



*“Formando líderes para la construcción
de un nuevo país en paz”*

**DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE
CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE
INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)**

Autor

Carlos Andres Mendoza Ortiz

Director

**Diego Alfonso Peláez Carrillo
MSc En Controles Industriales**

Codirector

**Oscar Javier Suarez Sierra
DSc. En ingeniería Con Énfasis En Control Automático**

**PROGRAMA INGENIERÍA ELECTRÓNICA
FACULTAD DE INGENIERÍAS Y ARQUITECTURA
UNIVERSIDAD DE PAMPLONA
PAMPLONA
19/11/2022**

**UNIVERSIDAD DE PAMPLONA
FACULTAD DE INGENIERÍAS Y ARQUITECTURA
PROGRAMA INGENIERÍA ELECTRÓNICA
TRABAJO PRESENTADO PARA OPTAR POR EL TÍTULO DE:
INGENIERO ELECTRÓNICO**

TEMA: Detección de Cataratas con Inteligencia Artificial

AGRADECIMIENTOS

Llegado al punto donde me encuentro doy gracias a todas las personas que me ofrecieron su mano amiga y profesores que sin lugar a dudas me dieron un empujón en mi camino con consejos de evolución personal y académica.

Quiero enfatizar mi agradecimiento a los profesores Diego Peláez quien tuvo la entera confianza en este proyecto al Dr. Oscar J. Suarez por su orientación y motivación en el desarrollo del mismo; a mis padres que sin lugar a dudas me han dado la fuerza para continuar día a día con este proyecto.

Gracias infinitas a todos los que me acompañaron en el proceso y no alcanzo a mencionar, para finalizar quiero decir que sin todas las personas que me acompañaron tanto en la universidad como compañeros de clase y fuera de ella con mano firme no habría sido posible el encontrarme en este punto. Gracias Dios por guiarme siempre.

1 Contenido

INTRODUCCIÓN.....	10
RESUMEN.....	11
ABSTRAC.....	11
PROBLEMA.....	12
JUSTIFICACIÓN.....	12
DELIMITACIONES.....	14
1.1 GENERALIDADES DE LAS CATARATAS EN LOS OJOS.....	15
1.2 ANATOMÍA DEL GLOBO OCULAR.....	15
1.2.1 MEMBRANA FIBROSA.....	16
1.2.2 LA ESCLERA.....	16
1.2.3 LA CORNEA.....	17
1.2.4 IRIS.....	17
1.2.5 RETINA.....	18
1.2.6 CAPAS DE LA RETINA.....	18
1.3 CATARATA.....	18
1.4 EPIDEMIOLOGIA.....	19
1.5 ETIOLOGÍA.....	20
1.6 TIPOS DE CATARATAS.....	20
1.7 ORIGEN.....	21
1.8 RED NEURONAL CONVOLUCIONAL.....	21
1.9 TRANSFER LEARNING.....	23
1.10 IMAGENET.....	24
1.11 MODELOS DE CLASIFICACIÓN.....	24
1.11.1 MAQUINAS DE SOPORTE VECTORIAL (VSM).....	24
1.11.2 RANDOM FORESTS.....	26
1.11.3 ARBOLES DE DECISIÓN.....	27
1.11.4 RED NEURONAL MULTICAPA.....	29
1.12 APRENDIZAJE GENERAL DE LA RED NEURONAL.....	29
1.13 ESCALADO DE LAS ENTRADAS.....	30
1.14 FUNCIONES DE ACTIVACIÓN.....	31
1.15 ERROR CUADRÁTICO MEDIO.....	31
1.16 TIPOS DE OPTIMIZADORES.....	31
1.16.1 ADAM.....	32

**DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS
OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP
LEARNING – MACHINE LEARNING)**

1.17	PCA	32
1.17.1	MODELOS DE REDUCCIÓN DE DIMENSIONALIDAD	33
1.18	PYTHON	34
1.19	APLICATIVO WEB	35
1.19.1	FLASK	35
1.	2.....	METODOLOGÍA
2.1	OBTENCIÓN DE LA IMÁGENES	37
2.2	EXTRACCIÓN DE PATRONES	38
2.2.1	INCEPTIONV3	41
2.2.2	MOVILNETV2	43
2.3	ENTRENAMIENTO DE LOS MODELOS	43
2.4	CLASIFICACIÓN	44
2.4.1	MULTI LAYER PERCEPTION	44
2.4.2	RANDOM FOREST	45
2.5	SUPORT VECTOR MACHINE (SVM)	45
2.5.1	LINEAR	49
2.5.2	NO LINEAR	50
2.6	PCA	50
2.7	DESARROLLO HERRAMIENTA WEB	51
2.	3.....	RESULTADOS
3.1	ACONDICIONAMIENTO DE LAS IMÁGENES PARA SU PROCESAMIENTO	54
3.2	ALGORITMOS PARA EL PROCESAMIENTO Y EXTRACCIÓN DE PATRONES	54
3.3	CLASIFICACIÓN	55
3.3.1	CLASIFICACIÓN RANDOM FOREST	56
3.	3.4.2 CLASIFICACIÓN MAQUINAS DE SOPORTE VECTORIAL DE MÍNIMOS CUADRADOS	60
3.4	APLICACIÓN WEB	65
4.	CONCLUSIONES	68
5.	REFERENCIAS	69
6.	ANEXOS	72

ÍNDICE DE TABLAS

Tabla 1 perceptrón multicapa	44
Tabla 2 Random Forest	45
Tabla 3 SVM -- LINEAR	49
Tabla 4 SVM -- No Linear	50
Tabla 5 Resultados generales	64

ÍNDICE DE FIGURAS

Figura 1 “Bridge Over a Pond of Water Lillies”, de Claude Monet, antes de desarrollar catarata.....	12
Figura 2 Membrana fibrosa del ojo humano	16
Figura 3 Ojo normal vs ojo afectado con catarata	19
Figura 4 LeNet-5 una de las primeras redes neuronales convolucionales [19].....	22
Figura 5 Flujo de trabajo de transfer learning: carga de red, reemplazo de capas, entrenamiento de red y evaluación de precisión [19]	24
Figura 6 Máquina de soporte vectorial de mínimos cuadrados [22].....	25
Figura 7 Árbol de decisión vs Bosque aleatorio	27
Figura 8 Árbol de decisión regresion.....	28
Figura 9 Red Neuronal Multicapa [22].....	29
Figura 10 Esquema de una red neuronal de alimentación directa de una sola capa oculta.....	30
Figura 11 Red neuronal: 10 unidades, sin pérdida de peso.....	30
Figura 12 Función de Activación	31
Figura 13 PCA of IRIS dataset	33
Figura 14 Matriz de confusión con dos etiquetas de clase.....	34
Figura 15 Matriz de confusión con 3 etiquetas de clase	34
Figura 16 Framework Flask	36
Figura 17 Metodología del proyecto	37
Figura 18 imágenes tomadas de la base de datos con sus respectivas características	38
Figura 19 proceso de extracción de patrones	39
Figura 20 Imágenes de Cataratas y Normales.....	39
Figura 21 Aumentación de datos	40
Figura 22 Arquitectura modelo de extracción de patrones.....	41
Figura 23 fs Modelo InceptionV3.....	42
Figura 24 Arquitectura de la convolución del INCEPTIONV3	42
Figura 25 Convolución para el entrenamiento de la red neuronal.....	42
Figura 26 Ejemplo con dos imágenes similares.....	43
Figura 27 fd Modelo MobileNetV2.....	43
Figura 28 Datos de entrenamiento	46
Figura 29 Separación errónea.....	47
Figura 30 Separación lineal imposible.....	48
Figura 31 Separación lineal perfecta.....	48
Figura 32 Arquitectura Support Vector Machine	49
Figura 33 Estrategia con PCA	51
Figura 34 (a) atributos	52
Figura 35 (b) cargar imagen en el Frontend	52
Figura 36 Recepción de imagen	53
Figura 37 Algoritmo de predicción	53

Figura 38 etiquetas de la base de datos	54
Figura 39 Arquitectura MobileNetV2.....	55
Figura 40 Matriz de confusión Random Forest con patrones extraídos por MLP- MobileNetv2	56
Figura 41 Clasification Report de Random Forest con patrones extraídos por MobilenetV2	56
Figura 42 Matriz de confusión Random Forest con patrones extraídos por MLP- InceptionV3	57
Figura 43 Clasification Report de Random Forest con patrones extraídos por MLP- InceptionV3	57
Figura 44 Matriz de confusión Random Forest con patrones extraídos por T- MobilenetV2	58
Figura 45 Clasification Report de Random Forest con patrones extraídos por T- MobilenetV2	58
Figura 46 Matriz de confusión Random Forest con patrones extraídos por T- InceptionV3	59
Figura 47 Clasification Report de Random Forest con patrones extraídos por T- InceptionV3	59
Figura 48 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV2.....	60
Figura 49 Clasification Report máquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV2.....	60
Figura 50 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV3.....	61
Figura 51 Clasification Report Máquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV3.....	61
Figura 52 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobilenetV2	62
Figura 53 Clasification Report Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobilenetV2	62
Figura 54 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobilenetV3	63
Figura 55 Clasification Report Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobilenetV3	63
Figura 56 MobileNetv2 en 3D	64
Figura 57 MobileNetv2 en 2D	64
Figura 58 Repositorio de la aplicación web	65
Figura 59 Porcentajes de los lenguajes y Frameworks usados para la API	65
Figura 60 Aplicación Web cargando una imagen	66
Figura 61 Aplicación Web clasificando la imagen.....	66
Figura 62 Aplicación Web clasificando la imagen.....	67

INTRODUCCIÓN

Diversos estudios poblacionales han demostrado que la pérdida de visión es una discapacidad temida, por lo que la catarata es una enfermedad con gran impacto o connotación social. La catarata es una patología con una gran opacidad del cristalino lo suficientemente intensa como para reducir el rango de visión. La mayoría de las cataratas se desarrollan lentamente debido a la exposición a la luz ultravioleta de la luz solar, lo que provoca cambios graduales en la visión.

Según la Organización Mundial de la Salud, alrededor del 90% de las personas ciegas viven en países en desarrollo; nuevamente, cada individuo presenta distintas variantes como principales factores de riesgo asociados a esta patología, entre las que se encuentran las enfermedades crónico-degenerativas, principalmente la diabetes y la hipertensión arterial.

También está relacionado y comprobado que el hábito tabáquico aumenta el desarrollo de cataratas, encontrando una relación dosis-acumulativa, es decir, a mayor cantidad de tabaquismo, mayor incidencia de cataratas.

Este proyecto clasificará y hará una predicción de la patología clínica de la catarata, donde el método empleado es el tratamiento, procesamiento, extracción de patrones y clasificación con inteligencia artificial. Se verá los beneficios de los distintos clasificadores y redes neuronales usados en el proyecto, los cuales son: Deep Learning y Machine Learning. También se observará una aplicación en la cual los usuarios del campo médico podrán hacer uso de esta, como ayuda al diagnóstico y predicción de la catarata ocular en Colombia.

RESUMEN

Desarrollar una herramienta para identificar cataratas en el ojo para proporcionar un pronóstico para las poblaciones más vulnerables para que los médicos puedan tratar los casos de cataratas de alto riesgo. El problema de la ceguera es una patología nueva en la práctica de los médicos. La ecografía ocular es una técnica ampliamente utilizada para diagnosticar o evaluar diversas enfermedades oculares, especialmente el examen por ecografía Doppler de los vasos oculares se ha convertido en una herramienta muy útil para predecir enfermedades oculares. Esta herramienta le permite predecir y determinar si un paciente tiene cataratas, las imágenes se toman con diferentes marcas de cámaras, los datos se pueden mejorar y entrenar previamente para producir un modelo matemático que le permite clasificar y predecir si se trata de una catarata. La patología se refiere a cataratas, que se implementa como una aplicación web que permite su uso desde cualquier computadora que pueda usar Internet para sus operaciones.

