

DETECCIÓN DE NIVEL DE FOTODAÑO POR MEDIO DE INTELIGENCIA ARTIFICIAL EN ROSTROS USANDO LUZ ULTRA VIOLETA PARA TRATAMIENTO CON MEDICINA REGENERATIVA

DETECTION OF LEVEL OF PHOTO-DAMAGE THROUGH ARTIFICIAL INTELLIGENCE IN FACES USING UV LIGHT FOR TREATMENT WITH REGENERATIVE MEDICINE

Contreras Masse Roberto

Tecnológico Nacional de México/ I.T. de Ciudad Juárez
Universidad Autónoma de Ciudad Juárez
<https://orcid.org/0000-0001-9030-2456>
rcontreras@itcj.edu.mx

Moheno Contreras Ana Silvia

Universidad Autónoma de Ciudad Juárez
<https://orcid.org/0009-0009-1107-1326>
anixta@gmail.com

Ochoa Zezzatti Alberto

Universidad Autónoma de Ciudad Juárez
<https://orcid.org/0000-0002-9183-6086>
alberto.ochoa@uacj.mx

Guevara Galván Esteban Manuel

Tecnológico Nacional de México/ I.T. de Ciudad Juárez
<https://orcid.org/0009-0002-3050-6697>
L18022289@cdjuarez.tecnm.mx

Romero Hernández César Alejandro

Tecnológico Nacional de México/ I.T. de Ciudad Juárez
<https://orcid.org/0009-0001-4505-9079>
L18111933@cdjuarez.tecnm.mx

DOI: <https://doi.org/10.61273/neyart.v2i4.81>

| Recibido: 17/08/2024 | Aceptado: 16/10/2024 | Publicado: 02/12/2024

Esta obra está bajo
una licencia internacional
Creative Commons Atribución 4.0.



Resumen: Esta investigación busca desarrollar una herramienta de trabajo que ayude en la detección del daño fotosolar aplicando inteligencia artificial. La metodología abarca desde la adquisición de la imagen digital, los elementos necesarios para crear el ambiente propicio con la luz UV y la creación de una interfaz gráfica que facilite el uso de esta investigación a personas que no están familiarizadas con inteligencia artificial o lenguajes de programación. Durante la ejecución de pruebas se encuentran nuevos problemas que al aplicar otras técnicas de aprendizaje automático no supervisado son resueltos favorablemente.

Palabras clave: Inteligencia artificial, Clustering, Toma de decisiones, Machine Learning, K-means.

Abstract: This research seeks to develop a work tool that helps in the detection of photosolar damage by applying artificial intelligence. The methodology encompasses everything from the acquisition of the digital image, the necessary elements to create the appropriate environment with UV light, and the creation of a graphical interface that facilitates the use of this research for people who are not familiar with artificial intelligence or programming languages. During the execution of tests, new problems are found that are favorably resolved by applying other non-supervised machine learning techniques.

Keywords: Artificial Intelligence, Clustering, Decision Making, Machine Learning, K-means.

INTRODUCCIÓN

La inteligencia artificial es una tecnología que está avanzando y crecimiento constantemente y ocupa cada vez más espacios dentro de la vida cotidiana, tal como ocurre con los motores de búsqueda, el reconocimiento de voz y no se queda atrás su uso en el desarrollo de aplicaciones médicas. La inteligencia artificial a través de algoritmos de aprendizaje, basándose en modelos estadísticos permite dar resultados de manera más rápida que la mente humana. Tal como es el caso de detectar o predecir enfermedades como cáncer de mama a través de estudios de tomosíntesis. Un estudio de tomosíntesis combina los métodos de mamografía digital con tomografía, en donde se obtienen cortes milimétricos que permiten una mejor definición y resolución espacial del parénquima mamario, así superando la limitante de la

superposición de tejidos y densidad mamaria que existe en mamografía 2D y que pudiera enmascarar diminutas lesiones.

En el estudio (Benedikt, Boatsman, Swann, Kirkpatrick, y Toledano, 2018) se expresa el desarrollo de un sistema de diagnóstico asistido por computadora (DAC) para la detección de densidades de tejidos blandos sospechosas a través de tomosíntesis. Este estudio reporta una lectura de estudios casi 30 % más rápida usando DAC en comparación cuando no se usa DAC, mejorando el rendimiento de interpretación de los médicos, con un incremento en la asertividad del diagnóstico.

Actualmente, la inteligencia artificial (AI) es una herramienta muy novedosa para la detección temprana y oportuna de distintos padecimientos que gracias a las nuevas tecnologías se logra disminuir el error estadístico en el diagnóstico. Una de estas nuevas tecnologías es la AI que aprovecha los avances en machine learning y deep learning, como redes neuronales convolutivas (Yu y cols., 2020) como herramienta auxiliar. Aunque la inteligencia artificial no puede reemplazar a ningún médico, se puede incorporar la inteligencia artificial a la medicina como un apoyo a un especialista y lograr un diagnóstico mas preciso.

La AI ha continuado su avance en distintas áreas de la medicina. Algunos de los casos de uso son análisis de imágenes radiológicas, mejora de imágenes de resonancias magnéticas, reducción de tiempo en toma de imágenes, digitalización de rayos-X, detección de metástasis en imágenes, clasificación y predicción de mutación de células, o bien, en la detección de retinopatía causada por diabetes (Kulkarni, Seneviratne, Baig, y Khan, 2020). Prácticamente, todas las especialidades de la medicina se han visto beneficiadas por el uso de la AI en sus actividades diarias. En dermatología se han realizado reconocimientos de patrones para identificar lesiones y condiciones de la piel. Los estudios que menciona (Kulkarni y cols., 2020) se limitan a diagnóstico de lesiones y condiciones de la piel más allá de cáncer, con resultados de alta efectividad, superando en ocasiones la precisión del diagnóstico realizado por el humano (Das y cols., 2021). También, (Li y cols., 2022) hace un extenso estudio sobre los avances de AI en dermatología, pero todos centrados en los padecimientos mencionados anteriormente, más acné, eczema, dermatitis atópica, micosis y psoriasis.

