



ESPE

UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

**CARRERA DE INGENIERÍA EN ELECTRÓNICA Y
TELECOMUNICACIONES**

**TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL
TÍTULO DE INGENIERO EN ELECTRÓNICA Y
TELECOMUNICACIONES**

**TEMA: DIAGNÓSTICO DE GASTRITIS BASADO EN
IRIDOLOGÍA MEDIANTE EL PROCESAMIENTO DIGITAL DE
IMÁGENES**

AUTORA:

SRTA. MAYA MEDINA, JENNIFER ELIZABETH

DIRECTOR: ING. CARRERA VINICIO PHD.

SANGOLQUÍ

2017



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
Y TELECOMUNICACIONES**

CERTIFICACIÓN

Certifico que el trabajo de titulación: ***“DIAGNÓSTICO DE GASTRITIS BASADO EN IRIDOLOGÍA MEDIANTE EL PROCESAMIENTO DIGITAL DE IMÁGENES”***, ha sido revisado en su totalidad y analizado por el software anti-plagio, el mismo cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad de Fuerzas Armadas ESPE, por lo tanto, me permito acreditarlo y autorizar a la señorita ***MAYA MEDINA JENNIFER ELIZABETH*** para que lo sustente públicamente.

Sangolquí, 10 de agosto del 2017

Ing. Vinicio Carrera PhD.

DIRECTOR



DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA


**CARRERA DE INGENIERÍA EN ELECTRÓNICA,
Y TELECOMUNICACIONES**

AUTORÍA DE RESPONSABILIDAD

Yo, **MAYA MEDINA JENNIFER ELIZABETH**, con cédula de identidad N°: 1722946645, declaro que este trabajo de titulación **“DIAGNÓSTICO DE GASTRITIS BASADO EN IRIDOLOGÍA MEDIANTE EL PROCESAMIENTO DIGITAL DE IMÁGENES”** ha sido desarrollado considerando los métodos de investigación existentes, así como también se ha respetado los derechos intelectuales de terceros considerándose en las citas bibliográficas.

Consecuentemente declaro que este trabajo es de mi autoría, en virtud de ello me declaro responsables del contenido, veracidad y alcance de la investigación mencionada.

Sangolquí, 10 de agosto del 2017


Maya Medina Jennifer Elizabeth
C.C. 1722946645




DEPARTAMENTO DE ELÉCTRICA Y ELECTRÓNICA

CARRERA DE INGENIERÍA EN ELECTRÓNICA, Y TELECOMUNICACIONES

AUTORIZACIÓN

Yo, **MAYA MEDINA JENNIFER ELIZABETH**, autorizo a la Universidad de las Fuerzas Armadas ESPE publicar en la biblioteca virtual de la institución el presente trabajo de titulación **“DIAGNÓSTICO DE GASTRITIS BASADO EN IRIDOLOGÍA MEDIANTE EL PROCESAMIENTO DIGITAL DE IMÁGENES”**, cuyo contenido, ideas y criterios son de nuestra autoría y responsabilidad.

Sangolquí, 10 de agosto del 2017



Maya Medina Jennifer Elizabeth
C.C. 1722946645

DEDICATORIA

El presente trabajo de titulación se lo dedico a mi mamá Rosalía Paquita Medina por ser el pilar fundamental en todo lo que soy, en toda mi educación, tanto académica, como de la vida, por su incondicional apoyo perfectamente mantenido a través del tiempo, por siempre ayudarme con una palabra de aliento, un abrazo sincero, una oración encomendándome siempre a Dios y el inmenso amor que me ha entregado en cada momento de mi vida.

A mi hermana María Fernanda Maya por sus constantes palabras de apoyo, creer firmemente en mí, y darme el mejor regalo que una hermana puede entregar, que son dos maravillosos sobrinos Julián y Valentina a quienes también dedico este trabajo de titulación.

Ustedes siempre serán mi motivación de ir más allá y salir de lo convencional, dando lo mejor de mí. Siempre intentando marcar una diferencia. Espero que ustedes estén tan orgullosas de mí como yo lo estoy de ustedes. Siempre juntas.

Jennifer Maya Medina

AGRADECIMIENTO

Agradezco a Dios, por cuidarme, bendecirme, demostrarme que el camino muchas veces no es como se quisiera, pero que a pesar de todo siempre se podrá sacar algo positivo, por ayudarme a mantener la fe y poner en mi camino a las personas adecuadas para alcanzar este objetivo.

A mis padres por sus sacrificios, trabajo y principalmente su paciencia. A mi madre por su bondad, inculcarme valores, recordándome constantemente que para ser un buen profesional es necesario ser una buena persona, por corregirme cuando cometo algún error y felicitarme por cada logro alcanzado, su constante preocupación por mí y por toda la dedicación que tuvo con mi hermana y conmigo. A mi padre por ser ejemplo de lo que debo lograr superar en mi vida académica y por su apoyo en muchas etapas de la vida.

A mi hermana por siempre estar pendiente de mí, regalarme ese abrazo de consuelo, ese silencio que muchas veces es necesario para reflexionar, su confianza, experiencia y principalmente por su comprensión en cada momento.

A mis amigos por formar parte de esta maravillosa etapa donde compartimos buenos y malos momentos, pero siempre nos tuvimos el uno al otro para salir adelante.

Al Dr. Telmo de la Torre por creer en este trabajo de titulación y ayudarme durante el desarrollo de la base de datos con su experiencia y conocimientos sobre iridología.

De manera especial quiero agradecer al Dr. Vinicio Carrera, por brindarme su paciencia, conocimientos, tiempo y dedicación. Gracias por confiar en este tema poco convencional y ayudarme a mejorarlo.

Jennifer Maya Medina

ÍNDICE DE CONTENIDO

CERTIFICACIÓN.....	i
AUTORÍA DE RESPONSABILIDAD	ii
AUTORIZACIÓN.....	iii
DEDICATORIA.....	iv
AGRADECIMIENTO	v
ÍNDICE DE CONTENIDO	vi
RESUMEN	xii
ABSTRACT.....	xiii
CAPÍTULO I.....	1
INTRODUCCIÓN	1
1.1. Antecedentes	1
1.2. Justificación e importancia.....	2
1.3. Alcance del proyecto.....	4
1.4. Objetivos	5
1.4.1. Objetivo general	5
1.4.2. Objetivos específicos	5
CAPÍTULO II	7
MARCO TEÓRICO.....	7
2.1. Introducción	7
2.2. Enfermedades del sistema digestivo.....	7
2.3. Anatomía del ojo.....	9
2.4. Medicina alternativa.....	10
2.4.1. Iridología.....	11
2.5. Imagen digital	17
2.6. Procesamiento Digital de Imágenes	18
2.6.1. Procesamiento digital basado en pixeles.....	18
2.6.2. Procesamiento basado en zonas de la imagen	20
2.6.3. Metodologías para localización de áreas circulares	21
2.7. Aprendizaje de máquina.....	25
2.7.1. Clasificadores	26
2.7.2. Árboles de decisión	28
2.7.3. Máquinas de soporte vectorial (SVM).....	29
2.7.4. K-Vecinos más cercanos (K-Nearest Neighbors)	32