ABSTRAC

To develop a tool for the identification of ocular cataracts, in order to provide the most vulnerable populations with a prediction and in a timely manner so that physicians can treat cases with a high risk of developing cataracts. Blindness problems constitute an emerging pathology within the internist's activities. Ocular ultrasound is a widely used technique to diagnose or evaluate different ocular conditions, in particular, the Doppler ultrasound study of the ophthalmic vessels has become a very useful tool in the prediction of ocular diseases. This tool allows to predict and identify if the patient has a diagnosis of cataract, the images are taken by cameras of different brands which could improve the data and perform the previous training to have a mathematical model which allows us to classify and predict if there is a pathology related to the cataract, this was implemented as a web application which allows it to be used from any computer where internet is available for operation.

PROBLEMA

La manifestación central de la catarata es el empeoramiento de la visión, el cual es en general lentamente progresivo. El impedimento no se limita a la agudeza visual, también compromete otros aspectos como la visión contraste, la saturación de color y el deslumbramiento (Vea Figura 1). La persona con catarata tiene dificultades al cambiar de ambientes con distinto grado de iluminación, puede presentar halos alrededor de las luces, problemas para conducir en la noche (especialmente con las luces de los vehículos que circulan en sentido contrario) y lectura limitada con iluminación habitual.




Figura 1 “Bridge Over a Pond of Water Lillies”, de Claude Monet, antes de desarrollar catarata

JUSTIFICACIÓN

En Colombia, se estima que hay 7.000 colombianos ciegos por cada millón (296.000 ciegos en todo el territorio). Estas cifras incluyen a toda la población, pero si se habla de niños el impacto en el aprendizaje y la desadaptación es mayor, observando en Colombia que entre 1 y 2% de los niños de seis a once años tienen menor AV que 20/60 en el mejor ojo y el 75% corrigen con el agujero estenopeico, lo cual indica que en una gran proporción las causas son defectos de refracción, alteración que puede ser corregida con la formula óptica adecuada. En un estudio sobre la prevalencia de Baja Visión funcional basado en 15 encuestas de países de América Latina, esta se ubicó entre 0.9 a 2.2 % de la población mayor de 50 años, las principales causas de Baja Visión Funcional se debían a degeneración macular relacionada con la edad (prevalencia media ponderada de 26%), glaucoma (23%), retinopatía diabética (19%), otras patologías de segmento posterior (15%), opacidades de la córnea no debidas al tracoma (7%), y las complicaciones de la cirugía de cataratas (4%),

de acuerdo a los requerimientos visuales de la población alrededor de 4000 personas por cada millón requieren servicios baja visión [23]

En la actualidad existen varios estudios que asocian la aparición de cataratas con trauma ocular directo. En los artículos relacionados se encuentra muchas disparidades entre los resultados de los diversos estudios, no se ha llegado a un consenso acerca del pronóstico visual final en pacientes con diagnóstico de catarata traumática.

En Colombia y particularmente en regiones donde la radiación solar es más fuerte, se llevan a cabo un gran número de cirugías de cataratas tanto en niños como en adultos, motivo por el cual resulta interesante que en estos pacientes se lleve a cabo una revisión oftalmológica detallada previa a realizar un procedimiento quirúrgico (Facoemulsificación de catarata).

Con esto se busca identificar si la persona padece o tiene síntomas referentes a las cataratas, con el uso de la herramienta; ya que en los hospitales y clínicas toman imágenes que pueden ser la referencia con la cual se entrenan los modelos de inteligencia artificial para clasificar si la persona tiene o no catarata. [14]

DELIMITACIONES

Objetivo General

- Desarrollar una herramienta para la identificación de cataratas oculares haciendo uso de técnicas de inteligencia artificial (Deep Learning – Machine Learning).

Objetivos Específicos

- Realizar el acondicionamiento de las imágenes mediante técnicas de preprocesamiento.
- Desarrollar el algoritmo de procesamiento y extracción de patrones para la segmentación de las imágenes.
- Plantear el algoritmo de inteligencia artificial para la clasificación automática de cataratas oculares.
- Realizar una interfaz gráfica para el monitoreo y visualización de los resultados.

CAPITULO 1

1.1 GENERALIDADES DE LAS CATARATAS EN LOS OJOS

Las cataratas constituyen la principal causa de ceguera en el mundo. Éstas son responsables de producir la disminución de la agudeza visual. Siendo la única manera de eliminarla, por medio de la intervención quirúrgica, es decir un tratamiento que es invasivo, pero termina por ser un procedimiento donde se extrae el cristalino opaco, y se sustituye por una lente intraocular; por lo que, “es la primera causa de ceguera reversible en el mundo y a su vez la enfermedad ocular de mayor prevalencia con tendencia a aumentar” (Velázquez et al., 2013, p. 3).

Por lo general, la historia de la catarata se remonta a 3000 años, tal como en el artículo de Velázquez. Si bien, el concepto de catarata se dice, se originó en la India, éste se propagó tras las incursiones de Alejandro de Macedonia, quien en aquel subcontinente implementó la existencia del cristalino y su opacidad, empleando términos que hasta hoy día son usados. Desde entonces se relaciona como una generalidad, el hecho de que el cristalino del ojo, si bien, puede degenerarse. De igual manera, es menester mencionar, que, en el código de Hammurabi en la Mesopotamia, solo se pagaba al cirujano cuando se tenía éxito en la operación, de ser el caso contrario, se era castigado seriamente (Velázquez et al., 2013).

La catarata senil suele ser relaciona con el envejecimiento, y generalmente afecta un ojo antes que otro, terminando por degenerar de manera lenta e indolora. Por lo tanto, la degeneración del cristalino, es decir, con el tiempo es propenso a que éste se ponga opaco; por lo que, impide ver de manera clara y se da como forma natural, resultado del proceso del envejecimiento del organismo, ya sea, por traumas, por formas de radiación diversas, por cambios metabólicos o drogas. La catarata resulta susceptible de ser tratada con éxito, así que, al realizar una cirugía de catarata se pueden arreglar consigo algunos problemas en el globo ocular, tales como lo es la hipermetropía, la miopía o el astigmatismo.

1.2 ANATOMÍA DEL GLOBO OCULAR

El globo ocular consiste en una estructura irregular, que está constituida por segmentos que se adoptan a la forma esférica del globo ocular. Tiene un tamaño de aproximadamente 25mm. Si bien, su función es tal, como la de ejercer visión lejana o cerca, de manera periférica y también tiene respuesta a la luz respectivamente.

Tiene un peso aproximado de 7 - 8 gramos y su consistencia es firme, por la presión que ejerce contra las paredes del globo ocular por los líquidos que almacena.

Se encuentra localizado en la parte anterior de la cavidad orbitaria. La constitución anatómica se divide en tres capas diferentes: La primera es la externa, formada por la túnica fibrosa que se desprende de la esclerótica y la córnea, seguida de la segunda, que es la intermedia, que es una túnica vascular y se divide en dos: Anterior (que está conformada por el iris y cuerpo ciliar) y una posterior (coroides) y por tercera y última, una capa interna o porción sensorial del ojo, mejor conocida como la retina. “Se encarga del sentido de la visión. Consta, además de estructuras adyacentes como los párpados, la glándula y las vías lagrimales, responsables de brindar protección física y lubricación al globo ocular” (Zuluaga et al., 2017, p. 3).

1.2.1 MEMBRANA FIBROSA




Figura 2 Membrana fibrosa del ojo humano

1.2.2 LA ESCLERA

Constituye un tercio de las partes de la superficie del globo ocular. Por lo general, es de color blanquecino, insípido y se encuentra formada por haces de conjuntivos con fibras elásticas que son muy resistentes, es decir, está formada por capas de tejido fibroso, por lo que, el globo ocular debe su consistencia a un tipo de capsula protectora firme.

Está formada por: EPI esclera, resulta siendo una capa vascular

y se insertan los músculos extraoculares, estroma escleral que está conformada por unas bandas de colágeno orientadas al azar y no tienen vasos sanguíneos; por lo que es una textura opaca a diferencia de la córnea, por última, la lámina fusca que resulta ser la capa más interna del tejido.[5] (Tamayo, 1997). En caso de padecer de escleritis, los dolores que se sienten son en comparación a la

cirugía de la catarata, fuertes, mientras que la cirugía es indolora, sufrir escleritis provoca un dolor fuerte y constante que puede acarrear pérdida de apetito y cambios en el horario del sueño.

Existen casos donde las personas con artritis reumatoide padecen de inflamaciones en la parte de la esclera que se encuentra en el globo ocular, pues, si bien la artritis causa una inflamación crónica, en ocasiones se puede experimentar un insoportable dolor ocular, lo cual causa enrojecimientos y severos dolores [5]

1.2.3 LA CORNEA

Por su transparencia y regular curvatura, actúa como una lente convergente. Es decir, posee una superficie refractante principal que está en el ojo. Además de proteger la parte frontal del ojo de lesiones entre sus funciones ópticas.

La córnea se encuentra por delante de la esclerótica, formando un relieve, y en medio de ellas, existe el limbo esclero-corneal (es la zona de transición entre la córnea y la esclerótica); por lo que, se unen en una zona con la esclera de transición más gruesa. [6] La córnea está formada por 5 capas: Epitelio corneal, lámina elástica anterior o membrana de Bowman, estroma, lámina elástica posterior o membrana de Descemet y endotelio corneal.

En la periferia de la córnea hay vasos sanguíneos y linfáticos y plexos nervioso, cuyas ramas se extienden por toda la córnea. Además, tiene un área esclerocorneal profunda donde se encuentra el canal de Schlemm y tiene un curso circular.[7]

Al ser la córnea transparente, permite que pase la luz a través de ella y pueda enfocarse en la retina. Una particularidad de la córnea, y que está presente en casos que se visibilizan desde la juventud hasta una edad avanzada a los cuarenta años y resulta ser conocida como queratocono, que no, es más que el resultado del mal hábito de rascarse los ojos. Si bien, esta enfermedad es la responsable de debilitar la córnea.

1.2.4 IRIS

Es el segmento anterior de la membrana vascular. Está separado de la córnea por la cámara anterior y tiene varios colores y ondas radiales. En el centro perfora la pupila. Su principal función es regular la cantidad de luz, el iris crea un diafragma que se encarga de la entrada de la luz a través de la pupila, de manera tal, que se dilata y se contrae debido a los cambios de luminosidad.

[8] Se encuentra conformada por: Epitelio anterior, estroma del iris, membrana de Bruch, epitelio posterior que hace parte de la retina., las arterias (ciliares cortas, largas y anteriores), las venas (se dirigen a las ciliares anteriores), los linfáticos y los nervios. [9] El iris resulta visible a través de la córnea y da color a

los ojos (Ferreruela, 2013).

Existen como en todo, defectos en los iris asociados a enfermedades congénitas, como lo es, el coloboma, si bien, esta es una enfermedad que se presenta desde el nacimiento, algunas veces incluso puede ser ocasionada por un procedimiento quirúrgico o algún traumatismo, esta, degenera la vista, generando un efecto fantasma o mejor conocido como visión doble.

1.2.5 RETINA

Es la capa más profunda, es frágil y en ella tienen lugar los procesos más importantes que garantizan la visión, porque es un tejido neuroepitelial que forma parte del sistema nervioso central y que esta conectado al cerebro a través del nervio optico. [10] “La retina es transparente y homogénea” (Cano et al., 2015, p. 3).

La retina está rodeada por dos capas, la coroides que la nutre y está en contacto directo con ella y la esclerótica que la protege. (Ferreruela, 2007). La retina se encuentra en la parte posterior del ojo, por lo que, resulta propensa a sufrir cambios a los diversos tipos de luz.

1.2.6 CAPAS DE LA RETINA

La retina es una capa delgada y transparente de la cornea que es muy sensible a la luz y consume mucho oxígeno. En su superficie exterior, está protegido por una capa de pigmento marrón opaco. Nuevamente conta de dos unidades funcionales: el epitelio pigmentario de la retina externa y la retina sensorial interna.

Dentro se distinguen diez capas: 1. Epitelio pigmentario, 2. Capa de conos y bastones, 3. Una membrana limitante externa, 4. Una capa nuclear externa, 5. Una capa plexiforme externa, 6. Una capa nuclear interna, 7. Una capa plexiforme interna, 8. Una capa ganglionar, 9. Una capa compuesta de fibras del nervio óptico y 10. Una membrana limitante que es interna.

