee buena capacidad para segmentar el cabello en imágenes.

La aplicación ofrece beneficios de asesoramiento personalizado y realista, brindando un cambio favorable en la apariencia del usuario al combinar la creatividad teórica y tecnológica.

Palabras clave: inteligencia artificial, coloración capilar, renderizado, procesamiento de imágenes, deep learning.

ABSTRACT

The importance in the world of hair coloring has become a trend and people who decide to change their hair color go to an esthetics where they usually ask for recommendations without knowing the final result.

The purpose of creating a hair color rendering application is to provide a digital tool that shows color recommendations through a process of hair colorimetry by previewing a hair tone virtually.

The application collects three physical characteristics: eye, skin and hair color that are stored in a MySQL database. The Support Vector Machine algorithm uses the TensorFlow and Keras libraries for the hair colorimetry process to predict hair color. The DeepLabv3 model segments the hair of a loaded image resulting in a mask. Finally, a process that couples the results of the previous algorithms is applied to display the customized hair color using the RGB model.

The evaluation of the hair colorimetry algorithm uses cross-validation and obtains a value of 0.78 in training and testing, being able to predict the color adequately. The quality metrics for the DeepLabv3 model present average results: recall 98%, Dice Coefficient 98% and IoU 97%, considering that the model has good ability to segment hair in images.

The application offers benefits of personalized and realistic counseling, providing a favorable change in the user's appearance by combining theoretical and technological creativity.

Keywords: artificial intelligence, hair coloring, rendering, image processing, deep learning

CAPÍTULO I

MARCO TEÓRICO

1.1. Tema de investigación

RENDERIZADO DE COLORACIÓN CAPILAR UTILIZANDO INTELIGENCIA ARTIFICIAL

1.1.1. Planteamiento del problema

En la actualidad la inteligencia artificial ha realizado una transformación total dentro de la industria de la moda, es por ello, que la clasificación del color del cabello juega un papel importante en el reconocimiento facial. Se desarrollan varias tecnologías en torno a aplicaciones virtuales en tiempo real que permiten a las personas experimentar matices estéticos capilares desde la comodidad de su hogar.

La importancia en el mundo para teñirse el cabello y cambiar el color natural no es nada nuevo, en el 2014 la revista "Consumidor" explica que incluso en los tiempos de los antiguos griegos se realizaba el cambio de tonos de cabello. Es por esto, que existen investigaciones internacionales enfocadas al desarrollo de aplicaciones que permitan el renderizado del mismo con el objetivo de mostrar el cambio de apariencia de una persona al instante.

En Latinoamérica existe una gran demanda de descarga de aplicaciones desde el principio de Pandemia muestran la creatividad para embellecer el entorno destacando el rostro de una persona. Dichas aplicaciones al conocer el color de cabello natural, el color de ojos y la tonalidad de la piel sugieren productos de acuerdo a su aspecto como si se tratase de un profesional asesor de belleza. La mayoría de las personas eligen cambiarse la tonalidad de cabello sin un análisis de colorimetría y en la comodidad de su hogar, es decir, siempre se ha acudido a un estilista fuera de casa y se han aplicado colores de acuerdo a la tendencia, más no los apropiados para beneficio de su apariencia.

En este contexto es crucial el desarrollo de una aplicación de coloración capilar que considere las preferencias de color de: ojos, piel y cabello ofreciendo una amplia gama de opciones personalizadas de color de cabello para adaptarse a la apariencia física de cada persona.

1.2. Antecedentes investigativos

A lo largo de los años, se han ido desarrollando varias investigaciones relacionadas con el tema de interés. En particular, es importante destacar las estrategias de la inteligencia artificial en el renderizado de coloración capilar mediante fundamentos teóricos y enfoques prácticos que permiten nuevos desafíos tecnológicos en la industria de la belleza, como se muestran en las siguientes investigaciones:

En la revista Eventos TI del año 2018, la tecnología de Nvidia, una empresa de Estados Unidos publica la investigación “Probar antes de teñir: IA permite encontrar tu color de pelo ideal”, explica la constante innovación en el área de la inteligencia artificial y la industria del cuidado del cabello. ModiFace, una empresa de Toronto utiliza la tecnología de Nvidia para transformar la forma en que las personas eligen nuevos colores para el cabello mediante aplicaciones con inteligencia artificial. Este tipo de aplicación utiliza técnicas de procesamiento de imágenes y machine learning para el proceso de detección y segmentación de cabello para luego aplicar el color seleccionado de manera realista en el cabello de una persona. El propósito es superar las expectativas del cliente reinventando la experiencia de la belleza con métodos que se adapten a los tonos de piel y muestren un aspecto desde diferentes puntos en tiempo real [2].

La investigación “Fast In-the-Wild Hair Segmentation and Color Classification” publicada en el año 2019 por Tudor Alexandru Ileni, Diana Laura Borza y Adrián Sergiu Darabant de la Universidad Técnica de Cluj-Napoca en Rumania, explica sobre el problema de la segmentación de cabello y la clasificación del color del cabello en imágenes faciales utilizando un enfoque de aprendizaje automático basado en redes neuronales convolucionales. Se evalúa el modelo de segmentación de cabello

utilizando la métrica de intersección Over Union (IoU) y el color del cabello se clasifica según el histograma de color normalizado de los píxeles utilizando una red neuronal artificial clásica. El método propuesto dio como resultado una precisión del 91,61% en la segmentación de cabello y una precisión del 89,6% en la clasificación del color del cabello [1].

Roc R. Currius, Ulf Assarsson y Erik Sintorn presentan en el año 2022 la investigación “Real-Time Hair Filtering with Convolutional Neural Networks” en el Instituto de Tecnología Chalmers, donde se menciona la complejidad de la renderización de cabello y pelaje realistas en tiempo real y para ello se propone el método Ground Truth, que se encarga de renderizar una geometría texturizada que representan varias hebras de cabello. El método permite una representación rápida de la geometría del cabello, manteniendo un alto detalle de frecuencia proporcional al trabajo sobre la eliminación de ruido trazada por un trayecto. Su finalidad es utilizar de una hasta cuatro muestras por píxel en una imagen y de ese modo obtener una buena compensación de rendimiento y calidad del renderizado. La noción de aplicar esta técnica logra un primer plano de alta calidad a más de 60 fps con una resolución de 1024x1024 píxeles, evaluando el color, especular, alfa, tangentes y profundidad mediante un algoritmo de color dando como resultado una imagen más detallada del grosor y transparencia del cabello de una manera más realista [2].

En el año 2022 Boram Kim de la Sociedad de Ciencia y Tecnología mediante el artículo “New Image Processing Algorithm towards More Realistic Expression on Hair Coloring”, explica la importancia de los servicios virtuales en la coloración de cabello, pues la experiencia que se ofrece permite al cliente observar si el color resultante es del agrado y cumple con las expectativas mucho antes de teñirse el cabello. Se aplica dentro de la investigación un método de procesamiento de color del cabello humano con un mecanismo de teñido permanente más realista e incluso se utiliza la interpolación lineal para cubrir toda la gama de brillo del cabello. Su base de datos consiste en una tabla de consulta con imágenes de las que se analizan el brillo mediante el sistema CieLab (espacios de color para evaluar el color de un objeto). La tabla de consultas se crea con la finalidad de obtener datos reales del tinte de cabello para de

ese modo mostrar excelente representación de color y proximidad a una coloración real del tinte de cabello. Finalmente se ratifica que, si el propósito es la diversión, el resultado virtual es aceptable, sin embargo, si el propósito es la promoción de un producto o la simulación de coloración, el resultado del renderizado debe mejorarse para publicitar el rendimiento del tinte [3].

Una gran contribución en la industria de la belleza en el año 2022 se titula “Artificial Intelligence: AI in fashion and beauty e-commerce” publicada por Duong Dang en LAB University of Applied Sciences, donde menciona el impacto significativo del comercio electrónico. Las metodologías a utilizar son cuantitativa y cualitativa ya que el objetivo principal es ampliar el conocimiento y contribución de la IA del comercio electrónico en el ámbito de la moda y la belleza, es por ello que el segmento teórico mediante la utilización de libros y artículos de especialistas en inteligencia artificial explica la clasificación, estado actual y beneficios de la IA. Por otro lado, se realiza una encuesta en línea para determinar los criterios de los clientes sobre la IA en donde se reconoce que la tecnología contemporánea mejora sus vidas. El resultado final demuestra que de los 155 encuestados el 73,4% han oído sobre inteligencia artificial, una de las funcionalidades más populares es el reconocimiento facial con un 85,7% y 39% revela la utilización de cosméticos en tiempo real, es ahí donde se ve reflejada la importancia del uso de inteligencia artificial en el comercio electrónico de la moda y la belleza, mejorando el rendimiento de la marca aumentando su rentabilidad [4].

Las investigaciones encontradas aportan con el desarrollo de nuevas técnicas y métodos utilizados que colaboran con la precisión de la predicción del color como resultado final, mostrando gran similitud con las imágenes más realistas de la coloración del cabello.

1.3. Fundamentación teórica

1.3.1. Cosmética Capilar

La cosmética capilar considera un conjunto de técnicas o tratamientos utilizados tanto para el cuidado como para embellecer el cabello abordando aspectos como limpieza,

hidratación, nutrición, fortalecimiento, peinado y estilismo. Su objetivo es mantener un cabello saludable y bonito, algo que solamente se logran con productos adecuados que entran en contacto con el cabello y el cuero cabelludo para mantenerlos en buenas condiciones [5].

1.3.1.1. Tendencias en cosmetología capilar

Las tendencias que hoy en día se han observado tiene mucho que ver con la tecnología y dispositivos capilares, aun así, estos procesos también incluyen ingredientes naturales, cuidado del cuero cabelludo, técnicas de coloración innovadoras, productos y tratamientos personalizados que buscan un enfoque sostenible.

Haciendo énfasis en las técnicas de coloración innovadoras, productos y tratamientos personalizados y tecnología, se ha tomado la iniciativa para lograr resultados con productos específicos para los usuarios tomando en cuenta sus características y necesidades individuales, incluso la aplicación de la tecnología da un giro completamente novedoso para las personas que desean teñir su cabello sin dañarlo.

1.3.1.2. Moda en cosmetología capilar

La cosmetología capilar tiene un papel fundamental en la moda pues se enfoca en varios aspectos como muestra la Figura 1.

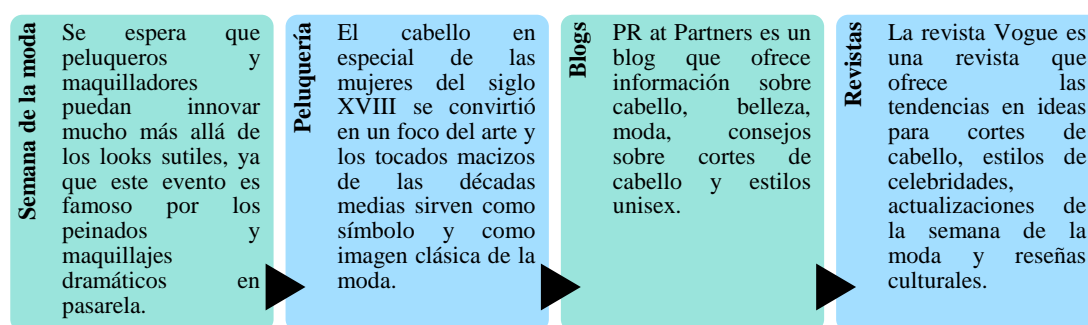


Figura 1: Aspectos de la cosmetología capilar

Elaborado por: El investigador basado en [6-9]

Cada recurso disponible brinda información sobre las últimas tendencias, estilos y técnicas sobre la cosmetología del cabello.

1.3.2. Cosmetología Capilar

La cosmetología capilar es una disciplina que se encarga de estudiar la acción y los efectos de los cosméticos y además determinar las normas generales del uso práctico en el cabello [10].

1.3.2.1. Colorimetría Capilar

Es la ciencia que estudia el desarrollo del color generando valores numéricos mediante una escala. Los profesionales de belleza lo utilizan mediante el círculo o estrella cromática que es un elemento en donde se sitúan los colores primarios y sus derivados [11].

Leyes de la colorimetría

La fundamentación teórica es bastante amplia, aun así, lo más fundamental es conocer las cuatro leyes del color como se especifica en la Figura 2.

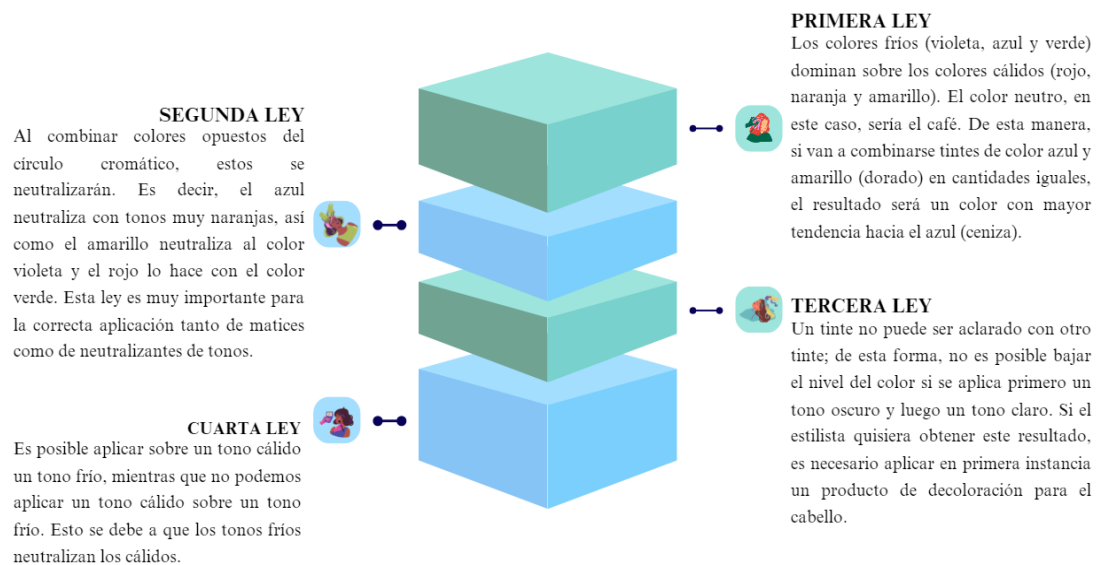


Figura 2: Leyes de colorimetría

Elaborado por: El investigador basado en [12]

1.3.2.2. Predicción de color

Indudablemente, es cierto que la anticipación de las tendencias en el ámbito de la belleza es un desafío. No obstante, en este terreno surgen personajes de singular

destreza, caracterizados por un agudo discernimiento, quienes tienen la capacidad de identificar innovaciones en el ámbito del color de cabello con notable antelación. Estos precursores de la estética, centran su atención en una nueva estación o ciclo, y mediante su perspicaz inteligencia, capturan tonalidades particulares o técnicas atrevidas de aplicación. En efecto, sientan las bases para propiciar la aceptación generalizada de tonalidades radiantes y enriquecedores en el panorama capilar [13].

Color de cabello según piel, ojos y cabello

El mercado ha evolucionado con todo tipo de técnicas y coloraciones para el cabello y para llevar a cabo al 100% que las mujeres se sientan a gusto con el aspecto que más les favorece, es ahí cuando entra en juego factores como el tono de piel, el color de los ojos o el color de cabello actual.

Según el color de ojos

- a. Negros / Marrones:** Este color de ojos combina con tintes de color chocolate, castaños, negros, incluso los ojos de color marrón oscuro también se sientan bien con colores caoba, pues si su tez es blanca los colores chocolate, rubio, cenizo o cobrizos y mechas en tonos castaños suavizan el rostro [14].
- b. Verdes:** Las pieles más claras con este color de ojos suelen favorecer su apariencia con los colores de cabello rubios, cenizo o con mechas y si las pieles son bronceadas encajan perfectamente con melenas castañas, bronde o rubias cobrizas [14].
- c. Azules / Grises:** Las melenas rubias van mejor con pieles claras como muestra la Figura 3, mientras que con pieles bronceadas los tonos dorados son la mejor elección. Incluso, las pieles claras con ojos azules pueden sacar partido a los morenos oscuros y tonos chocolate, pues genera contraste con la tez y el color del iris [14].



Figura 3: Según el color de ojos

Fuente: [14]

Según el tono de piel

- a. **Blanca:** También conocida como piel clara, son aquellas que tienden a quemarse bajo el sol con mucha facilidad y se sonrojan de manera evidente. Este tipo de piel opta por la gama de rubios más claros, dorados, caoba, bronde y castaños más claros como se observa en la Figura 4 [14].
- b. **Media:** Los castaños, caoba, castaño chocolate con reflejos cálidos acompañan bien a este tipo de pieles, también se puede optar por un tinte rubio, dorado o matices cobrizo y evitar el rubio oxigenado [14].
- c. **Morena:** Toda la gama de tintes castaños, chocolate, negro, aunque dependiendo del color de ojos el rostro se verá con las facciones más o menos endurecidas y para dulcificar el rostro lo mejor es combinar el tinte con una buena técnica de hair contouring que combine tonos dorados en las capas más superficiales de la melena [14].



Figura 4: Según el tono de piel

Fuente: [14]

Según el color de cabello actual

- a. **Rubio / Castaño claro:** Los colores claros y atrevidos deben realzar el color base y crear dimensión en el cabello como se observa en la Figura 5. Los tonos caramelo, marrón chocolate, tonos dorados, cobrizos o avellana realzan los

reflejos naturales y crean un aspecto luminoso. Una excelente opción para un cambio audaz y creativo se puede considerar colores de fantasía como rosa, azul, violeta o verde [14].

- b. Castaño:** A este tono puede darle vida una combinación de chocolate oscuro, dorado, rubio crema en puntos estratégicos para iluminar la mirada, también añadir matices rojizos o tono caramelo cambian el look por completo [14].
- c. Negro:** Este color puede dar un giro completo al aplicar colores como azul, negro azulado, violeta que añade destellos y matices [14].



Figura 5: Según el color de cabello actual

Fuente: [14]

1.3.2.3. Coloración Capilar

Se pueden encontrar varios aspectos para hablar y cada uno de ellos son relevantes, pues al incurrir en el proceso de coloración aplicando inteligencia artificial requiere explicar la importancia de este proceso desde la raíz.

