



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Maestría

Identificación de alteraciones en el iris para detectar
la aparición de un patrón para medir si existe
correlación con la diabetes mellitus.

presentada por

Ing. Juan Carlos Vigueras Villalba

como requisito para la obtención del grado de
Maestro en Ciencias de la Computación

Director de tesis

Dr. Máximo López Sánchez

Codirector de tesis

Dr. Raúl Pinto Elías

Cuernavaca, Morelos, México. Diciembre 2025.



Educación

Secretaría de Educación Pública

SEP TecNM CENTRO NACIONAL DE INVESTIGACIÓN Y DESARROLLO TECNOLÓGICO

RECIBIDO
07 NOV 2025
LMZ
SUBDIRECCIÓN ACADÉMICA



TECNOLÓGICO
NACIONAL DE MÉXICO



Centro Nacional de Investigación y Desarrollo tecnológico
Departamento de Ciencias Computacionales

Cuernavaca, Mor., 06/noviembre/2025

OFICIO No. DCC/334/2025

Asunto: Aceptación de documento de tesis


CENIDET-AC-004-M14-OFICIO

CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de **Juan Carlos Viguera Villalba** con número de control **M23CE089**, de la Maestría en Ciencias de la Computación, le informamos que hemos revisado el trabajo de tesis de grado titulado **"Identificación de alteraciones en el iris para detectar la aparición de un patrón para medir si existe correlación con la diabetes mellitus"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.

ATENTAMENTE

Excelencia en Educación Tecnológica®
"Conocimiento y Tecnología al Servicio de México"



Dr. Máximo López Sánchez
Director de tesis

Dr. Raúl Pinto Elías
Codirector de tesis

Dr. Nimrod González Franco
Revisor 1

Dra. Andrea Magadán Salazar
Revisor 2

C.c.p Depto. Servicios Escolares.
Expediente / Estudiante



2025
Año de
La Mujer
Indígena

Interior Internado Palmira S/N, Col. Palmira,
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 3201,
e-mail: dcc_cenidet@tecnm.mx tecnm.mx | cenidet.tecnm.mx

cenidet
Centro Nacional de Investigación y Desarrollo Tecnológico





Centro Nacional de Investigación y Desarrollo tecnológico
Subdirección Académica

Cuernavaca Mor, 07/noviembre/2025

Oficio No. SAC/258/2025

Asunto: Autorización de impresión de tesis

JUAN CARLOS VIGUERAS VILLALBA
CANDIDATO AL GRADO DE MAESTRO
EN CIENCIAS DE LA COMPUTACIÓN
P R E S E N T E

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"Identificación de alteraciones en el iris para detectar la aparición de un patrón para medir si existe correlación con la diabetes mellitus"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.


Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica®

"Conocimiento y Tecnología al Servicio de México"

CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO



c.c.p. Departamento de Ciencias Computacionales
Departamento de Servicios Escolares

CMAZ/lmz



2025
Año de
La Mujer
Indígena

Interior Internado Palmira S/N, Col. Palmira,
C. P. 62490, Cuernavaca, Morelos Tel. 01 (777) 3627770, ext. 4104,
e-mail: acad_cenidet@tecnm.mx tecnm.mx | cenidet.tecnm.mx

cenidet
Centro Nacional de Investigación
y Desarrollo Tecnológico



Dedicatoria

A mi familia, quienes me apoyaron en todo momento, en especial a mis padres Sofia y Carlos por los cuales tomé la decisión de aventurarme en este camino. A pesar de que ellos ya no están presentes en este trayecto sé que ellos estarían felices y orgullosos. A mis hermanos José Luis y María del Carmen los cuales estuvieron presentes en este trayecto siempre alentándome a seguir adelante; a mis sobrinos Diego y Miguel los cuales me brindaron un lugar de respiro para desestresarme, permitiendo tomar nueva fuerza para continuar. Este camino no fue fácil, pero gracias a mi familia y a las personas con los cuales tuve el gusto de compartir esta etapa de mi vida he podido alcanzar esta meta, muchas gracias a todos ustedes familia, doctores, maestros, compañeros de clase y demás personal del Instituto.

Agradecimientos

A la Secretaría de Ciencias, Humanidades, Tecnología e Innovación (Secihti) por su aporte económico como estudiante mediante el Programa Nacional de Posgrado de Calidad (PNPC).

A compañeros estudiantes del área quienes de forma directa o indirecta ayudaron a la realización de este trabajo con comentarios, críticas, ideas o sugerencias.

A mi comité conformado por el Dr. Nimrod González Franco y Dra. Andrea Magadan Salazar, los cuales dedicaron parte de su tiempo para revisar aportando correcciones, mejoras y sugerencias.

A mi codirector de tesis, el Dr. Raúl Pinto Elías, el cual me enseñó sobre los temas especializados en visión por computadora, otorgándome parte de su tiempo para explicarme de forma clara el procedimiento de cada paso.

A mi director de tesis, el Dr. Máximo López Sánchez, el cual me mostró la importancia de descubrir nuevos campos poco explorados en la ciencia, despertando la curiosidad de investigar. De igual manera agradezco su paciencia y disponibilidad de tiempo.

Al TecNM/Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET); doctores, maestros, alumnos y demás personal que creyó en mis capacidades y habilidades, los cuales me alentaron a seguir adelante pese a las dificultades y adversidades encontradas en el camino, permitiéndome ser parte de esta comunidad.

RESUMEN

Actualmente, el iris del ojo humano es utilizado como un medio de identificación biométrica, empleando el procesamiento de imágenes y técnicas de reconocimiento de patrones; sin embargo, el iris puede proporcionar información útil para otros campos como por ejemplo la iridología, en la cual a través de la observación del iris se puede determinar el estado de salud de una persona.

Basado en lo anterior, se realizó un trabajo de investigación para el reconocimiento de alteraciones en el iris del ojo humano para medir si existe una relación con la enfermedad diabetes mellitus, combinando las técnicas de procesamiento de imágenes y basándose en los estudios de iridología.

El proyecto de investigación está dividido en tres etapas:

La primera etapa consiste en obtener imágenes del iris ocular y mediante una aplicación permitir la detección de éste.

La segunda etapa es el procesamiento de la imagen del iris, normalizar la zona de interés, segmentando las regiones a analizar y extraer las características de la misma.

Finalmente, la tercera etapa consiste en realizar la clasificación de las imágenes en: iris con diabetes y sin diabetes, llevando a cabo la evaluación del sistema.

Al concluir este trabajo se presentan los siguientes resultados: en la etapa de segmentación correcta del iris se obtuvo un 0.984 en *accuracy* y 0.7852 en IoU, mientras que en la detección de la enfermedad el mejor resultado que se obtuvo fue un *accuracy* de 0.93548387.

Palabras clave: Iris, Diabetes, Segmentación, Extracción de Características, Clasificación, Diagnóstico de la enfermedad.

Abstract

The human iris is currently used as a means of biometric identification, leveraging image processing and pattern recognition techniques. However, the iris can also provide valuable information for other fields, such as iridology, which studies the health status of individuals through iris observations. Building on this, a research project was conducted to identify alterations in the human iris and investigate their potential relationship with diabetes mellitus, combining image processing techniques with iridology principles. The research project is structured into three stages:

The first stage involves capturing images of the ocular iris and using an application to enable its identification.

The second stage focuses on preprocessing and processing the iris images: normalizing the region of interest, segmenting the regions for analysis, and extracting relevant features.

The third stage involves the evaluation process, classifying the images into diabetic and non-diabetic categories.

Upon completion of this study, the following results were achieved: the segmentation of the iris achieved an accuracy of 0.984 and an IoU of 0.7852, while the best accuracy obtained for disease detection was 0.935.

Keywords: Iris, Diabetes, Segmentation, Feature Extraction, Classification, Disease Diagnosis.

Contenido

CAPÍTULO 1 INTRODUCCIÓN.....	1
1.1. INTRODUCCIÓN	2
1.2. ANTECEDENTES	4
1.3. PROBLEMA	5
1.3.1. DEFINICIÓN.....	5
1.3.2. JUSTIFICACIÓN.....	6
1.4. OBJETIVOS.....	7
1.4.1. OBJETIVO GENERAL	7
1.4.2. OBJETIVOS ESPECÍFICOS	7
1.5. ALCANCES Y LIMITACIONES.....	7
1.5.1. ALCANCES	7
1.5.2. LIMITACIONES	7
CAPÍTULO 2 MARCO TEÓRICO.....	8
2.1. MARCO TEÓRICO	9
2.1.1. DIABETES MELLITUS	9
2.1.2. MARCO TEÓRICO DEL FENÓMENO	9
2.1.3. MARCO TEÓRICO EN CONCEPTOS COMPUTACIONALES	17
CAPÍTULO 3 ESTADO DEL ARTE	26
3.1. ESTADO DEL ARTE.....	27
3.1.1. DETECCIÓN DE ENFERMEDADES.....	27
3.1.2. SEGMENTACIÓN DE IRIS.....	34
3.1.3. REVISIONES METODOLÓGICAS Y MARCOS TEÓRICOS EN IRIDOLOGÍA	37
3.1.4. LIBROS CONSULTADOS	38
3.2. CONCLUSIÓN:	41
CAPÍTULO 4 METODOLOGÍA Y DESARROLLO	42
4.1. MODELO DE SOLUCIÓN.....	43
4.2. DESARROLLO DEL MODELO.....	43
4.2.1. CONJUNTOS DE IMÁGENES.....	43
4.2.2. ALMACENAMIENTO.....	45
4.2.3. PREPROCESAMIENTO.	46

4.2.4. SEGMENTACIÓN	50
4.2.5. EXTRACCIÓN Y CLASIFICACIÓN DE CARACTERÍSTICAS	53
4.2.6. SELECCIÓN DE CARACTERÍSTICAS	53
4.2.7. ENTRENAMIENTO DE MODELOS DE CLASIFICACIÓN	54
CAPÍTULO 5 PRUEBAS Y RESULTADOS.....	58
5.1. PRUEBAS Y RESULTADOS	59
5.1.1 SEGMENTACIÓN.....	59
5.1.2. CLASIFICACIÓN.....	64
5.1.3. ANÁLISIS DE RESULTADOS.....	70
CAPÍTULO 6 DESARROLLO DE LA APLICACIÓN	72
6.1. DESARROLLO DE LA APLICACIÓN	73
6.1.1. CAPTURA DE DATOS Y DETECCIÓN DE IRIS.....	73
6.1.2. PROCESAMIENTO.....	74
6.1.3. EVALUACIÓN Y CLASIFICACIÓN	74
CAPÍTULO 7 CONCLUSIONES.....	77
7.1 CONCLUSIONES	78
ANEXOS	82
REFERENCIAS.....	85

Índice de figuras

Fig. 1. Anatomía del ojo (Academia Americana de Oftalmología 2023)	9
Fig. 2. Sección transversal del globo ocular. (Alañón Fernández et al. 2025).....	10
Fig. 3. Limbo esclerocorneal (Alcántara, 2023)	11
Fig. 4. Mapa iridológico (Jensen, 1980)	13
Fig. 5. Topología radial (Bernard D Jensen 2020).....	13
Fig. 6. zona de páncreas, (ROJAS L 2004).....	14
Fig. 7. Topología anular, imagen propia basada en (Figura 2. Zonas en el iris humano (Bernard, 1980) s. f.)	14
Fig. 8. Iris humano (Halim y Emanuel 2020).	15
Fig. 9. Signatura de la ruptura de las capas del iris según la profundidad de la enfermedad. (Diagnosticodelasalud.com 2024)	16
Fig. 10. Tipos de alteraciones en el iris ocular. (De La Fuente López y Onofre Aguero 2018)	16
Fig. 11. Tres generaciones de ANNs: perceptrón multicapa, neurona de McCulloch–Pitts y SNNs (Javanshir et al. 2023).....	24
Fig. 12. Arquitectura de ResNet-50, (Kundu 223).	25
Fig. 13. Modelo de solución.....	43
Fig. 14. DIABETES-IRIDOLOGY.....	45
Fig. 15. CASIA-iris	45
Fig. 16. UBIRIS.V2	45
Fig. 17. IIT DELHI.....	45
Fig. 18. MOBIUS	45
Fig. 19. Estructura de conjunto de datos.	46
Fig. 20. Filtros empleados para la detección del iris.....	47
Fig. 21. Detecciones de iris	49
Fig. 22. Detecciones de pupila	50
Fig. 23. Creación de máscara binaria para Segmentación de iris sin pupila.	51
Fig. 24. Eliminación de parpados.	51
Fig. 25. Creación de 12 máscaras tomando pupila como centroide.....	51
Fig. 26. Máscaras usadas para obtener zona páncreas.....	52
Fig. 27. Filtro CLAHE	53
Fig. 28. Imagen de conjunto de datos MOBIUS, donde se observa la máscara original y predicha combinadas, mostrando las diferencias (TP, FP, FN).	61

Fig. 29. Se observa la diferencia entre máscaras dependiendo de la posición del iris	62
Fig. 30. Imagen con máscara sobrepuesta en imagen. Máscara indicando con color azul el área que inca la segmentación.	64
Fig. 31. Etapas del sistema	73
Fig. 32. Mensaje de resultado de analisis	75
Fig. 33. Vista Home	75
Fig. 34. Vista información	75
Fig. 35. Vista captura de informacion	75
Fig. 36. Servidor FastApi	76
Fig. 37. Constancia innovatec	80
Fig. 38. Artículo No. ZTP128	81
Fig. 39. Registro de derechos de autor	81

Índice de tablas

Tabla 1. Niveles de glucosa en la sangre en personas sin diabetes, con prediabetes y diabéticas. (American Diabetes Association s. f.).....	2
Tabla 2. Detección de enfermedades.....	27
Tabla 3. Segmentación de iris	34
Tabla 4. Revisiones metodológicas y marcos teóricos en iridología	38
Tabla 5. Libros de iridología	39
Tabla 6. Conjuntos de datos usados	44
Tabla 7. Parámetros para el Procesamiento del Iris.....	47
Tabla 8. Parámetros para el Procesamiento de la Pupila	48
Tabla 9. Configuración de Modelos de Clasificación.....	54
Tabla 10. Características de conjuntos usados para entrenamiento de modelo segmentador.	59
Tabla 11. Resultados de entrenamiento de Unet y Samvit	59
Tabla 12. Resultados de evolución.	62
Tabla 13. Resultados de entrenamiento en segmentación zona páncreas.	63
Tabla 14. Características de Diabetes–Iridology (Farabi Eye Hospital).....	64
Tabla 15. Comparación de iris derecho, izquierdo y zona páncreas de un mismo sujeto.....	65
Tabla 16. Resultados de entrenamiento usando imágenes de iris derecho.	66
Tabla 17. Resultados de entrenamiento usando imágenes de iris izquierdo.	67
Tabla 18. Resultados de entrenamiento usando imágenes de zona páncreas.	69
Tabla 19. Mejores resultados dependiendo la imagen de entrada.	70

CAPÍTULO 1 INTRODUCCIÓN

1.1. INTRODUCCIÓN

La diabetes mellitus o también llamada diabetes tipo II considerada una enfermedad crónica, puede causar daños irreversibles en la vista, riñones o piel. Este tipo de diabetes suele presentarse en mayor proporción en personas mayores de 60 años; sin embargo, puede presentarse a cualquier edad. (Secretaría de Salud 2023)

Tal es el caso que la diabetes mellitus se presenta cuando el páncreas no produce suficiente insulina o el órgano no regula eficientemente el azúcar en la sangre provocando una hiperglucemia (aumento de azúcar en la sangre), dañando gravemente nervios y vasos sanguíneos. (Secretaría de Salud 2023).

“1,5 millones de muertes se atribuyen directamente a la diabetes cada año. Tanto el número de casos como la prevalencia de la diabetes han aumentado constantemente en las últimas décadas.” (WHO 2023a).

“La tasa anual de fallecimiento por diabetes mellitus es de 361 por cien mil habitantes, y la de tipo I es de 30 decesos por 100 mil.” (Secretaría de Salud 2023).

Entre los síntomas más comunes se encuentran el incremento en el volumen de orina, sensación de sed y hambre, fatiga, pérdida de peso y cansancio. En algunos casos falta de visión y respiración acelerada, El 13 de noviembre del año 2022 la Secretaría de Salud informó que en México 12.4 millones de personas viven con diabetes (Secretaría de Salud 2023).

El análisis de defunciones por diabetes mellitus, de acuerdo con el sexo, se encontró que, en 2022, 57,550 de las muertes ocurrió en hombres y 58,117, en mujeres (INEGI 2023).

Antes de que una persona desarrolle diabetes se presenta la prediabetes en la cual los índices de glucosa en la sangre son mayores a lo normal, pero no lo suficientemente altos para diagnosticar diabetes; 11 de cada 100 personas con prediabetes desarrollan diabetes (IMSS 2023), dependiendo el examen realizado se encuentran los valores mostrados en la tabla 1:

Tabla 1. Niveles de glucosa en la sangre en personas sin diabetes, con prediabetes y diabéticas. (American Diabetes Association s. f.)

Resultado	A1C	Glucosa plasmática en ayunas (FPG)	Prueba de tolerancia oral a la glucosa (OGTT)
Normal	menos de 5.7%	menor que 100 mg/dL	menor que 140 mg/dL
Prediabetes	5.7% a 6.4%	100 mg/dL a 125 mg/dL	140 mg/dL a 199 mg/dL
Diabetes	6.5% o más	126 mg/dL o más	200 mg/dL o más

Para detectar si una persona padece de diabetes existen diferentes métodos y entre los más usados está la medición de la glucosa en la sangre, prueba hemoglobina glicosilada A1C y prueba de glucosa plasmática aleatoria (Pinheiro 2015). Estos métodos son invasivos, ya que se requiere una muestra de sangre del paciente. Existen otros métodos que no son invasivos, como estudios de orina, saliva, sudor y fluidos oculares, los que tienden a ser imprecisos en comparación con los invasivos.

Existen muchas técnicas que se consideran alternativas dentro de la medicina, una de estas es la iridología. Actualmente, se han realizado estudios mediante sistemas inteligentes los cuales permiten analizar el iris, para esto se han utilizado *datasets* compuestos de imágenes de iris de personas sanas como enfermas, permitiendo realizar una clasificación de nuevas imágenes (María Jesús 2020). Este proceso permite a la iridología detectar diferentes patologías y condiciones de salud, tales como diabetes, insuficiencia renal crónica, enfermedades cardíacas, enfermedades pulmonares, trastornos gastrointestinales y enfermedades del hígado, entre otras. (Esteves et al. 2021)

Actualmente, se utilizan diferentes técnicas de procesamiento de imágenes para analizar el iris y extraer información relevante que sirva para el diagnóstico médico (Vresdian et al. 2022).

Esta tesis se enfoca en analizar las anomalías en el iris relacionadas con la diabetes mellitus, utilizando la técnica de iridología. Para esto, se realizará revisión de imágenes de iris.