“Las capas internas de la retina hasta la nuclear interna, derivan de su nutrición del sistema arterial” (Tamayo, 1997, p. 36). A su vez, las capas externas de la retina la derivan de la Coriocapilaris de la coroides. Por lo que, el sistema vascular de la retina se encuentra conformado por canales de arterias y venas que se extienden por las 4 vertientes de la retina. [11]

1.3 CATARATA

El término “cascada” proviene de la palabra latina cataracta que a su vez proviene del término griego kataraktes, que se significa cascada (caída, colapso o derumbe). Es posible que los médicos antiguos hayan llamado así a la

enfermedad porque creían que el contenido líquido del ojo se derramaría. Esta es una buena referencia a lo que hoy se conoce llama pérdida de la visión. (OMS, 2008) Por definición, una catarata es una opacidad del cristalino, aunque sea muy pequeña, pero desde el punto de vista clínico es una opacidad que produce cambios significativos en la función visual. [12]

Por lo tanto, “cualquier opacidad ya sea congénita o adquirida en la cápsula o en el contenido del cristalino, independientemente de su efecto sobre la visión, es a lo que se le denomina catarata” (Gamboa et al., 2010, p.2). Si bien, clínicamente es el resultado de la disminución en cuanto a la agudeza visual, ésta puede surgir de forma bilateral.

Existe además, las cataratas preseniles, que responden a diversas causas, como lo es los pacientes con diabetes mellitus, el hecho de que por prolongando tiempo se exponga a los rayos ultra violeta, por uso de esteroides o por traumatismos, entre otros; por lo que es poco habitual que se presenten estos casos, es más frecuente el hecho de que se presente la catarata senil, tal como se citó de la OMS (Organización Mundial de la Salud) en (Gamboa et al., 2010), se prevé que existan en el año 2025 alrededor de 40 millones de ciegos por cataratas en el mundo, sin embargo, actualmente su prevalencia es de al menos 20 millones de ciegos en el mundo. A pesar de los contantes esfuerzos de la OMS por decrecer las cifras de las personas afectadas y por mejorar la atención, posterior a la calidad de los profesionales encargados de disponer de las medidas respectivas y brindar la colaboración. [12]




Figura 3 Ojo normal vs ojo afectado con catarata

1.4 EPIDEMIOLOGIA

Uno de las consultas más frecuente que se generan es debido a la disminución de la visión o en general la pérdida de la misma, esto implica que las personas deberían ser más conscientes de lo que la pérdida de la visión genera. La etiología puede ser principalmente oftalmológica (catarata) o sistémica (desprendimiento de retina hipertensivo, que resulta en que la retina no funciona cuando hay un desprendimiento, lo que conlleva un grave problema). Es la principal causa de pérdida de la visión en los estadounidenses mayores de 40 años. En los estados unidos, se ha encontrado que la incidencia de cataratas es del 50% en personas mayores de 75 años. [13] En los países de África,

América y Asia, el 50% de la ceguera es producto de la catarata. [14] En la última evaluación de la OMS en 2010, las cataratas representaron el 51% de la ceguera en todo el mundo, afectando a unos 20 millones de personas. Las cataratas siguen siendo la principal causa de la ceguera. También es la principal causa de problemas de visión tanto en países desarrollados como en desarrollo.

[14] Según un informe publicado en Noticiero Oftalmológico Panamericano, en América Latina, por cada millón que existe de habitantes, en promedio hay 5000 ciegos y de 20 mil personas al menos, hay una disminución significativa de la agudeza visual; por lo que, la principal causa de ceguera es la catarata (3000 ciegos/millón).

[12] La incidencia de catarata aumenta cada vez más con la edad, aunque la edad de comienzo puede variar según la región: por ejemplo, en países como la India ocurre 14 años antes que a diferencia en países como Estados Unidos. [15]

La catarata senil es el tipo más importante porque como su nombre indica, es la más frecuente y la más frecuente en la vejez. Se estima que alrededor del 4% de los adultos hispanos mayores de 60 años son ciegos actualmente, y las cataratas representan el 50-60%. En la mayoría de los estudios, es más común en mujeres que en hombres. [16] Se ha descubierto que las cataratas son la principal causa de ceguera en América latina y en todo el mundo. Las cataratas afectan a 4 de cada 10 personas mayores de 60 años, causando pérdida de visión en más del 25% de las mujeres y el 12% de los hombres. El 95% de las personas mayores de 65 años tienen opacidades significativas en el cristalino, aunque no son infrecuentes algunas excepciones. A medida que la población envejece, su prevalencia va en aumento, y actualmente el único tratamiento efectivo y reparador es la cirugía. [12]

Por lo tanto, es menester el mencionar, aunque la catarata no sea algo posiblemente prevenible en la mayoría de los casos, su tratamiento quirúrgico es una de las intervenciones más eficaces y costosas de la atención sanitaria.

1.5 ETIOLOGÍA

Es multifactorial y puede ser degenerativa, traumática, metabólica, infecciosa o inflamatoria. Según la etiología puede ser: senil, secundaria o compleja (uveítis anterior crónica, miopía progresiva, glaucoma, tumoral, secundaria a radiación infrarroja, ionización y descarga, cuerpo extraño, toxicidad), metabólica. [12]

Por lo tanto, las cataratas son el resultado de las proteínas agrupadas en el cristalino del ojo que enturbian la visión de este.

1.6 TIPOS DE CATARATAS

Existen en las cataratas diversas anomalías, por lo que,

“entre sus principales ejemplos se encuentran las cataratas congénitas y las cataratas seniles. En caso de estar presentes es importantes describir si son nucleares, cuando se encuentran en el núcleo del cristalino, o capsulares, cuando se encuentran en la periferia, es decir, capsulares” (Zuluaga, 2017, p.25).

Si bien, es menester entender que las causas más frecuentes de baja visión, es a causa de la catarata congénita. Esta catarata congénita es estudiada desde el momento en que aparece, por lo general, se encuentra en el momento del nacimiento. También existe una catarata infantil que aparece en los primeros dos años de haber nacido, y una catarata juvenil que es desarrollada o que se presenta en la primera década de la vida, aparte está la catarata senil o degenerativa aparece usualmente en etapas posteriores a la tercera edad, siendo ésta la más frecuente. (Ramos et al., 2011).

1.7 ORIGEN

Los tipos de cataratas suelen estar relacionadas a la disminución del contenido de potasio, las proteínas, o el ácido ascórbico. Por lo general, se clasifican en: congénitas o degenerativas; por lo que, dentro de las cataratas adquiridas, se hallan las que son de tipo traumático, toxico, medicamentosas, secundarias, preseniles, metabólicas y las relacionadas con la edad. (Velázquez et al., 2013). Pueden estar clasificadas de diferentes formas según su origen, evolución o consistencia.

Por lo tanto, el proceso natural de envejecimiento del organismo va generando que el cristalino en el globo ocular, vaya perdiendo la capacidad de acomodarse, debido principalmente al endurecimiento de la sustancia que hay en el mismo.

Esta situación empieza a ser extrema entre los 60 años (Tamayo, 1997); por lo que, los individuos con incapacidad visual ocupan un importante número de personas en la población, que si bien pueden presentar una degeneración o malformación congénita debe tenerse en cuenta no solo en los individuos mayores, sino también en los primeros años de vida.

1.8 RED NEURONAL CONVOLUCIONAL

Las redes neuronales convolucionales son redes inspiradas biológicamente que se utilizan en computadoras de visión artificial para clasificación de imágenes y detección de objetos. La motivación básica para la red neuronal convolucional se obtuvo de la comprensión de Hubel y Wiesel del funcionamiento de la corteza visual del gato, en el que porciones específicas del campo visual parecían excitar neuronas particulares. Este principio más amplio se utilizó para diseñar una arquitectura dispersa para redes neuronales convolucionales. La primera arquitectura básica basada en esta inspiración biológica fue el neocognitrón, que luego se generalizó a la arquitectura LeNet-5. En la arquitectura de red neuronal convolucional, cada capa de la red es tridimensional, que tiene una extensión

espacial y una profundidad correspondiente al número de características. La noción de profundidad de una sola capa en una red neuronal convolucional es distinta⁴ de la noción de profundidad en términos del número de capas. En la capa de entrada, estas características corresponden a los canales de color como RGB (es decir, rojo, verde, azul), y en los canales ocultos estas características representan mapas de características ocultas que codifican varios tipos de formas en la imagen. Si la entrada está en escala de grises (como LeNet-5), entonces la capa de entrada tendrá una profundidad de 1, pero las capas posteriores seguirán siendo tridimensional. La arquitectura contiene dos tipos de capas, denominadas capas de convolución y submuestreo, respectivamente.

Históricamente, las redes neuronales convolucionales han sido las más exitosas de todos los tipos de Redes neuronales. Se utilizan ampliamente para el reconocimiento de imágenes, detección/localización de objetos, e incluso procesamiento de texto. El rendimiento de estas redes ha superado recientemente al de humanos en el problema de la clasificación de imágenes. Las redes neuronales convolucionales proporcionan un muy buen ejemplo del hecho de que las opciones de diseño arquitectónico en una red neuronal deben realizarse con conocimiento semántico sobre el dominio de datos en cuestión.




Figura 4 LeNet-5 una de las primeras redes neuronales convolucionales [19]

En el caso particular de la red neuronal convolucional, esta idea se obtuvo mediante la observación del biológico funcionamiento de la corteza visual de un gato, y utilizando en gran medida las relaciones espaciales entre los píxeles. Este hecho también proporciona alguna evidencia de que una mayor comprensión de la neurociencia podría también ser de ayuda para el desarrollo de métodos en inteligencia artificial. Redes neuronales convolucionales preentrenadas de recursos disponibles públicamente como ImageNet a menudo están disponibles para su uso en forma estándar para otras aplicaciones y conjuntos de datos. Esto se logra mediante el uso de la mayoría de los pesos preentrenados en la red convolucional sin ningún cambio a excepción de la capa de clasificación final. Los pesos de la clasificación final capa se aprenden del conjunto de datos en cuestión. Es necesario el entrenamiento de la capa final porque las etiquetas de clase en una configuración particular pueden ser diferentes de las de ImageNet. Sin embargo, los pesos en las primeras capas

siguen siendo útiles porque aprenden varios tipos de formas en las imágenes que pueden ser útiles para prácticamente cualquier tipo de aplicación de clasificación. Además, las activaciones de funciones en la penúltima capa se pueden usar incluso para aplicaciones no supervisadas. Por ejemplo, se puede crear una representación multidimensional de un conjunto de datos de imagen arbitraria al pasar cada imagen a través de la red neuronal convolucional y extraer las activaciones de la penúltima capa. Posteriormente, cualquier tipo de indexación se puede aplicar a esta representación para recuperar imágenes que son similares a una determinada imagen de destino. Tal enfoque a menudo proporciona resultados sorprendentemente buenos en la recuperación de imágenes. Debido a la naturaleza semántica de las características aprendidas por la red. Es de destacar que el uso de redes convolucionales preentrenadas es tan popular que rara vez se inicia el entrenamiento desde cero.

1.9 TRANSFER LEARNING

Transfer learning, o transferencia del aprendizaje, es una metodología de Deep Learning en la que un modelo que se ha entrenado para una tarea se utiliza como punto de partida para un modelo que realiza otra tarea similar. Suele ser mucho más fácil y rápido actualizar y volver a entrenar una red con transferencia del aprendizaje que entrenarla desde cero. Esta metodología se utiliza con frecuencia en aplicaciones de detección de objetos, reconocimiento de imágenes y reconocimiento de voz, entre otras.

La transferencia del aprendizaje es una técnica de uso habitual ya que:

- Permite entrenar modelos con menos datos etiquetados reutilizando modelos de uso habitual que ya se han entrenado con conjuntos de datos de gran tamaño.
- Ayuda a reducir el tiempo de entrenamiento y los recursos informáticos. Los pesos no se aprenden desde cero, dado que el modelo previamente entrenado ya ha aprendido los pesos a partir de los aprendizajes anteriores.
- Permite aprovechar arquitecturas de modelos desarrolladas por la comunidad de investigadores de Deep Learning, incluidas arquitecturas de uso habitual como GoogLeNet y ResNet.