Sin embargo, llama la atención que en la rama de medicina estética se encuentran muy pocos estudios en la literatura que apliquen AI, y los pocos desarrollos regresan a la patología o clínica. Destacan dos desarrollos que si aplican AI para la medicina estética (Li y cols., 2022; Kania, Montecinos, y Goldberg, 2024).

El primero es el Visia Skin, desarrollado en 2007 en Estados Unidos y ampliamente usado en la actualidad, con uso de luz ultravioleta para detectar arrugas, fotoenvejecimiento y otras características importantes para la dermatología estética. y el otro es Antera 3D, desarrollado en Irlanda en 2011. Este analiza y mide las arrugas dentro de las funciones que tiene. Desafortunadamente, el costo elevado de estos productos puede representar un impedimento para los médicos estéticos y maestros de medicina regenerativa. También, estas herramientas ofrecen únicamente el estado actual del paciente más no proveen una medición numérica que permita evaluar numéricamente la evolución del paciente.

Entonces, es importante buscar una herramienta que sea asequible y que permita tomar decisiones a los expertos de la salud. Este artículo aborda el desarrollo realizado para proveer precisamente una herramienta que cubra las necesidades expuestas anteriormente y además, aproveche la tecnología de inteligencia artificial que existe actualmente para contabilizar las diferentes tonalidades que se pueden observar bajo luz ultravioleta.

El artículo está organizado en cuatro secciones. La sección Desarrollo describe los fundamentos de la solución propuesta, los materiales y la construcción de la herramienta, junto con el plan de pruebas para validar los resultados que se obtengan al usar esta herramienta. La sección de Discusión y Análisis de Resultados discute cuales fueron las ventajas y desventajas de esta solución, para expresar las conclusiones que se encuentran en la sección Conclusiones. Finalmente, se comparten una serie de recomendaciones e investigación futura para la solución propuesta.

DESARROLLO

El médico que se dedica a la medicina regenerativa y estética requiere herramientas que permitan cuantificar el estado de la piel.

Por ejemplo, si hay daño solar o fotoenvejecimiento, al dar un tratamiento se necesita conocer si el tratamiento está o no está dando resultados (Nosrati y Nosrati, 2023). Generalmente, esto se hace por medio de la observación y la comparación con las notas de la historia clínica y el expediente médico. En ocasiones se toman fotografías y se hace una comparación empírica, para determinar la evolución del tratamiento. También, en la medicina estética es muy frecuente que el paciente quiera mejorar el aspecto de su cara, sin someterse a una cirugía. Entonces, esta solución debe centrarse como primera etapa en el análisis de la cara del paciente y enfocarse en un solo padecimiento.

Un padecimiento candidato es el fotoenvejecimiento de la piel, ya que es un proceso multifactorial que se produce como consecuencia de la exposición a la radiación ultravioleta (UV). La exposición a la UV

puede provocar una serie de cambios en la piel, como la aparición de arrugas, manchas, flacidez y pérdida de elasticidad. La radiación UV puede causar daño a la piel a través de dos mecanismos principales. Uno de ellos es la foto-oxidación, causada potencialmente por la radiación UV que puede provocar la ruptura de los enlaces químicos de las moléculas de la piel, conduciendo a la formación de radicales libres que pueden dañar las células de la piel (Gromkowska-Kepka, Puscion-Jakubik, Markiewicz-Zukowska, y Socha, 2021). Un segundo mecanismo es la inducción de la expresión de genes pro-envejecimiento, también relacionado a la exposición de radiación UV (Huang y Chien, 2020).

El fotoenvejecimiento de la piel es un proceso multifactorial que se produce como consecuencia de la exposición a la radiación ultravioleta (UV). La exposición a la UV puede provocar una serie de cambios en la piel, como la aparición de arrugas, manchas, flacidez y pérdida de elasticidad. La radiación UV puede causar daño a la piel a través de dos mecanismos principales:


1. **Fotooxidación:** La radiación UV puede provocar la ruptura de los enlaces químicos de las moléculas de la piel, lo que puede conducir a la formación de radicales libres. Los radicales libres son moléculas inestables que pueden dañar las células de la piel.
2. **Inducción de la expresión de genes pro-envejecimiento:** La radiación UV puede activar la expresión de genes que están involucrados en el envejecimiento de la piel.

El diagnóstico del fotoenvejecimiento de la piel se basa en la evaluación de las características clínicas de la piel, como la aparición de arrugas, manchas, flacidez y pérdida de elasticidad. Sin embargo, estos cambios pueden ser difíciles de detectar en las primeras etapas del fotoenvejecimiento. Una forma relativamente económica para detectar el fotoenvejecimiento es con la lámpara de Wood o luz de Wood (Parisi y cols., 2023).

La lámpara de Wood es un dispositivo que emite luz ultravioleta de longitud de onda corta (entre 365 y 400 nm). Esta luz es invisible al ojo humano, pero puede ser detectada por algunos materiales, como la piel. A este tipo de luz se le agrega un tono violeta detectado por el ojo humano. Bajo esta luz UV, inocua para el ser humano, la piel sana no fluoresce. Sin embargo, la piel fotoenvejecida presenta un patrón de fluorescencia característico, que puede ser utilizado para diferenciarla de la piel sana. La fluorescencia de la piel fotoenvejecida se debe a la acumulación de melanina, un pigmento que proporciona a la piel su color. La melanina absorbe la luz UV y la emite de nuevo en forma de luz visible (Bostan y Cakir, 2023). Con la lámpara de wood o luz UV es posible observar distintas condiciones de la piel que no son observables bajo la luz solar. Por ejemplo, las manchas de pigmento, como las pecas y las manchas

solares, pueden presentar una fluorescencia anormal bajo la luz de Wood. También, padecimientos graves como el cáncer de piel puede mostrar lesiones con una fluorescencia anormal bajo la luz UV; las infecciones de la piel, como la psoriasis y la rosácea, también pueden presentar una fluorescencia anormal bajo la luz UV. La figura 1 presenta un claro ejemplo de cómo la piel se observa bajo la luz UV. Las manchas oscuras son fotodaño en la piel. Ahora bien, es muy entendible que contabilizar la superficie total de la piel dañada resulta una tarea imposible para el médico.