1.2. ANTECEDENTES

Los trabajos que se han llevado a cabo dentro del Centro Nacional de Investigación y Desarrollo Tecnológico (CENIDET), y que están relacionados con esta propuesta de investigación, son los siguientes:

- A. Captura del iris del ojo mediante smartphone considerando la estabilización e iluminación de la imagen para reconocer alteraciones en el iris que permitan identificar la existencia del anillo de colesterol (Rosales Banderas 2017).

Este trabajo de tesis de maestría combina las técnicas de procesamiento de imágenes con los estudios de la iridología, para determinar la presencia del anillo de colesterol en el iris del ojo humano. En la iridología, el anillo es un signo de hiperlipidemia o colesterol elevado, por lo que el reconocimiento de esta marca en el iris a través del procesamiento de imágenes permite identificar los posibles niveles altos de colesterol en una persona.

En este caso, el valor identificado de la marca del anillo de colesterol del 85.17% de detecciones correctas del iris y una precisión del 81.08% en la detección del anillo de colesterol en las imágenes analizadas.

- B. Se presenta el desarrollo de una aplicación bajo la plataforma Android para la detección de reconocimiento Automático de Alteraciones en el Iris, caso de estudio: Cáncer abdominal. (Pineda Tapia 2016).

Se presenta el desarrollo de una aplicación bajo la plataforma Android para la detección de cáncer abdominal por medio del reconocimiento de alteraciones en el iris del ojo. Consta de cuatro fases, la primera es la captura de la imagen y la detección del iris, la que se realizó por medio de los algoritmos de Canny para detectar los bordes y la transformada de Hough para detectar circunferencias.

La segunda fase es el procesamiento, etapa en la cual se eliminan las áreas que no son de interés, se segmenta la zona pupilar e iridica y se extraen las características para la identificación de las alteraciones. El iris segmentado está dividido en cuatro cuadrantes, de los cuales en el tercero se encuentra la zona de interés donde se presenta la alteración relacionada con el cáncer abdominal.

La tercera fase consiste en la consulta de una base de datos con imágenes de la alteración en orden cronológico según la evolución del cáncer abdominal (cuatro fases), esta base de datos contiene 5008 imágenes de muestra. En esta fase también se llevó a cabo la obtención de más muestras y se realizó el entrenamiento para la clasificación de la alteración.

Por último, en la cuarta fase se llevaron a cabo las pruebas con varios clasificadores obteniendo un porcentaje de 98% de asertividad con respecto a la detección del cáncer abdominal

1.3 PROBLEMA

1.3.1. DEFINICIÓN

La diabetes mellitus es una enfermedad que tiene una gran tasa de muerte y discapacidad en el mundo, siendo *“1,5 millones de muertes los que se atribuyen directamente a la diabetes cada año. Tanto el número de casos como la prevalencia de la diabetes han aumentado constantemente en las últimas décadas”* (WHO 2023b); entre 2000 y 2019 las tasas de mortalidad por diabetes normalizadas por edades aumentaron en un 3%. En los países de ingresos medianos o bajos la tasa de mortalidad por diabetes aumentó en un 13% (WHO 2023a). En México se calcula que *“12.4 millones de personas viven con diabetes”* (Secretaría de Salud 2023), considerando que, en el año 2022, fallecieron 115,681 de los cuales 57,550 fueron hombres y 58,117 mujeres (INEGI 2023).

La Federación Internacional de la Diabetes (IDF) proyecta que 1 de cada 8 adultos, aproximadamente 783 millones, vivirá con diabetes, teniendo un aumento del 46% para el año 2045 (IDF s. f.).

Existen varios métodos para detectar si una persona padece diabetes. Entre los más comunes se encuentran la medición de la glucosa en la sangre, la prueba A1C y la prueba de glucosa plasmática aleatoria. Estos métodos son invasivos, ya que requieren que se extraiga una muestra de sangre del paciente. Aunque hay otros métodos no invasivos, como los estudios de orina, saliva, sudor y fluidos oculares, estos tienden a ser menos precisos en comparación con los métodos invasivos.

Con una detección temprana se puede tratar la diabetes y evitar o retrasar sus consecuencias mediante la actividad física y una alimentación sana, aunadas a la medicación y a realizar pruebas periódicas.

La diabetes mellitus es una enfermedad crónica degenerativa la cual afecta a gran parte de la población.

Por lo que el problema consiste en: **Proponer e implementar un modelo capaz de identificar y extraer la información de características de la diabetes mellitus en el iris del ojo, aplicando técnicas de IA.**

1.3.2. JUSTIFICACIÓN

La diabetes es una enfermedad crónica que se produce cuando el cuerpo no produce suficiente insulina o no puede usarla adecuadamente. Con el tiempo, la diabetes puede dañar los vasos sanguíneos, el corazón, los ojos, los riñones y los nervios.

Es posible obtener un diagnóstico temprano de la diabetes a través de análisis de sangre relativamente baratos; sin embargo, el IMSS reportó un gasto de \$50,619 millones de pesos en el 2022 representando el padecimiento más costoso (Zoé y IMS 2023). El tratamiento de la diabetes consiste en una dieta saludable y actividad física, junto con la reducción de la glucemia y otros factores de riesgo conocidos los que dañan los vasos sanguíneos. También es importante dejar de fumar para evitar complicaciones (WHO 2023a).

La Federación Internacional de la Diabetes (IDF) estimó que alrededor de 536 millones de personas fueron afectadas por la diabetes en 2021 y tiene un pronóstico de 642.8 millones de personas para el año 2030 y 783.7 millones de personas alrededor del mundo para el 2045 en un rango de edad entre 20 y 79 años. Según datos recopilados por la IDF en el año 2021, la diabetes ha causado unos 6,7 millones de muertes. Más de 2.6 millones de niños y adolescentes viven con diabetes tipo 1 (D. A. IDF s. f.).

1.4. OBJETIVOS

1.4.1. OBJETIVO GENERAL

Desarrollar e implementar un modelo de inteligencia artificial (IA) para la extracción de características e identificación de la diabetes mellitus en el iris del ojo.

1.4.2. OBJETIVOS ESPECÍFICOS

- Revisar el estado del arte relacionado con la metodología para identificar métodos de clasificación e identificación de patrones relacionados con iridología.
- Identificar características en el iris del ojo que están relacionadas con el área del páncreas de acuerdo con la iridología.
- Identificar la relación entre los patrones encontrados en el iris del ojo y la diabetes mellitus.
- Implementar un algoritmo de clasificación y aplicar las métricas tradicionales.
- Recopilar una base de datos de imágenes del iris de personas sanas y diabéticas.
- Evaluar desempeño de sistema y compararlo con el estado del arte.

1.5. ALCANCES Y LIMITACIONES

1.5.1. ALCANCES

- Se identifican patrones en el iris a través de imágenes.
- Identificación de condiciones ideales en imágenes para su procesamiento.
- La técnica que se utiliza no es invasiva para la salud.
- La aplicación solo indica si encuentra alteraciones en el iris ocular relacionadas con diabetes mellitus.
- Las imágenes de la base de datos son de pacientes diagnosticados clínicamente con dicha enfermedad.

1.5.2. LIMITACIONES

- No se relaciona la presente investigación con otras enfermedades que no sea la diabetes mellitus
- No se propone ningún algoritmo nuevo.
- La aplicación no realiza ningún diagnóstico al usuario.
- No se mejoran los algoritmos utilizados.
- No se da recomendación de tratamiento médico alguno.

CAPÍTULO 2 MARCO TEÓRICO

2.1. MARCO TEÓRICO

Para la realización de este trabajo, es fundamental comprender aspectos clave que facilitarán tanto la comprensión del problema como el método de solución a emplear. En particular, se adentrará en el campo de la iridología, la cual utiliza el análisis del iris del ojo para obtener información relevante sobre la salud.

2.1.1. DIABETES MELLITUS

“La diabetes de tipo 2 afecta a la forma en que el cuerpo utiliza el azúcar (glucosa) para obtener energía, impidiendo que use la insulina adecuadamente, lo que puede aumentar las concentraciones de azúcar en la sangre si no se trata adecuadamente. Con el tiempo, la diabetes de tipo 2 puede causar daños graves al organismo, sobre todo a los nervios y los vasos sanguíneos. El diagnóstico precoz es importante para prevenir sus efectos. La mejor manera de detectarla temprano es acudir a un proveedor de atención médica para hacerse exámenes regulares y análisis de sangre” (WHO, 2023b).

2.1.2. MARCO TEÓRICO DEL FENÓMENO

En este apartado se presentan conceptos sobre el ojo humano y sobre la iridología, de igual manera, se presentan el análisis del estudio para el estudio y la experimentación.

A. ESTRUCTURA DEL OJO HUMANO

Se presenta estudio de estructura del ojo humano (Fig. 1), para la mayor comprensión del mismo, funcionamiento e importación de sus partes.




Fig. 1. Anatomía del ojo (Academia Americana de Oftalmología 2023)

a. GLOBO OCULAR. (Villate, Méndez, y Echeverry 2016)

El globo ocular (Fig. 2) se encuentra en la cavidad orbitaria, formada por los huesos frontal, esfenoides, maxilar, cigomático, palatino, lagrimal y etmoides. El ojo es el órgano de la visión, posee un diámetro promedio de aproximadamente 23 a 25 mm se describe como una estructura casi esférica, con tres compartimentos que son:

- La cámara anterior: La cual es un espacio comprendido entre la córnea por su parte anterior y el iris en su parte posterior, está ocupada por el humor acuoso (líquido que está en constante circulación (Navalón 2020)). En toda su periferia la cámara anterior está delimitada por el limbo esclerocorneal (región anatómica que se encuentra en la unión entre la esclerótica y la córnea).
- La cámara posterior: es el espacio ubicado por detrás del iris y por delante del cristalino y el vítreo, está ocupada por el humor acuoso.
- La cámara vítrea: se encuentra posterior al cristalino y al cuerpo ciliar, contiene humor vítreo en contacto con las dos estructuras mencionadas anteriormente y con la capa nerviosa del globo ocular, la retina.




Fig. 2. Sección transversal del globo ocular. (Alañón Fernández et al. 2025)

b. CÓRNEA. (Villate et al. 2016)

Representa el principal medio refractivo del ojo, es parte de la capa más superficial del ojo llamada esclerocórnea o capa fibrosa, la córnea se encuentra ubicada en la porción anterior del ojo, esta está formada por cinco capas de anterior a posterior: epitelio, membrana de Bowman, estroma, membrana de Descemet y endotelio. La transparencia de la córnea se debe al entrecruzamiento regular y al tamaño similar de estas. El oxígeno y otros componentes requeridos para el metabolismo de la córnea se difunden a través de la película lagrimal, el humor acuoso y los vasos que llegan al limbo esclerocorneal (Fig. 3).




Fig. 3. Limbo esclerocorneal (Alcántara, 2023)

c. ESCLERÓTICA. (Alañón Fernández et al. 2025)

Membrana fibrosa constituida por fibras de colágena y fibras elásticas que protege los tejidos intramusculares del ojo.

Es una membrana blanca y resistente de aproximadamente 1mm de espesor, la que está conformada por tejido conjuntivo denso con gran cantidad de fibras colágenas. La esclera proporciona rigidez al globo ocular y protege los elementos internos de este. (Villate et al. 2016)

d. LIMBO ESCLEROCORNEAL. (Alañón Fernández et al. 2025)

Zona especial de transición entre esclera y córnea y constituye la pared externa del ángulo iridocorneal. A este nivel existen estructuras de drenaje del humor acuoso, además de ser zona de abordaje quirúrgico para determinadas técnicas. Su límite anterior lo constituye la membrana de Bowman y la de Descemet.

e. CAPA VASCULAR. (Villate et al. 2016)

La capa vascular se encuentra conformada por tres capas que en dirección anteroposterior son: El iris, el cuerpo ciliar y la coroides.

f. IRIS (Alañón Fernández et al. 2025)

Presenta la forma de un disco perforado en su centro por un orificio circular, la pupila, constituido por fibras lisas, está inervada por filetes nerviosos parasimpáticos que llegan a través de los nervios ciliares. Cada terminación nerviosa acaba en una sola célula, y la contracción es simultánea. Esto explica que la función pupilar siga siendo eficaz a pesar de cortar (iridotomía) o extirpar parte (iridectomía) de la zona periférica, como ocurre posteriormente al tratamiento del glaucoma de ángulo estrecho.

g. VÍA PUPILAR. (Alañón Fernández et al. 2025)

Regula el tamaño de la pupila, mediante el sistema nervioso simpático (dilatación) y parasimpático (constricción). La vía parasimpática consta de cuatro neuronas que permiten la respuesta pupilar a la luz, generando una contracción bilateral. La vía simpática, con tres neuronas, se inicia en el hipotálamo y llega al dilatador del iris tras pasar por la médula y el ganglio cervical. Alteraciones en estas vías pueden causar disfunciones pupilares.

h. CUERPO CILIAR. (Villate et al. 2016)

Es una estructura triangular y hace un puente entre las estructuras anteriores y posteriores del ojo; es muy pigmentado, se encuentra entre la coroides y el iris y contiene el músculo y los procesos ciliares; estos últimos son fibras longitudinales que salen del cuerpo ciliar y a partir de estos se extienden las fibras zonulares que se insertan en el cristalino y lo mantienen en su posición. El cuerpo ciliar discurre rodeando el ojo como un anillo, de forma ligeramente asimétrica pues en su lado nasal es más estrecha que en el temporal. Cerca de la ora serrata el cuerpo ciliar es muy pigmentado, la ora serrata es el límite anterior de la retina; esta se ubica en promedio a 7mm del limbo esclerocorneal.

i. COROIDES. (Alañón Fernández et al. 2025)

Su riqueza en células pigmentarias le confiere un papel de pantalla a la luz y su naturaleza vascular la hace membrana nutricia del ojo.

La capa coroidea gracias a su rica vascularización cumple una función nutritiva –de las capas más externas de la retina- y una función reguladora de la temperatura ocular –disipar el excesivo calor producido por la luz que absorben los melanocitos de EPR-.

j. RETINA. (Alañón Fernández et al. 2025)

Es la capa más interna del globo ocular, de estirpe neurosensorial. Es donde se inicia el proceso de la visión, siendo la parte especializada del sistema nervioso destinada a recoger, elaborar y transmitir las sensaciones visuales.

k. PARPADOS (Wiechers s. f.)

Los párpados son pliegues cutáneos modificados que se continúan con el resto de la piel facial, y cuya función es proteger el globo ocular de los estímulos externos.

B. ESTUDIO DE IRIDOLOGÍA.

En este apartado se presentan conceptos en el campo de la iridología, permitiendo entender cómo se realiza la evaluación de para identificar enfermedades o daños en los órganos y sistemas del cuerpo humano.

a. IRIDOLOGÍA (María Jesús 2020)

La iridología, constituye una disciplina que posibilita a un especialista identificar enfermedades sistémicas a través del análisis de imágenes del iris del individuo. Los profesionales examinan los patrones, colores y otras características del iris para evaluar la salud del paciente. Estos expertos comparan sus observaciones con cartas de iridología previamente elaboradas por otros autores, donde cada segmento del iris se asocia a una región específica del cuerpo.

La carta iridología muestra tanto el lado izquierdo como el derecho de una imagen del iris, con regiones resaltadas para cada órgano (Fig. 4).




Fig. 4. Mapa iridológico (Jensen, 1980)

b. TOPOLOGÍAS IRIDICAS (Asmecolpoz 2024)

Se identifican dos formas de topología que sirven identificar las distintas zonas del iris donde se ven reflejado los órganos.

○ TOPOLOGÍA RADIAL (Asmecolpoz 2024)

Se observará el iris como si fuera una de manecilla de un reloj; colocando los signos en las horas. Por lo tanto, la topografía radial divide el iris en doce porciones (Fig. 5).




Fig. 5. Topología radial (Bernard D Jensen 2020)

Los signos en el iris pueden estar media hora antes o después, es por lo que se consideran los mapas con relativa flexibilidad.

La localización de los órganos se ve representada en cada lado del iris; es decir, el iris derecho refleja los órganos del lado derecho del cuerpo y los órganos del lado izquierdo se ven representados en el iris izquierdo, mientras que órganos centrales se ven reflejados en ambos iris, como si fueran un espejo, por ejemplo, en

el iris derecho el bazo se encuentra a las 8, mientras que en el izquierdo se encuentra a las 4. De estas topologías se obtiene la región de cara iris que representa el estado de órganos y sistemas del cuerpo humano; sin embargo, estas zonas pueden variar.

“Es muy difícil localizar un punto exacto en el iris; ya que se puede decir que se encuentra a las seis, y puede estar media hora antes o después, es por lo que se toman los mapas con relativa flexibilidad.” (Asmecolpoz 2024)

Esta información es corroborada en entrevista posterior con un experto, Héctor Joel Iglesias Villarreal el cual cuenta con 38 años de experiencia.

En esta entrevista se menciona que la diabetes mellitus no es la única enfermedad que puede causar daños en el páncreas y reflejar esto en el iris. Por lo que se toma la decisión de realizar el análisis tanto en la zona del páncreas (Fig. 6) como en el iris completo, de esta manera comparar los resultados.




Fig. 6. zona de páncreas, (ROJAS L 2004)

○ TOPOLOGÍA ANULAR

Esta topología divide el iris en 7 anillos circulares como se muestra en la Fig. 7.




Fig. 7. Topología anular, imagen propia basada en (Figura 2. Zonas en el iris humano (Bernard, 1980) s. f.)

- 1- Área del estómago.
- 2- Área de los intestinos.
- 3- Glándulas suprarrenales, epífisis, y páncreas, área cardiaca y plexo solar.
- 4- Conductos bronquiales, pulmones, riñones y bazo.
- 5- Cerebro y órganos reproductores, hipófisis, tiroides e hígado.
- 6- Sistema circulatorio sanguíneo y linfático.
- 7- Piel, glándulas sudoríparas, nervios motores y sensitivos.

La zona dentada nos indica la banda del sistema nervioso autónomo.

c. IRIS. (Halim y Emanuel 2020)

El iris humano (Fig. 8) es una parte en forma de anillo situada entre la córnea y la pupila. Aunque el iris se considera un órgano humano, el iris puede observarse fácilmente desde el exterior. El iris es una pantalla donde se encuentran los sistemas nerviosos y contienen información sobre el cuerpo humano.




Fig.1. Human iris [1].

Fig. 8. Iris humano (Halim y Emanuel 2020).

○ IRIS MALO (ALTERACIÓN) (Asmecolpoz 2024)

El iris llamará la atención por su color sucio y turbio, en el cual se observan signos profundos con destrucción de fibras. Pueden aparecer lagunas muy profundas y marcadas.