Figura 5 Flujo de trabajo de transfer learning: carga de red, reemplazo de capas, entrenamiento de red y evaluación de precisión [19]

1.10 IMAGENET

ImageNet es una base de datos de imágenes organizada según la jerarquía de WordNet (actualmente solo los sustantivos), en la que cada nodo de la jerarquía está representado por cientos y miles de imágenes. El proyecto ha sido fundamental para el avance de la investigación en visión por ordenador y aprendizaje profundo. Los datos están disponibles de forma gratuita para los investigadores para su uso no comercial.

1.11 MODELOS DE CLASIFICACIÓN

1.11.1 MAQUINAS DE SOPORTE VECTORIAL (VSM)

Las Máquinas de Soporte Vectorial (SVM por su nombre en inglés Support Vector Machines) es una técnica de clasificación basada en la idea de minimización de riesgo estructural. En muchas aplicaciones las SVM han mostrado tener un mejor desempeño que las redes neuronales tradicionales y han sido introducidas como herramientas poderosas para resolver problemas de clasificación.

Una SVM primero mapea los puntos de entrada a un espacio de características de una dimensión mayor, (Ejemplo, si los puntos de entrada están en $\mathbb{R}^2$ entonces son mapeados por las SVM a $\mathbb{R}^3$) y encuentra un hiperplano que los separe donde maximice el margen del número de clases en este espacio como se observa en la **Figura 6** su comportamiento.




Figura 6 Máquina de soporte vectorial de mínimos cuadrados [22]

Maximizar el margen de cada clase es un problema de programación cuadrática (QP) y puede ser resuelto por su problema dual introduciendo multiplicadores de LaGrange, sin ningún conocimiento de mapeo. La SVM encuentra un hiperplano óptimo utilizando el producto punto con funciones en el espacio de características que son llamadas Kernels. La solución del hiperplano óptimo puede ser escrita como la combinación de unos pocos puntos de entrada que son llamados vectores soporte. [22]

$$\min J(w, b) = \min_{w, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l e_i^2 \quad (1)$$

$$\min J(w, b, \alpha, e) = \min_{w, b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l e_i^2 - \sum_{i=1}^l \alpha_i (y_i (w^t \phi(x_i) + b) - 1 + e_i) \quad (2)$$

Fijamos las derivadas parciales iguales a cero para

$$\frac{\delta J}{\delta w} = 0 \rightarrow w \sum_{i=1}^l \alpha_i y_i \phi(x_i) \quad (3)$$

$$\frac{\delta J}{\delta b} = 0 \rightarrow w \sum_{i=1}^l \alpha_i y_i = 0 \quad (4)$$

$$\frac{\delta J}{\delta e_i} = 0 \rightarrow \alpha_i = C e_i \quad (5)$$

$$\frac{\delta J}{\delta \alpha_i} = 0 \rightarrow y_i (w^t \phi(x_i) + b) - 1 + e_i = 0 \quad (6)$$

Podemos expresar estas ecuaciones en forma más compacta para conseguir

$$\alpha^T y = 0 \quad (7)$$

Donde $y=(y_1 \dots y_n)^T$ y $\alpha=(\alpha_1 \dots \alpha_n)^T$ y:

$$yb + (\Omega + C^{-1}I)\alpha = 1_l \quad (8)$$

Donde 1_l es un vector que tiene l componentes:

$$\Omega(i, j) = y_i y_j K(x_i, x_j), \quad 1 \leq i, j \leq l \quad (9)$$

1.11.2 RANDOM FORESTS

Random Forest es una combinación de árboles predictivos (clasificadores débiles); es decir, una modificación del Bagging, el cual trabaja con una colección de árboles incorrelacionados y los promedia en el cual se tiene que cada árbol depende de los valores de un vector aleatorio de la muestra de manera independiente y con la misma distribución de todos los árboles en el bosque. La generalización de error para los bosques converge a un límite en cuanto el número de árboles en el bosque sea grande. El error de generalización de un bosque de árboles de clasificación depende de la fuerza de los árboles individuales en el bosque y la correlación entre ellos. El uso de una selección aleatoria de características para dividir cada nodo produce tasas de error que se comparan favorablemente al algoritmo AdaBoost pero son más robustos con respecto al ruido (clasificador fuerte). Estimaciones internas supervisan el error, la fuerza y la correlación. Además, estos se utilizan para mostrar la respuesta al aumento del número de características utilizadas

La idea esencial del bagging es promediar muchos modelos ruidosos, pero aproximadamente insesgados, y por lo tanto reducir la varianza. Los árboles son candidatos ideales para el bagging, ya que pueden capturar estructuras de interacción complejas en los datos y, si crecen con suficiente profundidad, tienen un sesgo relativamente bajo.

Dado que los árboles son notoriamente ruidosos, se benefician en gran medida del promediado. Además, dado que cada árbol generado en el bagging está idénticamente distribuido la expectativa de un promedio de B de tales árboles es la misma que la expectativa de cualquiera de ellos. Esto significa que el sesgo

de los árboles ensacados es el mismo que el de los árboles individuales (bootstrap), y la única esperanza de mejora es la reducción de la varianza. Esto contrasta con el boosting, donde los árboles crecen de forma adaptativa para eliminar el sesgo, y, por tanto:

1. Para $b = 1$ a B :
 - a. Dibuja una muestra bootstrap Z^* de tamaño N a partir de los datos de entrenamiento.
 - b. Se crea un árbol forestal aleatorio T_b con los datos de la prueba de arranque, repitiendo recursivamente los siguientes pasos para cada nodo terminal del árbol, hasta que se alcance el tamaño mínimo de nodo N_{min} .
 - i. Seleccionar m variables al azar de las p variables
 - ii. Elija la mejor variable/punto de corte entre las m
 - iii. Dividir el nodo en dos nodos hijos.




Figura 7 Árbol de decisión vs Bosque aleatorio [19]

1.11.3 ARBOLES DE DECISIÓN

Los árboles de decisión (DT) son un método de aprendizaje supervisado no paramétrico que se utiliza para la clasificación y la regresión. El objetivo es crear un modelo que prediga el valor de una variable objetivo mediante el aprendizaje de reglas de decisión simples inferidas a partir de las características de los datos. Un árbol puede verse como una aproximación constante a trozos.

Por ejemplo, en el siguiente ejemplo, los árboles de decisión aprenden de los datos para aproximar una curva senoidal con un conjunto de reglas de decisión si-entonces-si. Cuanto más profundo sea el árbol, más complejas serán las reglas de decisión y más ajustado será el modelo.




Figura 8 Árbol de decisión regresión [28]

Algunas ventajas de los árboles de decisión son

Son fáciles de entender e interpretar. Los árboles pueden visualizarse.

Requiere poca preparación de los datos. Otras técnicas suelen requerir la normalización de los datos, la creación de variables ficticias y la eliminación de los valores en blanco. Sin embargo, hay que tener en cuenta que este módulo no admite valores perdidos.

El coste de utilizar el árbol (es decir, predecir los datos) es logarítmico en el número de puntos de datos utilizados para entrenar el árbol.

Puede manejar tanto datos numéricos como categóricos. Sin embargo, la implementación de scikit-learn no admite por ahora variables categóricas. Otras técnicas suelen estar especializadas en el análisis de conjuntos de datos que sólo tienen un tipo de variable. Consulte los algoritmos para obtener más información.

Capaz de manejar problemas de múltiples salidas.

Utiliza un modelo de caja blanca. Si una situación dada es observable en un modelo, la explicación de la condición se explica fácilmente mediante la lógica booleana. En cambio, en un modelo de caja negra (por ejemplo, en una red neuronal artificial), los resultados pueden ser más difíciles de interpretar.

Es posible validar un modelo mediante pruebas estadísticas. Eso permite dar cuenta de la fiabilidad del modelo.

Funciona bien incluso si sus supuestos son violados en cierta medida por el modelo real a partir del cual se generaron los datos.

1.11.4 RED NEURONAL MULTICAPA

Existen problemas que no son linealmente separables dentro del estudio de redes neuronales por eso se suele juntar en serie algunas capas individuales de neuronas que ofrezcan una mejor solución a dicho problema, lo anterior se conoce como redes neuronales multicapa.




Figura 9 Red Neuronal Multicapa [22]

Se puede observar que el número de patrones R se modifica en función de las neuronas de la capa 1, S^1 , luego el número de neuronas de esta capa se convierten en las entradas de la capa 2, que a su vez tendrá una salida que alimentará a la tercera capa, la salida total de la red neuronal está determinada por la última capa, en función de las anteriores.

$$a_3 = f^3(w^3 f^2(w^2 f^1(w^1 p + b^1) + b^2) + b^3) \quad (10)$$

1.12 APRENDIZAJE GENERAL DE LA RED NEURONAL

Se hace necesario un algoritmo capaz de ajustar automáticamente los pesos y la polarización una capa de neuronas, como se muestra a continuación donde p son los patrones o entradas y t son los targets o salidas correspondiente.

```

Iniciar aleatoriamente  $w, b$ 

Desde épocas=1 a  $N_{\text{épocas}}$ 

    Desde  $q=1$  a  $Q_{\text{repetir}}$ 

         $a_q = f(wp_q + b)$ 

         $e_q = t_q - a_q$ 

         $w = w + e_q t_q^T$ 
    
```

Algoritmo de Aprendizaje general




Figura 10 Esquema de una red neuronal de alimentación directa de una sola capa oculta

1.13 ESCALADO DE LAS ENTRADAS

Dado que la escala de las entradas determina la escala efectiva de los pesos en la capa inferior, puede tener un gran efecto en la calidad del final.




Figura 11 Red neuronal: 10 unidades, sin pérdida de peso [28]

1.14 FUNCIONES DE ACTIVACIÓN

Activation function	Equation	Example	1D Graph
Unit step (Heaviside)	$\phi(z) = \begin{cases} 0, & z < 0, \\ 0.5, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Sign (Signum)	$\phi(z) = \begin{cases} -1, & z < 0, \\ 0, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Linear	$\phi(z) = z$	Adaline, linear regression	
Piece-wise linear	$\phi(z) = \begin{cases} 1, & z \geq \frac{1}{2}, \\ z + \frac{1}{2}, & -\frac{1}{2} < z < \frac{1}{2}, \\ 0, & z \leq -\frac{1}{2}, \end{cases}$	Support vector machine	
Logistic (sigmoid)	$\phi(z) = \frac{1}{1 + e^{-z}}$	Logistic regression, Multi-layer NN	
Hyperbolic tangent	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	Multi-layer Neural Networks	
Rectifier, ReLU (Rectified Linear Unit)	$\phi(z) = \max(0, z)$	Multi-layer Neural Networks	
Rectifier, softplus	$\phi(z) = \ln(1 + e^z)$	Multi-layer Neural Networks	

Copyright © Sebastian Raschka 2016
(<http://sebastianraschka.com>)

Figura 12 Función de Activación

1.15 ERROR CUADRÁTICO MEDIO

La pérdida MSE es usada para la regresión. Como lo dice su nombre es calculado como el promedio de las diferencias entre el valor deseado y el predicho.

1.16 TIPOS DE OPTIMIZADORES

1º Orden: Afectan a la función de pérdida usando su gradiente, siendo el más popular el gradiente descendiente, la derivada indica si la función incrementa o decrementa en un punto determinado mediante la línea tangente a la superficie del error, se caracteriza por un gasto computacional menor.

2º Orden: Usan derivadas de segundo orden o un arreglo de Hessian que es una matriz de derivadas parciales de segundo orden. Requieren un gran costo computacional, pero son capaces de indicar si la derivada de primer orden aumenta o disminuye mostrando la curvatura de la función, suministrando una

superficie cuadrática que toca la función de error, estos requieren un mayor gasto computacional.