Figura 1. Ejemplo de piel normal (izq) vs piel bajo luz UV. Las manchas oscuras son ejemplo de daño solar que presenta la piel.



Entonces, la solución que se propone debe primero detectar las manchas y después calcular de alguna forma la superficie de piel que presenta esta condición. Para lograr esto, se recurre a la fotografía digital, la cual despliega la imagen en una matriz $n \times m$, y cada casillarepresenta un pixel. Ahora bien, para obtener la imagen digital se usa un teléfono celular. Hoy en día los teléfonos celulares incluyen cámaras de alta definición y pueden tomar fotos bajo luz UV sin necesidad de un filtro o lente especial. Esto abre la posibilidad de tener un laboratorio de bajo costo para adquirir imágenes bajo luz UV. La figura 2 muestra los componentes necesarios para adquirir imágenes. Es importante hacer notar que es muy recomendable tener un entorno donde no entre luz externa y tener una mampara negra atrás del paciente.

La luz UV se produce con dos focos de la marca KAPTA (Figura 3), de 120V y 15W. Ambos focos son del tipo E26 y emiten una luz UV por medio de LEDs en el rango de 395-400 nm, que es compatible con la frecuencia de luz de una lámpara de Wood.


El teléfono que se tiene disponible para tomar las fotografías es un Samsung Galaxy S21+ 5G que cuenta con cámara principal con tres módulos. El primero es 12 MP, f/1.8, 26mm (wide), 1/1.76", 1.8 μm , Dual Pixel PDAF, OIS. El segundo es 64 MP, f/2.0, 29mm (telephoto), 1/1.72", 0.8 μm , PDAF, OIS, 1.1x optical zoom, 3x hybrid zoom. Y por último un módulo de 12 MP, f/2.2, 13mm, 120° (ultrawide), 1/2.55" 1.4 μm , Super Steady video. La ventaja de este dispositivo es que cuenta también con un módulo

de cámara para auto-retrato (selfie) de muy buena calidad 10 MP, f/2.2, 26mm (wide), 1/3.24", 1.22 μm , Dual Pixel PDAF.

La imagen digital que se obtiene es de alta calidad, a color. Al ser digital, toda imagen se expresa como un arreglo bidimensional de píxeles. Como un ejemplo, una fotografía digital, de tamaño 1024 X 683 tiene un total de 699,392 píxeles. Ahora bien, en las imágenes de color, cada pixel está representado por 24 bits, agrupados en tres segmentos de 8-bits cada uno. Los segmentos representan el componente rojo, verde y azul, y pueden ir en el rango decimal de 0 a 255 (00-FF hexadecimal). Este modelo es RGB por sus colores en inglés.

Los colores también pueden expresarse como un modelo matemático. Un modelo es el de Colores Fundamentales, que es el RGB y RGB normalizado. Otro modelo es el perceptual, cuyos modelos representativos pueden ser el HSV, HSI y TSL. Un tercer modelo corresponde a los modelos ortogonales, como el YCbCr, YUV y YIQ. Finalmente, existe el modelo de color, como el CMY y CMYK. De estos modelos, cabe destacar que el modelo HSV es el que mejor representa la forma en como las personas describen las sensaciones de color (Basilio, Torres, Sánchez, Pérez, y Meana, s.f.). HSV es el acrónimo de Tonalidad (Hue) que atiende el tipo de color, como rojo, azul, verde; Saturación (Saturation) determina la cantidad de pureza de un color, cuando es alto este valor es vibrante, caso contrario hace que el color tienda hacia el gris; Valor (Value) es la claridad u oscuridad de un color. HSV es una transformación no lineal del modelo RGB y se logra con las ecuaciones 1, 2 y 3 para cada término.

Figura 2. Laboratorio para obtención de imágenes. Fuente: Creación propia.



$$H = \arccos \frac{0.5[(R - G) + (R - B)]}{\sqrt{(R - G)^2 + (R - B)(G - B)}} \quad (1)$$

$$S = 1 - 3 \frac{\min(R, G, B)}{R + G + B} \quad (2)$$

$$V = \frac{1}{3}(R + G + B) \quad (3)$$

Dicho lo anterior, es factible tomar una fotografía digital, poder revisar los colores existentes por cada pixel y contabilizar la frecuencia de cada color en la foto. De esta manera, se puede tener la cantidad de pixeles del color rojo, de color amarillo, de turquesa, hasta el punto de distinguir la más sutil variación de la tonalidad. Sin embargo, surge un problema adicional que es el ruido de fondo de la imagen. Para lograr esto, se usa la técnica de máscaras en objetos (masking), donde se puede aislar en la imagen el objeto o región de interés (Heras, 2017).

La técnica de masking es una imagen adicional que se utiliza como un "mapa.opatrón para especificar qué áreas de la imagen original se deben mostrar (revelar) y cuáles se deben ocultar (ocultar o enmascarar). La máscara se compone de pixeles, y cada pixel de la máscara determina si el píxel correspondiente en la imagen original debe ser visible o no. En el proceso se tiene la imagen original y la máscara. La imagen original es la que se desea modificar, y la máscara es una imagen separada que controla la visibilidad de los píxeles en la imagen original. Para aplicar el efecto de máscara a la imagen original, se realiza una operación de combinación de píxeles. Esto se hace común mediante la multiplicación, superposición o "blending"(combinación) de píxeles de la imagen original y la máscara.