Definición

El proceso de coloración del cabello es simplemente un proceso que aclara u oscurece el cabello mediante una reacción química. Entre los componentes del tinte que permiten aclarar el cabello y luego proporcionar un color del pigmento requerido se encuentra su protagonista destacado que es el peróxido de hidrógeno (H_2O_2), el cual actúa como agente oxidante, desencadenando una reacción que disuelve el pigmento natural del cabello y determinará el grado de aclaración. [8].

Principios básicos

Los principios básicos son dos: el pigmento y la estrella cromática, cada uno de ellos se especifican en la Figura 6 y 7.

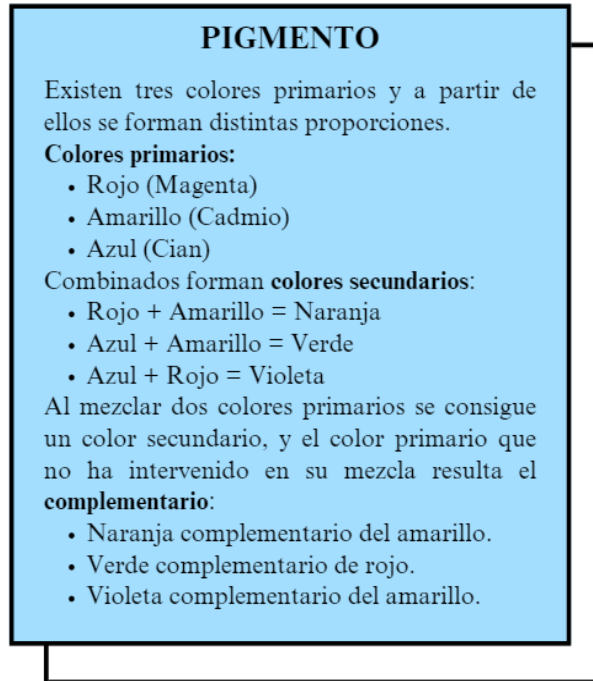


Figura 6: Primer principio básico de la coloración capilar.

Elaborado por: El investigador basado en [6]

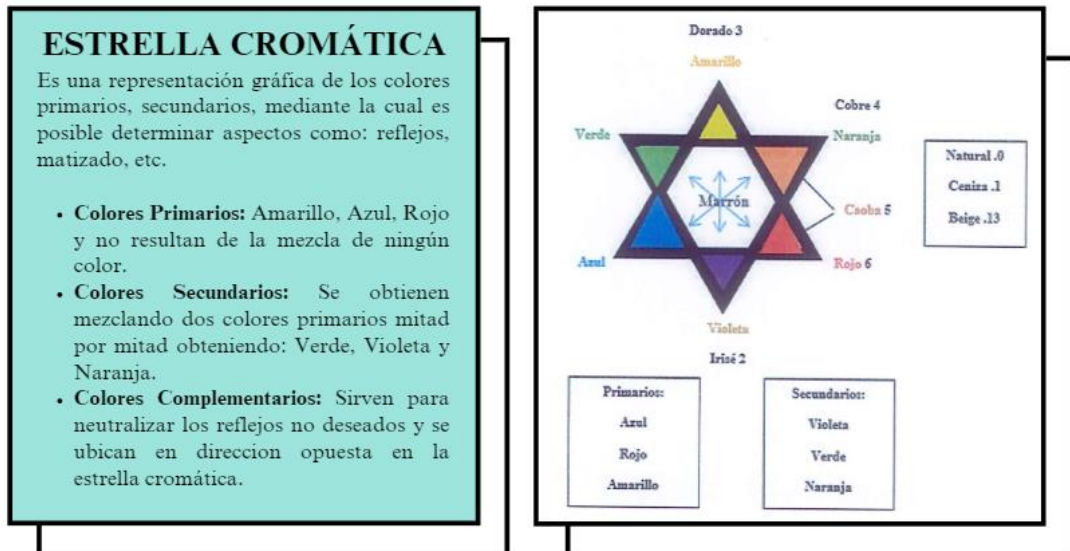


Figura 7: Segundo principio básico de la coloración capilar.

Elaborado por: El investigador basado en [6]

Tipos

Una visión general de los tipos más comunes de coloración capilar se clasifica según los elementos que se utilizan, características y tiempo de duración, estos tipos se explican en la Figura 8 [8].



Figura 8: Clasificación de la coloración del cabello

Elaborado por: El investigador basado en [8].

Colores en tendencia

Cada año existen nuevas tendencias de cabello que ayudan a una persona a lucir espectacular, cambiar el color del cabello puede sonar fácil, pero abarca un sinnúmero de conocimientos y técnicas. En el año 2023 la clave para dominar la coloración de cabello se basa en dos vertientes como la naturalidad y la elegancia, es por ello que los tonos más sencillos y distinguidos son los que se mencionan en la Figura 9 [9].

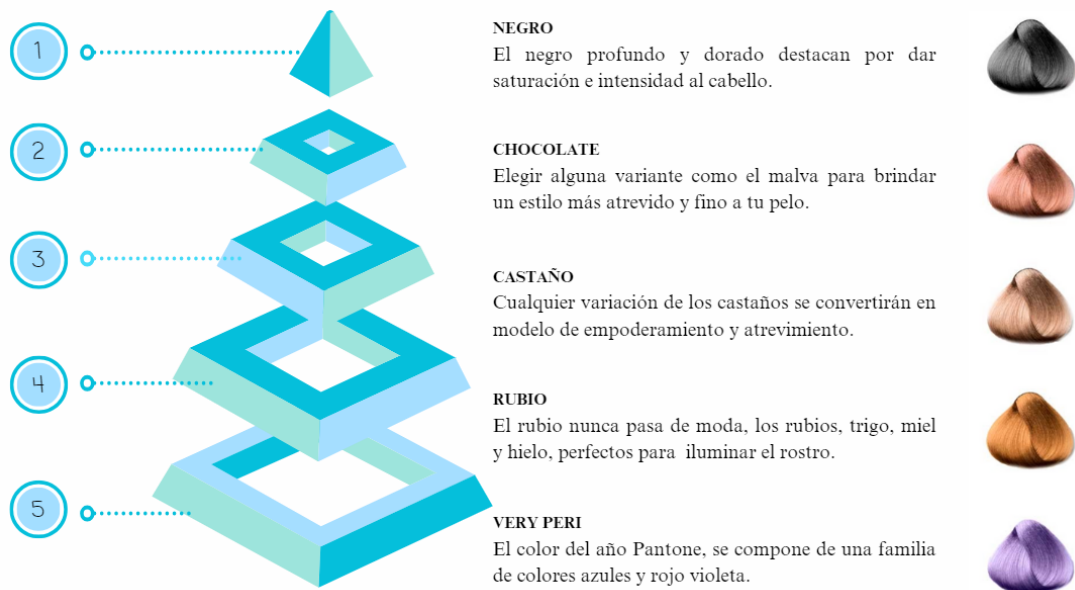


Figura 9: Colores de cabello en tendencia del año 2023

Fuente: El investigador basado en [9]

1.3.3. Procesamiento digital de imágenes

El procesamiento digital de imágenes se conoce como una rama de la electrónica que permite mejorar la calidad de la imagen para la percepción del ojo humano y extraer información de la misma para una posterior aplicación. Además, para procesar una imagen se necesita que sea capturada como una señal física o llamada luz y esta sea transformada en señal eléctrica o conocida como imagen digital [7].

1.3.3.1. Segmentación de imágenes

En el momento que se decide procesar una imagen es muy necesaria la segmentación de la misma, para de ese modo encontrar objetos presentes en el entorno y poder clasificarlos. Una buena segmentación es un buen procesado de una imagen más eficiente, pues se realizan filtrados de acuerdo al objeto que se desee identificar en la imagen. Tal y como se muestra en la Figura 10.

La segmentación domina tres conceptos como:

- **Similitud:** Los pixeles pueden contener valores parecidos con respecto alguna propiedad determinada.

- **Discontinuidad:** Los objetos en un entorno se diferencian del mismo ya que contienen puntos aislados, líneas y aristas.
- **Conectividad:** Los pixeles que forman una región o imagen se agrupan es decir se conectan para formar una región homogénea.




Figura 10: Segmentación de una imagen

Fuente: [15]

1.3.3.2. Técnicas de Segmentación de imágenes

Las técnicas más comunes de segmentación de imágenes incluyen:

1. **Segmentación por umbral:** Se basa en la selección de un umbral para separar los pixeles de una imagen en dos grupos: el que tiene valor de intensidad por encima del umbral y que él tiene un valor de intensidad por debajo del umbral [16].




Figura 11: Ejemplo de búsqueda de umbral mediante histograma de la imagen

Fuente: [16]

2. **Segmentación por regiones:** La imagen es subdividida por regiones, en donde cada una de ellas tienen propiedades distintas que las diferencian unas de otras, además se utilizan propiedades espaciales de la imagen para segmentarla por regiones y se trata de extraer los objetos de una imagen, las que pueden ser procesadas de forma independiente [15].



Figura 12: Ejemplo de segmentación orientada a regiones

Fuente: [15]

3. **Segmentación por bordes:** Esta es una técnica muy común para detectar discontinuidades significativas en el nivel de gris, pues son más frecuentes en las aplicaciones prácticas [15].




Figura 13: Detección de bordes en escala de grises.

Fuente: [15]

4. **Segmentación semántica:** Este tipo de segmentación es un conjunto de técnicas que permiten asignar una etiqueta o categoría a cada píxel de una imagen, creando regiones dentro de la imagen y atribuyendo un significado semántico. Se basa en técnicas de aprendizaje automático, como las redes neuronales convolucionales, que son entrenadas para reconocer y clasificar los diferentes objetos presentes en una imagen [17] [18].



Figura 14: Imagen y píxeles etiquetados

Fuente: [17]

Este tipo de segmentación no diferencia entre instancias de objetos y se trata de asignar una etiqueta individual a cada píxel de una imagen digital. Como ejemplo, en lugar de tener capas agrupadas y conectadas, es como pasar una imagen a través de una serie de circunvoluciones y cada convolución con un paso de 1 y un relleno “mismo”, al realizar este proceso, cada convolución conserva las dimensiones espaciales de su entrada y de ese modo se puede apilar un grupo de circunvoluciones y tener un modelo de segmentación como se muestra en la Figura 15 [19].

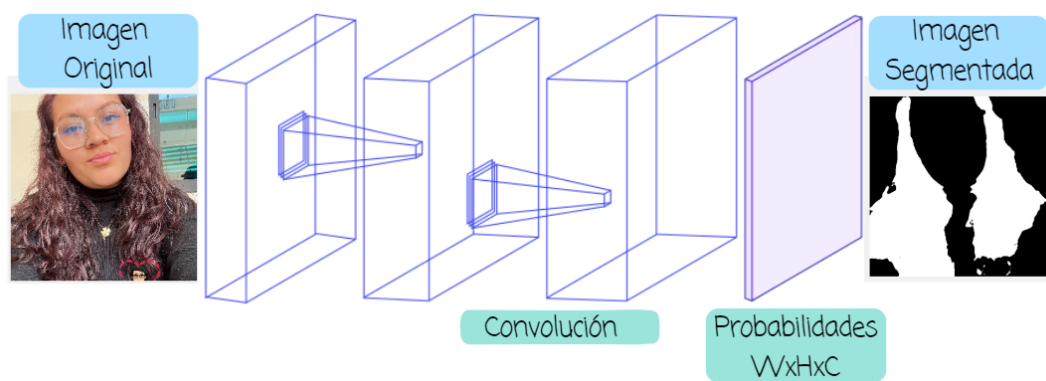


Figura 15: Red neuronal de convolución completa para tareas de predicción densas

Fuente: [19]

1.3.4. Inteligencia Artificial

1.3.4.1. Definición

La Inteligencia Artificial (IA) se enfoca en desarrollar la capacidad de las máquinas y sistemas informáticos para emular la inteligencia humana. Es un ámbito de estudio y desarrollo tecnológico que busca crear sistemas capaces de llevar a cabo tareas que normalmente requieren habilidades humanas, como el razonamiento, el aprendizaje, la percepción, el reconocimiento de voz, la toma de decisiones y el procesamiento del lenguaje natural [20].

La IA se fundamenta en algoritmos y modelos matemáticos complejos que permiten a las máquinas analizar grandes volúmenes de datos, identificar patrones y tomar decisiones o acciones basadas en esa información. La IA engloba diversas disciplinas, como el aprendizaje automático (machine learning), la visión por computadora, el procesamiento del lenguaje natural, la robótica y la inteligencia artificial general [21].

1.3.4.2. Inteligencia Artificial, Machine Learning y Deep Learning

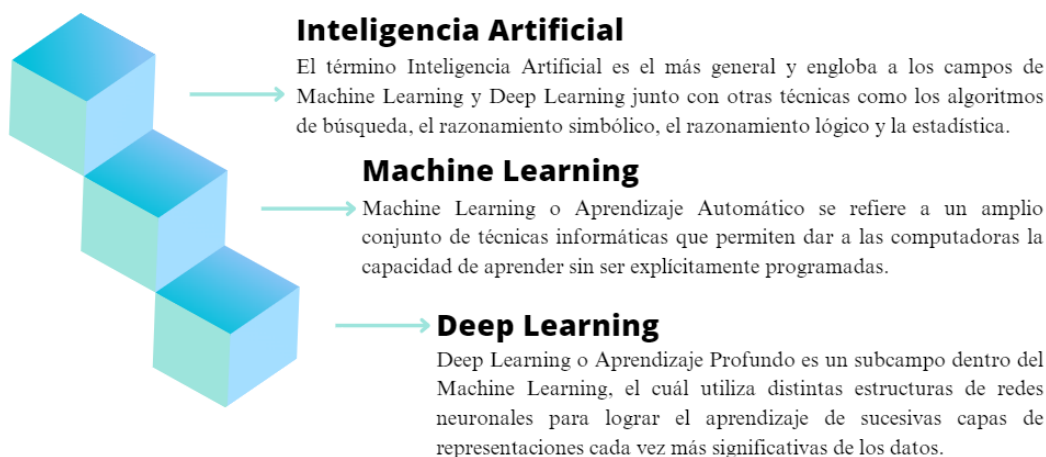


Figura 16: Inteligencia Artificial, Machine Learning y Deep Learning

Elaborado por: El investigador basado en [20]

1.3.4.3. Algoritmos y técnicas

Machine Learning

Técnicas de machine learning:

- **Aprendizaje supervisado:** Se entrena un modelo utilizando datos de entrada y salida conocidos para predecir salidas futuras. Algunos algoritmos populares son la regresión lineal, los árboles de decisión y las máquinas de vectores de soporte.
- **Aprendizaje no supervisado:** Se busca identificar patrones ocultos o estructuras intrínsecas en los datos de entrada sin utilizar datos de salida conocidos. Algunos algoritmos comunes son el clustering, la reducción de dimensionalidad y las reglas de asociación.
- **Aprendizaje por refuerzo:** El modelo aprende a través de la interacción con un entorno y recibe recompensas o castigos según sus acciones. Algunos algoritmos populares son Q-Learning y Deep Q-Networks [22] [23].

Algoritmos de machine learning:

- **Regresión lineal:** Se utiliza para predecir una variable continua basada en variables de entrada. Busca encontrar la mejor línea de ajuste que minimice el error cuadrático medio.
- **Árboles de decisión:** Se construye un árbol de decisiones basado en características de los datos para realizar predicciones o clasificaciones.
- **Máquinas de vectores de soporte (SVM):** Se utiliza para clasificar datos en diferentes categorías mediante la búsqueda de un hiperplano óptimo que separe los datos.
- **K-means:** Es un algoritmo de clustering que agrupa los datos en k grupos basados en su similitud.
- **Redes neuronales:** Son modelos inspirados en el funcionamiento del cerebro humano que utilizan capas de neuronas artificiales para procesar información y realizar predicciones.
- **Algoritmos genéticos:** Se basan en principios de la evolución biológica para encontrar soluciones óptimas a problemas complejos [24] [25].

Deep Learning

Técnicas de Deep Learning:

- **Redes Neuronales Artificiales:** Las redes neuronales artificiales son modelos inspirados en el funcionamiento del cerebro humano. Están compuestas por capas de neuronas interconectadas que procesan la información y aprenden a través del ajuste de los pesos de las conexiones. Son ampliamente utilizadas en aplicaciones de reconocimiento de imágenes, procesamiento de lenguaje natural y muchas otras áreas.
- **Redes Neuronales Convolucionales (CNN):** Las redes neuronales convolucionales son un tipo especializado de redes neuronales diseñadas para procesar datos con estructura de cuadrícula, como imágenes. Utilizan capas convolucionales para extraer características y capas de pooling para reducir la

dimensionalidad. Las CNN han demostrado un rendimiento sobresaliente en tareas de clasificación de imágenes.

- **Redes Neuronales Recurrentes (RNN):** Las redes neuronales recurrentes son adecuadas para el procesamiento de secuencias y datos con dependencias temporales. Tienen conexiones recurrentes que les permiten mantener información a lo largo del tiempo. Las RNN son ampliamente utilizadas en tareas de procesamiento de lenguaje natural, traducción automática y generación de texto.
- **Redes Generativas Adversariales (GAN):** Las redes generativas adversariales son un tipo de arquitectura de redes neuronales que consiste en dos modelos: un generador y un discriminador. El generador crea muestras sintéticas que intentan engañar al discriminador, que a su vez trata de distinguir entre las muestras reales y las sintéticas. Las GAN se utilizan para generar imágenes, videos y otros tipos de datos sintéticos [26].

Algoritmos de Deep Learning:

- **Backpropagation:** Es un algoritmo utilizado para entrenar redes neuronales mediante la retropropagación del error. Calcula las derivadas parciales del error con respecto a los pesos de las conexiones y ajusta los pesos en función de estas derivadas para minimizar el error.
- **Gradiente Descendente:** Es un algoritmo de optimización utilizado para ajustar los pesos de una red neuronal con el objetivo de minimizar una función de pérdida. Calcula el gradiente de la función de pérdida con respecto a los pesos y actualiza los pesos en la dirección opuesta al gradiente para encontrar el mínimo global.
- **Adam:** Es un algoritmo de optimización popular utilizado en el entrenamiento de redes neuronales. Combina las ventajas del método de gradiente descendente estocástico y el método de momento. Adam ajusta los pesos de manera adaptativa y eficiente, lo que lo hace especialmente efectivo en problemas de aprendizaje profundo [27].