	vii
2.7.5. Redes Neuronales	33
2.8. Evaluación de clasificadores	34
2.8.1. Validación cruzada	35
2.8.2. Matriz de confusión	36
2.8.3. Curvas ROC (Receiver Operating Characteristic)	37
2.9. Lenguajes de programación	38
2.9.1. OpenCV (Open Source Computer Vision)	38
2.9.2. Python	39
CAPÍTULO III.....	40
PROCEDIMIENTO	40
3.1. Introducción	40
3.2. Base de datos	41
3.2.1. Iriso	41
3.2.2. Imágenes adicionales	43
3.3. Descripción general del algoritmo.....	44
3.4. Preprocesamiento	45
3.4.1. Redimensión de imagen.....	46
3.4.2. Localización del área de interés	47
3.4.3. Segmentación del área de interés	50
3.4.4. Transformación de coordenadas	53
3.5. Extracción de características	55
3.5.1. Media de color.....	55
3.5.2. Desviación estándar.....	56
3.5.3. Intensidad de color según el nivel de afectación	56
3.5.4. Densidad de anomalías	57
3.5.5. Detección del anillo de absorción	57
3.5.6. Máxima intensidad de color.....	57
3.5.7. Mínima intensidad de color	57
3.6. Clasificador	58
CAPÍTULO IV	60
RESULTADOS	60
4.1. Introducción	60
4.2. Definición de <i>L</i>	60
4.3. Resultados con la base de datos de 100 imágenes	61

	viii
4.3.1. Árbol de decisión.....	61
4.3.2. Vecino más cercano KNN	63
4.3.3. SVM.....	63
4.3.4. Redes Neuronales	64
4.3.5. Comparativa del rendimiento de clasificadores	65
4.3.6. Matriz de confusión	65
4.3.7. Curvas ROC	67
4.4. Resultados con 77 imágenes de Iriso.....	67
4.4.1. Comparativa del rendimiento en los clasificadores	67
4.4.2. Matriz de confusión	68
4.1 Curvas ROC	69
CAPÍTULO V	71
CONCLUSIONES Y RECOMENDACIONES	71
5.1. Conclusiones.....	71
5.2. Recomendaciones.....	72
5.3. Trabajos Futuros	72
BIBLIOGRAFÍA	73

ÍNDICE DE TABLAS

Tabla 1	Inserción de la medicina alternativa dentro de los servicios de salud (2003)...	11
Tabla 2	Incidencia de enfermedades gástricas en 2014	14
Tabla 3	Comparativa de metodologías con la base de datos UBIRIS v1.....	25
Tabla 4	Ejemplo de matriz de confusión	36
Tabla 5	Características del computador empleado para las pruebas del prototipo	47
Tabla 6	Rango de intensidad según el nivel de afectación.....	56
Tabla 7.	Nombre de parámetros y número de atributos extraídos (implementados). ..	58
Tabla 8	Desempeño de los clasificadores según la distancia optima	60
Tabla 9	Rendimiento del clasificador árbol de decisión	61
Tabla 10	Desempeño de SVM según el kernel empleado	64
Tabla 11	Eficiencia de clasificadores	65
Tabla 12	Matriz de confusión árbol de decisión.	65
Tabla 13	Matriz de confusión vecino más cercano	66
Tabla 14	Matriz de confusión SVM.....	66
Tabla 15	Matriz de confusión redes neuronales	66

ÍNDICE DE FIGURAS

Figura 1 Anatomía del ojo	9
Figura 2 Mapa de Jensen ojo derecho	12
Figura 3 Mapa de Jensen ojo izquierdo.....	13
Figura 4 Muertes por enfermedades gástricas.....	15
Figura 5 Signos iridologicos en el iris humano.....	16
Figura 6 Etapas progresivas del reflejo tisular	17
Figura 7 Representación matricial del modelo RGB.....	18
Figura 8 Histograma de las componentes RGB de la imagen segmentada	19
Figura 9 Mascara de una imagen.....	20
Figura 10 Transformada de Hough circular	23
Figura 11 Técnicas de aprendizaje de máquina.....	26
Figura 12 Selección de algoritmo en el aprendizaje de máquina.....	27
Figura 13 Estructura de árbol de decisión	28
Figura 14 Ejemplo de los hiperplanos de separación para el conjunto de datos.....	30
Figura 15 Margen de separación óptimo que define el hiperplano se serpación	31
Figura 16 Uso del kernel para la división de clases	31
Figura 17 Distribución de tres grupos de datos con KNN.....	32
Figura 18 Ejemplo de red neuronal completamente conectada.....	34
Figura 19 Descrpción de validación cruzada	35
Figura 20 Representación gráfica de las curvas ROC.....	38
Figura 21 Imágenes del Iris: (a) Imagen con luz infrarroja, (b) Imagen a color.....	41
Figura 22 Tipos de iluminaciones disponibles en la base de datos Iriso.....	42
Figura 23 Imágenes adicionales con diferente resolución, iluminación y detalle	43
Figura 24 Proceso para la detección y diagnóstico de enfermedades gástricas.	45
Figura 25 Localización de un mapa de Jensen en un iris real.....	45
Figura 26 Preprocesamiento de imagen	46
Figura 27 Algoritmo de localización para el área de interes en la imagen.....	49
Figura 28 Reultado del proceso de localización de area de interes.....	50
Figura 29 Algoritmo para segmentación del area de interes	51
Figura 30 Máscara resultante para la imagen 1 de la base de datos	52
Figura 31 Máscara final implementada para la segmentación del iris.....	52
Figura 32 Imagen resultante de la segmentación.....	52
Figura 33 Ejemplo de normalización por el método de Daugman	53
Figura 34 Algoritmo para la transformación de coordenadas.....	54
Figura 35 Imagen realizada la transformación de coordenadas.....	55

Figura 36 Imagen resultante del proceso de cambio de coordenadas	55
Figura 37 Densidad de anomalías en base al color medio y desviación estándar	56
Figura 38 Imagen de segmentación binarizada	57
Figura 39 Algoritmo para los cuatro clasificadores.....	58
Figura 40 Grafica de ajuste del árbol de decisión con el criterio de entropía	61
Figura 41 Árbol de decisión con umbrrales por característica	62
Figura 42 Ajuste KNN en función del número de vecinos que considera	63
Figura 43 Desempeño de SVM según el kernel empelado.....	64
Figura 44 Curva ROC de SVM con un Kernel RBF	67
Figura 45 Curva ROC para el sistema con 77 imágenes	69