Figura 3. Focos LED utilizados para el proyecto, compatibles con la luz que emite una lámpara de Wood.




En la multiplicación de píxeles cada píxel de la imagen original se multiplica por el valor del píxel correspondiente en la máscara. Esto puede resultar en una atenuación de los píxeles originales donde la máscara tiene valores bajos y una preservación de los píxeles donde la máscara tiene valores altos. Al usar una máscara, se puede lograr efectos de transparencia o recorte. Por ejemplo, si la máscara tiene una región circular blanca en un fondo negro, solo los píxeles en la imagen original que corresponden a la región blanca de la máscara serán visibles, mientras que los píxeles correspondientes a la región negra serán ocultos. La Figura 4a muestra un claro ejemplo de esta situación. Entonces, al ser la región de interés el rostro de la persona, es necesario aplicar una técnica de máscara para delimitar el rostro, que será la región a analizar, y eliminar del análisis los píxeles fuera del rostro, que podría ser el cabello o el fondo del cuarto de laboratorio. El único inconveniente es que ahora se necesita una máscara irregular, como lo muestra la Figura 4b.

Figura 4(a). Máscara de objetos con un patrón conocido.



Figura 4(b). Máscara de objetos con un patrón variante.



El rostro de los pacientes en la imagen digital varía debido a varios factores. Forma de rostro, distancia donde se para la persona, altura de la persona, ángulo, rotación, inclinación, por mencionar algunas. Esto hace que la máscara de la región de interés sea complicado y se necesita que esa detección y máscara se realice de forma inteligente. Por lo tanto, es necesario incorporar a la solución inteligencia artificial. La forma más adecuada es apoyarse en la visión por computadora.


La visión por computadora es un concepto desarrollado desde la época de 1960, este concepto empezó en las universidades que eran pioneras en temas de inteligencia artificial. La visión por computadora

estaba destinada para imitar el sistema visual del humano, con la finalidad de dotar a los robots con un comportamiento inteligente. En sí, la visión por computadora hace referencias a un grupo de herramientas que dota a los equipos de cómputo el poder captar imágenes del mundo real, procesarlas y generar información de ellas. En otras palabras, se dota a una computadora la capacidad de ver, procesar y analizarlo que está viendo y llegar a una decisión inteligente (Kumar, Kaur, y Kumar, 2019). En este caso, se necesita detectar un objeto que es el rostro dentro de una imagen digital, donde no se sabe con exactitud tamaño, forma, ni posición en la imagen, además que las coordenadas entre ojos, boca, nariz y oreja varía entre cada individuo.

La detección de objetos es una rama de la visión por computadora que se centra en identificar y localizar la presencia de objetos en imágenes. Esta técnica implica el uso de algoritmos y metodologías de aprendizaje automático capaces de reconocer patrones en las imágenes y así poder detectar la presencia de objetos en una fotografía. Para entender cómo funciona la detección de objetos, se debe partir de una red convolucional (CNN), como se muestra en la Figura 5, que permite obtener una clasificación de una imagen dada. Mediante un algoritmo, se buscan regiones que pueden ser interesantes, por ejemplo, zonas contiguas de tonos parecidos, bordes coincidentes, para ser introducidos al CNN y determinar su clasificación. Finalmente se determina en cuál de las regiones de la imagen se encuentra el objeto y se indica su posición (Amit, Felzenszwalb, y Girshick, 2021). En el caso de este proyecto, se busca la cara de la persona para después aplicar una máscara y aislar perfectamente el rostro.

Figura 5. Diagrama de red neuronal convolutiva (CNN).

Adaptado de (Girshick y cols., 2014).



En la detección de rostros, se puede aprovechar la técnica de puntos de referencia faciales, o Facial Landmarks . Se necesita predecir los puntos clave del rostro humano, como son ojos, nariz, labios, entre otros. El algoritmo de Multi-task Cascaded Convolutional Networks (MTCNN) es muy socorrido para


detectar rostros y localizar las coordenadas de los puntos de referencia y ha sido previamente entrenado. Las bases de datos faciales estándares contienen 68 coordenadas X, Y que indica los puntos más importantes en el rostro de las personas. Dlib es una librería Open Source que es utilizada para trabajar con estos puntos de referencia. El sistema de 68 coordenadas faciales está limitado a un esquema básico en 2-D. La solución de Google denominada como MediaPipe es una malla facial o Face Mesh en inglés, esta solución utiliza un estimado de 468 puntos de referencia en un marco 3-D en tiempo real, que incluso funciona en dispositivos móviles.

Con estas piezas descritas anteriormente, la metodología para la solución propuesta está mostrada en la Figura 6 donde se observan las tareas y su orden de aparición. Primero, se necesita armar el laboratorio para tomar las fotografías bajo luz UV, como indica la Figura 2. La tarea número 2 se realiza con el smartphone descrito anteriormente. Entre esta tarea y el procesamiento de la imagen digital es necesario pasar la fotografía digital a un lugar donde pueda ser tomada como entrada para la tarea 3. Este paso de un dispositivo a otro es manual, por el alcance del proyecto. Las tareas 3 a la 5 se llevan a cabo en una interfaz gráfica de usuario (GUI) que debe ser desarrollada para facilitar el uso del algoritmo al momento de pruebas y posteriormente, el personal de salud.

Esta GUI se desarrollará en lenguaje Python por dos razones. La primera es la facilidad que tiene para el manejo de datos, librerías de visión de computadora, operaciones vectoriales y es ampliamente usado en machine learning. Segundo, tiene la capacidad de generar una GUI por medio de librerías específicas, como Flask, Tkinter o PyQT. La tarea 3 es el procesamiento de la imagen digital que es subida de forma manual por medio de la GUI. Este procesamiento implica la detección del rostro en la imagen, aplicar una máscara oval para delimitar los píxeles que conforman el rostro y finalmente eliminar los píxeles que están fuera de la máscara.