1.3.4.4. Frameworks para aplicaciones con inteligencia artificial

Existen varios frameworks que son utilizados para el desarrollo de aplicaciones como se puede apreciar en la Tabla 1.

Tabla 1: Frameworks para desarrollo de aplicaciones con inteligencia artificial

Deep Learning Framework	Año de Lanzamiento	Idioma	Modelos preentrenados
TensorFlow	2015	C++, Python	Si
Keras	2015	Python	Si
PyTorch	2016	Python, C	Si
Caffe	2013	C++	Si
Deeplearning4j	2014	C++, Java	Si

Elaborado por: El investigador basado en [28]

1.3.4.5. Machine Learning

Definición

Machine learning es una rama de la inteligencia artificial que se enfoca en instruir a las computadoras a ilustrarse de los datos y mejorar con la experiencia, en lugar de ser programadas explícitamente para hacerlo. Los algoritmos de machine learning se entrenan para encontrar patrones y correlaciones en grandes conjuntos de datos, tomar decisiones y hacer predicciones basadas en ese análisis. Las aplicaciones de machine learning mejoran con el uso y se vuelven más precisas a medida que tienen acceso a más datos.

La estructura machine learning de la Figura 17 consta de cuatro etapas principales: selección y preparación de datos de entrenamiento, entrenamiento del modelo, evaluación y ajuste del modelo, y uso del modelo para hacer predicciones [23].




Figura 17: Estructura Machine Learning

Fuente: [23]

Aprendizaje supervisado

Se refiere cuando los datos usados para el entrenamiento incluyen una solución deseada que se llama etiqueta [29].

- La precisión en la estructuración de los modelos de aprendizaje supervisado puede depender del nivel de experiencia requerido durante su formación.
- Esta tarea puede ser bastante tiempo consumidora. Además, los conjuntos de datos están sujetos a una mayor probabilidad de error humano, lo que puede llevar a que los algoritmos aprendan de manera incorrecta.
- A diferencia de los modelos de aprendizaje no supervisado, el aprendizaje supervisado carece de la capacidad de agrupar o clasificar datos de forma autónoma [30].

El procesamiento de imágenes es una parte esencial del aprendizaje supervisado de machine learning cuando se trabaja con datos de imágenes. Permite preparar, limpiar y transformar los datos de imágenes para que los algoritmos de aprendizaje puedan comprenderlos y aprender a realizar predicciones precisas en tareas como clasificación, detección de objetos, reconocimiento facial, entre otras [29].

Lenguajes de Programación orientados a Machine Learning

Existen varios lenguajes de programación de acuerdo a las necesidades específicas del proyecto, en este caso se utilizan las mencionadas en la Tabla 2.

Tabla 2: Lenguajes de programación orientados a Machine Learning

Lenguaje de programación	Descripción	Ventajas	Desventajas
Python	Es un lenguaje de alto nivel y puede ejecutarse en tipos diferentes de computadores sin modificación alguna o con pocas modificaciones.	Amplia variedad de bibliotecas y frameworks de ML.	Rendimiento inferior a lenguajes compilados.
Java	Es un lenguaje muy valorado ya que se puede ejecutar en diversas plataformas con varios sistemas operativos.	Buena escalabilidad y rendimiento.	Curva de aprendizaje más pronunciada.
C++	Un programa en C++ suele estar escrito en diferentes ficheros y durante el proceso estos se combinan y traducen a código objeto.	Rendimiento de ejecución rápido	Mayor complejidad de codificación.
Matlab	Es una herramienta sofisticada de computación para resolver problemas matemáticos, se pueden pensar que estos programas son sofisticadas	Amplia gama de herramientas de ML y análisis numérico.	Licencia de software propietario.

computadoras con base
en una computadora.

Elaborado por: El investigador basado en [28-32]

Tipos de bases de datos utilizadas en Machine Learning

Existen diferentes tipos y de ellos derivan varias opciones que son muy comunes en el entorno de Machine Learning como presenta la Tabla 3.

Tabla 3: Tipos de bases de datos utilizadas en Machine Learning

Bases de datos	Funcionalidad	Ejemplos
Relacionales	Están basadas en el modelo relacional y utilizan tablas para almacenar y organizar los datos. Son adecuadas para almacenar datos estructurados y ofrecen consultas eficientes y soporte para transacciones.	MySQL PostgreSQL Oracle
NoSQL	Están diseñadas para manejar grandes volúmenes de datos no estructurados o semiestructurados. Permiten almacenar y recuperar datos flexibles y escalables.	MongoDB Cassandra Redis
En memoria	Almacenan los datos en la memoria principal en lugar de en discos, lo que permite acceso rápido y mayor eficiencia en lectura y escritura de datos. Son útiles cuando se requiere un acceso ultrarrápido a los datos, como en aplicaciones de tiempo real o procesamiento de grandes volúmenes de datos.	Redis Memcached Apache Ignite
Distribuidas	Se utilizan cuando los datos deben ser almacenados y procesados en múltiples servidores. Son útiles cuando se necesita	Apache Hadoop Apache Cassandra Google Bigtable

almacenar y procesar grandes conjuntos de datos de manera escalable y tolerante a los fallos.

Elaborado por: El investigador basado en [33-35]

1.3.4.6. Deep Learning

El Deep Learning utiliza una especie de "cerebro artificial" compuesto por muchas capas que se van construyendo una encima de la otra. Cada capa aprende algo más complicado a partir de lo que le enseñó la capa anterior, como si fuese una cadena de mensajes donde cada capa toma algo sencillo y lo combina para crear algo un poco más complicado, y así sucesivamente hasta que la red neuronal puede entender cosas muy complejas. A medida que se le muestra más información, la red va aprendiendo y mejorando su capacidad para entender nuevos datos. [20]

Redes Neuronales Convolucionales o CNN

Este tipo de redes son muy similares a las redes neuronales ordinarias como el perceptrón multicapa, se componen de varias neuronas con pesos y sesgos que pueden aprender, como se presenta en la Figura 18. Cada neurona recibe entradas, realiza un producto escalar y aplicar una función de activación y también se va a tener una función de pérdida la cual estará totalmente conectada. La diferencia con las demás redes es que suponen explícitamente que las entradas son imágenes, lo que permite codificar ciertas propiedades en la arquitectura para ganar en eficiencia y reducir los parámetros en la red [20].

Una de las aplicaciones más importantes de las redes neuronales convolucionales en el procesamiento de imágenes es la identificación de objetos [38]. Incluso se usan en el reconocimiento y clasificación de imágenes con la finalidad de reconstruir una imagen para encontrar un rasgo diferente al utilizar un algoritmo de Machine Learning supervisado [39].

Son construidas con una estructura de tres tipos distintos de capas:

1. **Capa convolucional:** Asigna el nombre a la red.
2. **Capa de reducción:** Reduce la cantidad de parámetros para tener las características más comunes.
3. **Capa clasificadora totalmente conectada:** Genera el resultado final de la red.

Algunas implementaciones específicas sobre el tipo de redes son: inception v3, ResNet, VGG16 y xception, entre otras [20].

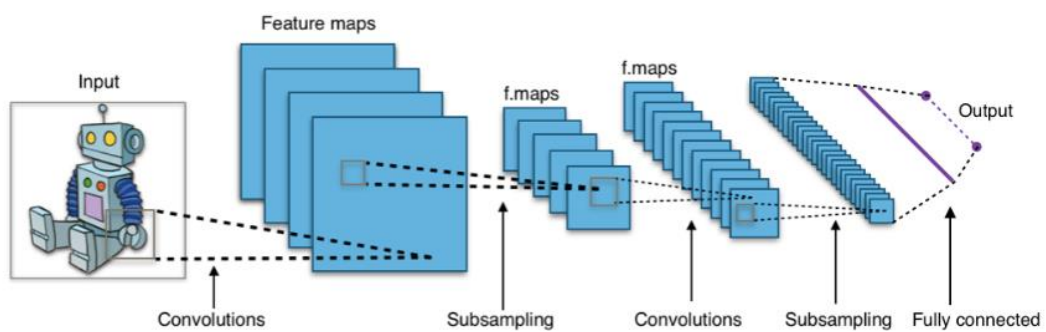


Figura 18: Estructura de redes neuronales convolucionales

Fuente: [20]

Clasificación de las Redes Neuronales Convolucionales

Las redes neuronales convolucionales se utilizan principalmente para tareas de procesamiento de imágenes y señales de audio. En general, se pueden encontrar diferentes redes neuronales convolucionales, de los cuales se describen en la Tabla 4.

Tabla 4: Clasificación de las redes neuronales convolucionales

Red Neuronal	Descripción
AlexNet	Es una arquitectura pionera en el aprendizaje profundo, desarrollada en 2012, que incluye capas convolucionales y completamente conectadas, lo que impulsó avances significativos en el campo y estableció las bases para desarrollos posteriores en redes neuronales convolucionales.

VGGNet	Es conocida por su simplicidad y profundidad, utilizando convoluciones pequeñas en varias capas para obtener un alto rendimiento en clasificación de imágenes. Su arquitectura uniforme y profunda ha demostrado resultados destacados en desafíos de visión por computadora.
GoogleNet	Es una arquitectura de red neuronal convolucional que utiliza módulos de convoluciones de diferentes tamaños para extraer características en paralelo. Es eficiente y se utiliza en tareas de clasificación de imágenes y detección de objetos.
ResNet	Es una red neuronal profunda que utiliza conexiones residuales para facilitar el entrenamiento de redes muy profundas. Es ampliamente utilizado en tareas de visión por computadora y reconocimiento de imágenes.
SE-Net	Es una arquitectura de red neuronal convolucional que utiliza el módulo "Squeeze-and-Excitation" para adaptar la importancia de cada canal de características. Esto mejora la capacidad de atención y representación de la información en la red, lo que ha demostrado obtener mejoras significativas en el rendimiento en tareas de visión por computadora.

Elaborado por: El investigador basado en [40]

DeepLabv3

Además de utilizar Atrous Convolution, utiliza un módulo ASPP mejorado al insertar características de nivel de imagen y normalización por lotes. [41]




Figura 19: Arquitectura DeepLabv3

Fuente: [41]

La arquitectura del modelo DeepLabv3 de la Figura 19 se resume en:

1. **Red Troncal:** El inicio de la red puede ser una red troncal, VGG, DenseNet o ResNet.
2. **Convoluciones Atrous:** O convoluciones dilatadas y DeepLabv3 las utiliza para refinar el campo de visión efectivo de la convolución.
3. **Atrous Spatial Pyramid Pooling (ASPP):** Es un módulo utilizado en DeepLabv3 para considerar objetos a diferentes escalas y capturar el contexto multiescala, además incorpora características a nivel de imagen para codificar el contexto global y mejorar en mayor nivel el rendimiento.
4. **Módulo decodificador (DeepLabv3+):** DeepLabv3+ es una extensión de DeepLabv3 que se encarga de añadir un módulo decodificador para refinar los resultados de la segmentación, especialmente a lo largo de los límites de los objetos. El módulo decodificador mejora los resultados de segmentación incorporando bloques intermedios de escalado, concatenación y procesamiento.
5. **Extracción de características y mapa de características de alta resolución:** El modelo extrae características de la imagen de entrada utilizando la red troncal y genera un mapa de características de alta resolución. Este mapa es crucial para preservar la información global en tareas de segmentación de imágenes biométricas [39-41].

La arquitectura del modelo DeepLabv3 ha ido mejorando continuamente con el tiempo para hacer frente a los retos de la segmentación semántica, como la captura de información a diferentes escalas y la preservación del contexto global, aprovechando las convoluciones atróficas y ASPP, tal y como presenta la Figura 20.

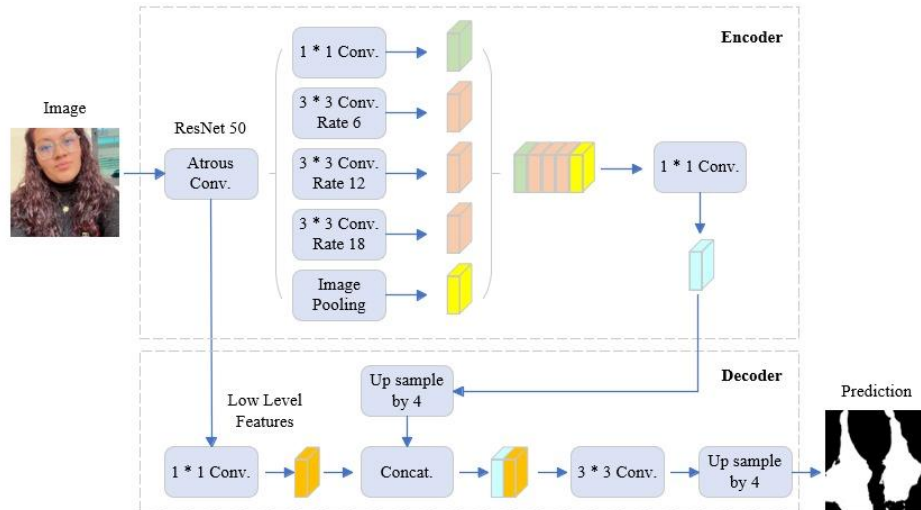


Figura 20: Arquitectura DeepLabv3+

Elaborado por: El investigador basado en [44]

Métricas de calidad para evaluar del modelo DeepLabv3

Las métricas aplicadas para evaluar la calidad del modelo son: dice_coef, iou, loss, lr, precision, recall y tienen las siguientes especificaciones:

- **Mejora progresiva:** El modelo mejora sus métricas (Dice Coeficiente, IoU, precisión y recall) con cada "epoch", demostrando un aprendizaje efectivo en la segmentación de cabello en las imágenes.
- **Alta precisión y recall:** El modelo tiene altas métricas de precisión y recall en el conjunto de validación, lo que indica una capacidad precisa para identificar el cabello en las imágenes y minimizar falsos positivos y falsos negativos.
- **Convergencia:** El valor del Loss disminuye con las "epochs", indicando que el modelo converge hacia una mejor solución y ajusta parámetros para reducir discrepancias entre predicciones y etiquetas reales.
- **Buena generalización:** El modelo parece generalizar bien a datos no vistos, ya que las métricas en el conjunto de validación (val_dice_coef, val_iou, val_precision y val_recall) también son altas y mejoran con el entrenamiento.
- **Tasa de aprendizaje adecuada:** El valor de la tasa de aprendizaje (lr) se mantiene constante durante el entrenamiento, lo que puede indicar que se encontró una tasa de aprendizaje adecuada para este modelo y conjunto de datos.

- **Riesgo de sobreajuste:** En algunos casos, las métricas en el conjunto de validación pueden ser ligeramente inferiores al conjunto de entrenamiento, lo que sugiere un riesgo de sobreajuste. Es recomendable considerar técnicas como la regularización para mitigar este problema y mejorar la generalización del modelo a nuevos datos [45-47].

Cada "epoch" representa una iteración de entrenamiento en la que el modelo ajusta sus parámetros para mejorar su rendimiento en la segmentación de cabello. Las métricas proporcionadas son valores numéricos que evalúan la precisión, similitud y rendimiento general del modelo en la segmentación de cabello en imágenes. Estas métricas son fundamentales para evaluar y mejorar la efectividad del algoritmo DeepLabV3.

1.1.1. Aplicación Web

Una aplicación web es un software que se ejecuta en un navegador web y se utiliza a través de una conexión a Internet. Las aplicaciones web se pueden acceder desde cualquier dispositivo con conexión a Internet y un navegador web, y no requieren instalación en el dispositivo del usuario. Las aplicaciones web son utilizadas en una amplia variedad de industrias y aplicaciones, desde aplicaciones empresariales y herramientas de productividad hasta juegos y aplicaciones de entretenimiento. Las aplicaciones web pueden ser desarrolladas en diferentes lenguajes de programación, como JavaScript, HTML y CSS, y pueden incluir tecnologías como bases de datos en línea, servicios web y aplicaciones de programación de interfaces (API) [48].

1.3.5. Arquitectura de una Aplicación Web

La arquitectura de una aplicación web puede variar dependiendo del tipo de aplicación y las tecnologías utilizadas, pero en general suele incluir los siguientes componentes, tal y como se visualiza en la Figura 21:

- **Front-end:** Es donde el usuario ve e interactúa, conocida como interfaz de usuario (UI). Esta aplicación escrita en lenguajes de marcado como HTML, estilos como CSS y programación en JavaScript, se ejecuta en el navegador web del usuario.

- **Back-end:** Es la que se encarga de procesar las solicitudes del usuario y gestionar la lógica de negocio. Se ejecuta en el servidor y puede estar escrita en lenguajes como PHP, Python, Ruby o JavaScript, utilizando frameworks y librerías para facilitar el desarrollo [49].
- **Base de datos:** Es el lugar donde se almacenan los datos, como información de usuarios, registros de actividad o cualquier otro tipo de información relevante. La base de datos se conecta con el back-end y puede estar diseñada con diferentes tecnologías, como MySQL, PostgreSQL o MongoDB.
- **Servicios web:** Son los servicios que proporciona para interactuar con otras aplicaciones o servicios externos, como APIs de redes sociales, servicios de pago, entre otros.

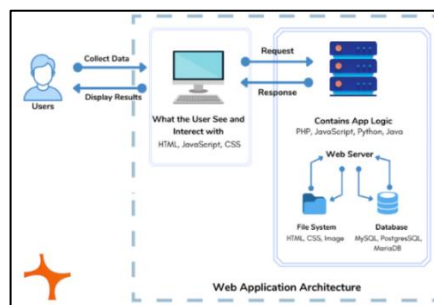


Figura 21 Arquitectura de una aplicación Web

Fuente: [50]

1.4. Objetivos

1.4.1. Objetivo General

Desarrollar el renderizado de coloración capilar utilizando inteligencia artificial.

1.4.2. Objetivos Específicos

- Analizar técnicas de inteligencia artificial aplicadas al renderizado de coloración capilar.
- Aplicar un algoritmo de inteligencia artificial para la colorimetría capilar.
- Diseñar una aplicación para el renderizado de coloración capilar.