Fig. 9. Signatura de la ruptura de las capas del iris según la profundidad de la enfermedad. (Diagnosticodelasalud.com 2024)

La Fig. 9 es la representación de las cuatro capas de pigmentación del iris, según los procesos de la enfermedad.

- Agudo: Inflamatorio por encima del iris.
- Subagudo: Debajo de la capa del iris.
- Crónico: Más profundo en el estroma del iris.
- Degenerativo: La capa más profunda del iris.

d. LAGUNAS. (Asmecolpoz 2024)

Son signos de forma usualmente ovalada o lanceolada, causados por la separación de las fibras, las cuales dejan ver en su interior un lecho, formado por la capa inferior del tejido del iris.

○ TIPOS DE LAGUNAS. (De La Fuente López y Onofre Aguero 2018)

Las alteraciones nombradas como lagunas por los iridólogos son características que deben estar presentes en personas que tengan daño en el páncreas, estas lagunas, pueden ser de diferentes tipos como se muestra en la Fig. 10.



Fig. 10. Tipos de alteraciones en el iris ocular. (De La Fuente López y Onofre Aguero 2018)

e. DESPLAZAMIENTOS Y DEFORMACIONES PUPILARES (Asmecolpoz 2024)

La pupila tiene que estar centrada, aunque esté de forma natural ligeramente desplazada hacia la parte nasal superior.

Cuando hay un desplazamiento de la pupila, se presentará una tensión de los órganos situados al lado hacia donde la pupila se ha desplazado; mientras que en el lado opuesto se presentarán dilataciones o debilidades. En la zona contraída aparecerán anillos y lagunas en la zona dilatada.

2.1.3. MARCO TEÓRICO EN CONCEPTOS COMPUTACIONALES

En este apartado se presentan conceptos técnicos sobre los procesos y técnicas computacionales, de igual manera, se presentan el análisis del estudio para el estudio y la experimentación.

A. MACHINE LEARNING. (IBM 2023)

Machine Learning es un componente importante del creciente campo de la ciencia de datos. Mediante el uso de métodos estadísticos, los algoritmos se entrenan para hacer clasificaciones o predicciones, y descubrir información clave dentro de los proyectos de minería de datos. Esta información clave facilita posteriormente la toma de decisiones dentro de las aplicaciones y las empresas, lo que afecta idealmente a las métricas de crecimiento clave.

B. PROCESAMIENTO DE IMÁGENES. (Torres 1996)

Se denomina procesamiento digital de imágenes (PDI) al conjunto de métodos y procedimientos destinados a descubrir o destacar la información presente en una imagen, siendo la computadora la herramienta principal utilizada en este proceso.

C. SEGMENTACIÓN DE IMÁGENES.

Las técnicas de segmentación de imágenes se utilizan para dividir las imágenes en partes significativas que tienen características y propiedades similares. El objetivo principal de la segmentación es simplificar y/o cambiar la representación de las imágenes en algo que sea más significativo y fácil de analizar. La segmentación de imágenes suele utilizarse para encontrar objetos y límites (líneas, curvas, etc.). (Hapsari et al. 2020)

La segmentación del iris es un proceso que se encarga de identificar los píxeles de una imagen que pertenecen a la región del iris. Este proceso es fundamental en el reconocimiento del iris, ya que una buena segmentación permite extraer más características discriminatorias y, por lo tanto, obtener una mayor precisión en el reconocimiento. (Reshma, Divya, y Subair 2019)

D. DETECCIÓN DE PATRONES

El reconocimiento de patrones es un proceso que consiste en utilizar algoritmos informáticos para clasificar datos de entrada en objetos, clases o categorías, en base a sus características principales o elementos constantes. El reconocimiento de patrones tiene aplicación en visión artificial, segmentación de imágenes, detección de objetos, procesamiento de datos de radar, reconocimiento de voz, clasificación de texto y mucho más (MathWorks 2024).

Es un conjunto de técnicas visuales y matemáticas que se usan para identificar patrones a partir de datos geocientíficos. El análisis de patrones puede aplicarse a un solo tipo de datos (univariante) o a varios tipos de datos (multivariante) para estudiar la proximidad y la relación entre los sucesos (Thakur et al. 2021).

La gran mayoría de los sistemas de reconocimiento del iris, transforman el patrón anular del iris en coordenadas cartesianas en una imagen rectangular normalizada de dimensiones fijas en coordenadas pseudopolares (Vresdian et al. 2022).

E. REGIÓN DE INTERÉS (ROI) (Halim y Emanuel 2020)

ROI (Región de Interés) es una parte específica de un conjunto de datos o una imagen que será identificada, operada o filtrada con un propósito particular. En iridología, la ROI es una parte específica de una imagen del iris que representa una parte u órgano particular del cuerpo humano. Esta región será analizada para determinar el estado de salud de ese órgano.

F. PREPROCESAMIENTO (Torres 1996)

Se denomina procesamiento digital de imágenes (PDI) al conjunto de métodos y procedimientos destinados a descubrir o destacar la información presente en una imagen, siendo la computadora la herramienta principal utilizada en este proceso.

G. FILTRO BILATERAL (Galvez Galvez 2017).

Descripción: El filtro bilateral es una técnica que suaviza la imagen mientras conserva los bordes. Combina la técnica de suavizado espacial del filtro gaussiano con la similitud de intensidad para calcular la contribución de cada píxel al filtro final. Los píxeles cercanos con intensidades similares tienen un mayor impacto en el resultado, preservando bordes y detalles.

Matemáticamente el filtro se define como:

$$W(i, j) = G_s(i, j) * G_r(i, j) \quad (1)$$

Donde:

- $(G_s(i, j))$ es la función gaussiana espacial que mide la similitud espacial entre los píxeles i y j .
- $(G_r(i, j))$ es la función gaussiana de rango que mide la similitud de intensidad entre los píxeles i y j .

La función gaussiana se define como:

$$P' = \sum_{i,j} W(i, j) * p_i \quad (2)$$

Donde p_i es el valor del píxel i . La suma se realiza sobre todos los píxeles en el vecindario de p .

Ventajas:

- Combina la suavización del ruido con la preservación de bordes y detalles finos de la imagen.
- Es particularmente efectivo en áreas con bordes definidos.

Desventajas:

- Su implementación es más compleja que los filtros gaussianos o los de la mediana.
- Requiere la selección adecuada de parámetros para obtener un resultado óptimo.

H. FILTRO SOBEL (Angie Padron 2022).

El filtro Sobel es un operador que se utiliza comúnmente para detectar bordes en imágenes al calcular las derivadas a lo largo de diferentes direcciones. Los operadores que definen al filtro Sobel se obtienen combinando dos tipos de operadores unidimensionales:

1. Derivación (hd): Este operador calcula la diferencia en la intensidad de píxeles para encontrar el cambio abrupto, que normalmente indica la presencia de un borde.
2. Promedio (hs): Este operador se usa para suavizar la imagen y así reducir el ruido antes de calcular la derivada. Se puede ver como un suavizado o una integración a lo largo de la dirección perpendicular al operador de derivación.

$$Hd = \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix} \quad hs = \begin{pmatrix} 1 \\ 2 \\ 1 \end{pmatrix}$$

El filtro Sobel se obtiene realizando combinaciones de estos dos operadores, definiéndose como: $s_x = h_s h_d^t$ y $s_y = h_d h_s^t = s_x^t$. Obteniendo

$$s_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \text{ y } s_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (3)$$

Permitiendo al filtro Sobel derivar y promediar para obtener el gradiente suavizando la imagen y resaltando los bordes.

I. TRANSFORMADA DE HOUGH (Urrea y Ospina 2004).

La Transformada de Hough es una técnica utilizada en visión por computadora para aislar y detectar características geométricas particulares dentro de una imagen. La función principal de la Transformada de Hough es parametrizar ciertos tipos de curvas geométricas, tales como líneas, círculos y otras formas, con el propósito de identificar eficientemente dichas características en una imagen.

Notación Paramétrica de una Línea $p = x \cos \theta + y \sin \theta$.

Donde:

- p es la distancia perpendicular (normal) desde el origen hasta la línea.
- θ es el ángulo de esta normal con respecto al eje x.

La ecuación general de un círculo en el plano 2D es:

$$(x - a)^2 + (y - b)^2 = c^2 \quad (4)$$

Donde:

- (a,b) son las coordenadas del centro del círculo.
- c es el radio del círculo.
- (x,y) son las coordenadas de los puntos en la circunferencia.

Para aplicar la Transformada de Hough se tiene que parametrizar la ecuación. La notación paramétrica es:

$$X = a + r \cos(\theta)$$

$$Y = b + r \sin(\theta)$$

Donde:

- θ es un parámetro que varía de 0 a 2π , representando el ángulo en radianes.
- (a,b) y r se consideran parámetros desconocidos que buscamos identificar para detectar círculos en la imagen.

J. FILTRO CLAHE (Hailakar et al. 2022).

El filtro de ecualización adaptativa de histograma limitada por contraste CLAHE (por sus siglas en inglés: Contrast Limited Adaptive histogram Equalization), limita la pendiente relacionada con la técnica de asignación de niveles de gris para evitar la saturación. Los píxeles recortados se redistribuyen uniformemente sobre el histograma completo después de 'recortar' el histograma para mantener el mismo

conteo total del histograma. CLAHE es un híbrido de ecualización de histograma adaptativa y ecualización de histograma ordinaria, a diferencia de este, no trabaja en toda la imagen, trabaja en pequeñas áreas de imágenes llamadas mosaicos. El contraste de cada mosaico se incrementa especificando que el histograma del área de salida se asemeje estrechamente al histograma definido por el parámetro 'Distribución'.

K. SEGMENTACIÓN

Las técnicas de segmentación de imágenes se utilizan para dividir las imágenes en partes significativas que tienen características y propiedades similares. La segmentación de imágenes suele utilizarse para encontrar objetos y límites (líneas, curvas, etc.) en las imágenes (Hapsari et al., 2020).

La segmentación del iris es un proceso que se encarga de identificar los píxeles de una imagen que pertenecen a la región del iris. Este proceso es fundamental en el reconocimiento del iris, ya que una buena segmentación permite extraer más características discriminatorias y, por lo tanto, obtener una mayor precisión en el reconocimiento (Reshma et al., 2019).

L. AUMENTO DE DATOS. (Gómez Sarasa y Ortega Pabón 2020)

El aumento de datos es una técnica ampliamente usada en el ámbito de la IA, cuya finalidad es aumentar el conjunto de datos aplicando diversas transformaciones al conjunto original, teniendo en cuenta que los nuevos datos obtenidos sean representativos y diferentes para los modelos a entrenar. Con esto se busca el mejoramiento de las métricas de desempeño (evitando así el sobreajuste) para obtener mejores resultados de clasificación.

M. SELECCIÓN DE CARACTERÍSTICAS (Gómez Sarasa y Ortega Pabón 2020).

La selección de características es parte del proceso de descubrimiento de conocimientos en conjuntos de datos en el que se selecciona un subconjunto de atributos que son más relevantes para la construcción del modelo predictivo sobre el que se esté trabajando.

a. ANOVA F-TEST, (Pathan et al. 2022).

El análisis de varianza (ANOVA) es una colección de modelos estadísticos paramétricos y procedimientos de estimación que permiten determinar si las medias de dos o más muestras provienen de la misma distribución. La prueba F, también conocida como estadística F, calcula la relación entre las varianzas de distintos grupos. En el contexto de la selección de características, el método ANOVA se considera una prueba estadística univariante que evalúa cada característica de forma individual frente a la variable objetivo, determinando si existe una relación estadísticamente significativa entre ellas.

b. MUTUAL INFO, (Beraha et al. 2019).

La información mutua (MI) es un índice de dependencia estadística entre variables aleatorias. Intuitivamente, mide saber cuánto el valor de una variable reduce la incertidumbre sobre la otra. A diferencia de otros índices, como el coeficiente de correlación de Pearson, la *MI* puede captar dependencias no lineales y es invariante ante transformaciones invertibles y diferenciables de las variables aleatorias.

Gracias a estas propiedades, la *MI* se ha utilizado extensamente como criterio de evaluación en métodos de selección de características tipo filtro, con el objetivo de identificar subconjuntos relevantes y no redundantes de características.

c. PCA, (Mangas y Verdejo 2012).

El Análisis de Componentes Principales (PCA) es una técnica matemática que transforma un conjunto de datos mediante una transformación lineal, proyectándolos sobre nuevas direcciones ortogonales llamadas componentes principales. Estas direcciones corresponden a las de máxima varianza en los datos originales. El objetivo es reducir la dimensión del conjunto de datos manteniendo la mayor cantidad de información posible. Los componentes principales están ordenados según la varianza capturada y son ortogonales entre sí, lo que facilita su análisis posterior. La base teórica del PCA se fundamenta en el álgebra lineal y está estrechamente relacionada con la Descomposición en Valores Singulares (SVD).

d. RANDOM FOREST SELECTION, (Nyongesa 2020).

La selección de características mediante Random Forest se basa en la métrica de "importancia de la variable", que cuantifica cuánto contribuye cada variable a reducir la impureza en los árboles del modelo. Aquellas variables que más contribuyen a mejorar las decisiones del modelo son consideradas más importantes, preferidas para su retención en la fase de selección.

N. MODELOS DE CLASIFICACIÓN, (Núñez y Campos 2017).

Los modelos de clasificación tienen como objetivo predecir una etiqueta de clase categórica. A partir de un conjunto de datos (variables o características) de entrada. El modelo de aprendizaje es una función de decisión partiendo del conjunto de datos y sus etiquetas, estos modelos son ampliamente utilizados en diagnósticos médicos (enfermo/no enfermo) detección de objetos en imágenes, segmentación etc.

Existen dos tipos de aprendizaje los cuales son aprendizaje supervisado y el no supervisado, la diferencia radica en que los datos de aprendizaje supervisado utilizan datos de entrenamiento (generalmente entre el 70% al 80%) y datos de prueba (entre al 30% y 20%) estos datos están estructurados por vectores de entrada con sus respectivos vectores de salida (entrada $x=(x_1, x_2, x_3, \dots, x_n)$ y salida $y=(y_1, y_2, y_3, \dots, y_n)$), mientras que el aprendizaje no supervisado solo cuenta con vectores de entrada ($x=(x_1, x_2, x_3, \dots, x_n)$), es decir no se cuenta con datos de entrenamiento, por lo que este realiza agrupamientos en base a las estructuras o patrones.

a. SVM, (Núñez y Campos 2017).

Maquina vector soporte o por sus siglas en inglés SVM (Support Vector Machine). Es un algoritmo que divide el conjunto de datos, mediante el hiperplano en dos clases una positiva y otra negativa, el hiperplano se define por los datos que se encuentran más cercanos a él siendo estos datos de diferentes clases y conociéndolos como vector soporte.

b. RANDOM FOREST

Proceso iterativo donde en cada iteración selecciona las mejores características o atributos los cuales permiten particionar el conjunto de datos de esta manera idéntica su clase.

c. GRADIENT BOOSTING, (Coors 2020).

Este método combina dos técnicas diferentes el Boosting en combinación descenso de gradiente (descenso más profundo), optimizando de forma iterativa, como un Random Forest minimizando una función de pérdida, ajustándose a los errores, aculando esta información, permitiendo conservar variables más significativas lo cual es muy útil en alto volumen de datos o cuando se requiere una reducción dimensional.

d. ADABOOST, (Freund et al. 1999).

Este algoritmo trabaja con un conjunto de datos de entrenamiento $(x_1, y_1), \dots, (x_n, y_n)$, donde cada x_i representa una observación que pertenece a un dominio X , y su etiqueta y_i se encuentra en un conjunto de clases posibles Y . AdaBoost utiliza un algoritmo de aprendizaje débil (es decir, uno que por sí solo tiene una precisión apenas mejor que el azar) y lo entrena en múltiples rondas $t=1, \dots, T$. En cada ronda, se ajustan los pesos de los ejemplos: se aumenta el peso de los ejemplos que fueron clasificados incorrectamente, obligando al algoritmo débil a "prestarles más atención" en la siguiente iteración. De esta forma, el modelo se va fortaleciendo poco a poco, enfocándose en los casos más difíciles.

e. LOGISTIC REGRESSION, (IBM 2021b).

Modelo estadístico enfocado en predecir la posibilidad de que ocurra un evento (positivo, negativo), en función a las variables independientes, siendo la diferencia con modelos lineales que predicen valores continuos, este modelo predice probabilidad, limitando su variable dependiente en 1 y 0, para ello aplica la transformada logit (el algoritmo de la razón de probabilidad), lo que permite modelar eventos categóricos.

f. KNN, (IBM 2021a).

KNN (k-nearest neighbors), emplea aproximación para realizar la clasificación o predicción basado en la agrupación, partiendo del supuesto de que se pueden encontrar puntos similares cerca uno del otro. KNN depende de una gran cantidad de memoria para almacenar todos los datos de entrenamiento debido a que en lugar de someterlos a entrenamiento se produce el cálculo al hacer la clasificación o

predicción.

g. DECISION TREE, (IBM 2021c).

Algoritmo de aprendizaje supervisado no paramétrico, tiene una estructura jerárquica con un nodo raíz del cual salen ramas que alimentan nodos internos llamados nodos de decisión, los nodos realizan evaluaciones formando subconjuntos homogéneos, los nodos finales representan los resultados posibles. Este algoritmo emplea estrategia divide y vencerás identificando los puntos de división óptimos, este proceso se repite de forma descendente hasta que todos o la mayoría de los registros se clasificaron con etiquetas específicas.

h. NAIVE BAYES, (Núñez y Campos 2017).

Este algoritmo clasifica los datos de prueba $x = (x_1, x_2, \dots, x_n)$ en un número de clases determinado (k clases) maximizando la probabilidad condicional de la clase dados los atributos de los datos de entrenamiento.

i. XGBOOST, (IBM 2024).

XGBoost (eXtreme Gradient Boosting) es un algoritmo de aprendizaje supervisado el cual emplea árboles de decisión potenciados por gradiente, siendo una implementación avanzada del impulso de gradiente.

O. REDES NEURONALES PROFUNDAS, (Javanshir et al. 2023).

Las redes neuronales artificiales (ANNs) son modelos computacionales inspirados en el cerebro humano, formados por neuronas artificiales interconectadas que aprenden a reconocer patrones a partir de datos. Estas redes pueden clasificarse en tres generaciones (Fig. 11): la primera utiliza neuronas binarias; la segunda incorpora funciones de activación continuas, como en los perceptrones; y la tercera está compuesta por redes neuronales de picos (SNNs), que imitan el comportamiento biológico mediante impulsos eléctricos.




Fig. 11. Tres generaciones de ANNs: perceptrón multicapa, neurona de McCulloch–Pitts y SNNs (Javanshir et al. 2023).