La siguiente tarea es la contabilización de píxeles. Aquí es donde se debe contar el total de píxeles del rostro y después contabilizar la cantidad de píxeles por cada color que exista. Teniendo las cantidades de color es posible seleccionar un tono en particular y determinar mediante una simple proporción, cuánto porcentaje representa ese color en el rostro. Esta quinta tarea de la metodología aporta la ventaja de analizar todo el rostro en un solo tiempo y no enfocarse en un área específica, cómo sería una mancha en particular, que es la forma tradicional que generalmente observa un médico. El propósito de este artículo no es discutir el código fuente de la GUI puesto que esta es solamente una herramienta. Lo que se discute en la siguiente sección son los resultados y ajustes que hicieron para lograr el resultado deseado.

Figura 6. Metodología del proyecto.



DISCUSIÓN Y ANÁLISIS DE RESULTADOS

Los resultados de este artículo están divididos en dos partes. Primero, se evalúa la toma de la foto digital. Segundo, el análisis del rostro usando AI.

Para las fotos digitales bajo luz UV, se tomaron cinco fotografías de distintos individuos aleatorios y se tomó la fotografía como está descrito en la Figura 2. Seguido esto, a los mismos individuos se cambiaron las lámparas UV de 15W por la lámpara de Wood.

Al comparar de forma visual ambas fotos, y con la supervisión de un médico entrenado, se concluyó que no existía una diferencia abismal entre la lámpara UV y la lámpara de Wood. La conclusión del médico fue que podía observar lo mismo con uno u otro aparato. La única diferencia fue que la lámpara de Wood usada por el médico tiene una lente de aumento, lo cual podría alterar el resultado. Sin embargo, se solicitó observar al paciente con la lámpara de Wood sin encenderla y solamente usando la lámpara UV de 15W. La conclusión es que la diferencia fue casi imperceptible. Esto prueba que para el ojo humano entrenado no habría diferencia significativa si se toma usando el celular, por lo que es factible continuar con la solución.

El análisis del rostro usando AI se inició con un análisis e investigación de que herramientas y/o librerías de Python serían candidatas para lograr identificar el rostro de la imagen y eliminar el ruido de fondo. Como resultado se seleccionó mediapipe (<https://pypi.org/project/mediapipe/>). MediaPipe permite aplicar soluciones de machine learning o aprendizaje automático en distintas aplicaciones y lenguajes. Mediapipe es una biblioteca de código abierto desarrollada por Google que proporciona un conjunto de herramientas y modelos preentrenados para el procesamiento de datos relacionados con la percepción humana, como el seguimiento de manos, la detección de rostros, el seguimiento de poses corporales, el reconocimiento de gestos, entre otros.


El código del listado 1 que se sigue para la detección del rostro es el siguiente:

Listado 1. Código para obtener el rostro.

```
# Obtener la imagen desde disco duro
img = cv2.imread(File_Path)
# Cambiar los canales de BGR a RGB para procesamiento correcto
plt.imshow(cv2.cvtColor(img, cv2.COLOR_BGR2RGB))
# Usar mediapipe para detectar el rostro
mp_face_mesh = mediapipe.solutions.face_mesh
face_mesh = mp_face_mesh.FaceMesh(static_image_mode=True)
# Crear la mascara oval para la cara
face_oval = mp_face_mesh.FACEMESH_FACE_OVAL
df = pd.DataFrame(list(face_oval), columns=["p1", "p2"])
# Guardar los indices para landmarks faciales y aplicar mascara
for source_idx, target_idx in routes_idx:
    source = landmarks.landmark[source_idx]
    target = landmarks.landmark[target_idx]
    relative_source = (int(img.shape[1] * source.x), int(img.shape[0] * source.y))
    relative_target = (int(img.shape[1] * target.x), int(img.shape[0] * target.y))
    routes.append(relative_source)
    routes.append(relative_target)
# Recortar imagen al contorno del rostro
(x, y, w, h) = cv2.boundingRect(np.array(routes))
out = out[y:y+h, x:x+w]
# Mostrar y guardar el rostro aislado
out = cv2.resize(out, dim, interpolation=cv2.INTER_LANCZOS4)
cv2.imwrite("Rostro.png", out)
```

Con este código se buscan las coordenadas de los puntos clave detectados en un rostro y con esas coordenadas se crea un polígono perimetral que servirá como máscara para la imagen. La Figura 7 del sitio "<https://www.assemblyai.com/blog/mediapipe-for-dummies/>" muestra un ejemplo de esta técnica. Los puntos externos detectados son los que marcan el contorno del rostro, recortar esos píxeles y finalmente guardar esta imagen exclusivamente del rostro para posterior análisis.


Figura 7. coordenadas del rostro detectados en una imagen.



Para contar los píxeles se toma en cuenta su valor hexadecimal de cada píxel, en sus tres canales rojo, verde y azul (RGB). Es más sencillo trabajar con una matriz aplanada que con una multidimensional, entendiendo que el valor de interés no se altera. De esta forma, un píxel de color de tono de piel que esté almacenado en la forma (217, 189, 173) equivale al valor hexadecimal #D9BDAD.

Asimismo, un píxel de color negro absoluto se almacena como (0, 0, 0) y es hexadecimal #000000, o bien, el blanco absoluto (255, 255, 255) que en hexadecimal es #FFFFFF. Al aplanar la matriz de píxeles, se convierte de hexadecimal al valor decimal, que en los casos anteriores mencionados serían, para el píxel de tono de piel el valor decimal 14,269,869; para el color negro el valor decimal 0; y para el color blanco 16,777,215. La Figura 8 muestra como de una imagen está organizada en píxeles y cada píxel toma un valor, que pueden ser diferentes, similares o iguales. El recuadro rojo es una matriz de 3x3 píxeles para fines de ejemplo.