RESUMEN

El procesamiento digital de imágenes (PDI) ha adquirido un papel importante en el desarrollo tecnológico actual, debido a la posibilidad de automatizar procesos cuando se trabaja conjuntamente con el aprendizaje de máquina. Una aplicación importante del PDI son los sistemas CAD (*Computer Aided Diagnosis*), los cuales se encargan de facilitar el diagnóstico de patologías en función a una mejora en la imagen donde se resalta cierta área de interés para el especialista. Los sistemas CAD se encuentran generalmente aplicados a la medicina tradicional, aunque en estudios recientes han sido aplicados a medicina alternativa como, por ejemplo, la iridología; la cual se encarga de localizar posibles alteraciones en la salud en base a características mostradas en el iris. Por la distribución del mapa del iris, se optó por detectar anomalías gástricas, concretamente la gastritis, ya que gran parte de la población presenta esta patología en algún momento de su vida. Basado en esto, el presente trabajo tiene como objetivo diseñar e implementar un prototipo para generar un diagnóstico preventivo de la gastritis de forma automática; utilizando el procesamiento digital de imágenes, plantillas iridológicas y aprendizaje de máquina. El sistema implementado trabaja con 100 imágenes en una base de datos de donde se extraen 12 características de color por imagen, las cuales ayudan al sistema a detectar la presencia de gastritis. El prototipo debe realizar un diagnóstico preventivo automático por lo que debe aprender a discernir entre la información obtenida; en otras palabras, debe clasificar los pacientes. Por esta razón, se emplea métodos de aprendizaje supervisado como son: árbol de decisión, vecinos más cercanos, máquinas de soporte y redes neuronales. Los resultados de la evaluación del mejor clasificador son 94% y 92% los cuales representan los valores de exactitud y capacidad predictiva del sistema respectivamente.

PALABRAS CLAVES:

- IRIDOLOGÍA
- PROCESAMIENTO DIGITAL DE IMÁGENES
- APRENDIZAJE DE MÁQUINA SUPERVISADO

ABSTRACT

The digital image processing (DIP) has acquired an important role in the current technological development, due to the possibility of automating processes when working in conjunction with machine learning. An important application of the DIP is CAD (Computer Aided Diagnosis) systems, which are responsible of facilitating the diagnosis of pathologies in function of an improvement that consists in highlighting an area of the image that the specialist has interest on. CAD systems are generally applied to traditional medicine, but also in recent studies they have been applied to alternative medicine, such as iridology; which is responsible for locating possible alterations in health, based on characteristics shown on the iris. It was decided to detect gastric anomalies, specifically gastritis because of the distribution of the iris map and that large part of the population has this pathology at some point in their life. Based on this, the present work aims to design and implement a prototype to generate an preventive diagnosis of gastritis; using digital image processing, iridological templates and machine learning. The implemented system works with 100 images in a database from which 12 characteristic colors per image are extracted, which help the system to detect the presence of gastritis. The prototype must perform an automatic preventive diagnosis so it must learn to discern the information obtained; it sorts patients. For this reason, we use supervised learning methods such as: decision tree, nearest neighbors, support vector machines and neural networks. The results of the evaluation of the best classifier are 94% and 92% which represent the values of accuracy and predictive capacity of the system respectively.

KEYWORDS:

- IRIDOLOGY
- DIGITAL IMAGE PROCESSING
- SUPERVISED MACHINE LEARNING

CAPÍTULO I

INTRODUCCIÓN

1.1. Antecedentes

Actualmente el procesamiento digital de imágenes (PDI) es ampliamente utilizado por múltiples disciplinas, ya que permite extraer características importantes de los elementos que componen una imagen; como, por ejemplo: color, patrones geométricos, presencia de objetos, etc. Adicionalmente, con el aprendizaje de máquina se puede automatizar procesos iterativos aplicando el reconocimiento de objetos en base a las características obtenidas con PDI (Monar, 2014).

Las dos áreas de conocimiento previamente mencionadas, forman gran parte de lo que generalmente se conoce como visión artificial. La visión artificial se encuentra presente en varias verticales de mercado como por ejemplo en el sector industrial, transporte, gubernamental e incluso en la medicina.

La visión artificial consigue identificar objetos mediante la aplicación de técnicas derivadas del procesamiento digital de imágenes (PDI), las cuales permiten mejorar la calidad de las mismas (Leal, 2010), o incluso presentar particularidades que se encuentran fuera del rango de visión del observador, para esta característica se puede tener como ejemplo, los sistemas de diagnóstico asistido por computador (*Computer aided diagnosis*), que se encargan de procesar una imagen por completo y dar realce a cierta área de interés del médico tratante.

El sistema CAD (*Computer Aided Diagnosis*) es una tecnología interdisciplinaria (Sotolongo, 2013), que requiere los principios de PDI para destacar y extraer información de las imágenes médicas (puede ser una radiografía) (Gómez, 2010), incluso en áreas de difícil visualización debido a su bajo contraste o resolución. Estos sistemas requieren además del aprendizaje de máquina (*machine learning*) para clasificar los patrones relevantes que ayuden al especialista en su diagnóstico definitivo.

Los sistemas CAD comúnmente son desarrollados para implementarse conjuntamente con la medicina tradicional, aunque en nuevas investigaciones se ha

visto su utilidad en la medicina alternativa (Jogi, 2014), particularmente en iridología, ya que hace un análisis integral preventivo del paciente. Esta rama de la medicina alternativa se encarga de detectar enfermedades en base al análisis de color del iris y sus delicadas estructuras musculares que lo componen.

Iridología es una rama de la ciencia médica que se encarga del estudio de la estructura del iris como un reflejo de la condición de los órganos y el sistema en el cuerpo humano (Herlambang, 2015). El iris de un ojo está conectado a un número inmenso de filamentos nerviosos minuciosos que, a través de los nervios ópticos, y de la médula espinal reciben excitaciones de cada nervio en el cuerpo (Jogi, 2014).

La iridología permite una revisión y un diagnóstico integral del paciente (Salles, 2008), por tal la razón se puede emplear esta rama de la medicina alternativa como una opción para el estudio preventivo de enfermedades comunes que puede desarrollar el ser humano, como es el caso de la infección causada por *Helicobacter pylori*¹ que por lo general es causante de la gastritis.

El *Helicobacter pylori* es considerada como la infección bacteriana más difundida y prevalente en el mundo (Martínez Echavarría, 2008). Se considera que gran parte de la población se ve afectada por esta infección en algún momento de su subsistencia, ocurriendo con mayor incidencia en países con niveles de desarrollo socio económicos bajos, donde se supera el 90% (Valdivia Roldán, 2011).

Se debe resaltar que varias enfermedades relacionadas al sistema gástrico son prevenibles, por lo cual es de gran importancia adoptar métodos de detección temprana dentro de la medicina en general (tradicional y alternativa) para brindar a los pacientes tratamientos acordes a sus necesidades, cuidando por la mejora de su calidad y esperanza de vida.