Dentro de esta evolución, las redes neuronales profundas (Deep Neural Networks, DNNs) representan una extensión de las ANNs tradicionales, caracterizadas por poseer múltiples capas ocultas que permiten aprender representaciones jerárquicas y resolver tareas complejas como clasificación o reconocimiento de imágenes.

a. U-Net (basado en una red FCN-ResNet50), (Alsabhan y Alotaiby 2022).

U-Net es una arquitectura de redes neuronales profundas que se utiliza principalmente para la segmentación semántica. La variante que se emplea aquí se basa en una estructura FCN-ResNet50, la cual integra capas convolucionales profundas con una red residual, lo que potencia la capacidad de extraer características relevantes de imágenes complejas.

b. TRANSFORMER (samvit_base_patch16.sa1b), (Kirillov et al. 2023).

Este modelo, que se basa en la arquitectura de Vision Transformer (ViT), utiliza mecanismos de atención para la segmentación de imágenes. La versión específica que se emplea, samvit_base_patch16.sa1b, está diseñada para dividir la imagen en parches y procesarlos a través de capas de atención, lo que facilita la captura de relaciones globales y detalles locales de manera eficiente.

c. ResNet-50, (Kundu 2023).

Modelo ResNet-50 (Fig. 12) es una arquitectura de red neuronal convolucional profunda desarrollada por Microsoft Research en 2015, consta de 50 capas, su arquitectura se divide en 4 capas principales:

- capas convolucionales,
- el bloque de identidad,
- el bloque convolucional y
- las capas totalmente conectadas,

siendo las capas convolucionales las encargadas de la extracción de características, mientras que los bloques de identidad y convolución procesan y transforman estas características y, por último, las capas totalmente conectadas realizan la clasificación.




Fig. 12. Arquitectura de ResNet-50, (Kundu 223).

CAPÍTULO 3 ESTADO DEL ARTE

3.1. ESTADO DEL ARTE

En este apartado se recopilieron 29 artículos relacionados con análisis de imágenes. Se destacan sus propuestas, metodología y sus resultados, así como artículos relacionados con la detección de enfermedades mediante análisis de imagen del iris ocular humano.

3.1.1. DETECCIÓN DE ENFERMEDADES.

Artículos enfocados en la detección de enfermedades tales como diabetes, colesterol, enfermedades cardiovasculares y renales mediante el análisis de imagen del iris, basados en iridología, técnicas de visión por computadora y aprendizaje automático (Tabla 2).

Tabla 2. Detección de enfermedades

Artículo	Qué propone/ metodología	Resultados
(Punia et al. 2023).	Identificar signos de diabetes y cardiopatías a partir de imágenes del iris. Uso de cámara EyeRonec, irisdocopio digital. Eliminación de ruido (filtro de mediana). Localización de las regiones del páncreas (03.50–04.20 mm). Extracción de características (SNR, media, desviación estándar), cálculo de ratios de píxeles blancos y negros. Clasificación binaria: Normal / Anormal usando umbrales definidos	Precisión: 90.91% en diabetes, 86.36% en enfermedades cardíacas.

Tabla 2. Detección de enfermedades (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(OZBİLGİN y KURNAZ 2023).	Diagnosticar la enfermedad arterial coronaria utilizando patrones del iris. Técnicas: Gradiente Conjugado Escalado (SCG) redes neuronales artificiales (RNA) en MATLAB	Valor AUC de 0,9103 para los datos de prueba
(Ying et al. 2023).	Examinar los cambios del volumen del iris medido por AS-OCT en pacientes con glaucoma tipo 2 con o sin diabetes mellitus	Disminución en el volumen de iris en pacientes diabéticos
(Janngam et al. 2023).	Comparar la eficacia del algoritmo IBiG-MSPA con BiG-SAM, iBiG-SAM y aiBiG-SAM en la clasificación de tres conjuntos de datos diabetes, enfermedad cardíaca UCI e iris	Precisión de entrenamiento del 77.11% y una precisión de prueba del 81.08%.
(Önal, Güraksin, y Duman 2023).	Desarrollar un modelo de red neuronal convolucional que pueda detectar la diabetes en imágenes de iris. Localización de iris: operador diferencial integral (IDO). Algoritmos de CNN utilizados fueron VGG-16, VGG-19, AlexNet, ResNet18 y GoogleNet.	El modelo VGG-16 tuvo el mejor rendimiento según las métricas utilizadas. Accuracy 80% Specificity 60% Sensitivity 100% Precision 71.42% F1 score 83.33%

Tabla 2. Detección de enfermedades (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Sandhiya y Aneetha 2023).	Predecir enfermedades o trastornos utilizando imágenes del iris. Localización de iris: operador diferencial integral (IDO) y la región del Iris con Hough Transform (CHT). Normalización: El método de la lámina de goma de Daugman, Mejora de contraste: Ecualización de histograma. Extracción: Gabor Filter, Matriz de coocurrencia de niveles de grises (GLCM) Clasificación: árboles de decisión, Naive Bayes, SVM y redes neuronales,	El estudio demuestra que el análisis de imágenes de iris junto con técnicas de aprendizaje automático puede utilizarse para predecir enfermedades y trastornos.
(Özbilgin, Kurnaz, y Aydın 2023).	Predecir la enfermedad arterial coronaria utilizando imágenes de iris Localización de iris: operador diferencial integral (IDO) Normalización: El método de la lámina de goma de Daugman Extracción: Gabor Filter, Hilbert Transform, and Discrete Wavelet Transform (DWT) Clasificadores: Árbol de Decisión, Naive Bayes, SVM y Redes Neuronales	SVM logró el valor de precisión más alto con un 93%.

Tabla 2. Detección de enfermedades (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Cui et al. 2023).	Examinar las diferencias en los índices de flujo sanguíneo en el iris de personas sanas y diabéticas. Utiliza tomografía de coherencia óptica de angiografía de iris para medir la densidad de área vascular (VAD) y la densidad de esqueleto vascular (VSD)	Muestran diferencias significativas en los índices de flujo sanguíneo del iris
(Javanshir et al. 2023).	Evaluar el rendimiento de varios algoritmos en varios conjuntos de datos de Iris para identificar: Cáncer, Diabetes, Hígado y Vino. Algoritmo Genético (GA). Evolución Diferencial (DE). Evolución Gramatical (GE). Optimización por Enjambre de Partículas (PSO). Colonia Artificial de Abejas (ABC). Cuckoo Search (CS). Búsqueda de Armonía (HS).	El Algoritmo CS registró el mejor rendimiento entre los siete algoritmos. Las precisiones fueron para los datos de: Iris, Cáncer, Diabetes e Hígado de: 98.58%, 97.68%, 77.52% y 68.71%, respectivamente

Tabla 2. Detección de enfermedades (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Padmasini et al. 2022).	Detección de anormalidades en los riñones debido a la diabetes mellitus utilizando la técnica de iridología. El estudio se realizó con 24 sujetos sanos y 24 sujetos con anormalidades renales debido a la diabetes mellitus. Se extrajeron características texturales de la región del iris que corresponde a los riñones utilizando la matriz de coocurrencia de niveles de gris (GLCM). Estas características se utilizaron como entrada para el algoritmo de clasificación Random Forest.	El sistema logró una precisión del 83.33% en la clasificación automática de casos normales y anormales, se señala que se necesitan más imágenes para confirmar la eficacia de la iridología como herramienta de diagnóstico de enfermedades renales
(Vresdian et al. 2022).	Recopilación de estudios que utilizan técnicas de procesamiento de imágenes para analizar el iris y extraer información relevante para el diagnóstico médico. Entre los métodos se observan: análisis discriminante lineal (LDA), redes neuronales (NN), filtros de Gabor, transformada de Hough, entre otros.	Se destaca el potencial de la iridología como método confiable en el diagnóstico médico, pero también se señalan las limitaciones y desafíos que aún deben abordarse.
(Yashodhara y Ranasinghe 2021).	Detección temprana de diabetes mediante iridología, se emplea una cámara Canon DSLR, se elimina el ruido de las imágenes usando Wiener Filter, se localiza y segmenta para extraer la información relevante del iris. Se emplea un modelo CNN.	Se alcanza una precisión del 85% en la predicción de diabetes

Tabla 2. Detección de enfermedades (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Digey 2021).	Propone un sistema para la detección de diabetes utilizando la retinopatía diabética y la implementación de redes neuronales convolucionales (CNN). El sistema propuesto utiliza imágenes de la retina para comprender sus condiciones fisiológicas y el estado de su páncreas.	Se logró una precisión del 93% en el conjunto de datos de entrenamiento y un 75% de precisión en el conjunto de datos de validación. El sistema dio resultados satisfactorios.
(Velia y Saputro 2020).	Detección temprana de diabetes mellitus mediante iridología utilizando una CNN (red neuronal convolucional). El entrenamiento se realizó con imágenes de 720x360 y se utilizó el algoritmo Adam con una tasa de aprendizaje de 0.001. Se emplean 35 imágenes de personas sanas y 14 con diabetes	Se realizó un conjunto de pruebas utilizando imágenes de iris y se obtuvo una precisión del 96.43%. Estos resultados demuestran la eficacia del sistema en la detección temprana de la enfermedad.
(Simangunsong et al. 2019).	Detección de enfermedades (colesterol y diabetes mellitus) utilizando iridología y técnicas de aprendizaje de imágenes, para el colesterol se emplea filtrado de Gabor en 15 imágenes propuestas. Se utiliza una CNN para la detección de diabetes mellitus.	La tasa de éxito del colesterol fue del 86%. La precisión en la diabetes fue del 96.43%

Tabla 2. Detección de enfermedades (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Samant y Agarwal 2019).	Diagnosticar diabetes utilizando aprendizaje automático y características del iris. Se extrajeron características basadas en coocurrencia de niveles de gris y características basadas en la matriz de longitud de ejecución de niveles de gris de áreas específicas del iris, se analizan 6 métricas (exactitud, precisión, sensibilidad, F1 y UAC) de cada clasificador. Se realizan pruebas a 334 sujetos.	Resultando en precisión 95%.
(Aminah y Saputro 2019).	Validar el uso de iridología para diagnosticar diabetes mediante el aprendizaje automático. Captura imagen, en ella se aplica Matriz de Coocurrencia para extraer características. Se utilizaron cinco métodos diferentes de clasificación. Se usan 16 sujetos no diabéticos y 11 sujetos diabéticos.	Se validaron y evaluaron los resultados utilizando validación cruzada k-fold y una matriz de confusión. Los resultados mostraron que la mejor precisión fue del 85,6%, con una especificidad del 0,90 y una sensibilidad del 0,80.
(Moradi et al. 2018).	Detectar diabetes mellitus utilizando imágenes de iris Segmentación: Hough Transform, Rubber sheet transform, extracción de características: filtro Gabor, histograma de gradientes orientados y patrón binario local. Clasificadores: Redes Neuronales, Random Forest, Análisis Discriminante Lineal, AdaBoost.	El modelo AdaBoost, con características de píxeles, HOG, LBP y filtro Gabor, tuvo la mejor precisión en la identificación de pacientes diabéticos con una tasa de precisión del 93%.

Tabla 2. Detección de enfermedades (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Samant y Agarwal 2018).	Validez diagnóstica de la iridología, utilizando métodos de computación suave. Se capturó imagen infrarroja de los ojos, para obtener características estadísticas, texturales y de transformación de ondas discretas de la región de interés del iris. Se aplicaron diferentes métodos de selección y 6 clasificadores diferentes. El estudio se realizó con 338 sujetos, 180 tenían diabetes y 158 no la tenían.	Mayor precisión: Random Forest con 89.63%, sensibilidad máxima de 0.988 y una especificidad máxima de 0.9687 utilizando este método de selección de características t-test.

3.1.2. SEGMENTACIÓN DE IRIS.

Artículos enfocados en la segmentación de iris ya que es un paso necesario para el análisis de esta región quitando la esclerótica, pupila parpados y demás elementos que no influyen en la investigación (Tabla 3).

Tabla 3. Segmentación de iris

Artículo	Qué propone/ metodología	Resultados
(Malgheet et al. 2023).	Propone una red de segmentación múltiple llamada MS-Net, que utiliza un enfoque de aprendizaje profundo para mejorar la precisión de la segmentación del iris en entornos no ideales.	La precisión de MS-Net se evaluó en las bases de datos CASIA-Iris.V4-1000 y UBIRIS.V2, logrando una precisión general del 97.11% y 96.128%, respectivamente.

Tabla 3. Segmentación de iris (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Mohamad Ayob 2022).	Algoritmo de segmentación adaptativo del iris. Se utiliza el filtrado de Wiener y el cierre morfológico para el preprocesamiento de las imágenes de iris borrosas, y luego integra un contorno activo adaptativo inicial (AIC), para lograr la segmentación precisa del iris.	Los resultados experimentales respaldan la eficacia del algoritmo propuesto en términos de precisión 97.2 y velocidad 0.65 de ejecución.
(Li et al. 2021).	Presenta algoritmo de segmentación de iris utilizando una CNN denominada "Interleaved Residual U-Net" (IRUNet). El algoritmo fue evaluado en la base de datos CASIA-Iris-Thousands, que consta de 20,000 imágenes de iris capturadas en entornos no cooperativos, se realiza una comparación con otros métodos CNN utilizando la métrica de intersección sobre unión (IoU) con un umbral de 0.8 para evaluar la precisión de la segmentación.	Los resultados mostraron que el algoritmo propuesto logró una precisión de segmentación del 98.9% para el límite externo del iris y del 97.7% para el límite interno
(Hu et al. 2020).	Se utiliza el modelo de red EfficientNet-b0, se aplican técnicas de segmentación, normalización, extracción y coincidencia de características del iris en una red unificada. Se realizan pruebas en bases de datos de iris mixtas (CASIA Thousand y Mmu2) y se comparan los resultados con otros modelos de redes neuronales convolucionales populares.	El modelo EfficientNet-b0 logró una precisión del 98%, en menos de 10 iteraciones de entrenamiento

Tabla 3. Segmentación de iris (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Hapsari et al. 2020).	Realizó una investigación sobre la segmentación de imagen del iris combinando la Transformada de Hough y el método de Fuzzy C-Means. Se utilizaron 30 imágenes de la base de datos UBIRIS V2 para realizar pruebas	La sensibilidad obtenida es de 99,56. El valor medio de especificidad fue de 57,7103 y el valor medio de precisión fue del 90,5884%.
(Sardar, Banerjee, y Mitra 2020).	Se emplea un modelo de aprendizaje profundo llamado ISqEUNet para la segmentación del iris, basado en la red UNet y el módulo Squeeze-Expand para mejorar la eficiencia y la precisión de la segmentación. Se utilizaron 3 base de datos CASIA-IrisV4-Interval, IITD y UBIRIS.v2.	ISqEUNet superó a los modelos UNet y AttUNet en términos de precisión de segmentación en todos los conjuntos de datos. Incorporó el aprendizaje interactivo para mejorar aún más la precisión de la segmentación.
(Sardar et al. 2020).	Se emplea un modelo de aprendizaje profundo interactivo llamado ISqEUNet para la segmentación del iris en entornos no ideales, basado en la red UNet y el módulo Squeeze-Expand para mejorar la eficiencia y la precisión de la segmentación. Se utilizaron 3 base de datos CASIA-IrisV4-Interval, IITD y UBIRIS.v2.	El modelo ISqEUNet superó a los modelos UNet y AttUNet en términos de precisión de segmentación en todos los conjuntos de datos.

Tabla 3. Segmentación de iris (continuación de artículos enfocados en este tema).		
Artículo	Qué propone/ metodología	Resultados
(Lian et al. 2018).	Segmentación del iris utilizando una red neuronal llamada ATT-UNet. Entrenamiento del modelado: se usa UBIRIS.v2 y CASIA-IrisV4-Distance. Se evalúa el rendimiento mediante métricas como la tasa de error promedio (MER) y la tasa de verdaderos positivos promedios (mTPR).	Los resultados muestran que el modelo ATT-UNet supera a otros enfoques existentes, logrando una tasa de error promedio de 0.76% en UBIRIS.v2 y 0.38% en CASIA-IrisV4-Distance.
(Korobkin et al. 2018).	El objetivo es mejorar la precisión y robustez de la segmentación del iris. Emplean arquitecturas CNN la cuales son FCN y SegNet. Las cuales combinan técnicas de clasificación y segmentación semántica. Se entrenaron y evaluaron con los conjuntos de datos CASIA-Iris-Lamp, que presenta condiciones difíciles como cambios de iluminación, obstáculos y variaciones de contraste y brillo.	Se lograron valores de IoU de 0.93 y 0.92, respectivamente. Además, se realizó una evaluación en un conjunto de datos modificado, que simula condiciones aún más desafiantes, y se obtuvieron resultados aún mejores, con valores de IoU de 0.92 y 0.924 para FCN y SegNet, respectivamente.

3.1.3. REVISIONES METODOLÓGICAS Y MARCOS TEÓRICOS EN IRIDOLOGÍA

Artículos enfocados en la revisión sistemática de parámetros técnicos y metodología, ya sea para reconocimiento biométrico de iris o detección de enfermedad (Tabla 4).

Tabla 4. Revisiones metodológicas y marcos teóricos en iridología

Artículo	Qué propone/ metodología	Resultados
(Esteves et al. 2021).	Identificar avances en el campo de la iridología en la salud humana, entre los años 2014 al 2019	Se identificaron 5 tipos de dispositivos empleados para capturar la imagen del iris. Se identifica el uso de inteligencia artificial para el análisis de datos. Proponen 3 marcos teóricos para interpretación de los signos iridológicos
(Halim y Emanuel 2020).	El artículo examina las regiones del iris, la precisión de los sistemas de reconocimiento de regiones del iris. Se utilizaron métodos de extracción de características: matriz de coocurrencia de niveles de gris (GLCM), la proporción de blanco y negro, y el filtro de Gabor.	Los resultados mostraron que las regiones más estudiadas fueron Arcus Senilis y el Páncreas

3.1.4. LIBROS CONSULTADOS

Se realiza análisis del tema de iridología para la identificación de la zona de estudio y de las alteraciones que influyen para la identificación de la diabetes mellitus, para esto se recopilaron 4 libros (Tabla 5) y una entrevista con un experto en el área.