CAPÍTULO II

METODOLOGÍA

2.1. Materiales

En el presente proyecto se desarrolló una aplicación para el renderizado de coloración capilar, basándose en el lenguaje de programación Python dentro del entorno de desarrollo Visual Studio Code. La interfaz gráfica del sistema es creada con PyQt5, el ingreso de datos se carga en una base de datos MySQL. Para predicción de color de cabello se aplica el algoritmo SVM (Máquinas de Vectores Soporte), además el modelo DeepLabv3 segmenta el cabello para la creación de la máscara en la imagen cargada, el entrenamiento del modelo utiliza una base de datos de internet con 1050 imágenes y 1050 máscaras denominada “mask_rcnn_hair_0200.h5”. El renderizado de coloración capilar utiliza el modelo RGB para la asignación personalizada del color de cabello.

2.2. Métodos

2.2.1. Modalidad de investigación

El presente proyecto utilizó la investigación aplicada, empleando los conocimientos teórico-prácticos adquiridos dentro de la carrera universitaria que aportaron a la solución del problema establecido.

Se utilizó investigación bibliográfica, debido a que se realizó una búsqueda de documentos, revistas, artículos, otros, que aportaron con el método para el desarrollo y análisis del proceso de renderizado de coloración capilar utilizando inteligencia artificial.

2.2.2. Recolección de información

Para la obtención de los datos e información necesaria se ingresó a los repositorios de universidades, publicaciones de revistas, libros, artículos que aportaron directamente al desarrollo de la investigación. En el entorno técnico se utilizaron guías prácticas, cursos online, manuales, foros, bases de datos técnicas e información de encuestas.

2.2.3. Procesamiento y análisis de datos

Para el análisis de datos de la investigación fue necesario tomar en cuenta las siguientes situaciones:

- Análisis del contenido que aporta a la investigación.
- Reconocimiento del renderizado de coloración capilar en tiempo real.
- Estudio de las alternativas para el desarrollo del algoritmo de inteligencia artificial.
- Selección de condiciones para el diseño de la aplicación.
- Diseño de la aplicación.

2.2.4. Desarrollo del Proyecto

Para cumplir con los objetivos propuestos en el desarrollo del renderizado de coloración capilar en tiempo real utilizando inteligencia artificial, se desarrollaron las siguientes actividades:

1. Análisis de las técnicas de IA actuales para renderizado de coloración capilar.
2. Selección de las técnicas para renderizado de coloración capilar.
3. Identificación del procesamiento de imágenes en la colorimetría capilar.
4. Establecimiento del algoritmo de IA en el proceso de colorimetría.
5. Selección de condiciones de diseño para la aplicación del renderizado de coloración capilar.
6. Diseño de la interfaz gráfica para que el usuario se pruebe el renderizado mediante los filtros de color.
7. Pruebas de funcionamiento de la aplicación de renderizado de coloración capilar.
8. Evaluación del proceso de coloración capilar mediante un test de validación.
9. Elaboración del informe final.

CAPÍTULO III

RESULTADOS Y DISCUSIÓN

3.1. Análisis y discusión de los resultados

El renderizado de coloración capilar implica la recolección de tres aspectos específicos del usuario como: color de piel, ojos y cabello para predecir un posible cambio de color de cabello a considerar que mejore su apariencia. La representación de quince colores de cabello en tendencia para el año 2023, de los cuales uno es escogido por el algoritmo de inteligencia artificial SVM Support Vector Machine, el mismo que permite la toma de decisiones al ofrecer resultados al instante garantizando la satisfacción del cliente.

3.2. Desarrollo de la propuesta

Para el desarrollo de la propuesta se utilizó como fuente de información varios artículos científicos que especifican la investigación del renderizado de coloración capilar, tesis de referencia en el procesamiento digital de imágenes, libros sobre colorimetría capilar, encuestas para lograr la automatización en la industria de la moda y la belleza, tomando en cuenta que no existen ideas innovadoras que sustituyan estos procesos utilizando la inteligencia artificial.

3.2.1. Consideraciones para el desarrollo del proyecto

Al desarrollar una aplicación sobre el renderizado de coloración capilar es necesario establecer criterios de diseño generales que sean base fundamental como:

- Investigar a fondo sobre la coloración capilar y las técnicas de renderizado más recientes. Esto ayudará a comprender mejor cómo lograr resultados realistas.
- Elegir las tecnologías adecuadas para su desarrollo.
- Recopilar una amplia variedad de imágenes de cabello para entrenar y probar el modelo de renderizado.
- Es fundamental validar y evaluar el modelo utilizando diferentes métricas para garantizar su precisión y rendimiento.

- Crear una interfaz de usuario amigable intuitiva y fácil de usar. La aplicación debe permitir a los usuarios cargar imágenes, visualizar colores deseados y resultados de la coloración capilar.
- Optimizar el rendimiento de la aplicación para que funcione de manera rápida y eficiente, esto implica optimizar el código.

Además, es primordial tener en cuenta las características de la computadora y la cámara que van a ser utilizadas en el proyecto tal y como muestra la Tabla 5.

Tabla 5: Requisitos mínimos y recomendados de los dispositivos.

REQUISITOS MINIMOS PC	REQUISITOS RECOMENDADOS PC
Sistema Operativo: Windows, MacOS, Linux	Sistema Operativo: Windows 10, MacOS 10.13 o superior.
Procesador: Intel Core i5 o AMD Ryzen 5.	Procesador: Intel Core i7 o AMD Ryzen 7.
Memoria RAM: 8GB	Memoria RAM: 16GB o superior.
Tarjeta gráfica: 2GB de memoria de video, Nvidia GTX 1050 o AMD Radeon RX 560.	Tarjeta gráfica: Nvidia GeForce GTX 1060 o superior.
Almacenamiento: 500GB libre en disco duro.	Almacenamiento: SSD de 512 GB o superior.
REQUISITOS MINIMOS CÁMARA	REQUISITOS RECOMENDADOS CÁMARA
Velocidad: Adecuada para capturar imágenes nítidas y sin desenfoque, adecuada para el procesamiento de renderizado.	Sensor: Imagen de alta calidad
Resolución mínima: 640x480 píxeles	Resolución recomendada: 1920 x 1080 píxeles o superior.
Dependen: En gran medida de la resolución de las imágenes en la base de datos y de la calidad de imagen deseada.	Lente: Con enfoque automático

Elaborado por: El investigador

3.2.2. Arquitectura general del sistema

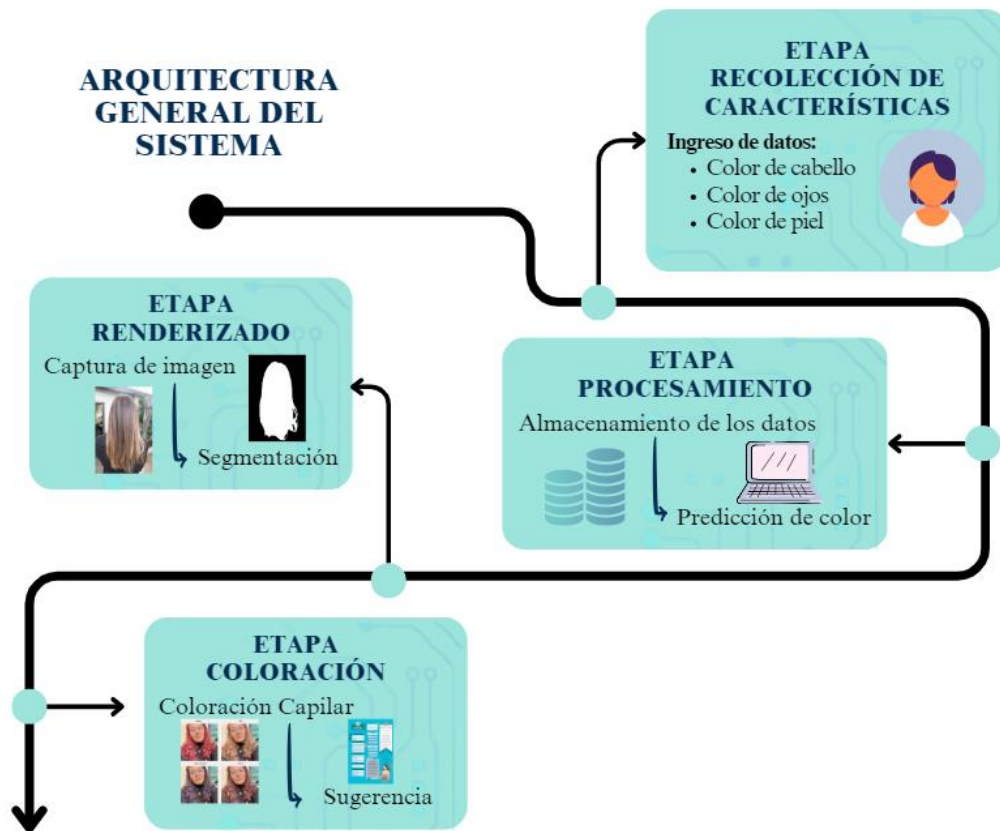


Figura 22: Arquitectura general del sistema

Elaborado por: El investigador

El sistema especificado en la Figura 22 se compone de cuatro etapas:

- **Recolección de características:** La información se recopila dentro de una interfaz gráfica desarrollada en Python, por medio de opciones desplegables relacionadas con las características físicas del usuario tales como: color de cabello, color de ojos y color de piel.
- **Procesamiento:** Las características físicas del usuario son almacenadas en una base de datos, las mismas que son utilizadas para el procesamiento mediante el algoritmo de inteligencia artificial que utiliza Machine Learning para el aprendizaje supervisado aplicando un algoritmo de máquina de vectores de soporte SVM en la predicción de color, el mismo que resuelve el proceso de colorimetría capilar que no es nada más que la recomendación de color más adecuada a la apariencia física del usuario.

- **Renderizado:** El renderizado de coloración capilar incluye una fotografía del usuario y su adquisición se realiza de dos formas posibles: carga una imagen o captura en tiempo real. Se emplea la técnica Deep Learning por medio de redes neuronales convolucionales, haciendo referencia específicamente al modelo DeepLabv3, el mismo que ejecuta el proceso de segmentación de cabello.
- **Coloración:** Este proceso acondiciona los resultados de la respuesta del algoritmo de colorimetría capilar y del modelo DeepLabv3 para mostrar el resultado de coloración del cabello mediante el modelo de color RGB, realizando un ajuste de transparencia para que visualización del color sea lo más realista posible.

3.2.3. Etapa recolección de características

El lenguaje de programación que se ha escogido es Python y se puede observar sus especificaciones dentro de la Tabla 2 (Capítulo I). El motivo principal para escoger el lenguaje de programación Python se debe a dos factores importantes como: es más simple que el lenguaje C++ y también soporta Tensorflow y keras, aparte de soportar la mayoría de frameworks mencionados en la Tabla 1 (Capítulo I).

Para el presente proyecto de investigación se utilizarán modelos que se encuentran implementados en Tensorflow y Keras con el lenguaje Python. Tensorflow es una librería de código abierto que está diseñada para el desarrollo de Machine Learning y Keras es una librería que actúa como si fuese una capa de abstracción entre el usuario y el Back-end que se está ejecutando sobre Tensorflow. [28]

Dentro del código fuente desarrollado en Python se va a especificar varios aspectos, a tener en cuenta como:

- La interfaz gráfica se realiza mediante PyQt5, esta biblioteca de Python permite la creación de aplicaciones más interactivas y atractivas. Su framework es Qt y se conoce principalmente por su uso en el desarrollo de interfaces gráficas que complementa las bibliotecas y frameworks de Machine Learning.

- Para el ingreso de datos como: Color de piel, Color de ojos y Color de cabello se utiliza “QComboBox”, que representa una lista desplegable con las opciones mencionadas dentro de la Tabla 6 (Capítulo III) y el usuario debe seleccionar según su apariencia física.

3.2.4. Etapa procesamiento

Después de ingresar las características del usuario, estos datos son almacenados dentro de una base de datos MySQL, esta es seleccionada debido a las numerosas características y beneficios que proporciona:

1. **Escalabilidad:** Es conocido por que maneja grandes volúmenes de datos y soportar aplicaciones de alto rendimiento.
2. **Rendimiento:** Está optimizado para ofrecer un rendimiento rápido y eficiente en la recuperación y manipulación de datos.
3. **Seguridad:** Tiene amplia gama de características como: autenticación de usuarios, cifrado de datos, permisos, asignar roles de acceso para protección de los datos.
4. **Flexibilidad:** Tiene compatibilidad con varias plataformas y sistemas operativos, lo que facilita la integración con otros componentes del sistema.
5. **Comunidad y Soporte:** Es ampliamente adoptada a una gran comunidad de usuarios y desarrolladores [51].

3.2.4.1. Creación de la base de datos

Para la creación de la base de datos, se escoge phpMyAdmin como herramienta de administración de bases de datos MySQL en la web, pues proporciona una interfaz gráfica de usuario que permite administrar y manipular las bases de datos MySQL de forma fácil sin la necesidad de escribir comandos manualmente.

Pasos para crear una base de datos con phpMyAdmin

- Paso 1:** Abrir phpMyAdmin en el navegador web. Acceder a phpMyAdmin escribiendo la URL "localhost/phpmyadmin" en el navegador, o abriendo mediante Xamp.
- Paso 2:** Inicia sesión en phpMyAdmin con las credenciales del servidor MySQL.
- Paso 3:** En la página principal de phpMyAdmin, se observa una lista de las bases de datos existentes en el panel lateral izquierdo. Si se desea crear una nueva base de datos, hacer clic en el botón "Nueva" en la parte superior izquierda de la pantalla.
- Paso 4:** Aparecerá un formulario de creación de base de datos. Ingresar un nombre para la nueva base de datos en el campo "Nombre de la base de datos".
- Paso 5:** A continuación, seleccionar el juego de caracteres y la configuración de clasificación para la base de datos. Se puede dejar las opciones predeterminadas o ajustarlas según las necesidades.
- Paso 6:** Hacer clic en el botón "Crear" para crear la base de datos. phpMyAdmin genera la consulta SQL correspondiente para crear la base de datos.
- Paso 7:** Una vez creada la base de datos, se muestra un mensaje de confirmación observando una lista del panel lateral izquierdo [52].

Creación de tablas en la base de datos

Se crea una base de datos llamada "cabello" y se procede a crear una tabla llamada "datos" con siete columnas: "id", "nombre", "fecha", "color_pelo", "color_piel", "color_ojos" y "recomendación".

- **Columna "id":** Esta columna se designa para contener un identificador único o código único asociado a cada registro en la tabla. Proporciona una forma única de identificar y distinguir cada entrada en la base de datos.
- **Columna "nombre":** La columna "nombre" se reserva para almacenar el nombre o identificación de la persona o entidad a la que corresponde la entrada de datos.

- **Columna "fecha":** La columna "fecha" se emplea para registrar la fecha en que se recopilaron los datos relacionados con el color de cabello, piel y ojos.
- **Columna "color_pelo":** En esta columna se consigna información acerca del color del cabello de la persona en cuestión.
- **Columna "color_piel":** La columna "color_piel" se utiliza para documentar el tono o matiz de la piel de la persona.
- **Columna "color_ojos":** Aquí se registran los datos relativos al color de los ojos de la persona.
- **Columna "recomendación":** La última columna, denominada "recomendación", desempeña un papel esencial en el proceso. Esta columna es donde se almacena la salida generada por el algoritmo de colorimetría capilar, que es responsable de predecir y determinar la recomendación de color capilar adecuada.

La secuencia de acciones descrita anteriormente se encuentra detallada y representada en la Figura 23, lo cual proporciona una representación visual de la estructura de datos esenciales en este proceso.

	id	nombre	fecha	color_pelo	color_piel	color_ojos	recomendacion
<input type="checkbox"/>	36	Joha	2023-06-28 22:50:40	Rubio - Castaño claro	Blanca	Azules - Grises	rubio cenizo
<input type="checkbox"/>	37	joha	2023-07-10 11:45:43	Rubio - Castaño claro	Blanca	Azules - Grises	rubio cenizo
<input type="checkbox"/>	38	Vini	2023-07-10 11:51:55	Negro	Media	Marrones - Negros	chocolate
<input type="checkbox"/>	39	Liss	2023-07-11 08:52:13	Rubio - Castaño claro	Blanca	Marrones - Negros	borgoña
<input type="checkbox"/>	40	Edd	2023-07-11 08:55:16	Castaño	Blanca	Marrones - Negros	rojizo
<input type="checkbox"/>	41	Juan	2023-07-11 08:58:42	Negro	Media	Marrones - Negros	chocolate
<input type="checkbox"/>	42	Monse	2023-07-11 09:00:56	Negro	Media	Marrones - Negros	chocolate
<input type="checkbox"/>	43	May	2023-07-11 09:04:22	Negro	Media	Marrones - Negros	chocolate
<input type="checkbox"/>	44	Roberto	2023-07-11 15:05:02	Negro	Media	Marrones - Negros	chocolate
<input type="checkbox"/>	45	Roberto	2023-07-11 15:05:21	Negro	Morena	Marrones - Negros	marron
<input type="checkbox"/>	46	Roberto	2023-07-11 15:05:57	Negro	Media	Marrones - Negros	chocolate
<input type="checkbox"/>	47	Joha	2023-07-12 07:48:00	Rubio - Castaño claro	Blanca	Marrones - Negros	borgoña
<input type="checkbox"/>	48		2023-07-12 16:25:36	Rubio - Castaño claro	Blanca	Azules - Grises	rubio cenizo
<input type="checkbox"/>	49	Diego	2023-07-18 03:54:58	Negro	Blanca	Marrones - Negros	negro azulado

Figura 23: Base de datos MySQL con phpMyAdmin

Elaborado por: El investigador

Conexión con la base de datos desde Python

Para conectarse a la base de datos se utiliza el módulo de conexión “[mysql.connector](#)” y se asignan los valores adecuados dentro de host, user, password y database, según se observa en la Figura 24.

```
# Conexión a la base de datos
conexion = mysql.connector.connect(
    host="localhost",
    user="root",
    password="",
    database="cabello"
)
```

Figura 24: Conexión con la base de datos

Elaborado por: El investigador

3.2.4.2. Selección del algoritmo de Machine Learning

Acondicionamiento de la Base de Datos

Adecuación del dataset

En un principio se desarrolla la Tabla 6, la misma que especifica cuales son las diferentes opciones para ingresar los datos de color de piel, color de cabello y color de ojos.