1.16.1 ADAM

(Adaptative Moment Estimation)- *Estimación adaptativa del momento*, funciona con momentos de primero y segundo orden. Desarrollado bajo la premisa que no se quiere ir tan rápido para no pasar el mínimo, disminuyendo la velocidad para buscar cuidadosamente. Además, se toma el promedio de disminución exponencial del cuadrado de los gradientes pasados como en AdaDelta. Llamado $M(t)$ y $V(t)$ son valores del momento de primer orden el cual es el promedio y el segundo es la varianza descentralizada de los gradientes respectivamente.

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (11)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (12)$$

Aquí, se toma el promedio de $M(t)$ y $V(t)$ así $E[m(t)]$ puede ser igual a $E[g(t)]$ donde $E[f(x)]$ es un valor esperado de $f(x)$.

Actualizando los parámetros:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \cdot m_t \quad (13)$$

Donde:

$$\beta_1 = 0.9, \beta_2 = 0.9999, \epsilon = 10^{-8} \quad (14)$$

1.17 PCA

El PCA se utiliza para descomponer un conjunto de datos multivariados en un conjunto de componentes ortogonales sucesivos que explican una cantidad máxima de la varianza. En scikit-learn, el PCA se implementa como un objeto transformador que aprende los componentes en su método de ajuste, y se puede utilizar en los nuevos datos para proyectarlos en estos componentes.

PCA centra pero no escala los datos de entrada para cada característica antes de aplicar el SVD. El parámetro opcional `whiten=True` permite proyectar los datos

en el espacio singular mientras se escala cada componente a la unidad de varianza. Esto suele ser útil si los modelos posteriores hacen fuertes suposiciones sobre la isotropía de la señal: este es el caso, por ejemplo, de las máquinas de vectores de apoyo con el núcleo RBF y el algoritmo de agrupación K-Means.

A continuación, se muestra un ejemplo del conjunto de datos del iris, que se compone de 4 características, proyectadas en las 2 dimensiones que explican la mayor parte de la varianza:




Figura 13 PCA of IRIS dataset [29]

1.17.1 MODELOS DE REDUCCIÓN DE DIMENSIONALIDAD

Una matriz de confusión es una representación matricial de los resultados de las predicciones de cualquier prueba binaria que se utiliza a menudo para describir el rendimiento del modelo de clasificación (o "clasificador") sobre un conjunto de datos de prueba cuyos valores reales se conocen.

La matriz de confusión es relativamente sencilla de comprender, pero la terminología relacionada puede ser confusa.

		Predicted Values	
		Negative	Positive
Actual Values	Negative	TN True Negative	FP False positive
	Positive	FN False Negative	TP True Positive

Figura 14 Matriz de confusión con dos etiquetas de clase [29]

Cada predicción puede ser uno de cuatro resultados, basado en cómo coincide con el valor real:

- **Verdadero Positivo (TP):** Predicho Verdadero y Verdadero en realidad.
- **Verdadero Negativo (TN):** Predicho Falso y Falso en realidad.
- **Falso Positivo (FP):** Predicción de verdadero y falso en la realidad.
- **Falso Negativo (FN):** Predicción de falso y verdadero en la realidad.




Figura 15 Matriz de confusión con 3 etiquetas de clase [29]

1.18 PYTHON

Python es un lenguaje que maneja una simplicidad, versatilidad y rapidez de desarrollo; que lo convierten en un lenguaje de propósito general multiplataforma orientado a objetos, permitiendo realizar aplicaciones para Windows, servidores

de red o incluso, páginas web. Es un lenguaje interpretado, lo que significa que no se necesita compilar el código fuente para poder ejecutarlo. [16]

Características del lenguaje

- Propósito general
- Multiplataforma
- Orientado a objetos
- Funciones y librerías
- Sintaxis clara
- Open source
- Lenguaje de alto nivel

1.19 APLICATIVO WEB

Desde mediados de la década de 1980, el mundo ha experimentado una explosión en la capacidad de producir, almacenar y comunicar datos, principalmente en formato digital. Junto con el acceso a la tecnología de la información, las computadoras personales, los teléfonos inteligentes y otros dispositivos portátiles reflejan este crecimiento y almacenamiento de datos mejorado, cálculo de información rápido y entrega de información en Internet [21]

Los sistemas de mantenimiento de registros electrónicos facilitan la recopilación de datos que pueden utilizarse con fines de investigación. Mejoran la estructuración y recuperación de la información del paciente, al tiempo que permiten la inclusión de medidas de práctica clínica y mejoran la identificación y el reclutamiento de pacientes calificados y proveedores de ensayos clínicos. [21]

1.19.1 FLASK

Flask es un framework escrito en Python que permite crear aplicaciones de forma sencilla y rápida. Es decir, un acelerador de tareas que funciona con pocas líneas de código y que ejecuta las aplicaciones rápidamente.

Las ventajas de flask son las mismas ventajas que aporta un framework cualquiera. Aunque hablando de flask, podemos concretarla en las siguientes.

- Estructura del proyecto: las apps que se construyen con Flask tienen elementos y ficheros idénticos. Hay una estructura y se puede seguir al dedillo, facilitando las tareas.

- Colaboración facilitada: colaboración entre programadores que quieran entrar a inspeccionar el proyecto que estás creando.



Figura 16 Framework Flask

CAPITULO 2

2 METODOLOGÍA

En la figura # se ilustra la representación en etapas del desarrollo de la herramienta para detectar las cataratas en los ojos a través de técnicas de inteligencia artificial (Deep Learning – Machine Learning).




Figura 17 Metodología del proyecto

2.1 OBTENCIÓN DE LA IMÁGENES

Es importante el uso de las imágenes adecuadas para lograr obtener resultados más eficientes. Se implementa una base de datos que contiene una gran cantidad de imágenes con pacientes sanos y otros con catarata.

Ocular Disease Intelligent Recognition (ODIR) es una base de datos oftálmica estructurada con más de 4000 mil pacientes. Las imágenes están en color y se toman las del ojo izquierdo y derecho. Este conjunto de datos representa pacientes de la “vida real” recopilada por Shangong Medical Technology Co Ltd

de diferentes hospitales y centros médicos del mundo. Estas imágenes de fondo del ojo son capturadas por varias cámaras en el mercado, como Canon, Zeiss y Kowa, lo que resulta en resoluciones de imagen alta y con buena definición.

Las anotaciones fueron etiquetadas por lectores humanos altamente capacitados con gestión de control de calidad. Clasifican al paciente en varias etiquetas como:

- Normales (N)
- Catarata (C)




Figura 18 imágenes tomadas de la base de datos con sus respectivas características

2.2 EXTRACCIÓN DE PATRONES

Los pasos del proceso de extracción de patrones se pueden ver en la figura xx, donde a nivel general se toman las imágenes de cataratas de ambos ojos, se redimensionan a unas dimensiones aptas para la entrada de la red, luego se aplicó aumentación de datos con rotación y dar vuelta, posteriormente se congelan las primeras capas ya que extraen patrones muy sencillos, además del clasificador para ser reemplazado por uno particular para este problema y así extraer patrones.

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)




Figura 19 proceso de extracción de patrones

La figura 20 muestra las imágenes obtenidas del dataset etiquetadas como cataratas y normales, a una dimensión de 224 x 224 píxeles.




Figura 20 Imágenes de Cataratas y Normales

La figura 3 muestra la aumentación de datos donde se puede ver la rotación y dar vuelta lo cual es adecuado para incrementar la diversidad de los datos lo que da la posibilidad de una mejor generalización del modelo, haciéndolo capaz de identificar entradas nunca vistas.

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)




Figura 21 Aumentación de datos

La figura 21 muestra el modelo de extracción de patrones usado el cual combina se usó el **input_preprocess** de cada red convolucional para adecuar las imágenes a las condiciones óptimas de cada red convolucional y su entrenamiento sea efectivo, posterior al uso de los modelos preentrenados la capa de **Global Average** realiza una disminución de longitud promediando altura y ancho, posteriormente **DropOut** hace un apagado aleatorio del 20% de las redes neuronales para evitar overfitting, y que solo se **memorice** el dataset de entrada, la etapa final es el aplanamiento para convertir el patrón en un vector unidimensional.




Figura 22 Arquitectura modelo de extracción de patrones

2.2.1 INCEPTIONV3

De igual manera se comparó el anterior modelo con Inception V3, el cual se ve en la figura fs, el cual posee bloques de compilación simétrico, que incluyen convoluciones, reducción promedio, reducción máxima, concatenaciones, retirados y capas completamente conectadas.

<https://cloud.google.com/tpu/docs/inception-v3-advanced?hl=es-419>

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)




Figura 23 fs Modelo InceptionV3

CONVOLUCIÓN DEL INCEPTIONV3




Figura 24 Arquitectura de la convolución del INCEPTIONV3




Figura 25 Convolución para el entrenamiento de la red neuronal




Figura 26 Ejemplo con dos imágenes similares

2.2.2 MOVILNETV2

Se decidió usar Transfer Learning para obtener una mayor precisión y velocidad a la hora de obtener resultados, para esto se consideraron dos modelos de entrenamiento, bases para extracción de patrones, el primero fue MobileNetV2 el cual posee una arquitectura conforme a la figura # donde se reemplazó el clasificador según la problemática para determinar las cataratas




Figura 27 fd Modelo MobileNetV2

2.3 ENTRENAMIENTO DE LOS MODELOS

Se realizó un entrenamiento de los modelos de extracción de patrones, es decir, se tomó las arquitecturas de las **figuras fs y fs** sin sus respectivos clasificadores, y una aplanación (**flatten**) de la respuesta, previo a esto se preparó el dataset según el flujo de la figura #.

2.4 CLASIFICACIÓN

Las imágenes obtenidas en el proceso de clasificación se dan a partir de la adquisición y clasificación con la base de datos, con un total de 2000 muestras donde las primeras 1000 mil pertenecen a un ojo sin catarata y las otras 1000 mil a un ojo enfermo con catarata.

En la primera fase del proyecto se efectúa la clasificación de las imágenes obtenidas, con la cual se desarrollan diferentes algoritmos de inteligencia artificial para la segmentación y extracción de patrones, donde el 80% de las imágenes son tomadas para el entrenamiento y el 20% para el test de validación. La tabla # muestra los porcentajes generales de clasificación obtenidos por diferentes técnicas de inteligencia artificial (Machine Learning – Deep Learning).

Debido a que la extracción de patrones fue un proceso efectivo, los clasificadores usados de machine learning tuvieron una configuración sencilla.

2.4.1 MULTI LAYER PERCEPTION

El perceptrón multicapa usado tiene la siguiente arquitectura, la cual se ha seleccionado teniendo en cuenta tomar un número reducido de capas ocultas para evitar el sobre entrenamiento de la red neuronal y que esta memorizara las predicciones, de la mano de esto la función de activación **Relu**, a cuál debido a su naturaleza no activa todas las neuronas al mismo tiempo, se presenta una restricción de signo ayudando a que la red entiendo mejor los patrones. mientras que el optimizador **ADAM** es la opción más equilibrada para obtener el mínimo global de los problemas en el menor tiempo posible, así potencializando el rendimiento de la red neuronal razón por lo cual se eligió un learning rate 0.001 para los cambios se lleven a pasos tal que no se pierda el rastro del mismo global.

Tabla 1 perceptrón multicapa

Parámetro	Valor
Capas ocultas	100
Función de activación	Relú
optimizador	adam
alpha	1
learning rate	0.001

2.4.2 RANDOM FOREST

El Random Forest usado tiene la siguiente arquitectura, estos hiperparámetros se escogieron con los siguientes criterios, la profundidad máxima de la red llamada **max_depth**, se definió como 5 que es un valor intermedio o promedio, para tener un balance de decisiones, ya que si los árboles tienen muchas divisiones se puede perder rendimiento en generalización al intentar buscar una característica que no tienen todas las muestras, por lo que 10 árboles fue suficiente para evitar una demora innecesaria de tiempo.


Tabla 2 Random Forest

Parámetro	Valor
max_depth	5
estimators	10
max_features	1


2.5 SUPORT VECTOR MACHINE (SVM)

Support Vector Machine o maquinas de vector soporte son un conjunto de algoritmos de aprendizaje supervisado desarrollados por Vladimir Vapnik y su equipo en los laboratorios de AT&T Bell. Estos nos permiten realizar clasificaciones y regresiones, a continuación, se muestra las metodologías y arquitecturas usadas en el proyecto, también de como es el funcionamiento de esta técnica de clasificación.