Tabla 5. Libros de iridología

Título/ autor/ año	Objetivo	Metodología	Aplicaciones	Conclusiones
Iridology Simplified (5th Ed.), Dr. Bernard Jensen, D.C. 1980 (Bernard D Jensen 2020)	Introducción a la iridología desde la perspectiva de Bernard Jensen, enfocada en los fundamentos y en la interpretación de signos básicos en el iris.	Observación empírica, creación de una carta del iris, identificación de signos y su relación con órganos del cuerpo.	Detección de inflamación, niveles de salud, análisis constitucional, identificación de necesidades nutricionales.	El iris refleja el estado del cuerpo entero y es una herramienta complementaria de diagnóstico.
Curso de Iridología Diagnosticodelasalud.com (Diagnosticodelasalud.com 2024)	Capacitar en la interpretación de signos iriológicos y en el uso clínico de la iridología.	Curso dividido en 9 clases con teoría, prácticas, mapas iridológicos y análisis de signos en pacientes.	Diagnóstico energético, patológico y psicológico; detección de intoxicaciones y debilidades constitucionales.	La iridología es una herramienta útil para el diagnóstico holístico y complementario en medicina integrativa.
Iridología - Curso Básico Asmecolpoz (Asmecolpoz 2024)	Ofrecer una guía básica para el aprendizaje de la iridología como ciencia de diagnóstico visual.	Explicación de signos en el iris, uso de mapas topográficos, y observación clínica.	Análisis de órganos afectados, determinación de niveles de inflamación, detección de toxicidad y deficiencias.	El iris refleja desequilibrios patológicos, y aunque no es concluyente por sí solo, es valioso como orientación diagnóstica.

Tabla 5. Libros de iridología (continuación de artículos enfocados en este tema).				
Título/ autor/ año	Objetivo	Metodología	Aplicaciones	Conclusiones
El gran libro de la iridología gráfico José Luis De La Fuente López, Claudia Azucena Onofre Agüero. 2012 (De La Fuente López y Onofre Agüero 2018)	Proporcionar una guía gráfica detallada para la interpretación del iris en diferentes sistemas del cuerpo.	Clasificación por tipos de iris, constituciones, toxicidades, y presencia de signos clínicos específicos.	Análisis avanzado del sistema gastro-intestinal, nervioso, circulatorio, linfático, y evaluación de tejidos.	La iridología permite observar alteraciones físicas y emocionales, apoyando un diagnóstico integral.

La iridología, constituye una disciplina que posibilita a un especialista identificar enfermedades sistémicas a través del análisis de imágenes del iris del individuo. Los profesionales examinan los patrones, colores y otras características del iris para evaluar la salud del paciente. Estos expertos comparan sus observaciones con cartas de iridología previamente elaboradas por otros autores, donde cada segmento del iris se asocia a una región específica del cuerpo (María Jesús 2020).

3.2. CONCLUSIÓN:

Este estudio indica métodos y procedimientos, anteriormente utilizados en proyectos que se enfocan en el análisis del iris, ya sea, para segmentación, reconocimiento o detección de enfermedades. De esta manera también se realiza en análisis de la teoría que facilita saber los métodos empleados por los expertos en el área iridología, identificando las zonas del iris relacionadas con los distritos órganos y sistemas del cuerpo humano; sin embargo, existen diversas enfermedades que pueden afectar el mismo órgano, de igual manera existen enfermedades que afectan múltiples órganos, por lo cual realizar un análisis completo del iris podría dar mejores resultados que el análisis de una zona en específico para la detección de una enfermedad.

Los artículos que se enfocan en la detección de enfermedades indican buena precisión en sus resultados, algunos con valores mayores al 90%, por lo que investigar la relación de enfermedades con alteraciones en el iris, resulta prometedor como un método no invasivo y no requiere recursos económicos elevados. De esta manera, puede ser una forma rápida, sencilla y económica para detectar enfermedades.

CAPÍTULO 4 METODOLOGÍA Y **DESARROLLO**

4.1 MODELO DE SOLUCIÓN

El modelo de solución cuenta con 7 procesos (Fig. 13), abarcando desde la adquisición de imágenes hasta la clasificación detectando la enfermedad diabetes mellitus, cada uno de estos pasos es importante para la detección de la misma.




Fig. 13. Modelo de solución

4.2. DESARROLLO DEL MODELO

En este apartado se describe el desarrollo de cada uno de los 7 procesos mencionados en el modelo de solución.

4.2.1 CONJUNTOS DE IMÁGENES.

Se recopilamos varios conjuntos de datos (Tabla 6), los cuales fueron empleados en entrenamiento de modelos de segmentación, evolución del modelo de segmentación y clasificación para la detección de la enfermedad diabetes mellitus.

Tabla 6. Conjuntos de datos usados

Conjunto de datos	Total de imágenes	Iris sanos	Iris diabéticos
diabetes-iridology Farabi Eye Hospital	325	175	150
CASIA	54.601	54.601	0
UBIRIS.V2	11.102	11.102	0
IIT Delhi Base de datos de iris versión 1.0 (2240 imágenes de iris)	1120	1120	0
MOBIUS (Segmentation) ¹	3,559	3,559	0

A. DIABETES-IRIDOLOGY, (Moradi et al. 2018).

88 casos diabéticos y 108 casos de control.

Se entrevistó a los sujetos diabéticos sobre su tipo de diabetes, la forma de control y el estado de la retinopatía diabética si existía (para investigaciones posteriores). El protocolo utilizado para la adquisición de datos fue bajo la supervisión de los oftalmólogos del Hospital de Farabi (Fig. 14).

B. CASIA-iris, (Chinese Academy of Sciences, Institute of Automation 2018).

Las imágenes de CASIA-Iris-Interval se realizan con cámaras de diseño propio para la cual se diseñó una matriz de LED NIR circular, con un flujo luminoso adecuado para la obtención de imágenes de iris, capturando imágenes muy claras permitiendo estudiar las características detalladas de la textura de las imágenes del iris (Fig. 15), (CASIA-IrisV4 2020).

C. UBIRIS.V2, (Proenca et al. 2010).

El objetivo principal del conjunto de datos consiste en evaluar la viabilidad de la longitud de onda visible, reconocimiento del iris en imágenes que no se encuentran en condiciones ideales. Cuenta con distintos tipos de imágenes no ideales, distancias de imagen, perspectivas y condiciones de iluminación (Fig. 16).

¹ "The images from the MOBIUS DATASET used in this work have been provided by the University of Ljubljana, Slovenia" (Matej et al. 2023; Matej Vitek et al. 2022; Vitek et al. 2020)

D. IIT DELHI BASE DE DATOS DE IRIS VERSIÓN 1.0, (Kumar y Passi 2010).

Este conjunto de datos se compone principalmente de las imágenes del iris recogidas de los estudiantes y el personal del IIT Delhi, Nueva Delhi, India. Adquirida usando cámara CMOS digital. Los sujetos tienen edades entre 14 a 55 años compuesto por 176 hombres y 48 mujeres. La resolución de estas imágenes es de 320' 240 píxeles y todas estas imágenes fueron adquiridos en el ambiente interior (Fig. 17).

E. MOBIUS (Segmentation), (Vitek et al. 2020).

Es un conjunto de datos disponible públicamente destinado principalmente a la investigación de reconocimiento ocular móvil. Fue desarrollado en la Universidad de Liubliana en el año 2019 (Fig. 18).




Fig. 14. DIABETES-IRIDOLOGY




Fig. 15. CASIA-iris



Fig. 16. UBIRIS.V2




Fig. 17. IIT DELHI



Fig. 18. MOBIUS

4.2.2 ALMACENAMIENTO.

En este proceso se separan las imágenes en distintas carpetas, esto para facilitar el posterior entrenamiento de los modelos, la primera separación es entre imágenes de personas diabéticas y no diabéticas. Dentro de estas carpetas se dividen los archivos en iris izquierdo y derecho, de igual manera se almacenan las máscaras e imagen segmentadas correspondientes en estas carpetas, como se muestra en la Fig. 19. Estructura de conjunto de datos.




Fig. 19. Estructura de conjunto de datos.

4.2.3. PREPROCESAMIENTO.

Lo primero que se realiza es la normalización del tamaño de las imágenes, permitiendo el uso de imágenes de diferentes fuentes y también reduce el tiempo de procesamiento.

Las imágenes se redimensionaron (modifican el tamaño) a un máximo de 356 x 356 píxeles. Esto mediante una regla de tres en relación entre el tamaño máximo permitido (356 píxeles) y la dimensión más grande de la imagen, se aplica este cálculo a ambos ejes (X e Y), asegurando que el ancho X y la altura Y se adapten sin deformar la proporción original. Para esto se usa la función cv2.resize de OpenCV. A continuación, se muestra la fórmula utilizada para calcular el factor de escala:

$$\text{Factor de escala} = \frac{\text{Tamaño máximo permitido}}{\max(\text{Ancho original}, \text{Alto original})} \quad (5)$$

De esta manera se garantiza que las imágenes sean adecuadas para su procesamiento, respetando sus características originales.

Posteriormente, se aplica el filtro Bilateral para la eliminación de ruido preservando los bordes de las imágenes. Para la obtención de bordes se utiliza el filtro Sobel y para la detección del iris se ocupa la transformada de Hough, tal como se puede observar en la Fig. 20.




Fig. 20. Filtros empleados para la detección del iris

Los parámetros usados en los filtros se dividen en dos, parámetros para la detección del iris (Tabla 7) y para la detección de la pupila (Tabla 8).

Tabla 7. Parámetros para el Procesamiento del Iris

Parámetros para el Procesamiento del Iris			
Parámetro	Valor	Función	Justificación
Filtro Bilateral	d=100, sigma_color=30, sigma_space=30	Suaviza la textura del iris preservando los bordes.	El iris tiene patrones complejos que necesitan suavizar sin perder su forma circular.
Sobel (ksize)	ksize=21	Detecta bordes gruesos del iris.	Un kernel grande (21x21) captura bordes difusos típicos del iris.
Hough (dp)	dp=1	Precisión máxima para detectar el círculo.	El iris es grande y necesita alta resolución en la detección.
Hough (min_dist)	altura_imagen / 8	Distancia mínima entre centros (evita duplicados).	Como solo hay un iris, se usa un valor alto relativo al tamaño de la imagen.

Parámetro	Valor	Función	Justificación
Hough (param1)	200	Umbral alto para el detector de bordes (Canny).	Filtra bordes débiles, conservando sólo los relevantes.
Hough (param2)	30	Sensibilidad para aceptar círculos.	Permite detectar el iris incluso si no es un círculo perfecto.
Hough (minRadius)	100 píxeles	Radio mínimo del iris.	Anatómicamente, el iris no puede ser muy pequeño en imágenes de alta resolución.
Hough (maxRadius)	120 píxeles	Radio máximo del iris.	Limita la detección a tamaños plausibles.

Tabla 8. Parámetros para el Procesamiento de la Pupila

Parámetros para el Procesamiento de la Pupila			
Parámetro	Valor	Función	Justificación
Umbralizado adaptativo	$\text{imagen} < (\text{min_val} + 0.1 * (\text{max_val} - \text{min_val}))$	Aísla píxeles oscuros (pupila).	La pupila es la región más oscura del ojo (umbral del 10% del rango dinámico).
Condición de color	promedio_intensidad < 50	Filtra círculos con intensidad promedio baja.	Elimina falsos positivos en zonas claras o reflejos.
Hough (dp)	dp=1	Precisión máxima para detectar el círculo.	La pupila necesita detección precisa, aunque ésta sea pequeña.
Hough (min_dist)	altura_imagen / 8	Distancia mínima entre centros.	Similar al iris, pero ajustado al tamaño de la imagen.

Parámetro	Valor	Función	Justificación
Hough (param1)	200	Umbral alto para el detector de bordes (Canny).	Prioriza bordes bien definidos de la pupila.
Hough (param2)	30	Sensibilidad para aceptar círculos.	Permite detectar pupilas ligeramente irregulares.
Hough (minRadius)	30 píxeles	Radio mínimo de la pupila.	La pupila es significativamente más pequeña que el iris.
Hough (maxRadius)	80 píxeles	Radio máximo de la pupila.	Evita confundir regiones grandes oscuras con la pupila.

Cabe mencionar que estos valores no funcionaron en todas las imágenes (Fig. 21 y Fig. 22), por lo que en este paso se tomó la decisión de entrenar modelos computacionales para evitar estos errores. Para ello se realizó la selección de las imágenes, las cuales funcionan con éxito con estos valores; de igual manera, se realizaron máscaras de forma manual mediante Paint, en imágenes donde al programa fallaba, para tener imágenes suficientes para un posterior entrenamiento.




Fig. 21. Detecciones de iris




Fig. 22. Detecciones de pupila

En conclusión, la detección del iris y pupila depende del tamaño de ambos círculos y ya que estos suelen variar en tamaño, los algoritmos deben ser capaces de procesar estos, pero, al realizar selección y entrenar un modelo que se encarga de esto, se reduce la probabilidad de cometer errores en este paso.

4.2.4. SEGMENTACIÓN

En este trabajo se realizan dos procesos de segmentación en imágenes de ojos humanos, la primera siendo la segmentación de iris. A este se le realiza una segunda segmentación la cual se encarga de aislar la zona del páncreas, tal como lo indica la iridología contemplando el desplazamiento de esta zona, dividiendo el iris en múltiples sectores los que corresponden a diferentes partes del cuerpo humano. La región del páncreas está en el área 7 pero puede estar desplazada por lo que es mejor abarcar las áreas 6 y 7.

A. SEGMENTACIÓN DE IRIS

En este proceso se crean imágenes binarias llamadas máscaras, las cuales representan píxeles activos e inactivos, indicando la región que se desea segmentar (iris y región páncreas del iris) de las imágenes obtenidas (conjuntos de datos), la creación de estas máscaras se logra mediante el preprocesamiento el cual nos permite localizar el iris y la pupila (Fig. 23), de esta manera se aísla solamente el iris, permitiendo crear las imágenes binarias, con las cuales se indica al algoritmo que región se desea conservar.




Fig. 23. Creación de máscara binaria para Segmentación de iris sin pupila.

De igual manera se realizan correcciones a las imágenes segmentadas mediante el uso de Paint (Fig. 24), para eliminación de párpados en imágenes donde el iris se ve cubierto por el mismo.




Fig. 24. Eliminación de párpados.

B. SEGMENTACIÓN DE ZONA PÁNCREAS

Se crea un código que divide las máscaras de cada iris en 12 partes (Fig. 25) tomando como centroide la pupila, para este proceso se emplean las máscaras generadas, considerando las áreas 6 y 7 (Fig. 26) uniendo las máscaras en una sola, la cual se denomina “zona páncreas” para esta tesis.




Fig. 25. Creación de 12 máscaras tomando pupila como centroide.



Fig. 26. Máscaras usadas para obtener zona páncreas

Después de obtener la máscara de iris y la zona del páncreas, se procede a realizar el entrenamiento, para esto se utilizan 4000 y 200 imágenes respectivamente, aplicando transformaciones para aumento de datos.

C. MODELOS DE SEGMENTACIÓN.

Los modelos entrenados fueron U-Net y samvit_base_patch16.sa1b, para facilitar la segmentación del iris y la región del páncreas ya que se abarcan diferentes tamaños de iris y pupila esto debido a su dilatación y contracción, de igual manera las variaciones en la distancia del dispositivo de captura, por lo que se vuelve necesario entrenar los modelos para una mayor precisión. Los datos para el entrenamiento de los modelos se dividieron en 80% para entrenamiento y 20% validación.

D. TRANSFORMACIONES.

Se utilizaron aumentos en los datos con el objetivo de mejorar el rendimiento de los modelos. Esto ayuda al modelo a aprender mejor al exponerlo a una mayor variedad de datos. Las transformaciones empleadas en ambos modelos fueron:

- Redimensionamiento (Resize): Ajusta las imágenes a un tamaño específico, en este caso, 224x224 píxeles. Esto asegura que todas las imágenes tengan dimensiones uniformes, facilitando su procesamiento por el modelo.
- Volteo Horizontal Aleatorio (RandomHorizontalFlip): Invierte las imágenes horizontalmente con una cierta probabilidad, ayudando al modelo a aprender invariancia a la orientación horizontal de los objetos.
- Ajuste Aleatorio de Color (ColorJitter): Modifica aleatoriamente el brillo y el contraste de las imágenes, simulando variaciones en las condiciones de iluminación y mejorando la robustez del modelo frente a cambios en la iluminación.
- Recorte Aleatorio Redimensionado (RandomResizedCrop): Extrae aleatoriamente una porción de la imagen y la redimensiona al tamaño deseado, permitiendo al modelo enfocarse en diferentes partes de la imagen y aprender características locales.
- Transformación Afín Aleatoria (RandomAffine): Aplica transformaciones geométricas como traslaciones, rotaciones y escalados, preservando la estructura de la imagen y ayudando al modelo a ser robusto frente a

variaciones geométricas.

- Desenfoque Gaussiano (GaussianBlur): Aplica un filtro de desenfoque gaussiano para suavizar la imagen, reduciendo el ruido y las variaciones de alta frecuencia.
- Ruido Gaussiano: Introduce ruido gaussiano a la imagen, simulando imperfecciones del mundo real y mejorando la capacidad del modelo para manejar datos ruidosos.
- Efecto de Reflejo (Flare): Añade un efecto de destello o reflejo a la imagen, simulando condiciones de iluminación intensa y ayudando al modelo a aprender a manejar tales artefactos.

4.2.5. EXTRACCIÓN Y CLASIFICACIÓN DE CARACTERÍSTICAS

La extracción de características se realiza usando ResNet-50 con preprocesamiento CLAHE (Fig. 27), para mejorar el contraste, una vez aplicado el filtro se remueve la última capa del modelo ResNet-50 (capa de clasificación) para obtener características intermedias (2048 dimensiones más columna de clasificación), almacenando “nombre_imagen, característica,..., etiqueta” el documento se guarda con el nombre de “caracteristicas_resnet_clahe.csv”.




Fig. 27. Filtro CLAHE

4.2.6. SELECCIÓN DE CARACTERÍSTICAS

Al documento “caracteristicas_resnet_clahe.csv” se le aplica selección de características, reduciendo la dimensionalidad de las características extraídas con ResNet-50 (de 2048 a 15 características) para mejorar la eficiencia y evitar *overfitting* (sobre ajuste).

Para la selección de características se aplican los siguientes algoritmos.

- Primero se eliminan características con varianza menores al 0.01
- ANOVA F-test: selecciona las 100 mejores características basadas en estadística F.
- Mutual Info: reduciendo a 50 características usando información mutua.
- PCA: proyecta 30 componentes principales.
- Random Forest Selection: elimina características con importancia menor a la mediana.

Se genera archivó “pipeline_seleccion.pkl” con los pasos para uso posterior en modelos entrenados.

El 80 % de las características seleccionadas se guardan en el archivo: “caracteristicas_seleccionadas_train.csv” para realizar entrenamientos de modelos, y el 20% en “caracteristicas_seleccionadas_test.csv” para pruebas. Esta división de datos y creación de los documentos se realiza automáticamente mediante código.

4.2.7. ENTRENAMIENTO DE MODELOS DE CLASIFICACIÓN

Se entrenaron y compararon múltiples modelos los cuales son:

- SVM
- Random Forest
- Gradient Boosting
- AdaBoost
- Logistic Regression
- KNN
- Decision Tree
- Naive Bayes
- XGBoost

Para este entrenamiento se aplicaron las configuraciones presentadas en la Tabla 9. Se usaron los documentos generados con las características: “caracteristicas_seleccionadas_train.csv” y “caracteristicas_seleccionadas_test.csv”, para ello se convierten las etiquetas categóricas ("diabetes", "no_diabetes") a numéricas (0/1) para compatibilidad con modelos.