Figura 8. Ejemplo de píxeles en una imagen, señalando un subconjunto en una matriz 3x3.




Esta matriz de 3x3 píxeles tiene una representación de valores de píxeles, que se muestran a continuación, pasando por su arreglo multidimensional, su equivalencia a valor hexadecimal aplanado y finalmente su valor decimal.

Al ver la matriz ejemplo, es aceptable argumentar que los píxeles en las coordenadas (3,1) y (3,3) podrían ser similares para el ojo humano, o también, los píxeles (1,1) y (2,2) podrían parecer iguales o similares. Sin embargo, al verificar sus valores numéricos es muy claro que ninguno de los 9 píxeles de ejemplo son iguales. De una imagen típica de 400 x 300 píxeles, que tiene 120,000 puntos de datos, es factible que varios píxeles sean iguales y entonces se puede sumar la cantidad de píxeles que son del mismo valor, y de , calcular el porcentaje en relación al rostro. Adicionalmente, se puede seleccionar con el puntero el píxel del rostro que le interesa al médico y calcular de forma automática la extensión y el porcentaje del rostro que tiene este color.

Al seguir esta metodología, se encuentra un problema que no estaba considerado, y es la variación de color. El efecto que se observa es que dos colores que sean diferentes, pero imperceptibles para el ojo humano, genera una granularidad muy alta de los diferentes colores encontrados en la imagen. La Figura 9 muestra dos tonos de píxeles numéricamente diferentes pero la variación es imperceptible para el ojo humano. Debido a esto, es necesario que se utilice otra técnica para buscar colores similares. Es aquí donde la inteligencia artificial, por medio de aprendizaje automático (ML, por su nombre en inglés) puede ayudar a encontrar los colores similares y reducir la granularidad experimentada en el análisis actual. Esto ayuda en la práctica al usuario al tener un número finito de opciones sobre los cuales encontrar los estadísticos sobre la imagen.

Figura 9. Variación de color de píxeles imperceptible para el ojo humano.



La clusterización es una técnica adecuada para resolver este problema. La clusterización con el algoritmo K-Means es una técnica de aprendizaje no supervisado utilizada para agrupar un conjunto de datos en diferentes grupos o clusters. Estos clusters se forman de manera que los elementos dentro de un mismo grupo sean más similares entre sí que con los elementos en otros grupos. El K-Means se puede utilizar en el procesamiento de imágenes. Para aplicar K-Means, en el contexto de los valores de píxeles, se siguen los siguientes pasos:

Inicialización. El algoritmo comienza seleccionando aleatoriamente k puntos iniciales, llamados centroides, que actuarán como representantes iniciales de los clusters.

Asignación de puntos a clusters. Cada punto (en este caso, píxel) en el conjunto de datos se asigna al cluster cuyo centroide es el más cercano en términos de distancia euclidiana. Esto crea k grupos iniciales.

Actualización de centroides. Una vez que los puntos se han asignado a los clusters, se calcula el centroide de cada grupo tomando el promedio de los valores de los puntos en ese cluster.

Reasignación de puntos. En esta etapa, cada punto se vuelve a asignar al cluster cuyo centroide es ahora el más cercano.

Iteración. La actualización de centroides y reasignación de puntos se repiten iterativamente, actualizando los centroides y reasignando puntos hasta que se alcance un criterio de convergencia. Por lo general, esto se logra cuando ya no hay un cambio significativo en las asignaciones de puntos a clusters.

Resultado final. Una vez que el algoritmo ha convergido, los clusters resultantes representan agrupaciones de puntos en función de su similitud. Cada píxel en la imagen final se asigna a un cluster, y los centroides representan valores de píxeles que son representativos del contenido del cluster.

La clusterización sirve para agrupar elementos que tengan características similares, y con distintas variables. Usar un valor de color único decimal no es la forma ideal para esta técnica, por lo que es más adecuado aprovechar las tres variables R, G y B, que es un modelo válido. En el contexto de la clusterización de píxeles de una imagen, como se muestra en el siguiente código, los píxeles se tratan como puntos en un espacio de características de tres dimensiones (rojo, verde y azul). El algoritmo K-Means busca agrupar estos píxeles en clusters de manera que los píxeles similares en términos de color sean asignados al mismo grupo. La clusterización con K-Means en imágenes puede ser utilizada para diversos propósitos, como reducción de colores, segmentación de objetos y análisis de texturas. En el siguiente código, se realiza la clusterización de los píxeles de la imagen del rostro en k clusters y se muestra el resultado visual para resaltar las áreas de similitud en términos de color. El listado 2 muestra la implementación.

Listado 2. Código para realizar la clusterización de píxeles.

```
def crearPix(rostroPath):  
    # Obtener la imagen del rostro con m scara aplicada previamente  
    img = cv2.imread(rostroPath)  
    # Obtener los p xeles de la imagen y convertirlos a un arreglo multidimensional  
    pixel_values = img.reshape((-1, 3))  
    # Convertir los valores de p xeles a flotantes. Esto es necesario para que el  
algoritmo funcione  
    pixel_values = np.float32(pixel_values)  
    # Definir los criterios de parada del algoritmo K-Means  
    criteria = (cv2.TERM_CRITERIA_EPS + cv2.TERM_CRITERIA_MAX_ITER, 100, 0.2)  
    # Ejecutar el algoritmo K-Means con 15 centros en este caso  
    k = 15  
    retval, labels, centers = cv2.kmeans(pixel_values, k, None, criteria, 15, 13  
cv2.KMEANS_RANDOM_CENTERS)  
    # Convertir los centros de cluster a valores de p xeles enteros  
    centers = np.uint8(centers)
```

```
# Asignar cada pixel a su cluster correspondiente
res = centers[labels.flatten()]
global res2
# Reorganizar los valores de pixel en la forma original de la imagen
res2 = res.reshape((img.shape))
#cv2.imshow('Imagen original', img)
cv2.imshow('Seleccione el color.', res2)
cv2.setMouseCallback('Seleccione el color.', obtener_color)
```