- 1) Lineal con separación perfecta



- 2) Lineal sin separación perfecta



3) No lineal



A partir de estos parámetros de funcionamiento se plantea lo siguiente




Figura 28 Datos de entrenamiento

La figura # muestra dos clases los cuales son los datos de entrenamiento para el SVM

Entonces se analizó, como se puede definir la línea de decisión cuando no hay una separación perfecta. Se consideran las muestras clasificadas erróneamente para ver el resultado.




Figura 29 Separación errónea

El Kernel maneja una matemática altamente compleja la cual permite realizar separación de los datos de una forma más eficiente, entre estos tenemos.

$$K(\mathbf{x}', \mathbf{x}) = \langle h(\mathbf{x}'), h(\mathbf{x}) \rangle =$$

linear $\langle \mathbf{x}', \mathbf{x} \rangle$

polynomial $(1 + \langle \mathbf{x}', \mathbf{x} \rangle)^n$

radial basis $\exp(-\|\mathbf{x}' - \mathbf{x}\|^2/c)$

sigmoid $\tanh(K_1 \langle \mathbf{x}', \mathbf{x} \rangle + K_2)$

Y se tienen en consideración el truco del Kernel, donde vemos los siguiente




Figura 30 Separación lineal imposible




Figura 31 Separación lineal perfecta

En la figura # se observa la arquitectura normalmente usada para la clasificación de clases usando SVM.




Figura 32 Arquitectura Support Vector Machine

2.5.1 LINEAR

El linear usado tiene la siguiente arquitectura, donde se puede notar que el kernel elegido fue linear para buscar una separabilidad de esto modo en las características, al tratarse de solo 2 clases, esta posibilidad era viable, debido a la complejidad de los datos se usó el valor de C bajo para que el control de error sea más a detalle y sea posible, establecer una línea adecuada en la región de separación entre las muestras con afectación ocular y las sanas, para este se dejó gamma como un valor por defecto ya que al ser una separación lineal, la curvatura en la frontera no tiene sentido ser calibrada y no afectaría la respuesta del modelo.

Tabla 3 SVM -- LINEAR

Parámetro	Valor
Kernel	linear
C	0.025
gamma	scale

2.5.2 NO LINEAR

El No Linear usado tiene la siguiente arquitectura, que es muy similar a la versión lineal, el kernel usado RBF o radial basis function, esta ayuda a obtener una separación no lineal, basado en una función radial que almacena los vectores de soporte durante el entrenamiento y no todo el dataset, lo que hace que reduzca la complejidad del problema, enfoque que usa de manera similar el algoritmo de vecinos cercanos, ya que en base de los datos en la frontera se establece la curva de separación, el hiperparametro C permació en 0.025 ya que el proposito era evaluar como afectaba el cambio de kernel a una solución no lineal, mientras que se eligió un gamma de 0.01 para tener una curvatura no tan exagerada que tomara muestras de otras zonas y asi creando un potencial error.

Tabla 4 SVM -- No Linear

Parámetro	Valor
Kernel	rbf
C	0.025
gamma	0.01

2.6 PCA

Se uso el PCA ya que es una representación de X (es una transformación lineal de X), donde las columnas de Y no tienen correlación:

$$C^{\hat{n}}(k, l) = 0$$

Para

$$k \neq l$$

Ordenando de mayor a menor las columnas de Y que están ordenadas por la mejor importancia.

En la siguiente figura se muestra la arquitectura que usa el PCA




Figura 33 Estrategia con PCA

Las ventajas del PCA son:

1. Nos permite la representación de muchas características y es mucho mas sencilla ya que se reduce la dimensionalidad
2. Nos permite tener una gráfica para visualización de los datos

2.7 DESARROLLO HERRAMIENTA WEB

Luego de evaluar los resultados se desarrolló un producto web usando el microframework de Python Flask para esta labor, ya que al ser una aplicación de inteligencia artificial el lenguaje con las mejores librerías es Python como keras, tensorflow, etc. Por lo que se decidió implementar el desarrollo en un framework web en Python, Flask presenta la versatilidad y herramientas necesarias para un sitio óptimo.

La figura # b, muestra cómo se carga la imagen a nivel de frontend desde un archivo hacia el aplicativo desde la etiqueta HTML en la figura # a, donde se almacena el archivo y se da una previsualización del gráfico.

```
<input
  class="input-form"
  type="file"
  name="file"
  id="uploadImage"
  accept=".png .jpg .jpeg"
/>
```

Figura 34 (a) atributos

```
function loadImage(e) {
  let file = e.target.files[0];
  loadedImage = file;
  let reader = new FileReader();

  reader.onload = function (event) {
    loadedImageComponent.src = event.target.result;
  };
  reader.readAsDataURL(file);
  console.log(reader);
}
```

Figura 35 (b) cargar imagen en el Frontend

Luego de enviar en un formulario la imagen es recibida en los scripts de Python donde se almacena según la figura # en una carpeta llamada uploads, para posteriormente ser usada en el algoritmo de la figura #, en la cual se carga la imagen de interés y esta redimensiona a 224px 224px, estas se convierten a un array la imagen, esta se redimensiona a [1,224,224] para ser enviada posteriormente al modelo de predicción.

```
@app.route('/predict',methods=["POST"])
def predict():
    print(request)
    if request.method == "POST":
        print(request.files)
        f = request.files['file']
        basePath = os.path.dirname(__file__)
        file_path = os.path.join(basePath,'uploads',secure_filename(f.filename))
        f.save(file_path)

        res = prediction(file_path)
        print(res)
        return jsonify({'res':str(res[0][0])})
    return None
```

Figura 36 Recepción de imagen

```
def prediction(path):

    img = cv2.resize(cv2.imread(path),(width_shape,height_shape),interpolation =cv2.INTER_AREA)
    model = load_model(MODEL_PATH)
    x = np.asarray(img)
    x = preprocess_input(x)
    x = np.expand_dims(x,axis=0)

    pred = model.predict(x)

    return pred
```

Figura 37 Algoritmo de predicción

CAPITULO 3

3 RESULTADOS

Este capítulo expone de manera clara y concisa los resultados obtenidos durante el desarrollo del proyecto.

3.1 ACONDICIONAMIENTO DE LAS IMÁGENES PARA SU PROCESAMIENTO

Para el acondicionamiento de las imágenes oculares, se verifico en el repositorio o base de datos cual era la etiqueta respectiva de las asignaciones a un ojo con catarata y un ojo normal o sea un paciente sano, se encontró que las etiquetas para catarata correspondían a C y los normales a N. Luego de saber esto se implementaron algoritmos para separar todas las imágenes que estaban en el repositorio y organizarlas adecuadamente.

Para organizar estas imágenes se usó Pandas, este permite manejar los diccionarios donde se encuentran almacenadas todas las etiquetas y separarlas de las demás imágenes oculares que no sean pertinentes o necesarias para el desarrollo del proyecto. En la figura # se muestra como leemos el dataset de las imágenes oculares, he imprimimos en pantalla sus referencias completas para comprender como realizar la separación.

```
[ ] 1 df = pd.read_csv("/content/drive/MyDrive/Datasets/Ocular/full_df.csv")
    2 df.head(3)
```

ID	Patient Age	Patient Sex	Left-Fundus	Right-Fundus	Left-Diagnostic Keywords	Right-Diagnostic Keywords	N	D	G	C	A	H	M	O	filepath	labels	target	filename	
0	0	69	Female	0_left.jpg	0_right.jpg	cataract	normal fundus	0	0	0	1	0	0	0	0	./input/ocular-disease-recognition-odirsk/ODI...	[N]	[1, 0, 0, 0, 0, 0, 0, 0]	0_right.jpg
1	1	57	Male	1_left.jpg	1_right.jpg	normal fundus	normal fundus	1	0	0	0	0	0	0	0	./input/ocular-disease-recognition-odirsk/ODI...	[N]	[1, 0, 0, 0, 0, 0, 0, 0]	1_right.jpg
2	2	42	Male	2_left.jpg	2_right.jpg	laser spot, moderate non proliferative retinopathy	moderate non proliferative retinopathy	0	1	0	0	0	0	0	1	./input/ocular-disease-recognition-odirsk/ODI...	[D]	[0, 1, 0, 0, 0, 0, 0, 0]	2_right.jpg

Figura 38 etiquetas de la base de datos

3.2 ALGORITMOS PARA EL PROCESAMIENTO Y EXTRACCIÓN DE PATRONES

Se decidió usar Transfer Learning para obtener una mayor precisión y velocidad a la hora de obtener resultados, para esto se consideraron dos modelos de entrenamiento bases para la extracción de patrones, el primero fue MobileNetV2 el cual posee una arquitectura conforme a la figura # donde se reemplazó el clasificador según la problemática para determinar las cataratas.




Figura 39 Arquitectura MobileNetV2

La extracción de patrones usando esta red se ve en la figura # y (a) y (b) para 2 y 3 dimensiones donde es posible diferencias visualmente ambas clases.

3.3 CLASIFICACIÓN

Las imágenes obtenidas en el proceso de clasificación se dan a partir de la adquisición y clasificación con la base de datos, con un total de 2000 muestras donde las primeras 1000 mil pertenecen a un ojo sin catarata y las otras 1000 mil a un ojo enfermo con catarata.

Las figuras # y # muestran cuanto separan las capas convolucionales de la red mobile netv2, después de haber pasado por todas las capas de separación, esa red extrae los patrones con las capas de convolución y solo se usan esas capas, para la parte de clasificación que es una red densamente conectada con una red perceptrón multicapa, este se sustituye por el problema que se tiene en la separación, y muestra cómo se está separando después de pasar por las capas convolucionales de la red mobilnetv2.

Las figuras #, # y # muestran el clasification report, donde se ven las distintas metricas del clasificador el de interés es el que dice acurasy que es la precisión que tiene la red.

En general, están las matrices de confusión figura #, # y # donde representan que también se comportó binariamente la red sabiendo que tanto se equivocó y en cuales no se equivocó, se puede determinar que en su mayoría después de que se extraen los patrones si pueden identificar si tiene o no catarata.

3.3.1 CLASIFICACIÓN RANDOM FOREST

MLP-MOBILENETV2




Figura 40 Matriz de confusión *Random Forest* con patrones extraídos por MLP-MobileNetv2

	precision	recall	f1-score	support
No Catarata	0.98	0.88	0.93	58
Catarata	0.93	0.99	0.96	98
accuracy			0.95	156
macro avg	0.96	0.93	0.94	156
weighted avg	0.95	0.95	0.95	156

Figura 41 *Classification Report* de *Random Forest* con patrones extraídos por *MobilenetV2*

MLP-INCEPTIONV3




Figura 42 Matriz de confusión *Random Forest* con patrones extraídos por MLP-InceptionV3

	precision	recall	f1-score	support
No Catarata	0.66	0.96	0.78	79
Catarata	0.93	0.48	0.63	77
accuracy			0.72	156
macro avg	0.79	0.72	0.71	156
weighted avg	0.79	0.72	0.71	156

Figura 43 *Clasification Report* de *Random Forest* con patrones extraídos por MLP-InceptionV3

Se puede observar que la extracción de patrones se queda mejor para Mobilenetv2 ya que la matriz de confusión de la figura 37 muestra que diferencia muestra unos falsos positivos de menores al 10% para cada clase, siendo 1.9% para no cataratas y 6.7% de cataratas. mientras que el clasificación reporte de la figura 38, enseña que todas las métricas son mayor sal 80%, con un recall mayor de 99% para cataratas lo cual es un rendimiento casi perfecto y determina el gran porcentaje de clasificación.