1.2. Justificación e importancia

Al realizar un estudio en salud, se debe considerar la variabilidad biológica de los pacientes, cada ser vivo es diferente e incluso en el mismo individuo se puede hallar

¹ Es una bacteria que se aloja generalmente en el estómago y es responsable de la infección bacteriana más frecuente en los seres humanos (Martínez Echavarría, 2008)

diferencias al evaluarlo en 2 etapas diferentes de su vida (Martín, 2004), aunque gracias a la estadística se puede modelar matemáticamente un fenómeno a partir de datos fundamentalmente impredecibles (Sosa, 2010).

Para definir un modelo de clasificación automática mediante computadoras se emplea aprendizaje de máquina donde su resultado final se representa en términos de probabilidad; a medida que aumenta el número de ensayos se obtiene una tendencia de probabilidad (Martínez, 2003), describiendo el comportamiento del fenómeno (ley de grandes números).

Por las múltiples aplicaciones que tiene el aprendizaje de máquina y el PDI, es necesario seguir con esta línea de investigación y enfocar sus técnicas a procesos que puedan ser optimizados como, por ejemplo; los diagnósticos preventivos de gastritis, debido a la incidencia y consecuencias que tiene esta enfermedad en la población. Por ejemplo, si la gastritis no es tratada a tiempo, se tiene mayor probabilidad de tener cáncer de estómago a largo plazo (Atherton, 2006).

Es importante frenar las incidencias de enfermedades crónicas en el sistema digestivo, ya que, por el estilo de vida actual, es cada vez más común detectar enfermedades como cáncer en personas menores a 40 años. Lo anteriormente descrito provoca un aumento en la tasa de mortalidad en países subdesarrollados, y además demuestra la ineficacia de los sistemas de salud en dichos países.

Para agilizar los procesos de diagnóstico, se tienen dos opciones; la primera, contratar más especialistas que atiendan adecuadamente a un mayor número de pacientes, evitando errores humanos por saturación de trabajo. La segunda opción es adquirir sistemas CAD, a un costo accesible, y con un proceso de diagnóstico ágil (máximo 5 minutos).

Los sistemas CAD apoyan en la detección y localización de anomalías en los pacientes, elaborando diagnósticos que serán corroborados por los especialistas (Gletsos, 2003). Aunque estos sistemas ayudan al problema, no representan una solución completa; ya que por cada tipo de examen que deba ser realizado (sangre, biopsia de tejido, etc.) se debe adquirir un costoso sistema CAD, que no es fácilmente

costeado por países subdesarrollados. Entonces se muestra la necesidad de efectuar un sistema CAD en base a exámenes integrales y de rápida toma de información.

Se debe contemplar a la medicina alternativa como una posible solución, porque una de sus fortalezas es realizar una revisión integral al paciente, mediante tratamientos naturales o procedimientos ancestrales como, por ejemplo, la acupuntura.

Por lo expuesto, se propone como solución a la “falta de detección temprana de enfermedades en el sistema digestivo en personas con nivel socio económico bajo” el diseñar un prototipo que realice el proceso de un sistema CAD que permita generar un diagnóstico preventivo de las enfermedades gástricas de forma automática.

El prototipo propuesto debe realizar un diagnóstico preventivo automático, por lo cual debe aprender a discernir la información entregada; en otras palabras, debe clasificar los pacientes. Por esta razón se debe emplear métodos de aprendizaje supervisado, conjuntamente con el procesamiento digital de imágenes y las plantillas iridológicas.

1.3. Alcance del proyecto

El alcance del presente proyecto es realizar un prototipo de sistema CAD que logre efectuar un diagnóstico preventivo automático de enfermedades gástricas mediante aprendizaje de máquina; en base a las características extraídas con procesamiento digital de imágenes y conocimientos de iridología.

Se van a evaluar varias imágenes del iris para extraer las características relevantes que indiquen la presencia de anomalías en el sistema gástrico. Con la finalidad de conocer los signos que se presentan en el iris de un paciente con alteraciones en su sistema gástrico, se cuenta con tutorías referentes a iridología por parte del Dr. Telmo de la Torre, médico cirujano especialista en medicina bio energética (Berdonces, 1999).

El prototipo de sistema CAD requiere un conjunto de imágenes (base de datos), de donde se extrae las características que revelen una anomalía. Para generar el vector respuesta de la base de datos de iridología se cuenta con ayuda del Dr. Telmo de la Torre, que en base a su experiencia da un diagnóstico (vector respuesta) sobre los iris

obtenidos. El Dr. Telmo de la Torre se encarga de evaluar cada iris y brindar un diagnóstico en base a patrones que detectó en la imagen, posteriormente compartió su conocimiento para establecer de manera general este tipo de anomalía lo cual permite determinar las características de color que deben ser halladas por el sistema CAD.

El objetivo del presente trabajo de titulación es aplicar técnicas de procesamiento digital de imágenes y aprendizaje de máquina supervisado a una nueva área de estudio, que en este caso es la iridología, aplicada a una problemática puntual que es la detección de gastritis.

Para el prototipo planteado en el presente documento, se requiere emplear técnicas de aprendizaje supervisado, ya que existe un “maestro-supervisor” que comprueba el resultado del proceso (el diagnóstico final lo da el médico especialista del tema). En base a lo anterior, se propone únicamente un diagnóstico preventivo automático, mas no un diagnóstico final, porque para definirlo siempre se requerirá un experto en la materia que corrobore los resultados entregados por el sistema CAD.

1.4. Objetivos

1.4.1. Objetivo general

- Diseñar, implementar y evaluar un algoritmo de diagnóstico asistido por computadora para la detección de enfermedades gástricas basado en iridología.

1.4.2. Objetivos específicos

- Localizar, segmentar y cuantificar las anomalías concernientes a problemas gástricos presentados en el iris.
- Implementar el algoritmo del sistema CAD que contempla el procesamiento digital de imágenes, la clasificación y el diagnóstico.
- Comprender el funcionamiento de varias técnicas de aprendizaje de máquina y evaluar sus desempeños para la detección de enfermedades gástricas.

- Evaluar los resultados obtenidos del sistema en términos de exactitud, sensibilidad, especificidad y capacidad predictiva para detectar enfermedades gástricas.

CAPÍTULO II

MARCO TEÓRICO

2.1. Introducción

La iridología es una rama de la medicina alternativa que ha ido ganando partidarios alrededor del mundo, por esta razón es que se ha convertido en el objetivo de varios casos de estudio e investigación, no solo por el procesamiento técnico que se requiere para su segmentación sino también por los beneficios que representa como herramienta preventiva de enfermedades.