Tabla 6: Opciones para datos de ingreso.

	COLOR DE PIEL
0	piel blanca
1	piel media
2	piel morena
	COLOR OJOS
0	ojos azules-grises
1	ojos verdes
2	ojos marrones-negros
	COLOR CABELLO NATURAL
0	cabello rubio-castaño claro
1	cabello castaño
2	cabello negro

Elaborado por: El investigador

La Tabla 7 muestra cuales serían las posibilidades que podría ingresar el usuario para el entrenamiento del algoritmo y predicción de color. Para las combinaciones se crean 6 columnas, una de ellas llamada “tono” que normalmente se refiere a la apariencia de la piel, es decir se refiere a las características y matices de color presentes en la piel y se clasifican en “tono frío” y “tono cálido” y para saber qué color es mejor para la predicción se aplica estos conceptos más la colorimetría y estrella cromática mencionadas anteriormente en las Figuras 2 y 7.

Tabla 7 Datos para entrenamiento de predicción de color.

Nº	COLOR DE CABELLO	COLOR DE OJOS	COLOR DE PIEL	TONO	COLOR PERSONALIZADO
1	0	0	0	FRIO	rubio cenizo
2	0	0	0	FRIO	rubo platino
3	0	0	0	CALIDO	castaño oscuro
4	0	1	0	CALIDO	castaño claro
5	0	1	1	CALIDO	cobrizo
6	0	1	2	CALIDO	caramelo oscuro
7	0	2	0	CALIDO	borgoña
8	0	2	1	CALIDO	rojizo
9	0	2	2	CALIDO	caramelo
10	1	0	0	FRIO	rubio cenizo
11	1	0	1	CALIDO	borgoña
12	1	0	2	CALIDO	miel
13	1	1	0	CALIDO	rojizo
14	1	1	1	CALIDO	caramelo
15	1	1	2	CALIDO	chocolate
16	1	2	0	CALIDO	rojizo
17	1	2	1	CALIDO	azul
18	1	2	2	CALIDO	caramelo
19	2	0	0	FRIO	negro azulado
20	2	0	1	FRIO	negro
21	2	0	2	FRIO	negro azulado
22	2	1	0	FRIO	azul
23	2	1	1	CALIDO	castaño claro
24	2	1	2	CALIDO	rojizo
25	2	2	0	FRIO	negro azulado
26	2	2	1	CALIDO	chocolate
27	2	2	2	CALIDO	marrón

Elaborado por: El investigador

Acondicionamiento del dataframe

El acondicionamiento utiliza la librería “pandas” y la herramienta “pandas.read” que lee y transforma a dataframe el archivo con extensión “.csv”. [53]

Construcción del algoritmo

Se escoge siete algoritmos de Machine Learning para probar la eficiencia de cada uno de ellos, se especifican en la Figura 25.

ALGORITMOS MACHINE LEARNING
Desition Tree
Random Forest
Gradient Boosting
Naive Bayes
K-Nearest Neighbor
Logistic Regression
Support Vector Machine

Figura 25: Algoritmos de Machine Learning

Elaborado por: El investigador

Entrenamiento algoritmo

En la fase de entrenamiento se toma en cuenta el objetivo principal es el ajuste al modelo y prestar atención al nivel de desempeño de los métodos designados para la evaluación. Para medir el rendimiento y eficacia de un algoritmo de inteligencia artificial se ha escogido la validación cruzada.

Este método de evaluación presenta las siguientes características:

- Permite aprovechar al máximo el conjunto de datos disponible.
- Divide los datos en subconjuntos para realizar iteraciones de entrenamiento y prueba y evita el desperdicio de datos.
- Evaluación más precisa y confiable del rendimiento del modelo.
- Permite identificar problemas de sobreajuste y sub-ajuste del modelo.
- Al realizar varias iteraciones se evalúa la estabilidad del modelo.
- Método más utilizado y recomendado para evaluar el rendimiento del algoritmo de machine learning [54].

Se evalúa la capacidad del modelo, observando a breves rasgos la eficiencia y precisión del algoritmo.




Figura 26: Gráfica de barras sobre entrenamiento del algoritmo

Elaborado por: El investigador

La Figura 26 muestra una gráfica de barras con los valores del entrenamiento de los datos y demostrar cuál de los algoritmos es el más eficiente. La precisión del modelo puede ser eficaz según el equilibrio entre los valores de precisión de entrenamiento y testeo para evitar el sobreajuste o sub-ajuste del modelo.

Explicando un poco sobre qué escenarios presentan los valores en la precisión de entrenamiento y testeo, se tienen las siguientes especificaciones:

1. **Caso ideal:** Ambas predicciones tanto en la precisión de entrenamiento como en testeo son altas y similares entre sí. Esto significa que el modelo ha captado bien cómo funcionan los datos de entrenamiento y puede hacer buenas predicciones con ellos.
2. **Sobreajuste:** La precisión de entrenamiento es alta pero la de testeo es más baja, esto puede indicar que el modelo ha memorizado los datos de entrenamiento en lugar de aprender patrones generalizables y puede estar demasiado ajustado, lo que hace que no se pueda generalizar a nuevos datos.
3. **Sub-ajuste:** La precisión de entrenamiento y la de testeo son bajas y esto explica que el modelo no ha aprendido lo suficiente de los datos de entrenamiento y no puede capturar los patrones en los datos.

- 4. Variabilidad:** La precisión de entrenamiento y testeo varían significativamente entre diferentes iteraciones y esto indica una alta sensibilidad del modelo a la partición de los datos y una falta de estabilidad en los resultados [55].

Teniendo en cuenta estos aspectos se determina el mejor algoritmo a ser utilizado es SVM Support Vector Machine. La precisión de entrenamiento es de 0.78 y la precisión de testeo de 0.78 como se observa claramente en la gráfica de barras de la Figura 26 (Capítulo III) y sus resultados del entrenamiento en código fuente de la Figura 27, reconociendo que los dos datos forman parte del caso ideal de la validación cruzada, lo que resuelve que el modelo ha aprendido bien los patrones de los datos de entrenamiento.

```
Validacion Cruzada - SUPPORT VECTOR MACHINE
Precision de entrenamiento: 0.786167875465271
Precision de testeo: 0.7810143885905946
-----MODELO GUARDADO-----
```

Figura 27: Resultados de entrenamiento del algoritmo SVM

Elaborado por: El investigador

3.2.5. Etapa de renderizado

Dentro de esta etapa se busca explicar el algoritmo de segmentación de cabello que se ha utilizado con su proceso.

3.2.5.1. Programación del modelo Deep Learning de Segmentación

Acondicionamiento de la base de datos

Adecuación del dataset

Para la base de datos de la segmentación de cabello, es importante encontrar imágenes con sus propias máscaras de cabello para de ese modo entrenar una base de datos ya procesada, reduciendo el tiempo al no tener que realizar otra metodología por completo para obtener las imágenes originales.

Las bases de datos encontradas tienen un conjunto de 1050 imágenes y 1050 máscaras como el modelo de la Figura 28, que se obtuvo del siguiente enlace: https://drive.google.com/file/d/1ZbWTqWLi7w-1Vvf7TQ59Gqil_SJnofbE/view encontrado en internet con el nombre de “mask_rcnn_hair_0200.h5”.

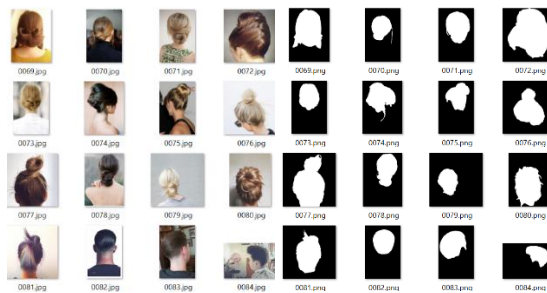


Figura 28: Imágenes y máscaras de cabello.

Acondicionamiento del dataframe

Al momento de escoger un grupo de imágenes en donde se pueden diferenciar entre la imagen original y la máscara es necesario crear más imágenes similares que permitan entrenar de mejor manera el modelo. Se decide utilizar el procesamiento de imágenes: espejo, escala de grises, cambio de colores, rotar su posición, elemento aleatorio y de esa manera utilizar una base de datos de alrededor 6000 imágenes para entrenar el modelo de forma más exacta. La Figura 29 y 30 explican las características de las funciones y sus representaciones gráficas respectivamente.

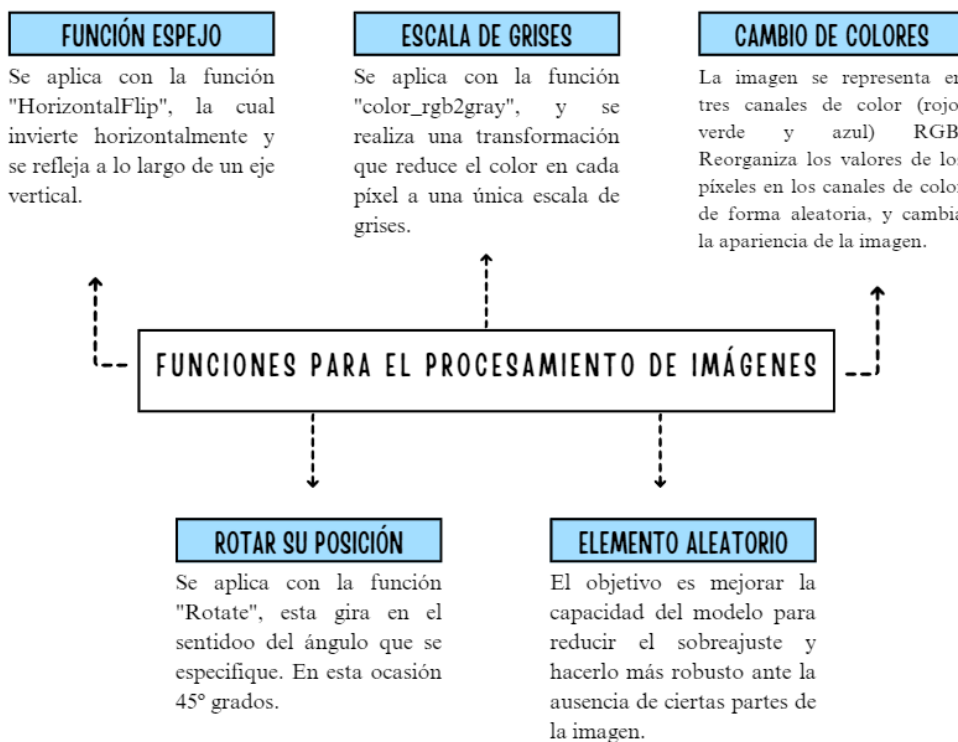


Figura 29: Procesamiento de la base de datos de las imágenes

Elaborado por: El investigador



Figura 30: Ejemplos para el procesamiento de la base de datos de las imágenes

Elaborado por: El investigador

Construcción modelo

Conforme a la Clasificación de las Redes Neuronales Convolucionales de la Tabla 4 (Capítulo I), el tipo de Red Neuronal a utilizar es ResNet. El modelo elegido DeepLabv3, es el encargado de la segmentación semántica que permite la segmentación de cabello. Se escoge este modelo porque es una de las más avanzadas dentro de la clasificación Pascal VOC (Pattern Analysis Statistical Modelling and Computational Learning Visual Object Classes uno de los datasets más comunes) para la segmentación de imágenes. [56]

DeepLabv3 utiliza ResNet como su "backbone" o red base para extraer características de alto nivel de las imágenes antes de realizar la segmentación semántica. Es decir, ResNet actúa como el extractor de características para DeepLabv3. Al utilizar ResNet como base, se beneficia de las ventajas de la arquitectura ResNet, su capacidad para manejar arquitecturas profundas y capturar características complejas en las imágenes, lo que mejora el rendimiento de la segmentación semántica.

Para cargar el modelo DeepLabv3 dentro de la programación se utiliza la sintaxis de la Figura 31, tomando en cuenta la función "`deeplabv3_plus`". DeepLabv3 es una arquitectura de red neuronal convolucional profunda que se utiliza para la segmentación de imágenes. La implementación de a función `deeplabv3_plus` en Python puede variar dependiendo de la biblioteca o paquete que se utilice y por lo

general esta función puede requerir el paso de argumentos como la ruta del modelo pre-entrenado, parámetros de configuración y datos de entrada [42].

```
""" Model """
model = deeplabv3_plus((H, W, 3))
model.compile(loss=dice_loss, optimizer=Adam(lr), metrics=[dice_coef, iou, Recall(), Precision()])
```

Figura 31: Código fuente para cargar el modelo DeepLabv3

Elaborado por: El investigador

Entrenamiento modelo

De acuerdo a varios autores [53], el conjunto de datos se dividió en 70% conjunto de entrenamiento, 30% conjunto de prueba, pues es lo recomendable para entrenar el modelo y comparar los resultados mediante pesos entrenado, que se divide dentro del código que muestra la Figura 32.

```
#-----Division datos de entrenamiento 70% /prueba 30%-----
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X,y,test_size=0.3,random_state=0)
```

Figura 32: División de datos de entrenamiento y prueba

Elaborado por: El investigador

Para la especificación de entrenamiento del modelo Deeplabv3 se preparan los datos mediante la asignación de una ruta que permite tomar los datos que ya existen para poder entrenarlos y comparar los resultados obtenidos con la base de datos de las imágenes que se han tomado como referencia y las que se han añadido para mejorar la precisión de la máscara de segmentación de cabello. La Figura 33 muestra la ruta de la carpeta “new_data” en la que se van a depositar los resultados obtenidos de la base y del entrenamiento del modelo junto con las del procesamiento de imágenes.

```
""" Dataset """
dataset_path = r"C:\Users\joha\Documents\TESIS\TESIS ARCHIVOS PRACTICOS\new_data"
train_path = os.path.join(dataset_path, "train")
valid_path = os.path.join(dataset_path, "test")

train_x, train_y = load_data(train_path)
train_x, train_y = shuffling(train_x, train_y)
valid_x, valid_y = load_data(valid_path)
```

Figura 33: Ruta para imágenes de entrenamiento del modelo

Elaborado por: El investigador

Validación modelo




Figura 34: Resultados del entrenamiento para la validación del modelo, (a) imagen y máscara para el entrenamiento, (b) resultados del modelo DeepLabv3

Elaborado por: El investigador

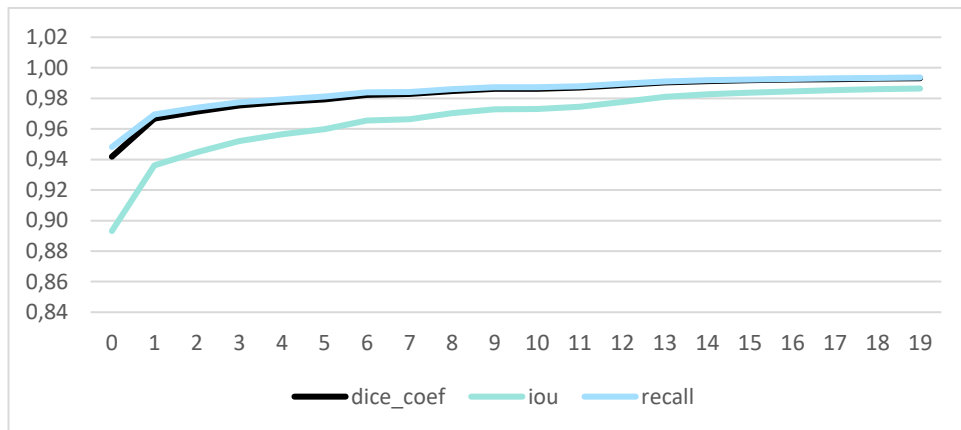


Figura 35: Métricas de calidad para el modelo DeepLabv3

Elaborado por: El investigador

La Figura 35 presenta los valores de las métricas de calidad del modelo DeepLabv3 para cada “epoch”, observando una mejora en cada iteración. Las métricas de precisión, recall, Dice Coeficiente y IoU son altas con un promedio de 98%, 98% y 97% respectivamente, es decir que el modelo de segmentación tiene una buena capacidad para segmentar el cabello en las imágenes.





3.2.6. Etapa coloración






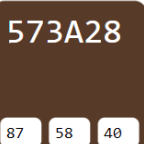


Dentro de esta etapa se aplica un proceso que hace referencia a los resultados de los algoritmos anteriores para mostrar la renderización de la coloración capilar en la imagen del cabello del usuario.

3.2.6.1. Programación de la coloración capilar

La preparación de los datos del algoritmo se utiliza la Tabla 8 que especifica la asignación de colores RGB para la gama de tintes con su respectivo tono y especificaciones generales. Cabe mencionar que opencv se utiliza el orden de color BGR dentro de la programación en Python.

Tabla 8: Tonos de tintes de la marca Nouvelle y colores RGB.

Nº	Colores	Tono	Imagen	RGB	Descripción
1	Rubio cenizo	8.1			El color gray / Cenizo con el código de color hexadecimal #808080 es una sombra de gris. En el modelo de color RGB #808080 dicho color se compone de 50.2% de rojo, 50.2% de verde y 50.2% de azul. En el espacio de color HSL #808080 tiene un tono de 0° (grados), 0% de saturación y 50% de luminosidad. Este color tiene una longitud de onda aproximada de 0 nm.
2	Rubio platino	90.01			El código de color hexadecimal #3b3728 es una sombra oscura de amarillo. En el modelo de color RGB #3b3728 dicho color se compone de 23.14% de rojo, 21.57% de verde y 15.69% de azul. En el espacio de color HSL #3b3728 tiene un tono de 47° (grados), 19% de saturación y 19% de luminosidad. Este color tiene una longitud de onda aproximada de 574.21 nm.