ANÁLISIS DE RESULTADOS

Después de varias calibraciones se determinó que el número de clusters (k) adecuado para esta aplicación es 15. Esto significa que el usuario tendrá 15 colores máximos para seleccionar y las lesiones o áreas de interés del profesional de la salud serán más fáciles de acceder y más fácil de visualizar para el ojo humano. Es importante resaltar que la imagen a presentar se debe presentar después de haber encontrado los clusters, de tal forma que el usuario pueda seleccionar las áreas de interés y poder hacer el cálculo de porcentaje de color seleccionado. Para hacer esto se requieren cinco pasos que se enumeran a continuación:

1. Convertir la imagen resultante de la clusterización al espacio de color HSV.
2. Convertir la matriz de valores HSV a un arreglo unidimensional para facilitar el cálculo numérico de porcentajes.
3. Aprovechando las facilidades de procesamiento de arreglos en Python, se excluyen los píxeles de color negro (0,0,0) y azul absoluto (0,0,255) que suelen corresponder al fondo o bordes de la imagen.
4. Calcular el total de píxeles (elementos en el arreglo unidimensional) que no son negro o azul absoluto.
5. Al seleccionar un color de los disponibles por clusterización, se puede hacer el cálculo rápidamente del número de elementos que coinciden con dicho valor y luego dividir entre el total de píxeles para así obtener la proporción del color seleccionado en la imagen.

Los resultados de este proceso se observan en tres figuras, iniciando por la Figura 10a que muestra la imagen digital original tomada desde el celular bajo luz UV. Ahi se puede observar como existen objetos que no son de interés como la camisa, cuello, cabello y fondo de la imagen.

Figura 10(a). Imagen original.



La Figura 10b muestra el resultado de la detección del rostro y la máscara aplicada por medio de inteligencia artificial. En esta imagen se puede observar como existe una similitud de colores en algunas áreas que el ojo humano lo vería como mismo color. Ejemplo de esto es la región que existe entre las cejas y la nariz. Sin embargo, aunque parezcan del mismo color, existen variantes tan sutiles que caen en el caso descrito en la Figura 9.

Figura 10(b). Imagen recortada por IA.



La Figura 10c muestra la clusterización correcta y, en consecuencia, los colores percibidos para el ojo humano, pero también se pueden hacer los cálculos necesarios que le otorgarán una herramienta para la toma de decisión al profesional de la salud.


Figura 10(c). Imagen después de clusterización.



Teniendo esto ya resuelto, la última parte de la metodología es integrarlo en una interfaz de usuario que permita al profesional de la salud analizar las fotos digitales que tome a sus pacientes. Esta debe ser simple y de fácil uso. La Figura 11 muestra dos pantallas.

La primera del extremo izquierdo es la pantalla de inicio donde el usuario puede cargar la imagen a analizar. Una vez seleccionada la imagen, se procesa y la aplicación muestra la imagen lista para que el usuario pueda usar el puntero para seleccionar un color en especial.


Figura 11. Interfaz de usuario como herramienta para el apoyo en el diagnóstico de daño fotosolar



La Figura 12 muestra al usuario seleccionado un tono de color en la punta de la nariz. En este ejemplo se detectaron 7,076 píxeles que corresponde al 9.48 % del área de la cara. Esto sirve como herramienta, pues el profesional de la salud puede anotar este valor de referencia, aplicar un tratamiento, y en un segundo tiempo poder repetir la foto, y verificar si hay cambios en el área de interés.

La herramienta indicará el porcentaje de píxeles de la nueva foto y se podrá determinar el progreso del tratamiento que fue indicado. Adicionalmente, se muestran los colores con mayor presencia, estos se incluyen en el recuadro inferior donde el usuario puede hacer click para conocer el porcentaje que representan.

Figura 12. Interfaz de usuario mostrando el cálculo de porcentaje de píxeles de un color determinado.



CONCLUSIONES

Con los resultados obtenidos se obtienen varias conclusiones. La primera indica que la aplicación de inteligencia artificial es factible para generar herramientas que ayuden al trabajo del profesional de la salud y al mismo tiempo confirma que en estos momentos no busca substituir las actividades del médico sino proveer datos para facilitar su trabajo. Adicional a esto, la tecnología cumple un rol importante como herramienta para tener una evaluación más precisa del avance de un tratamiento. Esto se observa al poder establecer el porcentaje exacto de píxeles en una imagen que a simple vista resultaría imposible de realizar. También, se encontró que la granularidad muy fina para analizar no resulta práctica. Esto es que analizar píxel por píxel no es una forma adecuada de hacer el análisis para este caso de uso, al no ser práctico para el usuario. Por esta razón, la técnica de clusterización del aprendizaje no supervisado interviene para mejorar el enfoque inicial y lograr los resultados esperados. Dentro de esta investigación también se contribuye con una forma novedosa, de bajo costo, que puede ser implementado por la mayoría de los médicos y profesionales de la salud, que consiste en una fuente de luz UV para uso humano, un celular inteligente equipado con cámara y una computadora. Esto abre la puerta a otras investigaciones que permitan aplicar tecnología de cómputo sin incurrir en altos costos o aparatos complejos y con ello se pueda democratizar el uso de la tecnología de la información e inteligencia artificial. Esto traerá beneficios a los pacientes directamente, puesto que el profesional tratante puede brindar un mejor servicio.