Los resultados que se han obtenido en las investigaciones sobre iridología son prometedores como, por ejemplo: en (Nor'aini, 2013) aplica SVM-RBF (*Radial Basis Function*) para la localización de un área de interés en el iris; su exactitud fue del 80%. En (Herlambang, 2015) se obtiene un 91,42% de exactitud aplicando redes neuronales para la detección de anomalías en el hígado, he incluso en (Zhang, 2013) se ha estudiado la relación que existe entre las deformaciones geométricas de la pupila y alteraciones en la salud del paciente, donde se obtuvo un 89,8% de exactitud con un algoritmo de clasificación SOM (*Self Organizing Map*).

A nuestro entender no se encontró un trabajo referente a las anomalías en el sistema gástrico y que empleara los métodos de clasificación propuestos para determinar su desempeño, pero si permitieron determinar una metodología tentativa para alcanzar los objetivos formulados en el presente trabajo de titulación.

En el presente capítulo se explica de forma general los conceptos necesarios que se emplean para la implementación del prototipo de sistema CAD y el estado del arte para el presente proyecto de titulación.

2.2. Enfermedades del sistema digestivo

Las enfermedades en el sistema gástrico se caracterizan por grados variables de inflamaciones o malformaciones en los órganos que lo conforman (Thews, 1983). Por tanto, este tipo de enfermedades no se tratan de un proceso patológico homogéneo, sino es un proceso heterogéneo de causa y mecanismo patológico multifactorial, con

un cuadro sintomático inespecífico e incluso en varios casos ausente, como es el caso, de la gastritis provocada por la bacteria *Helicobacter pylori* (Abreu, 2007).

La infección por *Helicobacter pylori* generalmente presenta un cuadro asintomático y prolongado; por lo que esta patología suele ser detectada en etapas avanzadas de otras enfermedades más graves, mediante exámenes de sangre, endoscopias o biopsias al tejido estomacal. Las enfermedades más comunes asociadas a esta infección bacteriana son la úlcera péptica y la gastritis, donde sus síntomas consisten básicamente en una inflamación de la mucosa gástrica (Thews, 1983).

Cuando se deja progresar la infección sin un tratamiento efectivo el tejido estomacal se ve gravemente dañado, lo cual provoca que las células que lo componen tengan un crecimiento anormal y formen carcinomas en el área afectada.

Un estudio realizado en el MIT (*Massachusetts Institute of Technology*) publicado en la revista *Cancer Prevention Research*, indica una reducción drástica en los carcinomas causados por la infección crónica que provoca la bacteria *Helicobacter pylori*, sí al paciente lo tratan con estrógenos (pruebas realizadas a ratones machos) (Sheh, 2011). Obviamente no se puede prescribir estrógenos a personas de género masculino, por lo cual es necesario que se investiguen nuevos métodos para reducir o detectar tempranamente la presencia de esta infección.

Como se mencionó en el estudio del MIT, uno de los factores de riesgo para el cáncer de estómago es la presencia de la bacteria *Helicobacter pylori* que se encuentra presente en la gastritis atrófica crónica, la cual puede generar problemas estomacales graves. Recientes investigaciones indican que ciertos subtipos de esta bacteria pueden convertir algunas sustancias de los alimentos en el químico que provoca un cambio en el ADN de las células; generando un crecimiento anormal (mutación) y provocando cáncer en los peores escenarios (Moreno, 2013).

El *Helicobacter pylori* está estrechamente relacionado con la gran mayoría de enfermedades inflamatorias que tienen como origen el estómago; entre las enfermedades existentes, se puede resaltar la gastritis, úlceras, lesiones gástricas, etc. La gastritis se divide en: gastritis atrófica (genera carcinomas) y gastritis aguda, donde se tiene mayor probabilidad de presentar una úlcera (Abreu, 2007).

2.3. Anatomía del ojo

Los ojos se forman gracias a la fusión de varios tejidos embrionarios; por ejemplo, la retina forma parte del sistema nervioso central ya que proviene del prosencéfalo, mientras que la córnea y el cristalino proceden de la capa embrional (Persaud, 2008). Los primeros signos de formación del ojo aparecen aproximadamente a la tercera semana de gestación (Rodríguez, 2008).

Al terminar de formarse el embrión, los ojos se encuentran en unas cavidades óseas llamadas órbitas, las cuales se encuentran en la parte frontal del cráneo. En la Figura 1 se muestra la anatomía final del ojo.




Figura 1 Anatomía del ojo

Fuente: (Latarjet, 2006)

A continuación, se describe las partes principales que conforman el ojo humano:

- La esclerótica está formada por seis músculos extra-oculares, formando una capa blanca, dura, opaca y que no permite el paso de luz (Carlson, 1996).
- La córnea se encuentra en la parte frontal del ojo; a diferencia de la esclerótica esta es transparente y permite el paso de luz (Carlson, 1996).
- El iris se encarga de regular la cantidad de luz que ingresa al lente, mediante la miosis (pupila estrecha) y la midriasis (pupila dilatada) (Latarjet, 2006). El iris está constituido por una parte coloreada y otra oscura, en la parte coloreada se puede diferenciar una zona marcada por los músculos radiados que corresponden a los vasos del iris (Latarjet, 2006). La parte oscura es cóncava y toma contacto con el lente.

En la medicina tradicional el examen del ojo brinda mucha información sobre el sistema nervioso, debido a la conexión directa que tiene con el cerebro mediante filamentos nerviosos (Lovesio, 2006).

Dentro de la valoración primaria en primeros auxilios se realiza una inspección de los reflejos oculares (miosis y midriasis) para un diagnóstico superficial del sistema nervioso central (cerebro) (Salcedo, 2017). El sistema nervioso se encarga de interactuar con el medio ambiente ya que está encargado del funcionamiento y razonamiento del paciente (Cuenca, 2006).

2.4. Medicina alternativa

La medicina alternativa o bioenergética está basada en las necesidades de las personas, por lo tanto, distintas personas pueden recibir distintos tratamientos incluso si, de acuerdo con la medicina tradicional, sufren la misma enfermedad.

La medicina bioenergética suele utilizarse para mejorar la calidad de vida del paciente al tratar dolencias provocadas por enfermedades crónicas o accidentes ocasionados en las tareas recurrentes (Salud, 2002). Algunos datos auguran resultados prometedores en tratamientos efectivos del dolor con los procedimientos en la medicina alternativa.

Actualmente se tienen estudios que respaldan la teoría de que varias técnicas de la medicina bioenergética alivian eficazmente el dolor y genera menos efectos secundarios que otros tratamientos, como es el caso de la acupuntura (OMS, 2016); por esta razón es que en la última década el interés por este tipo de tratamientos ha ido en aumento (OMS, 2016).