Tabla 9. Configuración de Modelos de Clasificación

Configuración de Modelos de Clasificación			
Modelo	Variables Clave	Controlan	Justificación
SVM	kernel='linear'	Tipo de frontera de decisión	Problemas médicos suelen tener relaciones lineales interpretables
	C=1.0	Regularización	Balance entre ajuste a datos y generalización
	probability=True	Estimación de probabilidades	Permite calcular ROC-AUC
Random Forest	n_estimators=100	Número de árboles	Balance entre rendimiento y costo computacional
	max_depth=None	Profundidad de árboles	Captura interacciones complejas
	max_features='auto'	Características por división	$\sqrt{n_features}$ para diversidad en árboles

Modelo	Variables Clave	Controlan	Justificación
Gradient Boosting	n_estimators=100	Iteraciones de boosting	Suficiente para convergencia sin sobreajuste
	learning_rate=0.1	Contribución de cada árbol	Valor típico para balancear velocidad y precisión
	max_depth=3	Profundidad de árboles base	Limita complejidad para evitar sobreajuste
AdaBoost	n_estimators=100	Número de estimadores	Similar a otros ensembles para comparación justa
	learning_rate=1.0	Peso de cada clasificador	Valor por defecto (sin atenuación)
Regresión Logística	penalty='l2'	Tipo de regularización	Maneja mejor características correlacionadas que L1
	max_iter=1000	Iteraciones máximas	Garantiza convergencia en problemas complejos
KNN	n_neighbors=5	Vecinos considerados	Valor inicial común para problemas binarios
	weights='uniform'	Peso de vecinos	Simplifica interpretación
Árbol de Decisión	criterion='gini'	Medida de división	Más eficiente computacionalmente que entropía
	max_depth=None	Profundidad ilimitada	Como baseline para ver sobreajuste natural
Naive Bayes	var_smoothing=1e-9	Estabilización de varianza	Evita varianzas cero en características

Modelo	Variables Clave	Controlan	Justificación
XGBoost	n_estimators=100	Número de árboles	Consistente con otros ensembles
	learning_rate=0.3	Tasa de aprendizaje	Valor más alto que otros boosting para convergencia más rápida
	max_depth=6	Profundidad de árboles	Mayor capacidad de modelado no lineal
	eval_metric='logloss'	Métrica de evaluación	Adecuada para problemas de clasificación binaria

Las métricas empleadas para la evolución de los entrenamientos son las siguientes:

- Accuracy (precisión), (Díaz 2020).
Esta métrica indica el porcentaje total de valores correctamente clasificados, tanto positivos como negativos.
- Recall (Sensibilidad), (Gareth et al. 2023).
La tasa de verdaderos positivos es la sensibilidad: la fracción de los casos positivos (defaults) que son identificados correctamente, utilizando un umbral dado
- F1-Score, (Díaz 2020).
Métrica utilizada en problemas con conjunto de datos a analizar está desbalanceado. Combinando métricas precision y recall, para obtener un valor más objetivo.
- ROC-AUC (Área bajo la curva ROC), (Gareth et al. 2023).
El rendimiento general de un clasificador, resumido en todos los posibles umbrales, está dado por el área bajo la curva ROC (AUC). Una curva ROC ideal se ajusta a la esquina superior izquierda; por lo tanto, cuanto mayor es el área bajo la curva ROC, mejor es el clasificador.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$F1 \text{ score} = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (9)$$

Donde:

TP: verdaderos positivos

FP: falsos positivos

TN: verdaderos negativos

FN: falsos negativos

Estas ayudan a entender mejor el rendimiento de los modelos al analizar su predicción.

Todos estos procesos (extracción de características, selección de características, entrenamiento y evolución mediante las métricas anteriormente mencionadas) se realizan en la parte de la imagen de los iris derechos, iris izquierdo y en la zona páncreas, generando una comparativa entre el análisis de estas imágenes.

CAPÍTULO 5 PRUEBAS Y **RESULTADOS**

5.1. PRUEBAS Y RESULTADOS

En este capítulo se abordan las pruebas de segmentación y clasificación y, los resultados obtenidos en el desarrollo de este trabajo de tesis.

5.1.1 SEGMENTACIÓN.

Para el entrenamiento de los modelos de segmentación se ocuparon los conjuntos de datos CASIA-iris, IIT DELHI y UBIURIS.V2, estos conjuntos cuentan con diferentes características por lo cual permite a los modelos entrenarse de mejor forma, sus características se pueden observar en Tabla 10.

Tabla 10. Características de conjuntos usados para entrenamiento de modelo segmentador.


Conjunto	Resolución	Color	Condiciones	Cantidad	Formato
CASIA-iris	320x280	Escala de grises	Controlado en laboratorio	1500	JPG
IIT DELHI	320x240	Escala de grises	Controladas en interior	2000	BMP
UBIURIS.V2	356x267	Color RGB	Entornos no controlados	500	TIFF
Total de imágenes usadas					4000

Cada conjunto se enfoca en diferentes objetivos, tanto CASIA-iris como IIT Delhi destaca por sus detalles de texturas en el iris, a diferencia de UBIRIS.V2 la cual presenta condiciones más realistas, teniendo imágenes con luz natural, distintos ángulos y distancias de captura, mayor reflejo y desenfoque. Las 4000 imágenes se dividieron en 80% entrenamiento y 20% validación.

Los resultados del entrenamiento de los modelos de segmentación mostraron que el modelo U-Net superó al modelo basado en Vision Transformer (samvit_base_patch16.sa1b). Esto se evidencia claramente en los valores que se presentan en la Tabla 11 y en la Gráfica 1, donde se comparan métricas clave como son: precision, recall, F1-score y Accuracy para ambos modelos.

Tabla 11. Resultados de entrenamiento de Unet y Samvit

Métricas	Accuracy	Precision	Recall	F1 Score	Train Loss	Val Loss
Unet	0.984	0.916	0.927	0.921	0.021	0.04511
Samvit	0.980	0.900	0.906	0.903	0.037	0.04568




Gráfica 1. Resultados de entrenamiento de modelo de segmentación.

Aumento de imágenes

Además, se realizaron 11 rotaciones a las imágenes y sus máscaras, con ángulos de 30 grados, generando imágenes rotadas a 30°, 60°, 90°, 120°, 150°, 180°, 210°, 240°, 270°, 300° y 330°. Esto resultó en una mejora del Accuracy de 0.003.

El código de entrenamiento está configurado para un máximo de 100 épocas, con una condición de parada si no hay mejoras en 15 épocas. Por lo tanto, el entrenamiento concluyó en la época 42 (Gráfica 2).



Gráfica 2. Resultados del entrenamiento de la segmentación.

A. EVALUACIÓN DE MODELO DE SEGMENTACIÓN.

La evaluación del modelo se llevó a cabo comparando las máscaras generadas con las originales, utilizando para ello el conjunto de datos MOBIUS (Segmentación)².

La métrica principal para evaluar la precisión en modelos de segmentación es el IoU (Intersection over Union por sus siglas en inglés). Este análisis se realiza píxel por píxel, donde el área detectada del IoU representa la relación entre el área de intersección entre la máscara generada por el modelo y la máscara original. Este cálculo se efectúa mediante la siguiente ecuación:

$$IoU = \frac{TP}{(TP + FP + FN)} \quad (10)$$

Siendo:

TP: área de intersección entre la máscara predicha y máscara original.

FP: área predicha fuera del área de la máscara original.

FN: área que el modelo no pudo predecir.

Para entender mejor lo que se mencionó anteriormente, se genera un código que el cual proporciona las máscaras (la máscara predicha por el modelo y la máscara original) superpuestas. En esta representación, el área de intersección (TP) se muestra en color amarillo, el área predicha fuera de la máscara original (FP) en azul, y el área que el modelo no pudo predecir (FN) en blanco. Esto se puede observar en la imagen siguiente (Fig. 28), de igual manera se muestran los resultados en la Tabla 12.



Fig. 28. Imagen de conjunto de datos MOBIUS, donde se observa la máscara original y predicha combinadas, mostrando las diferencias (TP, FP, FN).

² The images from the MOBIUS DATASET used in this work have been provided by the University of Ljubljana, Slovenia” (Matej et al. 2023; Matej Vitek et al. 2022; Vitek et al. 2020)

Tabla 12. Resultados de evolución.

Métrica	Valor	Descripción
Val Loss	0.0424	La pérdida (loss) es bastante baja, lo cual sugiere que el modelo está funcionando bien en el conjunto de validación.
Accuracy	0.9835	Una precisión alta indica que el modelo clasifica correctamente la mayoría de los píxeles.
Precision	0.8842	La precisión mide la proporción de verdaderos positivos sobre el total de predicciones positivas. Indica que el modelo está prediciendo correctamente la mayoría de las áreas positivas.
Recall	0.8758	El recall mide cuántos de los verdaderos positivos son recuperados por el modelo. Es ligeramente inferior a la precisión, lo que puede indicar que el modelo pierde algunas áreas positivas.
F1 Score	0.8763	El F1 Score es el promedio armónico de precisión y recall. Es consistente con la precisión y el recall, y un valor de 87.63% indica un modelo bien equilibrado.
IoU (Intersection over Union)	0.7852	Un IoU de 78.52% indica que el modelo podría estar perdiendo algunas áreas o incluyendo píxeles incorrectos en las predicciones.
Dice Coefficient	0.8763	Similar al F1 Score.

Se nota que en las imágenes donde la mirada no está dirigida a la cámara o en aquellas con mucho reflejo, las máscaras presentan una mayor diferencia en comparación con las originales (Fig. 29). Por lo tanto, es importante que las imágenes utilizadas tengan el menor reflejo posible y que las personas miren de frente a la cámara o al dispositivo de captura.




Fig. 29. Se observa la diferencia entre máscaras dependiendo de la posición del iris


Por lo que las imágenes deben cumplir con estas condiciones para garantizar un buen funcionamiento del modelo.

B. SEGMENTACIÓN ZONA PÁNCREAS

Después de modificar las máscaras para obtener la zona del páncreas, como se explica en el tema 4.2.4; se procede a realizar entrenamiento. Para esto se utilizan 200 imágenes que fueron aumentadas aplicando las mismas transformaciones que se emplearon en los modelos anteriores (segmentación de iris), obteniendo un Accuracy de 0.992719. Los resultados de este entrenamiento se pueden observar en la Tabla 13 y en la Gráfica 3.

Tabla 13. Resultados de entrenamiento en segmentación zona páncreas.

Accuracy	Precision	Recall	F1 Score	Val Loss	Train Loss	Epoch
0.992719	0.78275	0.895979	0.835546	0.024719	0.009523	100



Gráfica 3. entrenamiento de segmentación zona páncreas.

Como los resultados indican, se tiene un alta Accuracy, lo que refleja un buen entrenamiento de este modelo. Esto, se puede observar en la Fig. 30.



Fig. 30. Imagen con máscara sobrepuesta en imagen. Máscara indicando con color azul el área que inca la segmentación.

5.1.2. CLASIFICACIÓN




Esta etapa se integra de 3 pruebas, las cuales incluyen 9 algoritmos de clasificación, para esto se emplea el conjunto de imágenes diabetes-iridology, del hospital Farabi Eye Hospital. Las características de las imágenes se muestran en Tabla 14 ,este conjunto cuenta con imágenes de 106 personas diabéticas y 124 personas sanas.

Tabla 14. Características de Diabetes–Iridology (Farabi Eye Hospital)

Resolución	Color	Condiciones	Cantidad	Formato
3456 x 2304	Color RGB	Entorno clínico: iluminación moderada, ligera variabilidad en enfoque y reflejos naturales del ojo	75 imágenes de control y 150 de diabéticos	JPG

Los 3 casos de experimentación se realizan mediante la usando imágenes de iris derecho, iris izquierdo y la zona páncreas, ubicada en el iris derecho, generando una comparativa entre el análisis de estas imágenes (Tabla 15). Los datos se dividieron en 80% entrenamiento y 20% validación en cada caso.

Tabla 15. Comparacion de iris derecho, izquierdo y zona páncreas de un mismo sujeto

	Iris derecho	Iris izquierdo
Imagen Hombre 61 años Diabetes tipo 2		
Segmentado Iris completo		
Zona páncreas		


A. PRIMER CASO: EVALUACIÓN DE IRIS DERECHO.

El objetivo de esta prueba es evaluar las características del iris del ojo derecho.

Se comparan los resultados de los 9 modelos de clasificación entrenados, de los cuales el mejor resultado obtenido fue con XGBoost obteniendo Accuracy de 0.93548387, Precisión de 0.93548387, F1-Score de 0.93548387 y ROC-AUC de 0.94017094 como se muestra en Tabla 16 y en Gráfica 4.

Tabla 16. Resultados de entrenamiento usando imágenes de iris derecho.

Resultados de entrenamiento usando imágenes de iris derecho				
Modelo	Accuracy	Precisión	F1-Score	ROC-AUC
SVM	0.87096774	0.87983871	0.87178097	0.91452991
Random Forest	0.83870968	0.84182705	0.83939239	0.94017094
Gradient Boosting	0.87096774	0.87096774	0.87096774	0.89316239
AdaBoost	0.90322581	0.90593657	0.90363543	0.94444444
Logistic Regression	0.87096774	0.87983871	0.87178097	0.91025641
KNN	0.90322581	0.92137097	0.90383254	0.91239316
Decision Tree	0.70967742	0.7074137	0.70779425	0.6965812
Naive Bayes	0.80645161	0.83518569	0.80725806	0.9017094
XGBoost	0.93548387	0.93548387	0.93548387	0.94017094



Gráfica 4. Resultados de entrenamiento usando imágenes de iris derecho.

Estos resultados indican un mejor desempeño del modelo XGBoost alcanzando los valores en: Accuracy de 0.93548387 (93.55%), Precisión de 0.93548387 (93.55%), F1-Score de 0.93548387 (93.55%) y ROC-AUC de 0.94017094 (94.02%).

Los modelos más próximos a XGBoost son AdaBoost y KNN, ambos con Accuracy de 0.9032, indicando un resultado menor por 0.0323. mientras que el peor resultado lo obtuvo Decision tree con un Accuracy de 0.7097, Precisión de 0.7074, F1-Score de 0.7078 y ROC-AUC de 0.6966.


B. SEGUNDO CASO: EVALUACIÓN DE IMÁGENES DE IRIS IZQUIERDO.

El objetivo de esta prueba es evaluar las características del iris del ojo izquierdo.

Se comparan los resultados de los 9 modelos de clasificación entrenados, de los cuales el mejor resultado obtenido Naive Bayes obteniendo Accuracy de 0.78571429, Precisión de 0.81845238, F1-Score de 0.78571429 y ROC-AUC de 0.83333333, como se muestra en Tabla 17 y en Gráfica 5.

Tabla 17. Resultados de entrenamiento usando imágenes de iris izquierdo.

Resultados de entrenamiento usando imágenes de iris izquierdo.				
Modelo	Accuracy	Precisión	F1-Score	ROC-AUC
SVM	0.67857143	0.68278388	0.67981567	0.80729167
Random Forest	0.67857143	0.68278388	0.67981567	0.8203125
Gradient Boosting	0.71428571	0.74404762	0.71428571	0.78645833
AdaBoost	0.71428571	0.74404762	0.71428571	0.71875
Logistic Regression	0.71428571	0.7244898	0.71575092	0.796875
KNN	0.67857143	0.68278388	0.67981567	0.79166667
Decision Tree	0.67857143	0.6967033	0.67980296	0.6875
Naive Bayes	0.78571429	0.81845238	0.78571429	0.83333333
XGBoost	0.71428571	0.7244898	0.71575092	0.72916667



Gráfica 5. Resultados de entrenamiento usando imágenes de iris izquierdo.

Los resultados que usan estas imágenes indican una mejor predicción usando el modelo Naive Bayes obteniendo un Accuracy 0.78571429, Precisión 0.81845238, F1-Score 0.78571429 y ROC-AUC 0.83333333.

Los modelos que más se le aproximan serian Gradient Boosting, AdaBoost, Logistic Regression y XGBoost con Accuracy de 0.71428571 con una diferencia de 0.071 con respecto a Naive Bayes.

Mientras que los modelos SVM, Random Forest, KNN y Decision Tree presentaron un menor rendimiento obteniendo un Accuracy de 0.67857143, teniendo una diferencia de 0.107 comparado con Naive Bayes.


C. TERCER CASO: EVALUACIÓN DE IMÁGENES DE ZONA PÁNCREAS.

El objetivo de esta prueba es evaluar las características del iris en zona páncreas.

Se comparan los resultados de los 9 modelos de clasificación entrenados (*Tabla 18*), de los cuales el mejor resultado obtenido fue con Logistic Regression obteniendo Accuracy de 0.83870968, Precisión de 0.83842671, F1-Score de 0.83766347 en y ROC-AUC de 0.82905983en, como se muestra en *Tabla 18* y en *Gráfica 6*.

Tabla 18. Resultados de entrenamiento usando imágenes de zona páncreas.

Resultados de entrenamiento usando imágenes de zona páncreas.				
Modelo	Accuracy	Precisión	F1-Score	ROC-AUC
SVM	0.80645161	0.80645161	0.80645161	0.81196581
Random Forest	0.74193548	0.74046921	0.73797397	0.7991453
Gradient Boosting	0.74193548	0.75134409	0.74356194	0.76068376
AdaBoost	0.70967742	0.71360802	0.7109063	0.71367521
Logistic Regression	0.83870968	0.83842671	0.83766347	0.82905983
KNN	0.80645161	0.8155914	0.80767146	0.78205128
Decision Tree	0.67741935	0.67741935	0.67741935	0.66880342
Naive Bayes	0.80645161	0.80762463	0.80348048	0.83333333
XGBoost	0.67741935	0.68709677	0.67945243	0.74358974



Gráfica 6. Resultados de entrenamiento usando imágenes de zona páncreas.

El análisis de datos indica que al usar imágenes de zona páncreas el modelo Logistic Regression logró un mejor desempeño, ya que obtuvo los valores más altos en Accuracy (0.8387), Precisión (0.8384) y en F1-Score (0.8377), destacando en su capacidad de clasificaciones positivas correctas.

De esta manera Logistic Regression es mejor que MVS Y Naive Bayes los cuales tienen un Accuracy 0.8065, lo representa una mejora relativa del 3.32%. por otra parte, los modelos de Decision Tree y XGBoost obtuvieron el menor desempeño con un Accuracy de 0.6774.


5.1.3. ANÁLISIS DE RESULTADOS

Al comparar los resultados obtenidos en los distintos entrenamientos se concluye que el mejor resultado se obtuvo usando el iris completo derecho, siendo el mejor modelo XGBoost con un Accuracy de 0.93548387, de igual manera se presentan los mejores resultados en la Tabla 19.