RANDOMFOREST-MOBILENETV2




Figura 44 Matriz de confusión *Random Forest* con patrones extraídos por T-MobileNetV2

	precision	recall	f1-score	support
No Catarata	0.90	0.91	0.91	58
Catarata	0.95	0.94	0.94	98
accuracy			0.93	156
macro avg	0.92	0.93	0.92	156
weighted avg	0.93	0.93	0.93	156

Figura 45 Clasification Report de *Random Forest* con patrones extraídos por T-MobileNetV2

RANDOMFOREST-INCEPTIONV3




Figura 46 Matriz de confusión *Random Forest* con patrones extraídos por T-InceptionV3

	precision	recall	f1-score	support
No Catarata	0.86	0.92	0.89	79
Catarata	0.92	0.84	0.88	77
accuracy			0.88	156
macro avg	0.89	0.88	0.88	156
weighted avg	0.89	0.88	0.88	156

Figura 47 *Clasification Report* de *Random Forest* con patrones extraídos por T-InceptionV3

3.4.2 CLASIFICACIÓN MAQUINAS DE SOPORTE VECTORIAL DE MÍNIMOS CUADRADOS

SVC_LINEAR-MOBILENETV2




Figura 48 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV2

	precision	recall	f1-score	support
No Catarata	0.98	0.90	0.94	58
Catarata	0.94	0.99	0.97	98
accuracy			0.96	156
macro avg	0.96	0.94	0.95	156
weighted avg	0.96	0.96	0.95	156

Figura 49 Clasification Report máquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV2

SVC_Linear-InceptionV3




Figura 50 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV3

	precision	recall	f1-score	support
No Catarata	0.94	0.92	0.93	79
Catarata	0.92	0.94	0.93	77
accuracy			0.93	156
macro avg	0.93	0.93	0.93	156
weighted avg	0.93	0.93	0.93	156

Figura 51 Clasification Report Máquinas de soporte con patrones extraídos por SVC_LINEAR-MobilenetV3

SVC_NO_LINEAR-MOBILENETV2




Figura 52 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobilenetV2

	precision	recall	f1-score	support
No Catarata	0.78	0.91	0.84	58
Catarata	0.94	0.85	0.89	98
accuracy			0.87	156
macro avg	0.86	0.88	0.87	156
weighted avg	0.88	0.87	0.87	156

Figura 53 Clasification Report Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobilenetV2

SVC_No_linear-InceptionV3




Figura 54 Matriz de confusión Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobileNetV3

	precision	recall	f1-score	support
No Catarata	0.85	0.77	0.81	79
Catarata	0.79	0.86	0.82	77
accuracy			0.81	156
macro avg	0.82	0.81	0.81	156
weighted avg	0.82	0.81	0.81	156

Figura 55 Clasification Report Maquinas de soporte con patrones extraídos por SVC_NO_LINEAR-MobileNetV3

En la primera fase del proyecto se efectúa la clasificación de las imágenes obtenidas, con la cual se desarrollan diferentes algoritmos de inteligencia artificial para la segmentación y extracción de patrones, donde el 80% de las imágenes son tomadas para el entrenamiento y el 20% para el test de validación. La tabla # muestra como fue la precisión de las distintas capas de extracción de patrones de la MobileNetv2, InceptionV3 y el contrastado con los clasificadores que son las columnas (Random Forest, perceptrón multicapa y las máquinas de soporte vectorial)

Tabla 5 Resultados generales

Precisión	MLP	Random Forest	SVC_Linear	SVC_NoLinear
InceptionV3	72%	88%	93%	81%
MobileNetV2	95%	93%	96%	87%

Luego de obtener los resultados de la extracción de patrones se procedió a exponer estas características a un conjunto de árboles de decisión.

MOBILENETV2




Figura 56 MobileNetv2 en 3D




Figura 57 MobileNetv2 en 2D

3.4 APLICACIÓN WEB

Esta aplicación esta alojada en un repositorio de GitHub donde se le pueden realizar sus respectivos cambios a través de las ramas y commits, esto es muy esencial a la hora de cambiar algún parámetro y poder ver que se hizo anteriormente para tener una comparación y un seguro del funcionamiento de la aplicación web.

models	v 1.0	last month
static	spinner and clean	last month
templates	spinner and clean	last month
uploads	v 1.0	last month
.gitignore	Initial commit	last month
LICENSE	Initial commit	last month
Procfile	Initial Commit	3 months ago
README.md	starter -> template	3 months ago
main.py	v 1.0	last month
requirements.txt	fix req	last month
runtime.txt	fix req	last month

Figura 58 Repositorio de la aplicación web




Figura 59 Porcentajes de los lenguajes y Frameworks usados para la API

Las figuras permiten ver cómo funciona el aplicativo web, donde es posible cargar una imagen y posteriormente obtener un dictamen de la situación ocular de la persona todo en base al análisis previamente realizado de los resultados obtenidos en los distintos clasificadores

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)



Figura 60 Aplicación Web cargando una imagen




Figura 61 Aplicación Web clasificando la imagen

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)




Figura 62 Aplicación Web clasificando la imagen

CONCLUSIONES

Fue posible realizar un proceso de análisis y ciencia de datos para identificar imágenes oculares con y sin catarata usando un dataset existente en la plataforma Kaggle, usando transfer learning basado en los modelos convolucionales **InterceptionV3** y **MobilenetV2**, para la extracción de patrones, reentrenando sus pesos para una separación de características adecuadas. donde se pude notar que el segundo modelo presento **MobilenetV2**, una mejor separación de los datos, confirmando el gran valor de usar aprendizaje por transferencia para optimizar tiempos de diseño y entrenamiento en una problemática de clasificación compleja en múltiples dimensiones.

A partir de los patrones obtenidos, se pudo verificar distintos clasificadores de **Machine Learning** y **Deep Learning**, donde se puede afirmar que en cuestión de clasificar algoritmos de Machine Learning como Máquinas de Soporte Vectorial, Random Forest, tienen un grande rendimiento y tiempos de entrenamiento mejores que un ciertas arquitecturas de Deep Learning, por lo que un pipeline óptimo de resolución de problemas complejos es hacer uso de Transfer learning y Machine Learning , aportando gran precisión y velocidad de respuesta.

Fue posible desarrollar un aplicativo web con el microframework Flask el cual nos ayuda a combinar las bondades de la red con el manejo de datos, logrando un producto interactivo capaz de realizar tareas de clasificación de imágenes oculares, aportando al campo científico un estudio exhaustivo de anomalías médicas y a la vez un producto manejable por cualquier persona y enfocada a ser una herramienta médica para apoyo de los diagnósticos.

REFERENCIAS

- [1] C. De, M. Humana, D. Alexander, and A. Torres, “UNIVERSIDAD NACIONAL DE LOJA ÁREA DE LA SALUD HUMANA Autor: Tesis previa a la obtención del título de Médico General.”
- [2] A. Shen *et al.*, “Metastatic neuroendocrine tumors mimicking as primary ocular disease,” *Am J Ophthalmol Case Rep*, vol. 26, Jun. 2022, doi: 10.1016/j.ajoc.2022.101425.
- [3] R. Martinez-Carrasco, P. Argüeso, and M. E. Fini, “Membrane-associated mucins of the human ocular surface in health and disease,” *Ocular Surface*, vol. 21. Elsevier Inc., pp. 313–330, Jul. 01, 2021. doi: 10.1016/j.jtos.2021.03.003.
- [4] D. Juan, D. Esteve, G. Ayala Gallego, and A. S. Vidal, “Técnicas para la correspondencia y reconocimiento Esther de Ves Cuenca,” 1999.
- [5] K. Asiedu, “Role of ocular surface neurobiology in neuronal-mediated inflammation in dry eye disease,” *Neuropeptides*, vol. 95. Churchill Livingstone, Oct. 01, 2022. doi: 10.1016/j.npep.2022.102266.
- [6] I. Flores-González and D. H. Calonje, “Telemedicine for detection of ocular diseases capable to cause blindness in Mexico,” *Revista Mexicana de Oftalmología*, vol. 91, no. 6, pp. 297–305, Nov. 2017, doi: 10.1016/j.mexoft.2016.12.002.
- [7] M. Chacón *et al.*, “Impedance-based non-invasive assay for ocular damage prediction on in vitro 3D reconstructed human corneal epithelium,” *Bioelectrochemistry*, vol. 146, Aug. 2022, doi: 10.1016/j.bioelechem.2022.108129.
- [8] R. N. van Gelder, “Molecular Diagnostics for Ocular Infectious Diseases: 78th Edward Jackson Memorial Lecture, American Academy of Ophthalmology,” *Am J Ophthalmol*, vol. 235, pp. 300–312, Mar. 2022, doi: 10.1016/j.ajo.2021.12.002.
- [9] W. G. Loaiza, “Monografía Reconocimiento De Objetos Usando Técnicas De Inteligencia Artificial.”


- [10] C. Y. Zhang *et al.*, “Corneal perforation in ocular graft-versus-host disease,” *Am J Ophthalmol Case Rep*, vol. 24, Dec. 2021, doi: 10.1016/j.ajoc.2021.101224.
- [11] M. N. Pham, R. L. Fuleihan, K. E. Sullivan, and C. Cunningham-Rundles, “Ocular Manifestations in Primary Immunodeficiency Disorders: A Report From the United States Immunodeficiency Network (USIDNET) Registry,” *Journal of Allergy and Clinical Immunology: In Practice*, vol. 10, no. 7, pp. 1788–1796, Jul. 2022, doi: 10.1016/j.jaip.2022.03.028.
- [12] P. Karely, R. Laureano, D. Álvaro, and J. M. Jarquín, “Facultad de Medicina Tesis para obtener el Diploma de Especialidad en Oftalmología.”
- [13] S. Kheder Alatawi, H. E. Alyahyaw, N. Akhter, R. A. Alharbi, W. AM Ahmed, and S. Saleh R. Almalki, “Prevalence of adenoviruses as ocular disease causatives in Saudi Arabia,” *Saudi Journal of Biological Sciences*, vol. 29, no. 4. Elsevier B.V., pp. 2026–2032, Apr. 01, 2022. doi: 10.1016/j.sjbs.2021.12.053.
- [14] P. Therkildsen *et al.*, “A nationwide study of ocular manifestations leading to hospital contacts among patients with giant cell arteritis,” *Semin Arthritis Rheum*, vol. 56, Oct. 2022, doi: 10.1016/j.semarthrit.2022.152071.
- [15] L. Castilla-Guerra, A. Gómez Escobar, and J. F. Gómez Cerezo, “Revista Clínica Española Utility of Doppler ultrasound for the study of ocular vascular disease,” 2021. [Online]. Available: www.elsevier.es/rce
- [16] E. Sarrias-Arrabal, G. Izquierdo-Ayuso, and M. Vázquez-Marrufo, “Attentional networks in neurodegenerative diseases: anatomical and functional evidence from the Attention Network Test,” *Neurologia*. Spanish Society of Neurology, 2020. doi: 10.1016/j.nrl.2020.05.015.
- [17] F. Silva Molina, “La Inteligencia Artificial y su incidencia en las comunicaciones.”
- [18] acobo Zavaleta, W. Zavaleta-Gavidia, V. Zavaleta-Gavidia, and P. Clave, “Deep Learning y enfermedades oculares,” 2022.
- [19] MathWorks: Redes Neuronales Convolucionales. <https://la.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>, visitado el 2019-11-23.