La medicina alternativa se ha introducido en muchos países en el mundo, pasando a formar parte de sus sistemas de salud, e incluso realizando investigaciones de las bondades que se obtiene en ciertos tratamientos y dolencias. En la Tabla 1 se presenta el porcentaje de inclusión de la medicina bioenergética dentro de los servicios de salud en distintos países alrededor del mundo.

Tabla 1
Inserción de la medicina alternativa dentro de los servicios de salud (2003).

País	% Inclusión en los servicios de salud	Cantidad de personas tratadas (Millón)
China	40%	517
Chile	71%	12
Colombia	40%	17
India	65%	702
Australia	48%	9
Canadá	70%	22
Estados Unidos	42%	122
Francia	49%	30
Alemania	49%	40

Fuente: (salud., 2002)

Como se puede ver en la Tabla 1, la medicina alternativa ha tomado varios partidarios alrededor mundo, independientes a su cultura, etnia, o desarrollo socio-económico, etc., esto se debe a la inconformidad que genera el sistema de salud convencional debido a los tiempos de espera y a la mala práctica o errores en el diagnóstico de enfermedades (salud., 2002).

2.4.1. Iridología

La iridología se encarga de estudiar el iris, la estructura más compleja en una persona debido a sus delicadas y pequeñas estructuras (Jensen, 1980).

La estructura del ojo humano es muy compleja pues tiene innumerable cantidad de terminaciones nerviosas (28.000 aproximadamente) que están conectadas a todos los tejidos del cuerpo a través del cerebro y el sistema nervioso (Sulistiyo, 2014).

Los filamentos nerviosos, las fibras musculares y los diminutos vasos sanguíneos en diferentes áreas del iris reproducen condiciones cambiantes en los órganos correspondientes (teoría del reflejo). Es por eso que cada parte del iris tiene relación con un órgano distinto, a la representación gráfica de esta relación se le llama mapa de

Jensen o mapa iridológico (Ver Figura 2). El mapa de Jensen el cual es uno de los más aceptados y difundidos en las áreas referentes a la iridología (Othman, 2010), donde básicamente se divide al iris de forma similar a un reloj (12 horas).




Figura 2 Mapa de Jensen ojo derecho

Fuente: (Sulistiyo, 2014)

El mapa del iris izquierdo es el reflejo del iris derecho, si se quiere detectar anomalías en el sector del tórax o el pulmón es necesario conocer el iris estudiado (izquierdo o derecho) para no confundir sus zonas.

Por ejemplo, como se ve en la Figura 2 el iris derecho en la sección entre 9-10 se puede estar determinando el estado del pulmón, pero en el iris izquierdo () en la misma sección se encuentra la representación de la garganta, entonces se vuelve mandatorio conocer el iris estudiado para esos casos particulares.

De las señales que muestra el iris se extrae la información clínica por medio de varias marcas, signos, colores anormales o decoloraciones en el iris (signos iridológicos).

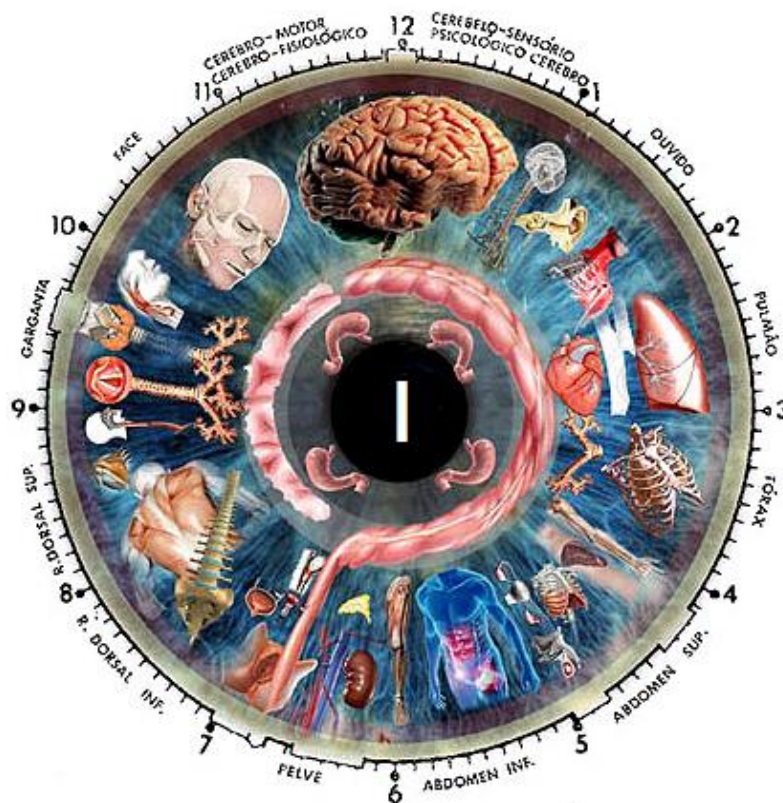


Figura 3 Mapa de Jensen ojo izquierdo

Fuente: (Sulistiyo, 2014)

El iris está conectado a todo el cuerpo gracias a su conexión con el sistema nervioso central. La iridología por sí sola no puede diagnosticar una enfermedad, pero puede reconocer problemáticas potenciales para una enfermedad.

La iridología es una rama de la medicina alternativa dedicada a entregar información del estado de los órganos del cuerpo humano (Haigh, 1999). Esta medicina debe ser empleada únicamente en la salud preventiva (Ceolin, 2009), en otras palabras, solo se la emplea para obtener información del cuerpo en general, por esta razón se requiere de la medicina tradicional para poder dar un tratamiento completo al paciente. Los beneficios de la iridología son varios, pero podemos resaltar que es segura, económica, rápida y no invasiva (Jogi, 2014).

Además del alto índice de incidencia que tiene la gastritis en la población mundial, se tomó en consideración el mapa de Jensen, ya que el sector que representa el estómago es un área concéntrica a la pupila, y por tal razón no es relevante saber si el ojo estudiado es el izquierdo o derecho.

2.4.1.1. Iridología en el mundo

La iridología es una de las herramientas diagnósticas que ha ido tomando más partidarios alrededor del mundo (Sparber A, 2001). Particularmente en Estados Unidos, Alemania, Corea del Sur, Malasia y Kazajistán existe muchas escuelas e institutos de iridología (Sehouli, 2003).

Debido a la inconformidad con los sistemas de salud convencionales, varios países alrededor del mundo han llegado a integrar la medicina alternativa dentro de los servicios de salud públicos y privados.

En la Tabla 2 se refleja el número muertes provocadas por enfermedades gástricas, en países donde es aceptada la iridología como método de diagnóstico y en el Ecuador donde la iridología no es muy aceptada hasta el momento. Los datos son obtenidos de los informes de la OMS para el año 2014.