Tabla 19. Mejores resultados dependiendo la imagen de entrada.

Zona	Mejor Modelo	Accuracy	Precisión	F1-Score	ROC-UAC
Iris derecho	XGBoost	0.935	0.9355	0.9355	0.9402
Zona páncreas	Logistic Regression	0.838	0.8384	0.8376	0.8290
Iris izquierdo	Naive Bayes	0.785	0.818	0.7857	0.8333

La diferencia entre los mejores resultados señala una superioridad de 9.6% en Accuracy por parte de XGBoost (usando iris derecho), con respecto a Logistic Regressio (usando zona páncreas) y con respecto a Naive Bayes (iris izquierdo) la diferencia es de 19.1%. En la Gráfica 7 se observa el resultado obtenido dependiendo la imagen usada destacando el iris derecho.



Gráfica 7. Comparación de mejores resultados.

Cabe mencionar que estos procesos de entrenamiento se realizaron usando imágenes de personas clínicamente diagnosticadas por oftalmólogos del Hospital de Farabi, mencionado en el artículo “Discovering Informative Regions in Iris Images to Predict Diabetes” (Moradi et al. 2018), en el cual se realiza un análisis de imágenes de iris completo y zona de páncreas. El artículo obtiene los mejores resultados con una Accuracy de 91.8% usando imagen de iris completo, estos resultados los lograron mediante adaBoost.

En comparación este proyecto de tesis, se logró una exactitud del 93.5% usando XGBoost con imágenes del iris derecho, en cuanto a los demás modelos se observó resultados muy similares.

CAPÍTULO 6 DESARROLLO DE LA **APLICACIÓN**

6.1. DESARROLLO DE LA APLICACIÓN

En este proceso digital, el cual trabaja con imágenes, por lo general requiere una gran cantidad de recursos (memoria, procesamiento y espacio de almacenamiento) en el dispositivo computacional ya sea en dispositivos móviles o fijos, por lo que el desempeño o velocidad de respuesta se ve afectados, considerando esto, la estrategia pensada para solucionar este problema consiste en tener un servidor que se encargue del procesamiento de la imagen y una aplicación móvil que solo se encargue de la captura de datos, comunicándose vía ethernet como se muestra en Fig. 31, mostrando que el proceso de solución consta de 3 fases.




Fig. 31. Etapas del sistema

Para desarrollar la aplicación primero se requiere adquirir un conjunto de imágenes para entrenar los modelos (modelo de segmentación y modelo de clasificación o predicción), por lo que, se enfoca en primera instancia en conseguir conjuntos de datos enfocados en el ojo humano para la creación de máscaras binarias mediante las cuales realizar el entrenamiento del modelo segmentación del iris. Posteriormente, se realiza la adquisición de imágenes de iris de personas con la enfermedad diabetes mellitus para el entrenamiento de modelos de clasificación.

6.1.1. CAPTURA DE DATOS Y DETECCIÓN DE IRIS.

La aplicación móvil se desarrolló usando flutter (*Flutter 2025*), ya que es multiplataforma lo cual facilita la migración a diferentes sistemas móviles (Android, ios), aplicaciones web e incluso aplicaciones para distintos sistemas operativos Windows, macOS y Linux, la aplicación por el momento se creó exclusivamente para Android ya que es el sistema telefónico con mayores usuarios y de más fácil acceso.

Entradas: Imágenes de iris ocular humano.

Desarrollar aplicación para dispositivos móviles la cual permitirá la adquisición de imágenes de iris para su posterior procesamiento en un servidor.

La aplicación es capaz de capturar imagen y datos, dar información a los usuarios sobre las características de la imagen que se debe cumplir, esta aplicación da información sobre el uso de la imagen y los demás datos recabados.

Datos del paciente usuario

Para crear poder usar la aplicación se debe de enviar la información: edad, sexo y de forma opcional agregar enfermedades diagnosticadas.

Detección de globo ocular, se realiza mediante librería haarcascade_eye.xml de OpenCV.

6.1.2. PROCESAMIENTO

El procesamiento de la imagen se realiza en el servidor, los datos confidenciales (edad, sexo y enfermedades) solo se almacenan en una base de datos.

- Segmentación del iris: se entrenó modelo Unet para segmentación de iris y región de páncreas los resultados indican una mejor clasificación usando el iris derecho por lo que el sistema realiza la evaluación de esta imagen, pero cuenta con ambos modelos.
- Extracción de características: emplea ResNet-50 para la extracción de características y mediante la selección de características, se identifican las más relevantes que puedan estar relacionadas con la diabetes, tales como la textura, la forma etc.

6.1.3. EVALUACIÓN Y CLASIFICACIÓN

Este proceso se realiza en el servidor, usando los modelos de clasificación para predecir la clase de pertenencia de la imagen ya se ha de persona diabética o persona sin diabetes.

- Clasificación: se entrenaron diversos modelos de clasificación al evaluarlos se determinó que el XGBoost cuenta con una mejor precisión por lo que es el encargado de realizar esta tarea.

Salidas:

- Al enviar los datos la aplicación de resultados del análisis estos indican Diabetes /no diabetes, de igual manera, informa que no es un diagnóstico, recomendando acudir al médico Fig. 32.




Fig. 32. Mensaje de resultado de analisis

Interfaz de Usuario:

La interfaz de usuario cuenta con 3 páginas de visualización la primera de visualización:

- **Home:** página de inicio da la bienvenida al usuario e informa que es una página para el análisis del iris, da opciones para acceder a las páginas de información y de captura de datos Fig. 33.
- **Información:** proporciona información sobre qué es la iridología y sobre cómo usar la aplicación Fig. 34
- **Captura:** permite al usuario capturar información (foto, edad, sexo, enfermedades diagnosticadas). Para enviar a analizar la imagen del iris es obligatorio tomar foto o seleccionar de galería, de igual forma la edad y sexo son obligatorios, agregar enfermedades diagnosticadas es opcional (Fig. 35)



Fig. 33. Vista Home




Fig. 34. Vista información




Fig. 35. Vista captura de informacion

CAPÍTULO 7 CONCLUSIONES

7.1 CONCLUSIONES

El presente proyecto de tesis cumple con los objetivos propuestos en los cuales son los siguientes:

A. OBJETIVO GENERAL

Desarrollar e implementar un modelo de inteligencia artificial (IA) para la extracción de características e identificación de la diabetes mellitus en el iris del ojo.

Se concluye que el sistema cumple con el objetivo principal del proyecto el cual realiza la detección de diabetes mellitus. Si bien al estudiar la iridología se detectaron factores que limitan la identificación de dicha enfermedad mediante un solo patrón, por ello, es más factible un análisis completo del iris en lugar de una sola región. De igual manera la teoría Iridología indica que estos patrones pueden estar desplazados 30 grados positivos o negativos dependiendo de cada individuo, por lo que no es posible realizar una delimitación precisa por este desplazamiento. Esto se justifica ya que estas alteraciones son indicativos de daños a los órganos, y estos daños pueden ser causados por múltiples enfermedades, por lo que es mejor analizar todo el iris a solo una región.

B. OBJETIVOS ESPECÍFICOS

- Revisar el estado del arte relacionado con la metodología para identificar métodos de clasificación e identificación de patrones relacionados con iridología.

En la iridología se observan alteraciones en los iris llamadas lagunas que indican daños en distintos órganos de igual manera se observan colores que indican envenenamiento o intoxicación en el cuerpo.

- Identificar características en el iris del ojo que están relacionadas con el área del páncreas de acuerdo con la iridología.

Se realizó el análisis de 4 libros sobre iridología, de igual manera se consultó con un experto en el área para corroborar la metodología, de esta manera se identificó que la alteración en del iris llamadas lagunas, se encuentra en el anillo 3, zona radial 7. Sin embargo, debido al que esta zona radial puede estar desplazada 30 grados y que los anillos se ven afectados por la dilatación y contracción de la pupila se tomó la decisión de tomar las áreas 6 y 7, uniéndolas para garantizar la observación de esta alteración.

- Identificar la relación entre los patrones encontrados en el iris del ojo y la diabetes mellitus.

Se realizó un proceso de extracción y selección de características en imágenes de iris y se utilizaron modelos de clasificación supervisada para la identificación. Estos modelos lograron un reconocimiento de personas sanas y personas con la enfermedad basándose solo en las características extraídas de imágenes, por lo

cual se infiere que existen patrones discriminativos en los iris asociados a la diabetes.

- Implementar un algoritmo de clasificación y aplicar las métricas tradicionales.

Se implementaron 9 algoritmos de clasificación y se aplicaron métricas tradicionales permitiendo analizar el desempeño de cada modelo. La experimentación y los resultados obtenidos se pueden ver en detalle en el capítulo 5.

- Recopilar una base de datos de imágenes del iris de personas sanas y diabéticas.

Se obtuvo el conjunto de datos de personas clínicamente diagnosticadas, por oftalmólogos del Hospital de Farabi, mencionado en el artículo “Discovering Informative Regions in Iris Images to Predict Diabetes” (Moradi et al. 2018), este conjunto de datos cuenta con 175 archivos de control y 150 archivos de personas diagnosticadas, las imágenes provienen de 106 personas diabéticas y 124 personas sanas.

De igual manera se recolectaron imágenes en varios centros clínicos, de las cuales se obtuvieron 146 imágenes de personas diagnosticadas, sin embargo, las condiciones del entorno, debido a la alta iluminación con la que cuentan estas instalaciones provocaron demasiado reflejo en las imágenes, y algunas personas contaban con afectaciones que imposibilitaban visualizar la zona del páncreas por lo que se descartan ya que no permitían su análisis

Cabe señalar también que las condiciones de la imagen en cuanto a iluminación y reflejo deben de ser lo menos invasivas posibles ya que estos factores junto con la mirada del individuo no dirigida al dispositivo de captura dificultan el análisis del iris, provocando ruido u obstruyendo la visualización completa del mismo.

- Evaluar desempeño de sistema y compararlo con el estado del arte.

La evaluación del sistema se realizó dividiendo el conjunto de datos en 80% para entrenamiento y 20%, para evaluación los resultados se pueden observar en el tema 5.1.3. ANÁLISIS DE RESULTADOS, de igual manera se compara con el trabajo “Discovering Informative Regions in Iris Images to Predict Diabetes”, el cual utiliza el mismo conjunto de datos y reporta un Accuracy de 91.8%, por lo que se concluye que el rendimiento de XGBoost de nuestro trabajo tiene un desempeño superior a este con un Accuracy de 93.5%.

C. LOGROS OBTENIDOS O CONTRIBUCIONES

Se realiza aplicación móvil la cual al conectarse con un servidor permite el análisis del iris realizando la predicción de la enfermedad, de esta manera los usuarios no requieren tener un dispositivo de gama alta, ya que el trabajo del análisis se hace en el servidor.

Se identifica que el iris indicado para esta predicción realizando una comparación entre iris derecho e izquierdo. ya que en este se encuentra la zona del páncreas y al analizar el iris completo se complementa con otras alteraciones que

pueden ser indicativos de la diabetes, de esta forma no se limita el área, lo permite detectar estos indicativos aun con el desplazamiento de los mismos.

D. TRABAJO A FUTURO

La aplicación móvil tiene la función de recabar datos de edad, enfermedades diagnosticadas, sexo y la imagen del usuario, por lo que, permite realizar una base de datos con toda esta información permitiendo en un futuro usar esto para el entrenamiento de nuevos modelos de identificación de enfermedades, teniendo en cuenta las variables de sexo y edad.

La falta de un conjunto de datos de imágenes de iris de personas con enfermedades diagnosticadas imposibilita la aplicación directa de redes neuronales por lo que se emplearon métodos tradicionales; aun así, los resultados son prometedores obteniendo 93.5 % de *accuracy* en la detección de este padecimiento, justificando la investigación y experimentación en este campo aplicando modelos de inteligencia artificial.

E. ACTIVIDADES ACADÉMICAS

Participación en proyecto Di-LSM de la categoría bienes de consumo en el certamen de proyectos, de la cumbre nacional de desarrollo tecnológico, emprendimiento e innovación, INNOVATEC 2025 etapa local (Fig. 37).




Fig. 37. Constancia innovatec

Se realizó un artículo publicado en academia journals (Fig. 38) titulado “Análisis de Imágenes de Iris Ocular de Personas Diabéticas y no Diabéticas”, No. ZTP128, con ISSN 1946-5351 online, Vol. 17, No. 06 en el cual se presentó en el 5º Congreso Internacional de Investigación Academia Journals CDMX desarrollado los días 02 y 03 de octubre de 2025, co-organizado por el Instituto Tecnológico de Iztapalapa y el Centro de Investigación Productos y Servicios Estratégicos para Investigación y Posgrado PYSEIP.



Fig. 38. Artículo No. ZTP128

Dos Certificados de autor otorgados por el Instituto Nacional del Derecho de Autor (INDAUTOR) por importantes desarrollos tecnológicos enfocados en el análisis del iris humano para la detección de patrones relacionados con la diabetes mellitus, junto con Dr. Nimrod González Franco, Dr. Máximo López Sánchez, Dr. Raúl Pinto Elías, Dr. René Santaolaya Salgado (Fig. 39).



Fig. 39. Registro de derechos de autor

ANEXOS

1. ESPECIFICACIONES DEL SISTEMA - ESTACIÓN DE TRABAJO

Hardware:	
Componente	Especificación
Procesador	Intel Xeon E5-2690 v4 @ 2.60GHz (2 procesadores)
Núcleos/Hilos	14 núcleos / 28 hilos (por procesador)
RAM	64.0 GB DDR4 (63.9 GB utilizable)
Almacenamiento	SSD: 894 GB ADATA SU630 HDD: 932 GB WDC WD10JPCX-24UE4T0
Tarjeta Gráfica	NVIDIA GeForce RTX 4060 (8 GB GDDR6)
Arquitectura	x64
Software:	
Componente	Versión
Sistema Operativo	Windows 10 Pro 22H2 (Build 19045)
Editor Principal	Visual Studio Code 1.103.2

2. ESPECIFICACIONES DEL SISTEMA – DESARROLLO DE APLICACIÓN MÓVIL

2.1 ARQUITECTURA TÉCNICA

Componente	Tecnología	Versión
Framework Principal	Flutter	3.19.0+
Lenguaje Desarrollo	Dart	3.3.0+
Lenguaje Nativo	Kotlin	1.8.22
Computer Vision	OpenCV	4.8.0+
Gradle Plugin	Android Gradle Plugin	8.1.0
Gradle	Gradle Build Tool	8.5

2.2 HERRAMIENTAS DE DESARROLLO

Herramienta	Versión	Propósito
Visual Studio Code	1.103.2+	Editor principal
Android SDK	API 34	Desarrollo Android
Java JDK	17+	Compilación Java/Kotlin
Flutter SDK	3.19.0+	Framework Flutter

2.3 COMPATIBILIDAD CON VERSIONES DE ANDROID

Android Versión	API Level	Soporte
Android 14	API 34	Completo
Android 13	API 33	Completo
Android 12	API 31-32	Completo
Android 11	API 30	Completo
Android 10	API 29	Completo
Android 9.0 Pie	API 28	Completo
Android 8.0-8.1 Oreo	API 26-27	Completo
Android 7.0-7.1 Nougat	API 24-25	Básico
Android 6.0 Marshmallow	API 23	Básico
Android 5.0-5.1 Lollipop	API 21-22	Básico

3. ESPECIFICACIONES DEL SISTEMA – DESARROLLO DE APIREST

Componente	Tecnología	Versión
Lenguaje	Python	3.10+
Framework	FastAPI	0.104.0+
Base de Datos	MySQL	8.0+

REFERENCIAS

- Academia Americana de Oftalmología. 2023. «partes del ojo y como vemos». <https://www.aao.org/salud-ocular/anatomia/partes-del-ojo>.
- Alañón Fernández, Félix Jesús, Manuela Cárdenas Lara, Miguel Angel Alañón Fernández, y Ana Martos Aguilera. 2025. «ANATOMÍA Y FISIOLOGÍA DEL APARATO OCULAR».
- Alsabhan, Waleed, y Turkey Alotaiby. 2022. «Automatic Building Extraction on Satellite Images Using Unet and ResNet50». *Computational Intelligence and Neuroscience* 2022:5008854. doi:10.1155/2022/5008854.
- American Diabetes Association. s. f. «Diagnóstico | ADA». Recuperado 27 de febrero de 2024. <https://diabetes.org/espanol/diagnostico>.
- Aminah, Ratna, y Adhi Harmoko Saputro. 2019. «Application of Machine Learning Techniques for Diagnosis of Diabetes Based on Iridology».
- Angie Padron. 2022. «Detección de bordes en datos sísmicos con filtros Sobel». Universidad Nacional de La Plata.
- Asmecolpoz. 2024. «Iridología». <https://infolibros.org/pdfview/14766-iridologia-asmecolpoz/>.
- Beraha, Mario, Alberto Maria Metelli, Matteo Papini, Andrea Tirinzoni, y Marcello Restelli. 2019. «Feature Selection via Mutual Information: New Theoretical Insights».
- Bernard D Jensen. 2020. *Iridology Simplified 5th Ed Bernard DJensen*. 5.^a ed.
- CASIA-IrisV4. 2020. <https://hycasia.github.io/dataset/casia-irisv4/>.
- Chinese Academy of Sciences, Institute of Automation. 2018. «BIT». <http://biometrics.idealtest.org/#/datasetDetail/2>.
- Coors, Stefan. 2020. «Automatic Gradient Boosting». Ludwig-Maximilians-Universität München.
- Cui, Lipu, Ying Xiao, Yu Qian, Qiurong Lin, Zhaoyu Xiang, Zhangling Chen, Jiaqi Sun, Xinran Qin, Chenhao Yang, y Haidong Zou. 2023. «Discrepancies in Vessel Density and Blood Flow Distribution in Different Areas of the Iris among Pediatric Type 1 Diabetes Mellitus and Adult Type 2 Diabetes Mellitus Patients». *Ophthalmic Research* 66(1):1139-47. doi:10.1159/000533278.
- De La Fuente López, José Luis, y Claudia Azucena Onofre Aguero. 2018. «El gran libro de iridología grafico». <https://es.slideshare.net/lucildalima1/el-gran-libro-de-iridologia-grafico>.