- [20] Moreno, G. “*Estadística de Sequías y Heladas Meteorológicos en Colombia*”. IDEAM. 1996. Disponible:
<http://documentacion.ideam.gov.co/openbiblio/bvirtual/009375/009375.pdf>
- [21] Malpica, J. “*Inteligencia Artificial y conciencia*”. Departamento de Matemáticas de la UAH. Disponible:
http://www3.uah.es/benito_fraile/ponencias/inteligencia-artificial.pdf
- [22] Sucar, L. “*Métodos de inteligencia artificial*”. Tecnologías de Información. UPAEP. Disponible en : <https://ccc.inaoep.mx/~esucar/Clases-MetIA/MetIA-16.pdf>
- [23] G. B. Bernal and S. General, “ALEJANDRO GAVIRIA URIBE Ministro de Salud y Protección Social FERNANDO RUIZ GÓMEZ Viceministro de Salud Pública y Prestación de Servicios CARMEN EUGENIA DÁVILA GUERRERO Viceministra de Protección Social.”
- [24] Ting, Fung Fung, Yen Jun Tan y Kok Swee Sim: Convolutional neural network improvement for breast cancer classification. Expert Systems with Applications, 120:103–115, 2019, ISSN 09574174. <https://doi.org/10.1016/j.eswa.2018.11.008>.
- [25] Chougrad, Hiba, Hamid Zouaki y Omar Alheyane: Deep Convolutional Neural Networks for breast cancer screening. Computer Methods and Programs in Biomedicine, 157:19–30, 2018, ISSN 18727565. <https://doi.org/10.1016/j.cmpb.2018.01.011>.
- [26] Google LLC: Kaggle, 2010. <https://www.kaggle.com/>, visitado el 2022-07-05
- [27] MathWorks: Redes Neuronales Convolucionales. <https://la.mathworks.com/solutions/deep-learning/convolutional-neural-network.html>
- [28] Scikit-learn: Árboles de decisión <https://scikit-learn.org/stable/modules/tree.html>
- [29] Scikit-learn: Descomposición de señales en componentes (problemas de factorización de matrices) <https://scikit-learn.org/stable/modules/decomposition.html#pca>


ANEXOS

```
1 plt.figure(figsize=(12,7))
2
3 for i in range(10):
4     sample = random.choice(range(len(dataset)))
5     image = dataset[sample][0]
6     category = dataset[sample][1]
7     label = ("Cataract","Normal")[category == 0]
8     plt.subplot(2,5,i+1)
9     plt.imshow(image)
10    plt.xlabel(label)
11
12
```

/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:7: DeprecationWarning: In future, it will be an error for 'np.bool_' scalars to be interpreted as an int




```
1 from sklearn.metrics import confusion_matrix
2 from sklearn.metrics import ConfusionMatrixDisplay
3 import matplotlib.pyplot as plt
4 import numpy as np
5
6 cm = confusion_matrix(predict_,y_test)
7 disp = ConfusionMatrixDisplay(confusion_matrix=cm,display_labels=["Catarata","No Catarata"])
8 disp.plot(cmap=plt.cm.Blues)
9 plt.show()
```



DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)


```
1 plt.figure(figsize=(12,7))
2
3 for i in range(10):
4     sample = random.choice(range(len(dataset)))
5     image = dataset[sample][0]
6     category = dataset[sample][1]
7     label = ("Cataract", "Normal")[category == 0]
8     plt.subplot(2,5,i+1)
9     plt.imshow(image)
10    plt.xlabel(label)
11
12
```

/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:7: DeprecationWarning: In future, it will be an error for 'np.bool_' scalars to be interpreted as an index
import sys




```
3 for i in range(10):
4     sample = random.choice(range(len(dataset)))
5     image = dataset[sample][0]
6     augmented_data = data_aug(tf.expand_dims(image,0))
7     category = dataset[sample][1]
8     label = ("Cataract", "Normal")[category == 0]
9     plt.subplot(2,5,i+1)
10    plt.imshow(augmented_data[0]/255)
11    plt.xlabel(label)
12
```

/usr/local/lib/python3.7/dist-packages/ipykernel_launcher.py:8: DeprecationWarning: In future, it will be an error for 'np.bool_' scalars to be interpreted as an index




```
21 for target,val,color,marker in zip([0,1],labels,colors,markers):
22     row_ix = np.where(y_train == target)[0]
23     ax.scatter(new_components[row_ix, 0], new_components[row_ix, 1], new_components[row_ix, 2],marker=marker, edgecolor="k",c=color,label=val)
24
25
26
27 ax.w_xaxis.set_ticklabels([])
28 ax.w_yaxis.set_ticklabels([])
29 ax.w_zaxis.set_ticklabels([])
30 ax.legend()
31 plt.show()
32
```



DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)

```
1 classifiers = {
2     "Knc": KNeighborsClassifier(3),
3     "SVC_Linear": SVC(kernel="linear", C=0.025),
4     "SVC_NoLinear": SVC(gamma=0.01, C=0.025),
5     "Guassian": GaussianProcessClassifier(1.0 * RBF(1.0)),
6     "DecesionTree": DecisionTreeClassifier(max_depth=5),
7     "RandomForest": RandomForestClassifier(max_depth=5, n_estimators=10, max_features=1),
8     "MLP": MLPClassifier(alpha=1, max_iter=1000),
9     "AdaBoost": AdaBoostClassifier(),
10    "GaussianNB": GaussianNB(),
11    "QDA": QuadraticDiscriminantAnalysis(),
12 }
```

```
1 from sklearn.metrics import confusion_matrix
2 from sklearn.metrics import ConfusionMatrixDisplay
3 import matplotlib.pyplot as plt
4 import numpy as np
5
6 cm = confusion_matrix(predict, y_test, normalize="true")
7 disp = ConfusionMatrixDisplay(confusion_matrix=cm, display_labels=["No Catarata", "Catarata"])
8 disp.plot(cmap=plt.cm.Blues)
9 plt.savefig(path_url+"/confussion_matrix.jpg")
10 plt.show()
11
```



APLICACIÓN WEB – CODIGOS

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)

models	v 1.0	last month
static	spinner and clean	last month
templates	spinner and clean	last month
uploads	v 1.0	last month
.gitignore	Initial commit	last month
LICENSE	Initial commit	last month
Procfile	Initial Commit	3 months ago
README.md	starter -> template	3 months ago
main.py	v 1.0	last month
requirements.txt	fix req	last month
runtime.txt	fix req	last month

 README.md 

title	description	tags
Flask	A popular minimal server framework for Python.	python flask

Python Flask Example

This is a [Flask](#) app that serves a simple JSON response.

 [Deploy on Railway](#)

🌟 Features

- Python
- Flask

👤 How to use

- Install Python requirements `pip install -r requirements.txt`
- Start the server for development `python3 main.py`

CSS de la aplicación web

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)

```
177 lines (141 sloc) | 2.38 KB
Raw Blame

1  *{
2      margin: 0;
3      padding: 0;
4      font-family: Arial, Helvetica, sans-serif;
5  }
6
7  .header{
8      background-color: #5a5aeb;
9      color: white;
10     padding: 20px 40px;
11     font-weight: bold;
12     font-size: 20px;
13 }
14
15
16 .container{
17     padding: 10px;
18     text-align: center;
19 }
20
21 .mt-10 {
22     margin-top: 10px
23 }
24
25
26 .img{
27     border: 1px solid rgb(160, 160, 160);
28     width: 30%;
29     height: 50%;
30     margin: auto;
31     border-radius: 10px;
32 }
33
34 @media (max-width: 900px) {
35     .img{
36         width: 40%;
37     }
38 }
```

JS PRINCIPAL DE LA API

```
81 lines (69 sloc) | 2.3 KB
Raw Blame

1  /* Load Image */
2  function loadImage(e) {
3      let file = e.target.files[0];
4      loadedImage = file;
5      let reader = new FileReader();
6
7      reader.onload = function (event) {
8          loadedImageComponent.src = event.target.result;
9      };
10     reader.readAsDataURL(file);
11     console.log(reader);
12 }
13
14
15 /* Clean data */
16 function cleanAction() {
17     result.innerHTML = "";
18     loadedImageComponent.src = "";
19     result.classList.remove("good");
20     result.classList.remove("bad");
21     loadedImage = "";
22 }
23
24 /*Close toast */
25 function closeToast() {
26     toast.classList.toggle("no_visible");
27 }
28
29 /* sumit Form */
30 async function sendForm(e) {
31
32     /* don't let continue if there is no loaded an image */
33     if (!loadedImageComponent.src || !loadedImage) {
34         toastContent.innerHTML = "Debe cargar la imagen";
35         toast.classList.toggle("no_visible");
36         return;
37     }
38 }
```

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)

```
39   try {
40     loadingScreen.classList.toggle("no_visible");
41     const data = new FormData();
42     data.append("file", loadedImage);
43     console.log(data)
44     console.log(loadedImage)
45     const resDB = await fetch("/predict", { method: "POST", body: data });
46     const resJson = await resDB.json();
47     const resData = parseFloat(resJson.res) > 0.69 ? "1" : "0"; /*we have a threshold in 0.69 to decide cataract or no cataract */
48     result.innerHTML = responses[resData];
49     result.classList.add(resData === "1" ? "bad" : "good");
50   } catch (error) {
51     console.log(error);
52   }
53   loadingScreen.classList.toggle("no_visible");
54 }
55
56 const uploadFile = document.querySelector("#uploadImage");
57 const uploadContent = document.querySelector("#upload-content");
58 const submitButton = document.querySelector("#send");
59 const cleanButton = document.getElementById("clean");
60 const loadedImageComponent = document.getElementById("loaded-img");
61 const result = document.getElementById("result");
62 const loadingScreen = document.getElementById("loading");
63 /* toasts */
64 const toast = document.getElementById("toast");
65 const toastContent = document.getElementById("toast_content");
66 const toastClose = document.getElementById("toast_close");
67
68 /* data*/
69 const responses = {
70   1: "Catarata",
71   0: "No Catarata",
72 };
73
74 let loadedImage;
75
76
77 /* events*/
78 uploadFile.addEventListener("change", loadImage);
79 submitButton.addEventListener("click", sendForm);
80 cleanButton.addEventListener("click", cleanAction);
81 toastClose.addEventListener("click", closeToast);
```

HTML DE LA API


```
27 lines (23 sloc) | 699 Bytes
Raw Blame
1 <html lang="en">
2   <head>
3     <meta charset="UTF-8" />
4     <meta name="viewport" content="width=device-width, initial-scale=1.0" />
5     <meta http-equiv="X-UA-Compatible" content="ie=edge" />
6     <title>Ocular classification</title>
7
8     <link
9       href="{{ url_for('static', filename='css/main.css') }}"
10      rel="stylesheet"
11    />
12  </head>
13
14  <body>
15    <div
16      id="header">{% include 'header.html' %}</div>
17
18    <div id="content">{% block content%} {% endblock %}</div>
19
20    <div id="toast" class="no_visible">{% include 'toast.html' %}</div>
21  </div>
22 </body>
23 <script
24   src="{{ url_for('static', filename='js/main.js') }}"
25   type="text/javascript"
26 ></script>
27 </html>
```

```
4 lines (1 sloc) | 52 Bytes
Raw Blame
1
2
3 <div class="header"> Cataract Identifier </div>
```

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)

```
34 lines (29 sloc) 696 Bytes
1 {% extends "base.html" %} {% block content %}
2
3 <div class="container">
4   <div class="img">
5     <img id="loaded-img" />
6   </div>
7
8   <form
9     id="upload-content"
10    method="post"
11    enctype="multipart/form-data"
12    class="mt-10"
13  >
14    <input
15      class="input-form"
16      type="file"
17      name="file"
18      id="uploadImage"
19      accept=".png .jpg .jpeg"
20    />
21  </form>
22
23  <div>
24    <button type="button" id="send" class="mt-10">Clasificar</button>
25    <button type="button" id="clean" class="mt-10 clean">Limpiar</button>
26  </div>
27
28  <div id="loading" class="loading no_visible">
29    <div class="spinner"></div>
30  </div>
31
32  <div class="result" id="result"></div>
33 </div>
34 {% endblock %}
```


```
7 lines (4 sloc) 157 Bytes
1 <div class="toast">
2
3   <span id="toast_content" class="content"> Debe cargar una imagen</span>
4
5   <span id="toast_close" class="close">X </span>
6
7 </div>
```



FUNCIONAMIENTO

Se selecciona la imagen ocular para su respectiva clasificación y predicción

DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS
OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP
LEARNING – MACHINE LEARNING)




Seleccionar archivo Ninguno archivo selec.

Clasificar

Limpiar


DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP LEARNING – MACHINE LEARNING)



Seleccionar archivo 254_left.jpg



DESARROLLAR UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE CATARATAS
OCULARES HACIENDO USO DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL (DEEP
LEARNING – MACHINE LEARNING)



Seleccionar archivo 1_left.jpg

Clasificar

Limpiar

No Catarata

ENLACE DE LA APLICACIÓN

<https://flask-production-1146.up.railway.app/>