Tabla 2
Incidencia de enfermedades gástricas en 2014

País	Incidencia	Muerte por enfermedades gástricas
Malasia	2563	1265
Corea	21338	7014
Ecuador	1381	1278
Kazajstán	2310	1757
Alemania	36567	15186
Estados Unidos	69045	32350

Fuente: (Sehouli, 2003)

Como se puede ver en la Tabla 2, países como Alemania o Estados Unidos existe un gran número de incidencias de enfermedades gástricas, pero las muertes causadas por las mismas representan 42% y 47% respectivamente, esto quiere decir que más de la mitad de casos incidentes fueron controlados y tratados a tiempo evitando consecuencias más graves, mientras que, en Ecuador, el 93% de las incidencias de enfermedades gástricas terminaron en muertes de los pacientes.

En la Figura 4 se muestra el porcentaje de muertes causadas por enfermedades gástricas, para este gráfico se toma al número de incidencias (presentan la patología) como el número total de posibles muertes, mientras que el número de muertes por enfermedades gástricas representa el número real de muertes; con estas dos cifras se obtiene un proporcional.

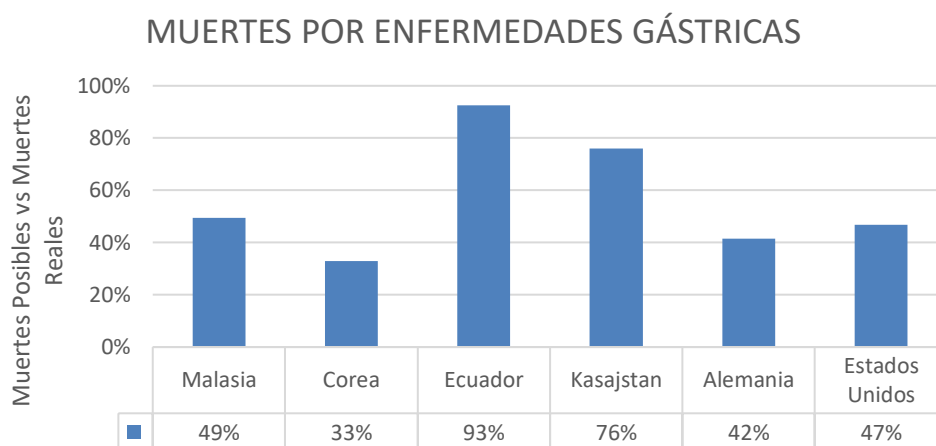


Figura 4 Muertes por enfermedades gástricas

Fuente: Elaboración propia

Como se puede ver, Ecuador presenta un 93% de muertes, en otras palabras, casi todas las personas que tienen esta patología no tienen mayor esperanza de vida ya que la mayoría fallece.

Esto se debe a las deficiencias dentro del sistema de salud que no adopta métodos de detección temprana, donde la enfermedad aún puede ser tratada a menores costos; no solo en relación al factor económico sino también al humano, ya que se tendría un menor índice de mortalidad en pacientes que padecen enfermedades crónicas, como la gastritis crónica y particularmente al cáncer del sistema gástrico.

2.4.1.2. Signos iridológicos

La iridología presenta ciertos signos en el ojo que indican una patología o estado del organismo en particular, en la Figura 5 se encuentra una representación gráfica de los signos iridológicos descritos a continuación:

- **Criptas:** Son pequeños agujeros que se presentan generalmente en forma de rombo, afectan el tejido del iris hasta sus capas más profundas, por lo que se

observan de un color muy oscuro y representan la última fase de alguna patología que esté afectando al órgano en cuestión.

- **Rayos solares:** Están relacionados con alteraciones en el sistema digestivo, ya que nacen en la región del estómago y se abren camino hasta la periferia (Berdonces, 1999).
- **Manchas orgánicas:** Son pigmentos que marcan el iris, por lo general son señales de sobrecargas metabólica o lesiones orgánicas (Berdonces, 1999).
- **Anillos Nerviosos:** Son arcos que se sitúan en el iris, indican que el paciente está bajo mucha presión o estrés (Berdonces, 1999).
- **Anillo de absorción:** Indica problemas en lo que refiere a la asimilación de nutrientes importantes para el cuerpo humano (Berdonces, 1999), el sistema encargado de la absorción de nutrientes es el sistema digestivo, concretamente el estómago. El anillo de absorción puede indicar alguna problemática en el estómago.

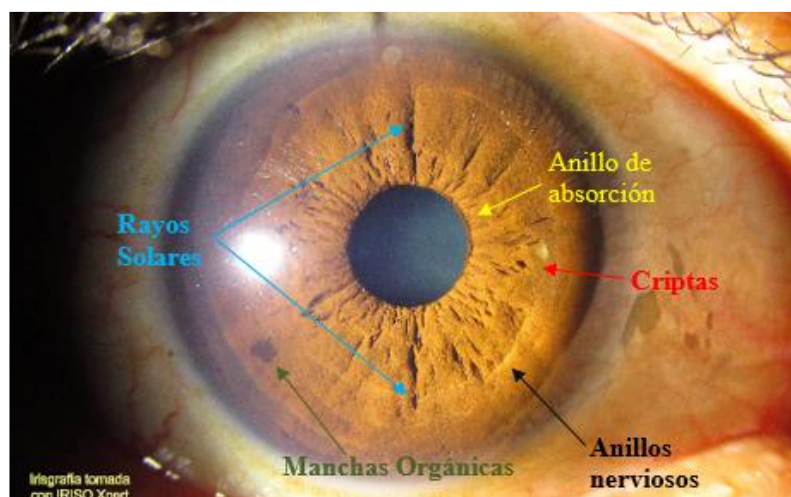


Figura 5 Signos iridológicos en el iris humano.

Fuente: Elaboración propia

Las enfermedades tienen varios índices de afectación, que pueden ir desde el grado agudo hasta el degenerativo. La iridología muestra las mismas etapas progresivas de una enfermedad, y esto depende del grado de profundidad que muestren las membranas que componen el iris. Se pueden determinar 4 grados patológicos, los cuales se pueden ver en la Figura 6




Figura 6 Etapas progresivas del reflejo tisular

Fuente: (Luna, 2016)

Como se puede ver en la Figura 6 lado derecho los grados patológicos son: (1) aguda, (2) subaguda, (3) crónica y (4) degenerativa. Aunque el iris presente un grado degenerativo no implica una muerte próxima ya que simplemente el iris está reflejando un órgano muy afectado por toxinas, lesiones, falta de nutrientes o daños generados por enfermedades crónicas.

Como se puede ver en la Figura 6 del lado izquierdo existe una variación de color desde la etapa 1 (aguda) hasta 4 (degenerativa), las zonas más oscuras representan un daño mayor, pero no mortal, por esta razón, es importante analizar las tonalidades de color para detectar anomalías.

2.5. Imagen digital

Una imagen digital es una representación visual bidimensional, que está definida por el valor que toman los píxeles que la componen. Las imágenes pueden ser a blanco y negro, escala de grises o color. En blanco y negro el rango de valores de los píxeles que la componen únicamente presenta los valores de 1 (blanco) y 0 (negro).