- Diagnosticodelasalud.com. 2024. *Curso de Iridología*. Infolibros.
- Díaz, Roberto. 2020. «▷ Métricas de Clasificación - Aprende a EVALUAR tu modelo». <https://www.themachinelearners.com/metricas-de-clasificacion/>.
- Digey, Mr Bhavesh. 2021. «DIABETES DETECTION USING CONVOLUTIONAL NEURAL NETWORKS (CNN) BASED MODEL».
- Esteves, Rafael Braga, Juceli Andrade Paiva Morero, Sandra De Souza Pereira, Karina Dal Sasso Mendes, Kathleen Mary Hegadoren, y Lucilene Cardoso. 2021. «Parameters to Increase the Quality of Iridology Studies: A Scoping Review». *European Journal of Integrative Medicine* 43:101311. doi:10.1016/j.eujim.2021.101311.
- Figura 2. Zonas en el iris humano (Bernard, 1980). s. f. Recuperado 4 de noviembre de 2025. https://www.researchgate.net/figure/Figura-2-Zonas-en-el-iris-humano-Bernard-1980_fig2_283080396.
- Flutter. 2025. «Multi-Platform». [//flutter.dev/multi-platform/](https://flutter.dev/multi-platform/).
- Freund, Yoav, Robert E. Schapire, T. Labs, Shannon Laboratory, Park Avenue, y Florham Park. 1999. «A Decision-Theoretic Generalization of on-Line Learning and an Application to Boosting». <https://cseweb.ucsd.edu/~yfreund/papers/IntroToBoosting.pdf>.
- Galvez Galvez, Yanet. 2017. «Suavizado de imágenes digitales mediante procesamiento a nivel de subpíxel».
- Gareth, James, Witten Daniela, Hastie Trevor, y Tibshirani Robert. 2023. *An Introduction to Statistical Learning*. 2.^a ed. Springe.
- Gómez Sarasa, Cristian Camilo, y José David Ortega Pabón. 2020. «Técnicas de aumento de datos para imágenes aéreas y evaluación de rendimiento en modelos de deep learning». *Revista Universidad Católica de Oriente* 31(45):100-115. doi:10.47286/01211463.285.
- Hailakar, Sarthak, Sanket Godase, Abhishek Laygude, y P. A. Bhor. 2022. «X-Ray Image Enhancement Using CLAHE Method». 09(02).
- Halim, Robby, y Andi Emanuel. 2020. «A Review of Iris Recognition System ROI and Accuracy». Pp. 1-6 en.
- Hapsari, R. K., M. I. Utoyo, R. Rulaningtyas, y H. Suprajitno. 2020. «Iris Segmentation Using Hough Transform Method and Fuzzy C-Means Method». *Journal of Physics: Conference Series* 1477(2):022037. doi:10.1088/1742-6596/1477/2/022037.
- Hu, Qingqiao, Siyang Yin, Huiyang Ni, y Yisiyuan Huang. 2020. «An End to End

- Deep Neural Network for Iris Recognition». *Procedia Computer Science* 174:505-17. doi:10.1016/j.procs.2020.06.118.
- IBM. 2021a. «¿Qué es el algoritmo de k vecinos más cercanos?» <https://www.ibm.com/mx-es/think/topics/knn>.
- IBM. 2021b. «¿Qué es la regresión logística?» <https://www.ibm.com/mx-es/think/topics/logistic-regression>.
- IBM. 2021c. «¿Qué es un árbol de decisión?» <https://www.ibm.com/mx-es/think/topics/decision-trees>.
- IBM. 2023. «¿Qué es machine learning? | IBM». <https://www.ibm.com/es-es/topics/machine-learning>.
- IBM. 2024. «¿Qué es XGBoost?» <https://www.ibm.com/mx-es/think/topics/xgboost>.
- IDF. s. f. «Facts & Figures». Recuperado 24 de enero de 2024. <https://idf.org/about-diabetes/diabetes-facts-figures/>.
- IDF, Diabetes Atlas. s. f. «Global Diabetes Data Report 2000 — 2045». Recuperado 24 de enero de 2024. <https://diabetesatlas.org/data/>.
- IMSS, GOB. 2023. «Diabetes Mellitus | Sitio Web “Acercando el IMSS al Ciudadano”». <https://imss.gob.mx/salud-en-linea/diabetes-mellitus>.
- INEGI, Estadísticas de defunciones registradas. 2023. «Defunciones registradas por diabetes mellitus por entidad federativa de residencia habitual de la persona fallecida y grupo quinquenal de edad según sexo, serie anual de 2010 a 2022». https://www.inegi.org.mx/app/tabulados/interactivos/?pxq=Mortalidad_Mortalidad_04_d711a1b5-36f6-4b12-9ed4-461f6ec71417.
- Janngam, Kobkoon, Suthep Suantai, Yeol Je Cho, Attapol Kaewkhao, y Rattanakorn Wattanataweekul. 2023. «A Novel Inertial Viscosity Algorithm for Bilevel Optimization Problems Applied to Classification Problems». *Mathematics* 11(14):3241. doi:10.3390/math11143241.
- Javanshir, Amirhossein, Thanh Thi Nguyen, M. A. Parvez Mahmud, y Abbas Z. Kouzani. 2023. «Training Spiking Neural Networks with Metaheuristic Algorithms». *Applied Sciences* 13(8):4809. doi:10.3390/app13084809.
- Kirillov, Alexander, Eric Mintun, Nikhila Ravi, Hanzi Mao, Chloe Rolland, Laura Gustafson, Tete Xiao, Spencer Whitehead, Alexander C. Berg, Wan-Yen Lo, Piotr Dollár, y Ross Girshick. 2023. «Segment Anything».
- Korobkin, M., G. Odínokikh, Yu. Efimov, I. Solomatin, y I. Matveev. 2018. «Iris Segmentation in Challenging Conditions». *Pattern Recognition and Image*

Analysis 28(4):652-57. doi:10.1134/S1054661818040193.

Kumar, Ajay, y Arun Passi. 2010. «Comparison and Combination of Iris Matchers for Reliable Personal Authentication». *Pattern Recognition* 43(3):1016-26. doi:10.1016/j.patcog.2009.08.016.

Kundu, Nitish. 2023. «Exploring ResNet50: An In-Depth Look at the Model Architecture and Code Implementation». <https://medium.com/@nitishkundu1993/exploring-resnet50-an-in-depth-look-at-the-model-architecture-and-code-implementation-d8d8fa67e46f>.

Li, Yung-Hui, Wenny Ramadha Putri, Muhammad Saqlain Aslam, y Ching-Chun Chang. 2021. «Robust Iris Segmentation Algorithm in Non-Cooperative Environments Using Interleaved Residual U-Net». *Sensors (Basel, Switzerland)* 21(4):1434. doi:10.3390/s21041434.

Lian, Sheng, Zhiming Luo, Zhun Zhong, Xiang Lin, Songzhi Su, y Shaozi Li. 2018. «Attention Guided U-Net for Accurate Iris Segmentation». *Journal of Visual Communication and Image Representation* 56:296-304. doi:10.1016/j.jvcir.2018.10.001.

Malgheet, Jasem Rahman, Noridayu Bt Manshor, Lilly Suriani Affendey, y Alfian Bin Abdul Halin. 2023. «MS-Net: Multi-Segmentation Network for the Iris Region Using Deep Learning in an Unconstrained Environment». *IEEE Access* 11:59368-85. doi:10.1109/ACCESS.2023.3282547.

Mangas, Andrés Sánchez, y Vanessa Gómez Verdejo. 2012. «ANÁLISIS DE COMPONENTES PRINCIPALES»:

María Jesús, Cano Llergo. 2020. «CONTROVERSIA SOBRE LA IRIDOLOGÍA - [PDF Document]». <https://vdocuments.mx/controversia-sobre-la-iridologia.html>.

Matej Vitek, Abhijit Das, Diego Rafael Lucio, Luiz Antonio Zanolensi, David Menotti, Jalil Nourmohammadi Khirak, Mohsen Akbari Shahpar, Meysem Asgari-Chenaghlu, Farhang Jaryani, Juan E. Tapia, Andres Valenzuela, Caiyong Wang, Yunlong Wang, Zhaofeng He, Zhenan Sun, Fadi Boutros, Naser Damer, Jonas Henry Grebe, Arjan Kuijper, Kiran Raja, Gourav Gupta, Georgios Zampoukis, Lazaros Tsochatzidis, Ioannis Pratikakis, S. V. Aruna Kumar, B. S. Harish, Umapada Pal, Peter Peer, y Vitomir Štruc. 2022. «Exploring Bias in Sclera Segmentation Models: A Group Evaluation». 17:1962-75. doi:10.1109/TIFS.2022.3175415.

Matej, Vitek, Bizjak Matic, Peer Peter, y Štruc Vitomir. 2023. «IPAD: Iterative Pruning with Activation Deviation for Sclera Biometrics». doi:10.1016/j.jksuci.2023.04.019.

MathWorks. 2024. «Reconocimiento de patrones (Pattern Recognition)».

<https://la.mathworks.com/discovery/pattern-recognition.html>.

- Mohamad Ayob, Ahmad Faisal. 2022. «ADAPTIVE INITIAL CONTOUR AND PARTLY-NORMALIZATION ALGORITHM FOR IRIS SEGMENTATION OF BLURRY IRIS IMAGES». *Journal of Information and Communication Technology* 21. doi:10.32890/jict2022.21.3.5.
- Moradi, Parsa, Naghme Nazer, Amirhosein Ahmadi, Hoda Mohammadzade, y Hasan Jafari. 2018. «Discovering Informative Regions in Iris Images to Predict Diabetes». Pp. 1-6 en.
- Navalón, Dr Jorge. 2020. «Qué es el humor acuoso y qué función tiene». <https://www.clinicabaviera.com/blog/humor-acuoso-que-es-funcion/>.
- Núñez, Melisa Andrea Acevedo, y Karen Elizabeth Vargas Campos. 2017. «Machine Learning: algoritmos de clasificación y sus aplicaciones en el análisis de datos». Universidad Nacional Autónoma de México.
- Nyongesa, Denis. 2020. «Variable Selection Using Random Forests in SAS®».
- Önal, Merve Nur, Gür Emre Güraksin, y Reşat Duman. 2023. «Convolutional Neural Network-Based Diabetes Diagnostic System via Iridology Technique». *Multimedia Tools and Applications* 82(1):173-94. doi:10.1007/s11042-022-13291-3.
- OZBİLGİN, Ferdi, y Cetin KURNAZ. 2023. «Koroner Arter Hastalığının İris Görüntülerinden Yerel İkili Örüntüler ve Yapay Sinir Ağı Kullanılarak Tahmini». <https://dergipark.org.tr/tr/pub/kfbd/issue/77891/1266996>.
- Özbilgin, Ferdi, Çetin Kurnaz, y Ertan Aydın. 2023. «Prediction of Coronary Artery Disease Using Machine Learning Techniques with Iris Analysis». *Diagnostics* 13(6):1081. doi:10.3390/diagnostics13061081.
- Padmasini, N., J. Aarthi, U. Deepika, y R. Deepshikhaa. 2022. «Iridology Based Diagnosis of Kidney Abnormalities Due to Diabetes Mellitus». 12(1).
- Pathan, Muhammad Salman, Avishek Nag, Muhammad Mohsin Pathan, y Soumyabrata Dev. 2022. «Analyzing the impact of feature selection on the accuracy of heart disease prediction».
- Pineda Tapia, Rodrigo. 2016. «Reconocimiento Automático de Alteraciones en el Iris; caso de Estudio: Cáncer Abdominal». <http://187.188.90.136:8880/file.php?code=RkOMhdfltb5x>.
- Pinheiro, Dr Pedro. 2015. «Pruebas para diagnóstico y monitoreo de la diabetes». <https://www.mdsau.de.com/es/endocrinologia-es/diagnostico-de-la-diabetes-mellitus/>.

- Proenca, Hugo, Silvio Filipe, Ricardo Santos, Joao Oliveira, y Luis A. Alexandre. 2010. «The UBIRIS.v2: A Database of Visible Wavelength Iris Images Captured On-the-Move and At-a-Distance». *IEEE Transactions on Pattern Analysis and Machine Intelligence* 32(8):1529-35. doi:10.1109/TPAMI.2009.66.
- Punia, Sanjeev Kumar, Manoj Kumar, Surendra Kumar Pathak, y Xiaochun Cheng. 2023. «Diabetes and Heart Disease Identification Using Biomedical Iris Data». *Applied and Computational Engineering* 2(1):336-45. doi:10.54254/2755-2721/2/20220676.
- Ramírez, Sebastián. 2025. «Alternatives, Inspiration and Comparisons - FastAPI». <https://fastapi.tiangolo.com/alternatives/>.
- Reshma, P. A., K. V. Divya, y T. B. Subair. 2019. «Detection of Heart Abnormalities and High-Level Cholesterol Through Iris». Pp. 339-46 en *Proceedings of the International Conference on ISMAC in Computational Vision and Bio-Engineering 2018 (ISMAC-CVB)*. Vol. 30, *Lecture Notes in Computational Vision and Biomechanics*, editado por D. Pandian, X. Fernando, Z. Baig, y F. Shi. Cham: Springer International Publishing.
- Rosales Banderas, José de Jesús. 2017. «Captura del Iris del Ojo Mediante Smartphone Considerando la Estabilización e Iluminación de la Imagen para Reconocer Alteraciones en el Iris que Permitan Identificar la Existencia del Anillo de Colesterol». <http://187.188.90.136:8880/file.php?code=v0cojKYj6-QK>.
- Samant, Piyush, y Ravinder Agarwal. 2018. «Machine Learning Techniques for Medical Diagnosis of Diabetes Using Iris Images». *Computer Methods and Programs in Biomedicine* 157:121-28. doi:10.1016/j.cmpb.2018.01.004.
- Samant, Piyush, y Ravinder Agarwal. 2019. «Analysis of Computational Techniques for Diabetes Diagnosis Using the Combination of Iris-Based Features and Physiological Parameters». *Neural Computing and Applications* 31(12):8441-53. doi:10.1007/s00521-019-04551-9.
- Sandhiya, M., y A. S. Aneetha. 2023. «A Survey of Advanced Learning Techniques Used for Initial Detection of Vital Human Organs Disorders through Iris». Pp. 1-4 en *2023 9th International Conference on Smart Structures and Systems (ICSSS)*. CHENNAI, India: IEEE.
- Sardar, Mousumi, Subhashis Banerjee, y Sushmita Mitra. 2020. «Iris Segmentation Using Interactive Deep Learning». *IEEE Access* 8:219322-30. doi:10.1109/ACCESS.2020.3041519.
- Secretaría de Salud, Salud. 2023. «547. En México, 12.4 millones de personas viven con diabetes». <http://www.gob.mx/salud/prensa/547-en-mexico-12-4-millones-de-personas-viven-con-diabetes?idiom=es>.

- Simangunsong, Louis Paulus Doli, Indri Natalia Napitupulu, Rina E. Lumbantoruan, Situlus Zalukhu, y Mariana Zebua. 2019. «The Expert System of Cholesterol Detection Based on Iris Using the Gabor Filter». *Sinkron* 4(1):13. doi:10.33395/sinkron.v4i1.10161.
- Thakur, Sanchari, LakshmiKanthan Muralikrishnan, Bijal Chudasama, y Alok Porwal. 2021. «Pattern Analysis». Pp. 1-4 en *Encyclopedia of Mathematical Geosciences, Encyclopedia of Earth Sciences Series*, editado por B. S. Daya Sagar, Q. Cheng, J. McKinley, y F. Agterberg. Cham: Springer International Publishing.
- Torres, Alejandro Domínguez. 1996. «Procesamiento digital de imágenes». *Perfiles Educativos* (72). hapsari.
- Urrea, Juan Pablo, y Emmanuel Ospina. 2004. «IMPLEMENTACIÓN DE LA TRANSFORMADA DE HOUGH PARA LA DETECCIÓN DE LÍNEAS PARA UN SISTEMA DE VISIÓN DE BAJO NIVEL.» *Scientia et technica* 1(24):79-84.
- Velia, Dyla, y Adhi Harmoko Saputro. 2020. «Retracted: Designing Diabetes Mellitus Detection System Based on Iridology with Convolutional Neural Network Modeling». Pp. 1-6 en *2020 4th International Conference on Informatics and Computational Sciences (ICICoS)*. Semarang, Indonesia: IEEE.
- Villate, María Amparo Mora, Juan Diego Bernal Méndez, y Juan Esteban Paneso Echeverry. 2016. «Anatomía quirúrgica del ojo: Revisión anatómica del ojo humano y comparación con el ojo porcino». *Morfología* 8(3):21-44.
- Vitek, M., A. Das, Y. Pourcenoux, A. Missler, C. Paumier, S. Das, I. De Ghosh, D. R. Lucio, L. A. Zanlorensi, D. Menotti, F. Boutros, N. Damer, J. H. Grebe, A. Kuijper, J. Hu, Y. He, C. Wang, H. Liu, Y. Wang, Z. Sun, D. Osorio-Roig, C. Rathgeb, C. Busch, J. Tapia, A. Valenzuela, G. Zampoukis, L. Tsochatzidis, I. Pratikakis, S. Nathan, R. Suganya, V. Mehta, A. Dhall, K. Raja, G. Gupta, J. N. Khirak, M. Akbari-Shahper, F. Jaryani, M. Asgari-Chenaghlu, R. Vyas, S. Dakshit, P. Peer, U. Pal, y V. Struc. 2020. «SSBC 2020: Sclera Segmentation Benchmarking Competition in the Mobile Environment». Pp. 1-10 en *2020 IEEE International Joint Conference on Biometrics (IJCB)*. Houston, TX, USA: IEEE.
- Vresdian, Devan Junesco, Anindya Ananda Hapsari, Shahad Al-Yousif, Arie Jaenul, Agnemas Yusoep Islami, y Brainvendra Widi Dionova. 2022. «Retracted: A Review of Image Processing Approaches of the Iridology as A Biomedical». Pp. 81-86 en *2022 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE)*. Riau, Indonesia: IEEE.
- WHO. 2023a. «Diabetes». <https://www.who.int/es/news-room/fact-sheets/detail/diabetes>.

WHO. 2023b. «Diabetes». <https://www.who.int/health-topics/diabetes>.

Wiechers, Dr Enrique Graue. s. f. «El ojo: estructura y función».

Yashodhara, P. H. A. H. K., y D. D. M. Ranasinghe. 2021. «Early Detection of Diabetes by Iris Image Analysis». Pp. 615-32 en *Inventive Computation and Information Technologies*. Vol. 173, *Lecture Notes in Networks and Systems*, editado por S. Smys, V. E. Balas, K. A. Kamel, y P. Lafata. Singapore: Springer Nature Singapore.

Ying, Su, Ge Qing-Shu, Li Zong-Yi, Bu Qian-Wen, Hu Die, Zhou Long-Fang, y Pan Xiao-Jing. 2023. «Assessment of iris volume in glaucoma patients with type 2 diabetes mellitus by AS-OCT». 16(5):5.

Zoé, Robledo, y Instituto Mexicano del Seguro IMS. 2023. «¿Cuánto cuesta la diabetes? ¿Qué hicimos?» <http://www.gob.mx/imss/articulos/cuanto-cuesta-la-diabetes-que-hicimos-zoe-robledo>.