3 Castaño oscuro	7.35		 <p>3F2522</p> <p>63 37 34</p>	<p>El código de color hexadecimal #3f2522 es una sombra oscura de rojo. En el modelo de color RGB #3f2522 dicho color se compone de 24.71% de rojo, 14.51% de verde y 13.33% de azul. En el espacio de color HSL #3f2522 tiene un tono de 6° (grados), 30% de saturación y 19% de luminosidad. Este color tiene una longitud de onda aproximada de 601.4 nm.</p>
4 Castaño claro	5.3		 <p>3A251A</p> <p>58 37 26</p>	<p>El código de color hexadecimal #3a251a es una sombra oscura de naranja. En el modelo de color RGB #3a251a dicho color se compone de 22.75% de rojo, 14.51% de verde y 10.2% de azul. En el espacio de color HSL #3a251a tiene un tono de 21° (grados), 38% de saturación y 16% de luminosidad. Este color tiene una longitud de onda aproximada de 588.8 nm.</p>
5 Caramelo	7.53		 <p>573A28</p> <p>87 58 40</p>	<p>El código de color hexadecimal #573a28 es una sombra oscura de naranja. En el modelo de color RGB #573a28 dicho color se compone de 34.12% de rojo, 22.75% de verde y 15.69% de azul. En el espacio de color HSL #573a28 tiene un tono de 23° (grados), 37% de saturación y 25% de luminosidad. Este color tiene una longitud de onda aproximada de 587.44 nm.</p>
6 caramelo oscuro	6.53		 <p>3F2621</p> <p>63 38 33</p>	<p>El código de color hexadecimal #3f2621 es una sombra oscura de rojo. En el modelo de color RGB #3f2621 dicho color se compone de 24.71% de rojo, 14.9% de verde y 12.94% de azul. En el espacio de color HSL #3f2621 tiene un tono de 10° (grados), 31% de saturación y 19% de luminosidad. Este color tiene una longitud de onda aproximada de 597.16 nm.</p>

7 borgoña

6.65



El código de color hexadecimal #3b0707 es una sombra muy oscura de rojo. En el modelo de color RGB #3b0707 dicho color se compone de 23.14% de rojo, 2.75% de verde y 2.75% de azul. En el espacio de color HSL #3b0707 tiene un tono de 0° (grados), 79% de saturación y 13% de luminosidad. Este color tiene una longitud de onda aproximada de 611.37 nm.

8 rojizo


7.66



El código de color hexadecimal #4f090f es una sombra oscura de rosa-rojo. En el modelo de color RGB #4f090f dicho color se compone de 30.98% de rojo, 3.53% de verde y 5.88% de azul. En el espacio de color HSL #4f090f tiene un tono de 355° (grados), 80% de saturación y 17% de luminosidad. Este color tiene una longitud de onda aproximada de 617.41 nm.

9 miel

6.71



El código de color hexadecimal #4c381e es una sombra oscura de marrón. En el modelo de color RGB #4c381e dicho color se compone de 29.8% de rojo, 21.96% de verde y 11.76% de azul. En el espacio de color HSL #4c381e tiene un tono de 34° (grados), 43% de saturación y 21% de luminosidad. Este color tiene una longitud de onda aproximada de 581.39 nm.

10 chocolate 5.53



El código de color hexadecimal #2c201e es una sombra muy oscura de rojo. En el modelo de color RGB #2c201e dicho color se compone de 17.25% de rojo, 12.55% de verde y 11.76% de azul. En el espacio de color HSL #2c201e tiene un tono de 9° (grados), 19% de saturación y 15% de luminosidad. Este color tiene una longitud de onda aproximada de 597.27 nm.

11 azul 9.010









El código de color hexadecimal #2e4259 es una sombra oscura media de cian-azul. En el modelo de color RGB #2e4259 dicho color se compone de 18.04% de rojo, 25.88% de verde y 34.9% de azul. En el espacio de color HSL #2e4259 tiene un tono de 212° (grados), 32% de saturación y 26% de luminosidad. Este color tiene una longitud de onda aproximada de 477.93 nm.

12 negro 1



El código de color hexadecimal #0b0604 es una sombra muy oscura de rojo-naranja. En el modelo de color RGB #0b0604 dicho color se compone de 4.31% de rojo, 2.35% de verde y 1.57% de azul. En el espacio de color HSL #0b0604 tiene un tono de 17° (grados), 47% de saturación y 3% de luminosidad. Este color tiene una longitud de onda aproximada de 587.45 nm.

13 negro azulado	1.10			<p>El código de color hexadecimal #08111c es una sombra muy oscura de cian-azul. En el modelo de color RGB #08111c dicho color se compone de 3.14% de rojo, 6.67% de verde y 10.98% de azul. En el espacio de color HSL #08111c tiene un tono de 213° (grados), 56% de saturación y 7% de luminosidad. Este color tiene una longitud de onda aproximada de 477.15 nm.</p>
14 marrón	6.35			<p>El código de color hexadecimal #27140f es una sombra muy oscura de rojo-naranja. En el modelo de color RGB #27140f dicho color se compone de 15.29% de rojo, 7.84% de verde y 5.88% de azul. En el espacio de color HSL #27140f tiene un tono de 12° (grados), 44% de saturación y 11% de luminosidad. Este color tiene una longitud de onda aproximada de 595.4 nm.</p>
15 cobrizo	8.43			<p>El código de color hexadecimal #492116 es una sombra oscura de rojo-naranja. En el modelo de color RGB #492116 dicho color se compone de 28.63% de rojo, 12.94% de verde y 8.63% de azul. En el espacio de color HSL #492116 tiene un tono de 13° (grados), 54% de saturación y 19% de luminosidad. Este color tiene una longitud de onda aproximada de 597.03 nm.</p>

Elaborado por: El investigador basado en [57].

A continuación, se especifica en la Figura 36 el orden en que se colocan los colores de acuerdo a la asignación RGB que se ha mencionado en la Tabla 8 mencionada en el anterior párrafo, de ese modo se muestran los quince colores de una manera organizada en la interfaz.

```
#           1           2           3           4           5
colors = [(47, 46, 42), (40,55,59), (34,37,63), (26, 37, 58), (40,58,87),
          6           7           8           9           10
(33, 38, 63), (7, 7, 59), (15, 9, 79), (30, 56, 76), (30, 32, 44),
          11          12          13          14          15
(89, 66, 46), (4, 6, 11), (28, 17, 8), (15, 20, 39), (22, 33, 73)]
```

Figura 36: Colores RGB para la máscara de color

Elaborado por: El investigador

Transparencia

Se utiliza un ajuste de transparencia, pues para que el color de cabello se muestre de una manera realista se necesita de un parámetro que modifique la visualización del color dentro de la imagen, en este caso el parámetro es alpha y su sintaxis se muestra en la Figura 37.

```
# Ajustar la transparencia de la máscara roja
alpha = 1 # ajusta este valor según tus necesidades
output = cv2.addWeighted(image, 1-alpha, red_masked_image, alpha, 0, dtype=cv2.CV_8S)
output = output*y + image

line = np.ones((h, 10, 3)) * 128
cat_images = np.concatenate([output], axis=1)
cv2.imwrite(f"z_Resultados_filtro\\{name}_{i}.png", cat_images)
```

Figura 37: Ajuste de transparencia de la imagen

Elaborado por: El investigador

3.2.6.2. Sugerencia

En el apartado de sugerencia el usuario recibe un reporte sobre el pre y post cuidado de su cabello como: productos a utilizar, cuidado personal, consejos, que debe hacer antes de teñirse el cabello, que debe recordar y cuáles son los datos importantes a tomar en cuenta si su decisión es cambiarse el color de cabello. Este reporte se genera en extensión “pdf” y muestra la fecha en la que se emite el archivo imprimible y se puede observar en el Anexo 4.

3.2.7. Desarrollo de la aplicación

Para el desarrollo y diseño de la aplicación se realiza un diagrama de secuencias que se muestra en la Figura 38, empezando desde el ingreso de características físicas del usuario hasta la visualización de la sugerencia que se imprime con las recomendaciones para el cuidado del cabello.

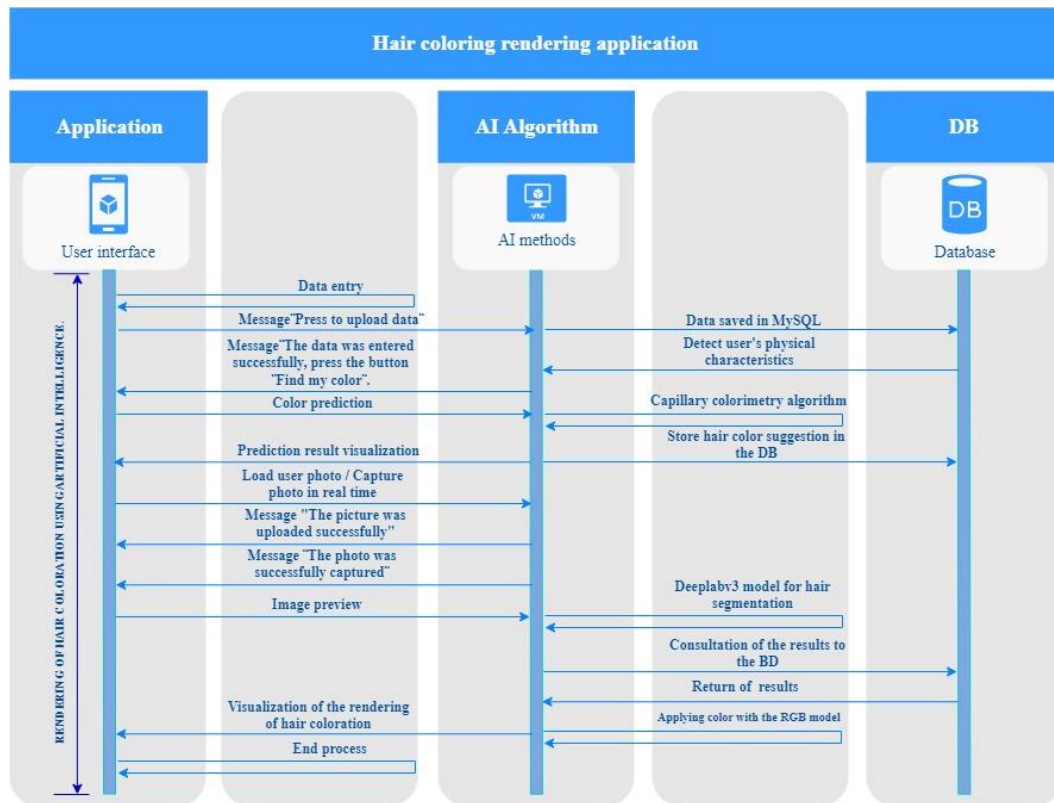


Figura 38: Diagrama de secuencias del desarrollo de la aplicación

Elaborado por: El investigador

3.2.7.1. Creación de la interfaz gráfica

La creación de la interfaz gráfica es fundamental para brindar una experiencia intuitiva y atractiva del usuario tomando las siguientes consideraciones:

- Crear un diseño visual ordenado, lógico y coherente.
- Elegir colores, fuentes y estilos que reflejen la estética.
- Desarrollar componentes interactivos, intuitivos y fáciles de usar.
- Pruebas de usabilidad.

Además, un diagrama secuencial como el de la Figura 39 es indispensable para mostrar ordenadamente todo el proceso a realizarse.



Figura 39: Diagrama secuencial del funcionamiento de la aplicación

Elaborado por: El investigador

3.2.8. Pruebas de funcionamiento

3.2.8.1. Especificaciones para las pruebas de funcionamiento

Las pruebas de funcionamiento han sido realizadas considerando las características presentadas en la Tabla 9.

Tabla 9: Especificaciones para pruebas de funcionamiento

RESOLUCION DE LA CAMARA	Las especificaciones se dan a conocer en la Tabla 5.
PARÁMETROS DE LA IMAGEN RECOMENDADOS	Tamaño: No tiene dimensiones exactas, pero se debe tener en cuenta su resolución. Luminosidad: 50% Sombra: 50% Resolución: Se recomienda utilizar mínimo 500*500 píxeles, caso contrario se ajustará al mencionado. Formato: Admite los formatos: jpeg, jpg, png.
ESPECIFICACIONES DE LA IMAGEN CARGADA	Se requiere cargar imágenes totalmente a color y no en escala de grises u otro.
ESPACIO LIBRE	Se recomienda que el lugar en donde sea capturada la fotografía con la cámara debe estar libre sin objetos que interrumpan la imagen.
PLANO DE CAPTURA DE LA IMAGEN	Es recomendable capturar la imagen en primer plano fotográfico para que se pueda enfocar específicamente la sección del cabello. También se recomienda colocarse en uno de mejor posición para la visualización del cabello.

Elaborado por: El investigador

3.2.8.2. Comprobación del funcionamiento de la base de datos

Para la comprobación del funcionamiento se genera un registro en el que se detecta el ingreso de los datos mediante la interfaz de la Figura 40, la Figura 41 muestra los datos que han sido cargados en la base de datos dentro del código fuente de la interfaz y finalmente la Figura 42 muestra la captura de la interfaz de la base de datos en phpMyAdmin.

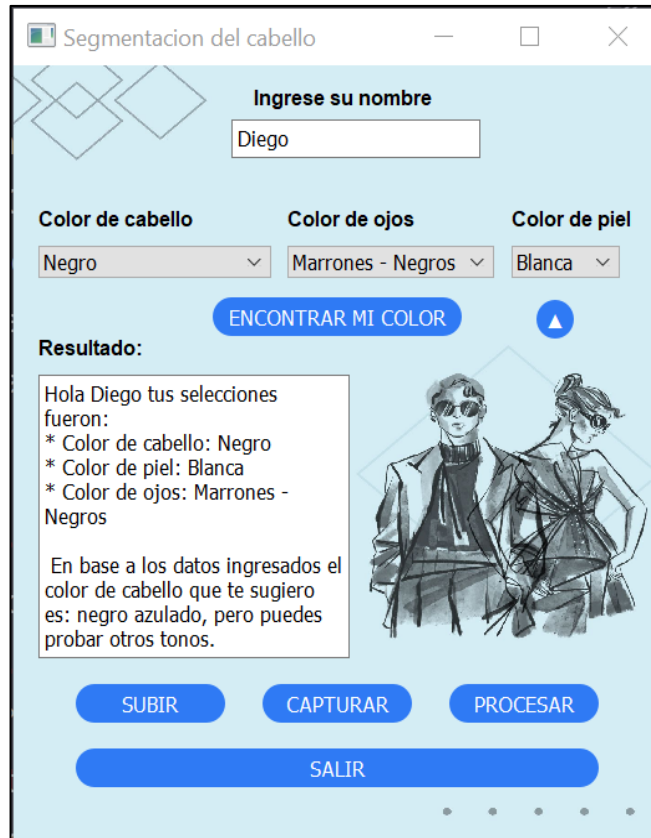


Figura 40: Ingreso de datos para prueba de funcionamiento de la base de datos

Elaborado por: El investigador

```
df = pd.read_sql(query, data_base)
id          49
nombre     Diego
fecha      2023-07-18 03:54:38
color_pelo Negro
color_piel Blanca
color_ojos Marrones - Negros
```

Figura 41: Confirmación de ingreso en la base de datos en el código fuente

Elaborado por: El investigador









Figura 42: Registro en la base de datos phpMyAdmin

Elaborado por: El investigador

3.2.8.3. Pruebas de funcionamiento de la aplicación

El total de muestras son 20 imágenes de 10 hombres y 10 mujeres con diferentes características, tomando en cuenta que el color de cabello negro o castaño no disminuirán mucho su tono y el color castaño claro o rubio tendrán un aspecto un poco más atrevido, tal y como se visualiza en la Tabla 10.

Tabla 10: Pruebas de funcionamiento de la aplicación

Nº	Fotografía Cargada	Color de cabello	Color de ojos	Color de piel	Predicción de color	Segmentación de cabello	Renderizado de coloración capilar
1		Negro	Marrones-Negros	Media	Chocolate		
2		Negro	Marrones-Negros	Blanca	Negro azulado		

3



Rubio – Castaño
Claro

Marrones-Negros

Blanca

Borgoña



4



Rubio – Castaño
Claro

Marrones-Negros

Blanca

Borgoña



5



Negro


Marrones-Negros

Media

Chocolate



6



Negro

Marrones-Negros

Media

Chocolate



7



Castaño

Marrones-Negros

Blanca

Rojizo



8




Negro

Marrones-Negros

Media

Chocolate



9



Rubio – Castaño
Claro


Marrones-Negros

Blanca

Borgoña



10



Negro

Marrones-Negros

Media

Chocolate



11



Negro

Marrones-Negros

Media

Chocolate



12



Negro

Marrones-Negros

Blanca

Negro azulado



13




Rubio – Castaño
Claro

Marrones-Negros

Blanca

Borgoña



14




Negro

Marrones-Negros

Media

Chocolate



15



Rubio – Castaño
Claro

Azules - Grises

Blanca

Rubio Cenizo



16



Rubio – Castaño
Claro

Marrones-Negros

Blanca

Borgoña



17




Rubio – Castaño
Claro

Azules - Grises

Media

Rubio Platino



18



Rubio – Castaño
Claro

Azules - Grises

Media

Rubio Platino



19



Negro

Azules - Grises

Morena

Negro Azulado



20




Rubio – Castaño
Claro

Azules - Grises

Blanca

Rubio Cenizo



Elaborado por: El investigador

<input type="checkbox"/>				50 Ali	2023-07-19 06:32:11	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				51 Daniel	2023-07-19 07:47:35	Negro	Blanca	Marrones - Negros negro azulado
<input type="checkbox"/>				52 Danny	2023-07-19 07:54:04	Castaño	Blanca	Marrones - Negros rojizo
<input type="checkbox"/>				53 Elii	2023-07-19 08:04:25	Negro	Morena	Marrones - Negros marron
<input type="checkbox"/>				54 Erick	2023-07-19 08:10:22	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				55 Erika	2023-07-19 20:29:51	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				56 Estefa	2023-07-19 20:58:45	Castaño	Blanca	Marrones - Negros rojizo
<input type="checkbox"/>				57 Eve	2023-07-19 21:15:37	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				58 Fercho	2023-07-19 21:23:14	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				59 Tefa	2023-07-19 21:34:30	Castaño	Blanca	Marrones - Negros rojizo
<input type="checkbox"/>				60 Javier	2023-07-19 21:47:56	Negro	Morena	Marrones - Negros marron
<input type="checkbox"/>				61 Jehu	2023-07-19 22:19:10	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				62 Jonathan	2023-07-20 01:59:49	Negro	Blanca	Marrones - Negros negro azulado
<input type="checkbox"/>				63 Elii	2023-07-20 02:36:33	Negro	Morena	Marrones - Negros marron
<input type="checkbox"/>				64 Juan	2023-07-20 02:39:15	Rubio - Castaño claro	Blanca	Marrones - Negros borgoña
<input type="checkbox"/>				65 Karen	2023-07-20 02:44:34	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				66 Majo	2023-07-20 02:48:08	Negro	Blanca	Marrones - Negros negro azulado
<input type="checkbox"/>				67 Marcos	2023-07-20 02:55:10	Rubio - Castaño claro	Blanca	Marrones - Negros borgoña
<input type="checkbox"/>				68 Mishu	2023-07-20 02:59:12	Castaño	Blanca	Marrones - Negros rojizo
<input type="checkbox"/>				69 Pako	2023-07-20 03:03:40	Negro	Media	Marrones - Negros chocolate
<input type="checkbox"/>				70 Pame	2023-07-20 03:11:39	Castaño	Blanca	Marrones - Negros rojizo

Figura 43: Almacenamiento en la base de datos

Elaborado por: El investigador

En la preparación de los datos para el algoritmo y el modelo fue necesario utilizar tablas que especifiquen las predicciones de color conforme a la colorimetría capilar y también una base de datos de 1050 imágenes y máscaras de cabello para su entrenamiento respectivamente. Estos datos fueron la base para ser entrenados y seleccionar los métodos más adecuados para emplear y evaluar correctamente el renderizado de coloración capilar.