RECOMENDACIONES

Esta investigación no tiene por intención mostrar un resultado absoluto, sino que sirva como base e inspiración para otros investigadores que puedan mejorar este método o crear uno nuevo para el mismo fin. Es recomendable que se dedique tiempo para afinar varios puntos de esta metodología y que puede derivar en nuevas hipótesis e investigaciones. Como ejemplo, se planea realizar un estudio para el análisis de las variantes para la adquisición de imagen digital. Derivado de este estudio se antoja estudiar el ángulo de iluminación de luz UV, la distancia y altura a la que debe estar la lámpara y la distancia a la que debe estar la cámara.

Otro estudio que puede realizarse es buscar el número óptimo de clusters k que debe usarse, que inclusive, podría ser dinámico dependiendo de las características de la imagen digital. Además, buscar otros algoritmos que sean más eficientes que el k -means.

Esto permite usar deep learning, redes neuronales convolutivas y otras técnicas más que pueden marcar la diferencia en manejo y análisis inteligente de imágenes y video.

Por último, este trabajo no solo puede inspirar a los investigadores, sino que también a los alumnos de posgrados y estudiantes de pregrado. Los primeros pueden realizar estudios interdisciplinarios entre medicina e ingeniería para conocer la aplicación de estas técnicas en el campo real, mientras que los estudiantes de pregrado pueden desarrollar una interfaz gráfica en dispositivos móviles y realizar el análisis directamente desde el dispositivo inteligente. También puede ayudar a desarrollar un dispositivo que permita emitir luz UV que se adapte al teléfono al usar LEDs de emisión de luz UV apta para el uso humano.

REFERENCIAS

- Amit, Y ., Felzenszwalb, P., y Girshick, R. (2021). Object detection. En Computer vision: A reference guide (pp. 875–883). Springer.
- Basilio, J. A. M., Torres, G. A., Sánchez, G., Pérez, K. T. M., y Meana, H. M. P. (s.f.). Novedosa técnica para la detección de imágenes pornográficas empleando modelos de color hsv y ycbcr novel method for pornographic image detection using hsv and ycbcr color models.
- Benedikt, R. A., Boatsman, J. E., Swann, C. A., Kirkpatrick, A. D., y Toledano, A. Y. (2018). Concurrent computer-aided detection improves reading time of digital breast tomosynthesis and maintains interpretation performance in a multireader multicase study. *American Journal of Roentgenology* ,210(3), 685–694.
- Bostan, E., y Cakir, A. (2023). The dermoscopic characteristics of melasma in relation to different skin phototypes, distribution patterns and wood lamp findings: a cross-sectional study of 236 melasma lesions. *Archives of Dermatological Research* , 1–12.
- Das, K., Cockerell, C. J., Patil, A., Pietkiewicz, P., Giulini, M., Grabbe, S., y Goldust, M. (2021). Machine learning and its application in skin cancer. *International Journal of Environmental Research and Public Health*, 18(24), 13409.
- Girshick, R., Donahue, J., Darrell, T., y Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation.
- Gromkowska-Kępcza, K. J., Puścion-Jakubik, A., Markiewicz-Zukowska, R., y Socha, K. (2021). The impact of ultraviolet radiation on skin photoaging—review of in vitro studies. *Journal of cosmetic dermatology* ,20(11), 3427–3431.
- Heras, D. (2017). Fruit image classifier based on artificial intelligence. *Revista Killkana Técnica* ,1(2), 21–30.

- Huang, A. H., y Chien, A. L. (2020). Photoaging: a review of current literature. *Current Dermatology Reports* ,9, 22–29.
- Kania, B., Montecinos, K., y Goldberg, D. J. (2024). Artificial intelligence in cosmetic dermatology. *Journal of Cosmetic Dermatology*, 23(10), 3305–3311.
- Kulkarni, S., Seneviratne, N., Baig, M. S., y Khan, A. H. A. (2020). Artificial intelligence in medicine: where are we now? *Academic radiology* ,27(1), 62–70.
- Kumar, A., Kaur, A., y Kumar, M. (2019). Face detection techniques: a review. *Artificial Intelligence Review* ,52, 927–948.
- Li, Z., Koban, K. C., Schenck, T. L., Giunta, R. E., Li, Q., y Sun, Y . (2022). Artificial intelligence in dermatology image analysis: current developments and future trends. *Journal of Clinical Medicine* ,11(22), 6826.
- Nosrati, H., y Nosrati, M. (2023). Artificial intelligence in regenerative medicine: applications and implications. *Biomimetics*, 8(5), 442.
- Parisi, M., Verrillo, M., Luciano, M. A., Caiazzo, G., Quaranta, M., Scognamiglio, F., . . . others (2023). Use of natural agents and agrifood wastes for the treatment of skin photoaging. *Plants* ,12(4), 840.
- Yu, J., Yang, B., Wang, J., Leader, J., Wilson, D., y Pu, J. (2020). 2d cnn versus 3d cnn for false-positive reduction in lung cancer screening. *Journal of Medical Imaging* ,7(5), 051202–051202.

TABLA TRABAJO COLABORATIVO

Rol	Autor (es)
Conceptualización	Roberto Contreras-Masse y Alberto Ochoa
Metodología	Roberto Contreras
Software	Esteban Guevara y César Romero
Validación	Ana Moheno
Análisis Formal	Roberto Contreras-Masse
Investigación	Esteban Guevara, Cesar Romero, Roberto Contreras-Masse
Recursos	Roberto Contreras-Masse
Curación de datos	Esteban Guevara
Escritura - Preparación del borrador original	Cesar Romero
Escritura - Revisión y edición	Roberto Contreras-Masse y Ana Moheno

EDICIÓN ESPECIAL

OSCAR CARLOS MIRAMONTES GONZÁLEZ

ISSN: 2992-7161

Vol. 2 No. 4 | Julio - Diciembre 2024