El presente trabajo de investigación contiene secciones importantes como la aplicación del algoritmo de inteligencia artificial SVM que se entrena en base al proceso de colorimetría capilar para ser partícipe en la predicción de un color que beneficie la apariencia del usuario de entre quince tintes en tendencia en el año 2023, por otro lado se escoge el modelo DeepLabv3 el cual se encarga del procesamiento digital de imágenes por medio de la segmentación de cabello permitiendo separar el cabello entre las diferentes áreas de la imagen para de ese modo aplicar un nuevo proceso en el que se aplica el color RGB específicamente en el área capilar para que observe el usuario cuál sería el resultado final.

Los resultados que se obtienen en la evaluación del algoritmo SVM incluyen una precisión de entrenamiento y testeo de 0.78 siendo parte del caso ideal de la validación cruzada y permitiendo que los patrones se apliquen de manera correcta. Para evaluar el modelo DeepLabv3 en el proceso de segmentación de imágenes se toman en cuenta métricas de calidad como recall, Dice Coeficiente y IoU con un promedio de 98%, 98% y 97% respectivamente, dando como resultado un buen rendimiento del modelo para segmentar el cabello en imágenes.

Finalmente, este proceso se desarrolla con imágenes de 500x500 píxeles en una computadora con una memoria RAM de 8GB y una cámara integrada con una resolución de 640x480 píxeles para realizar las pruebas de funcionamiento.

3.2.9. Presupuesto del proyecto

En el detalle del presupuesto se explica la Tabla 11 con cada una de las especificaciones de los costos generales y a continuación se detalla el presupuesto de software y mano de obra.

Tabla 11: Presupuesto del proyecto

Ítem	Recursos Económicos	Cantidad	Precio Unitario	Precio total
1	Computador portátil	1	--	--
2	Impresiones	200	0,05\$	10\$
3	Internet	6 meses	30 \$	180\$
4	Libros	2	30 \$	60\$
5	Transporte	-	-	60\$
6	Anillado	2	4 \$	8 \$
7	Materiales de oficina	1	25 \$	25 \$
Subtotal				343 \$
Imprevistos				34,30 \$
TOTAL				377,30 \$

Elaborado por: El investigador

Por otro lado, el presupuesto utilizado para el desarrollo de la aplicación incluye el paquete de software libre sin costo como:

- Python 3.10.8
- Base de datos en MySQL
- Visual Studio Code 1.81.1

Según [58] el precio de la mano de obra para un ingeniero en Telecomunicaciones está estimada en \$850.00 y para hallar la remuneración por hora se toma en cuenta 22 días laborales del mes con 8 horas de trabajo.

$$\mathbf{Remuneración}_{diaria} = \frac{\mathbf{Remuneración}_{mensual}}{\mathbf{Días laborables}} = \frac{\$850}{22} = 38,63$$

$$\mathbf{Remuneración}_{hora} = \frac{\mathbf{Remuneración}_{diaria}}{\mathbf{Horas laborables}} = \frac{\$38,63}{8} = 4,82$$

Entonces, el desarrollo tuvo un tiempo de 150 horas laborales el precio de la mano de obra total es de \$723.

CAPÍTULO IV

CONCLUSIONES Y RECOMENDACIONES

4.1. Conclusiones

- Las técnicas de inteligencia artificial utilizadas para el renderizado de coloración capilar son aprendizaje supervisado y redes neuronales convolucionales debido a su capacidad para proporcionar predicciones precisas en el procesamiento de imágenes. Las métricas de precisión que se evalúan en base al modelo DeepLabv3 definen la eficacia del sistema mediante recall, Dice Coeficiente e IoU con un promedio de 98%, 98% y 97% respectivamente y una capacidad para producir resultados realistas en una imagen con resolución de 500x500 píxeles.
- El algoritmo utilizado para la colorimetría capilar es Máquinas de Vectores Soporte, con un dataset de tres características físicas: color de piel, color de ojos y color de cabello. Obteniendo una precisión en el entrenamiento y testeo de 0.78 en comparación con otros algoritmos de Machine Learning evaluados. Para la segmentación de cabello se utiliza el modelo DeepLabv3 con un dataset de internet de 1050 imágenes y máscaras, utilizando funciones para el procesamiento de imágenes que perfeccione el entrenamiento. El modelo RGB permite la unión de los resultados arrojados entre el algoritmo de colorimetría capilar y la segmentación de cabello obteniendo la máscara de color aplicada mediante la interfaz de usuario.
- La interfaz de la aplicación para el renderizado de coloración capilar muestra una gama de quince tonos en tendencia (Rubio cenizo, Rubio platino, Castaño oscuro, Castaño claro, Caramelo, Caramelo oscuro, Borgoña, Rojizo, Miel, Chocolate, Azul, Negro, Negro azulado, Marrón, Cobrizo) para mayor oportunidad de selección del usuario. El diseño es interactivo, atractivo y fácil

de utilizar debido a sus colores y detalles visuales colocados, pues un buen diseño es decisivo para retener al usuario y proporcionar confianza.

4.2. Recomendaciones

- Al momento de cargar o capturar la imagen del usuario se debe verificar su formato: jpeg, jpg o png, la resolución recomendada es 500x500 píxeles con una luminosidad y sombra del 50%, teniendo en cuenta que la zona capilar debe encontrarse en un primer plano de la fotografía.
- Para un óptimo funcionamiento del sistema es aconsejable cumplir con los requisitos mínimos y recomendados: computador con una memoria RAM de 8GB o superior y una cámara con resolución de 640x480, 1920x1080 píxeles o superior.
- El entrenamiento del modelo necesita que el dispositivo a utilizar se caracterice por su rendimiento no menor a un 90%, Python versión 3.10.8 y Visual Studio Code versión 1.81.1, para que el proceso no ralentice ni ocasione problemas debido a la gran cantidad de datos cargados al dataset.

BIBLIOGRAFÍA

- [1] T. A. Ileni, D. L. Borza y A. S. Darabant, Fast In-the-Wild Hair Segmentation and Color Classification, Rumania: Department of Computer Science, Faculty of Mathematics and Computer Science, 2019.
- [2] R. R. Currius, U. Assarsson y E. Sintorn, Real-Time Hair Filtering with Convolutional Neural Networks, Suecia: Chalmers Institute of Technology, 2022.
- [3] B. Kim y H. J. Suk, New Image Processing Algorithm towards More Realistic Expression on Hair Coloring, Republic of Korea: Department of Industrial Design, 2022.
- [4] D. Dang, Artificial Intelligence: ai in fashion and beauty e-commerce, LAB University of Applied Sciences, 2022.
- [5] Claudia di Paolo, «L'exclusivité,» L'exclusivité, [En línea]. Available: <https://lexclusivite.com/cosmetica-capilar/>.
- [6] R. Calderón, M. B. Vaca, G. Dueñas, M. Ramos y V. Gordón, «Principios Básicos de la Coloración,» de *Manual básico de colorimetría*, Santo Domingo, Instituto Tecnológico Superior LENDAN, 2019.
- [7] C. Chávez, Sistema de semaforización inteligente para el control de flujo vehicular mediante el Procesamiento Digital de Imágenes, Ambato: UNIVERSIDAD TÉCNICA DE AMBATO, 2015.
- [8] Blog Agendapro Belleza, «Todo lo que necesitas saber sobre la coloración del cabello,» de *Agendapro*, Blog Agendapro , 2021.
- [9] Aprende Institute, «Peluquería y estilismo - Tendencias de cabello 2023 ¿Qué está de moda este año?,» de *Aprende Institute*, Aprende Institute, 2023.

- [10] J. Pons, «Trabajar en el campo de la cosmetología capilar,» de *Josep Pons Formación*, Catalunya, OMAT, SOC, 2021.
- [11] Y. L. Esquerre Mendoza, «Colorimetría capilar,» de *Colorimetría capilar*, Lima - Perú, Universidad César Vallejo, 2017, p. 10.
- [12] Apuntes de estética y cosmética, «Las cuatro leyes de la colorimetría.,» de *Apuntes de estética y cosmética - Fundamentos técnicos sobre peluquería.*, 2020.
- [13] teknomers, «Las predicciones de tendencias de color de cabello para 2023 apuntan a un año vibrante por delante,» de *Teknomers Noticias*, teknomers, 2022.
- [14] ABDdesevilla, «Test y consejos de experta para elegir el color de pelo que más te favorece,» de *Bulevar Sur*, Bulevar Sur , 2023.
- [15] N. L. S. Palomino y U. R. Concha, Técnicas de Segmentación en Procesamiento Digital de Imágenes, Lima - Perú: Universidad Nacional Mayor de San Marcos - Revista de Ingeniería de Sistemas e Informática vol. 6, 2009.
- [16] alojamiento.us, «Segmentación de imágenes mediante umbralización,» de *Segmentación de imágenes*, alojamientos.us.es.
- [17] MathWorks, Segmentación semántica, MathWorks, 2023.
- [18] R. Rodríguez Abril, «Segmentación semántica y U-Net,» de *La Máquina Oráculo*, La Máquina Oráculo, 2021.
- [19] T. Silva Santos, Deeplab Image Semantic Segmentation Network, Sthalles.github.io, 2018.
- [20] R. E. López Briega, Inteligencia Artificial, Buenos Aires - Argentina: Libro online de IAAR - comunidad argentina de inteligencia artificial.

- [21] P. Londoño, «Inteligencia artificial: qué es, cómo funciona e importancia en 2023,» HubSpot, 06 febrero 2023. [En línea]. Available: <https://blog.hubspot.es/marketing/inteligencia-artificial-esta-aqui>.
- [22] M. Crispino, Técnicas y Algoritmos de Machine Learning: qué tipo de problemas se pueden resolver usando Machine Learning., GeneXus Blog, 2020.
- [23] SAP, Definición de machine learning en detalle, SAP AI, 2023.
- [24] MathWorks, ¿Qué es Machine Learning?, América Latina: MathWorks, 1994 - 2023.
- [25] iat20, MACHINE LEARNING. TIPOS, MODELOS, TÉCNICAS Y USOS, iat.es, 2021.
- [26] I. Pérez Borrero y M. E. Gegúndez Arias, DEEP LEARNING, Huelva: uhu.es publicaciones, 2021.
- [27] A. Centeno Franco, Deep Learning, Sevilla: Universidad de Sevilla, 2019.
- [28] R. García Páez, Análisis de técnicas de segmentación semántica sobre imágenes aéreas con deeplabv3+, Barcelona: Universidad Autónoma de Barcelona, 2019.
- [29] F. Garrucho Fernández, «Procesamiento de imágenes con técnicas de aprendizaje profundo para la detección de hojas en plantas,» Universidad de Sevilla, Sevilla, 2022.
- [30] IBM Cloud, «Desafíos del aprendizaje no supervisado,» de *¿Qué es el aprendizaje supervisado?*, IBM Cloud, 2023.
- [31] A. B. Downey, J. Elkner y C. Meyers, How to think like a computer scientist: learning with Python, Massachusetts: Green Tea Press, 2002.
- [32] J. Martínez Ladrón de Guevara, Fundamentos de programación en Java - Facultad de Informática Universidad Complutense de Madrid, Madrid: EME.

- [33] V. Benjumea y M. Roldán, Fundamentos de Programación con el Lenguaje de Programación C++, Madrid: Universidad de Málaga, 2022.
- [34] H. Moore, MATLAB para ingenieros, México: Pearson Educación, 2007.
- [35] A. Silberschatz, H. F. Korth y S. Sudarshan, Fundamentos de Bases de datos, Madrid: Mc Graw Hill, 2002.
- [36] L. Joyanes Aguilar, «BASES DE DATOS NOSQL Y "EN MEMORIA",» de *Inteligencia de Negocios y analítica de datos - Una visión global de Business Intelligence & Analytics*, México, Alfaomega - Marcombo, 2019.
- [37] Ayudaley, «Base de datos distribuida. ¿Qué es? Características,» de *Ayudaley*, 2023.
- [38] D. Campos Sánchez, «Procesamiento de imágenes con redes neuronales,» Universidad Complutense Madrid, Madrid, 2023.
- [39] Softtek, «Las CNN mejoran el análisis de imágenes,» de *the softtek blog*, México, Softtek, 2021.
- [40] D.-A. Lara Moreno, «Análisis comparativo de arquitecturas de redes neuronales para la clasificación de imágenes,» de *Máster Universitario en Inteligencia Artificial*, Madrid, Universidad Internacional de la Rioja (UNIR), 2020.
- [41] ArcGIS Developers, «How PSPNet works,» de *ArcGIS API for Python*, Pythonic, 2023.
- [42] S. Mallick, «The Ultimate Guide to DeepLabv3 – With PyTorch Inference,» de *AprenderOpenCV*, San Diego, University of California, 2022.
- [43] A. Chokshi, «A Guide to Using DeepLabV3 for Semantic Segmentation,» de *Datature*, Datature, 2023.

- [44] B. Rashid Hussein, . O. Ahmed Malik, W.-H. Ong, J. Willem y F. Slik, Semantic Segmentation of Herbarium Specimens Using Deep Learning Techniques, Singapore: Springer Nature Singapore Pte Ltd., 2020.
- [45] Y. Alouini, All the segmentation metrics!, kaggle, 2021.
- [46] A. Aziz Taha y A. Hanbury, Metrics for evaluating 3D medical image segmentation: analysis, selection, and tool, BMC Part of Springer Nature, 2015.
- [47] D. Muller, I. Soto Rey y F. Kramer, Towards a guideline for evaluation metrics in medical image segmentation, BMC Part of Springer Nature, 2022.
- [48] Ionos, «Desarrollo Web - Aplicaciones Web,» *Ionos.es*, 2023.
- [49] bbva, «Estructura de una aplicacion web,» *bbva.com*, 2023.
- [50] P. Sharma, «7 razones para tratar la arquitectura de aplicaciones web con seriedad,» *CYNOTECK*, 17 12 2021.
- [51] A. I. Quinaluiza Arias, «INTERFAZ DE PROGRAMACIÓN DE APLICACIONES PARA LA GENERACIÓN AUTOMÁTICA DE PROCEDIMIENTOS ALMACENADOS EN MYSQL,» UNIVERSIDAD TÉCNICA DE AMBATO, Ambato , 2018.
- [52] F. García, «codigosql.top,» @MrFranklingr, 18 Abril 2022. [En línea]. Available: <https://codigosql.top/crear-base-de-datos-en-phpmyadmin/>.
- [53] N. A. Villafuerte Lozada, «ASISTENTE VIRTUAL DE TELEMEDICINA CON DISPOSITIVO ELECTRÓNICO DE MEDICIÓN DE TRIAJE PARA EL DIAGNÓSTICO MÉDICO DE INFECCIONES RESPIRATORIAS UTILIZANDO INTELIGENCIA ARTIFICIAL,» UNIVERSIDAD TÉCNICA DE AMBATO, Ambato, 2023.
- [54] Microsoft Azure, «Modelo de validación cruzada,» de *Desafíos de conocimientos de la nube*, Microsoft Azure, 2023.

- [55] R. A. Irizarry, «Validación Cruzada,» de *Introducción a la ciencia de datos - Análisis de datos y algoritmos de predicción con R*, Creative Commons Attribution-NonCommercial-ShareAlike 4.0 Internacional, 2021.
- [56] M. Everingham, S. M. A. Eslami, L. Van Gool, C. K.I. Williams, J. Winn y A. Zisserman, *The PASCAL Visual Object Classes Challenge: A Retrospective*, Edinburgh: The University of Edinburgh, 2015.
- [57] Encycolorpedia, «Encycolorpedia,» Encycolorpedia, [En línea]. Available: <https://encycolorpedia.es/help>. [Último acceso: 16 06 2023].
- [58] GLASSDOOR, «GLASSDOOR,» 12 Mayo 2023. [En línea]. Available: https://www.glassdoor.com.ar/Sueldos/ecuador-ingeniero-de-telecomunicaciones-sueldo-SRCH_IL.0,7_IN68_KO8,39.htm#:~:text=%C2%BFCu%C3%A1nto%20gana%20un%20Ingeniero%20de%20telecomunicaciones%3F%20El%20sueldo,Ingeniero%20de%20telecomunicaciones%20es%20de%20%2.

ANEXOS

Anexo 1: Evaluación de algoritmos para Aprendizaje Supervisado

```
# ARBOL DE DECISIONES-----
from sklearn import tree, ensemble
dt = tree.DecisionTreeClassifier(max_depth=5)
dt.fit(X_train, y_train)

# RANDOM FOREST-----
rf = ensemble.RandomForestClassifier(n_estimators=20)
rf.fit(X_train, y_train)

# GRADIENT BOOSTING-----
gb = ensemble.GradientBoostingClassifier(n_estimators=40)
gb.fit(X_train, y_train)

# NAIVE BAYES-----
from sklearn.naive_bayes import GaussianNB
nb = GaussianNB()
nb.fit(X_train, y_train)

# K-NEAREST NEIGHBOR-----
from sklearn.neighbors import KNeighborsClassifier
knn = KNeighborsClassifier(n_neighbors=3)
knn.fit(X_train, y_train)

# LOGISTIC REGRESSION-----
from sklearn.linear_model import LogisticRegression
lr = LogisticRegression()
lr.fit(X_train, y_train)

# SUPPORT VECTOR MACHINE-----
from sklearn import svm
vm = svm.SVC(probability=False)
vm.fit(X_train, y_train)
```

Anexo 2: Funciones de procesamiento de imágenes para entrenamiento del modelo.

```
"""Argument"""
if augment == True:
    aug = HorizontalFlip(p=1.0) #aplicar la funcion espejo
    augmented = aug(image=x, mask=y)
    x1 = augmented['image']
    y1 = augmented['mask']

    x2 = cv2.cvtColor(x, cv2.COLOR_RGB2GRAY) # escala de grises
    y2 = y

    aug = ChannelShuffle(p=1) # cambio de colores
    augmented = aug(image=x, mask=y)
    x3 = augmented['image']
    y3 = augmented['mask']

    aug = CoarseDropout(p=1, min_holes=3, max_holes=10, max_height=32, max_width=32)
    augmented = aug(image=x, mask=y)# agrego objetos en posiciones aleatorias para obstruir la img
    x4 = augmented['image']
    y4 = augmented['mask']

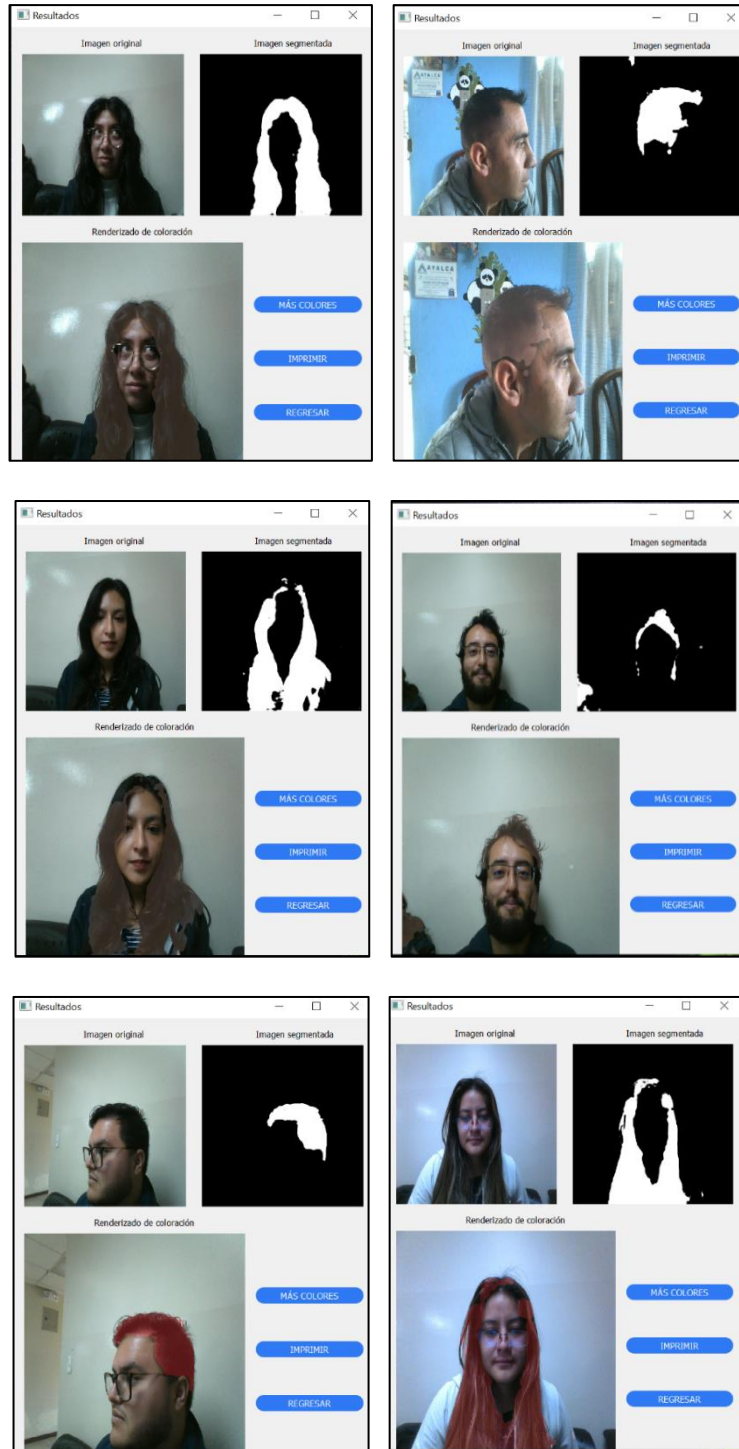
    aug = Rotate(limit=45, p=1.0) #rota 45 grados
    augmented = aug(image=x, mask=y)
    x5 = augmented['image']
    y5 = augmented['mask']

    X = [x, x1, x2, x3, x4, x5]
    Y = [y, y1, y2, y3, y4, y5]

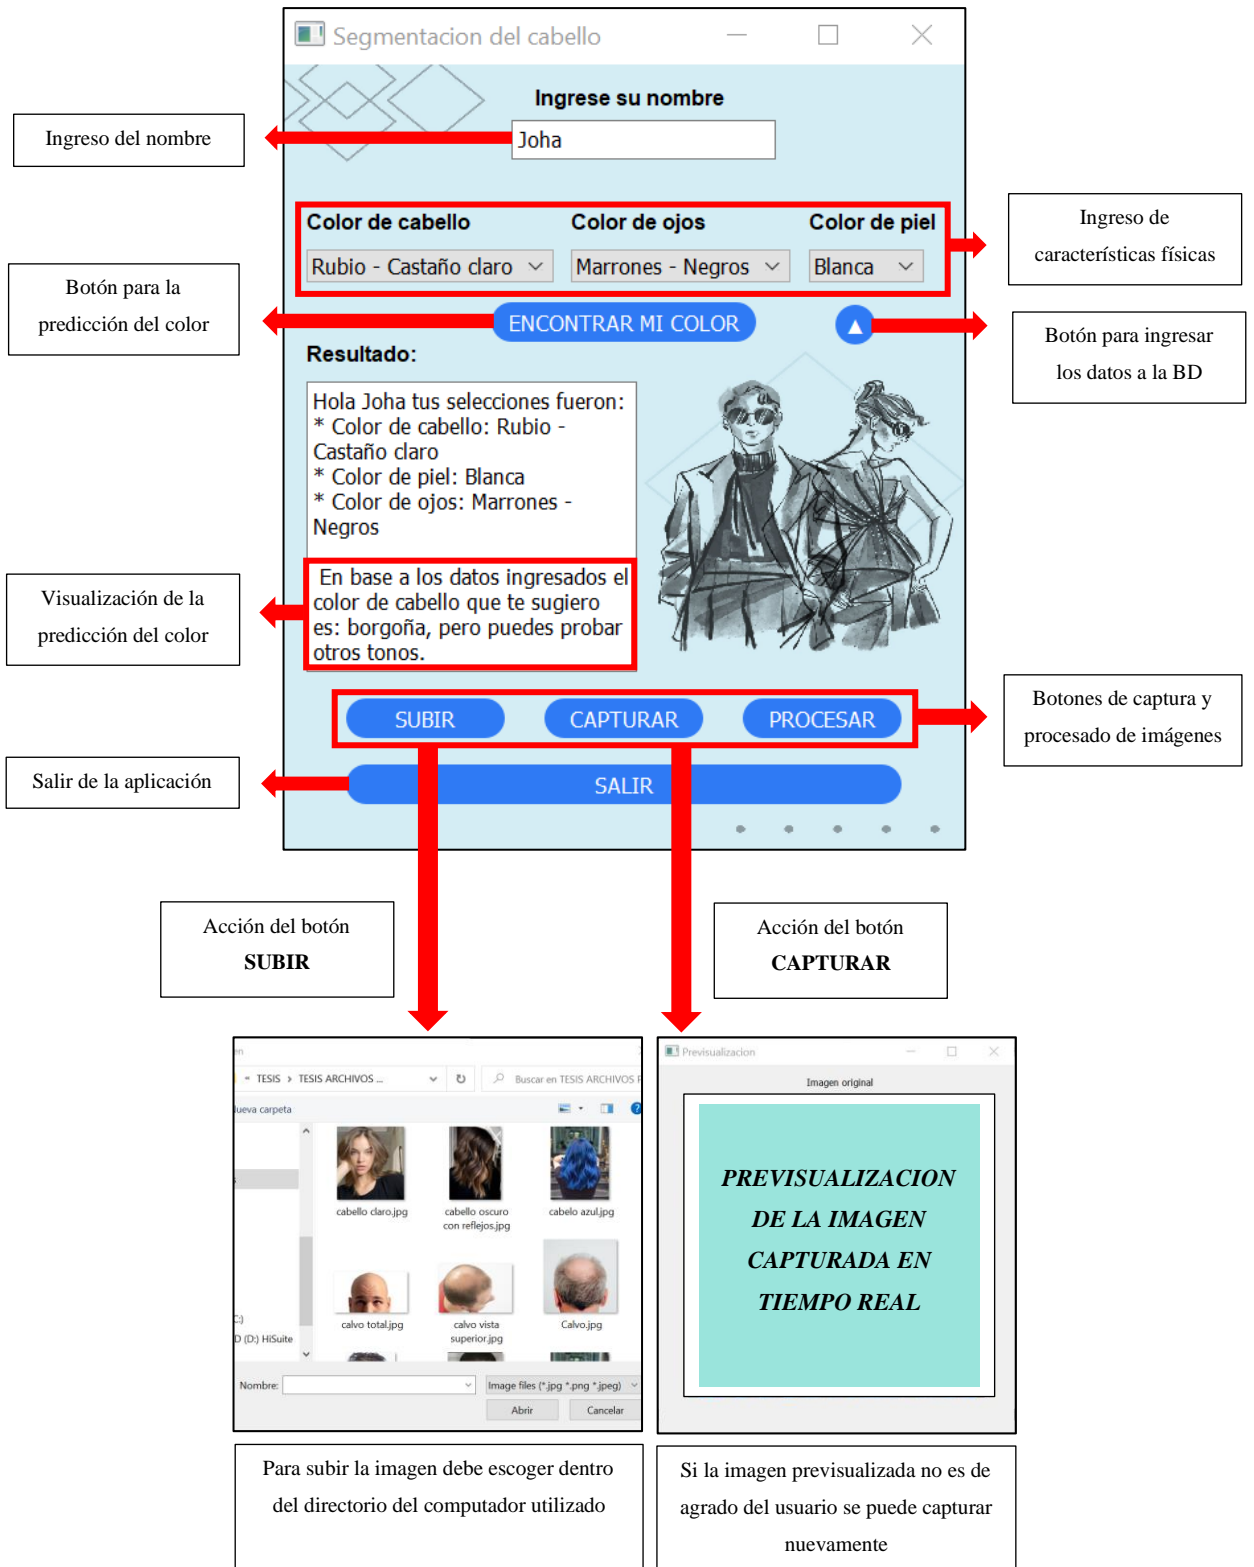
#p=1 probabilidad

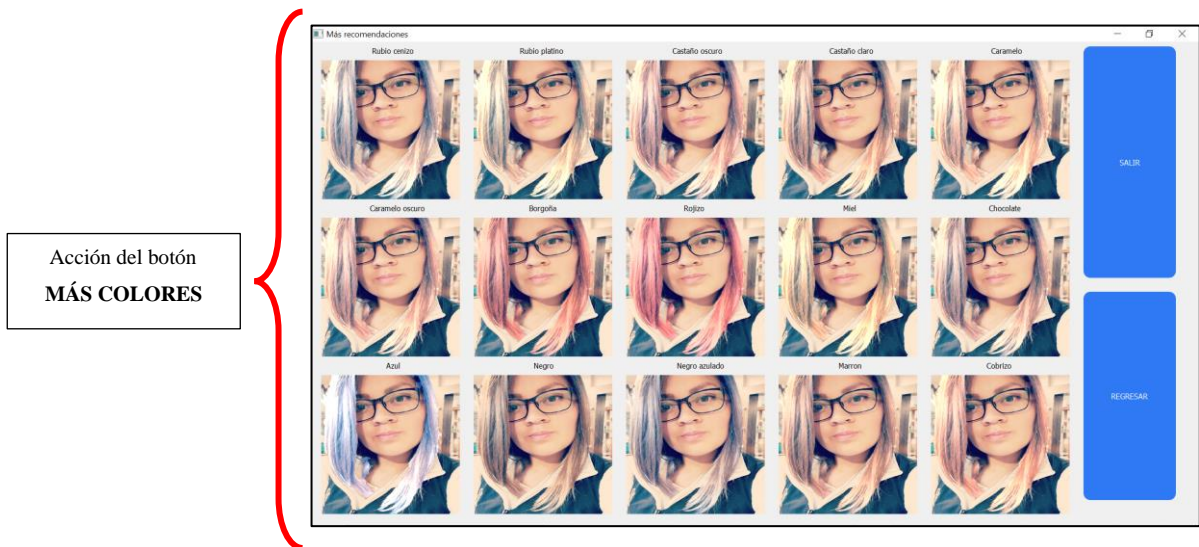
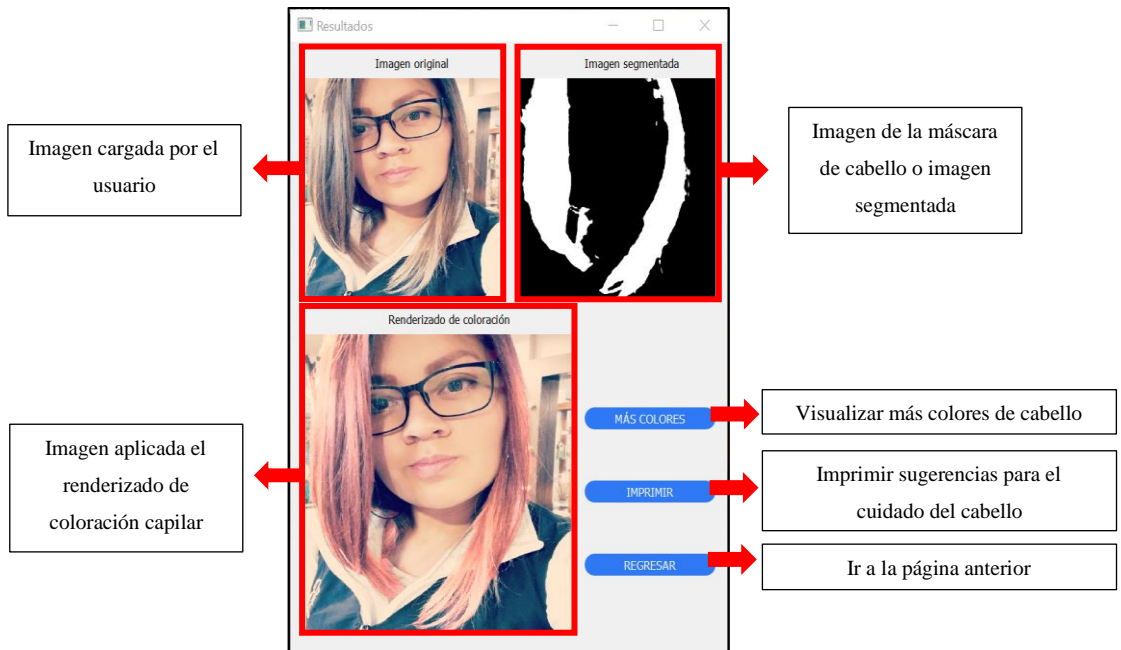
else:
    X = [x]
    Y = [y]
```

Anexo 3: Pruebas de funcionamiento al capturar la imagen en tiempo real.



Anexo 4: Manual de Usuario






Acción del botón
IMPRIMIR




Joha_resultados.pdf



**CUIDEMOS TU CABELLO
SOY TU APP FAVORITA**

CUIDADO PERSONAL



Antes de teñir el cabello

Productos

Marcas de tintes

NOUVELLE

WELLA

KOLESTON

Cuidado

Acondicionamiento profundo

Aplicar aceites capilares

Tratamientos de proteínas

Sérum o suero capilar

Tratamientos de Queratina

Tratamientos

Repolarización de cabello

Ampolletas

Lociones Capilares

Acondicionador

Mascarillas Naturales

Miel, avena, huevo

Huevo, aceite de oliva

Lociones Naturales

Agua de arroz

Agua de romero

Agua de linaza

RECORDAR

LAVADO

ALIMENTACIÓN

PROTECCIÓN

Consejos

Evitar el calor

Peinar con cuidado

Usar acondicionador

Prueba de sensibilidad

Hidratación

Protector de cabello

Realizar un tratamiento

Cortar si es necesario

Sacar orquilla si es necesario

Realizar prueba de mechón

Seguir instrucciones

DATOS IMPORTANTES

Si tu color recomendado es azul, es bueno que intentes con colores de fantasía


Para mejorar tu color de cabello se pueden realizar iluminaciones más claras que tu color de cabello.

Si NO te gusta un solo color en el cabello, pide a tu estilista opciones sobre balayage o iluminaciones.

Después de la coloración se debe proteger el cabello de la exposición al sol.

Utilizar shampoo, acondicionador, matizante, y más, para mantener el color y prevenir la opacidad.

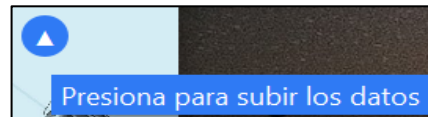
MANTÉN UN ESTILO ÚNICO TENIENDO UN CABELLO HERMOSO




Anexo 5: Mensajes de alerta de los procesos y botones.

MENSAJES DE LOS BOTONES

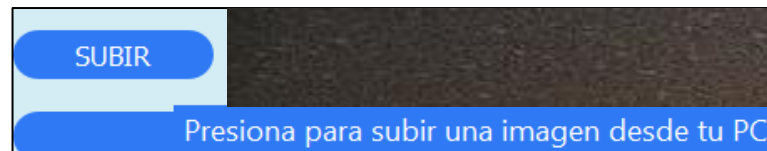
Botón para subir a la base de datos




Botón encontrar mi color




Botón Subir




Botón Capturar




Botón Procesar




Botón Salir




Botón más colores



Botón Imprimir



Botón regresar



MENSAJES DE ALERTA DE PROCESOS