En escala de grises se define los bits en los que se desea representar los píxeles, el valor generalmente utilizado es de 8 bits por píxel, lo cual implica 256 tonalidades de gris; donde 0 representa la ausencia de color (negro) y 255 la claridad máxima (blanco).

Una imagen a color está definida por la combinación de los tres colores primarios que son: rojo, verde y azul; en la nomenclatura se lo reconoce como componentes RGB (*red, green, blue*). Con estos colores es posible representar cualquier color que se requiera. Una imagen a color tiene los tres canales de color, por tal razón generalmente

su dimensión matricial viene representada de la siguiente manera $(m, n, 3)$; donde m y n expresan la dimensión bidimensional de la imagen y 3 representa las componentes RGB que se encuentran en la imagen.




Figura 7 Representación matricial del modelo RGB

Fuente: (Acero, 2015)

2.6. Procesamiento Digital de Imágenes

El procesamiento digital de imágenes está orientado a obtener una mejora en las imágenes mediante herramientas tecnológicas, donde se dispone los recursos necesarios en hardware y software para el tratamiento de grandes cantidades de información en forma matricial (Esqueada, 2005). El procesamiento de imágenes está asociado a la visión artificial ya que se puede analizar, segmentar, almacenar y detectar objetos o parámetros dentro de una imagen. (Esqueada, 2005).

2.6.1. Procesamiento digital basado en píxeles

Estas metodologías radican en algoritmos que varían el valor de un píxel basados en el valor anterior de cierto píxel o en la vecindad que lo rodea. Se realiza una búsqueda píxel por píxel dentro de la imagen a procesar para generar *LUT/Look-Up Table* (Santamaría, 2013).

Si se requiere además del valor anterior del píxel y la localización del mismo, puede ser necesario utilizar fórmulas o una combinación de las mismas con tablas de búsqueda.

Estas técnicas mencionadas no modifican las relaciones espaciales dentro de la imagen y en consecuencia no pueden modificar el grado de detalle contenido en las

mismas, debido a su simplicidad, su implementación se puede realizar en circuito electrónico para una ejecución en tiempo real (Santamaría, 2013).

2.6.1.1. Histograma

Corresponde a un gráfico que permite obtener una “primera vista” de la distribución de intensidad en los píxeles de una imagen, de una porción de la misma o de las componentes de color que la conforman (Shapiro, 2001).

Se puede denotar como $h(i)$, el número de píxeles que se encuentra dentro de la región de interés y tiene el valor de intensidad i , donde ($i = 0,1,2 \dots 255$) es el número posible de niveles de color por componente RGB para la imagen. El histograma proporciona importante información acerca de características intrínsecas de la imagen como son: intensidad, contraste, así como de su rango dinámico (Ross, 2011). En la Figura 8 se muestra el dibujo de un histograma de una imagen del iris, obtenida de una base de datos Iriso.

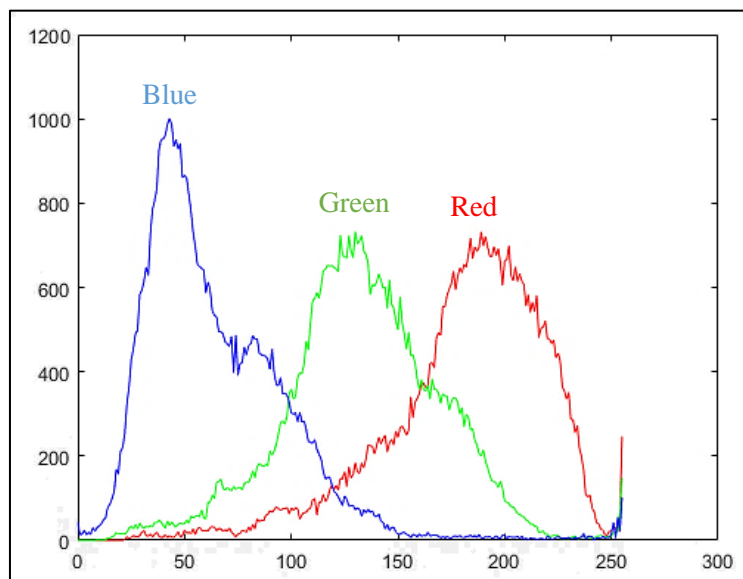


Figura 8 Histograma de las componentes RGB de la imagen segmentada

Fuente: Elaboración propia

Como se mencionó anteriormente las zonas que presentan algún tipo de afección sea: aguda, crónica o degenerativa tienden a ser más oscuras, por lo tanto, para la detección de anomalías (zona cercana a cero) serán importantes las componentes azul y verde (la imagen empleada fue extraída la pupila, esclerótica y parpados).

2.6.1.2. Mejora en imágenes por modificación de contraste

El contraste de una imagen, puede ser corregido mediante un cambio en la intensidad de cada pixel, en otras palabras, la intensidad correspondiente a cada pixel de entrada (imagen original) y que denotaremos por x , se puede modificar atenuando o realzando su intensidad (rango dinámico) en base a una transformación específica (Mancebo Pérez, 2013).

2.6.2. Procesamiento basado en zonas de la imagen

Las técnicas de procesamiento basadas en una zona específica tienen muchas aplicaciones en la extracción de características, estos procedimientos permiten diferenciar a los objetos que conforman una imagen (Passariello, 1995).

Uno de los procesos más utilizados para la subdivisión de regiones en una imagen, es la localización de contornos o bordes; esta técnica permite delimitar los objetos dentro de la imagen para poder extraerlos posteriormente empleando una máscara.

Una máscara es una plantilla de igual dimensión que la imagen original, pero el área que corresponde al objeto de interés es rellenada con unos y el resto con cero. Al multiplicar la imagen original por la plantilla se consigue extraer únicamente el área de interés (Ver Figura 9).



Figura 9 Mascara de una imagen

Fuente: (Osorio Roig, 2017).

Otro proceso utilizado es la atenuación de ruido aleatorio, esto se consigue aplicando un filtro para suavizar la imagen y en base al comportamiento (tendencia) extraído de la vecindad que rodea los píxeles del objeto (Calot, 2008).

2.6.2.1. Segmentación de imágenes

La segmentación es un proceso que localiza áreas relevantes en una imagen y cuyos píxeles presentan características similares, debido a que pertenecen al mismo

elemento físico. La segmentación de imágenes es uno de los procesos más importantes de un sistema automatizado (Palomino, 2009), se aplica este procedimiento con la finalidad de aislar el objeto de interés y hallar únicamente las características que describen al objeto como, por ejemplo; su dimensión, forma geométrica, color medio, etc.

Para el presente trabajo se emplean las técnicas basadas en fronteras (bordes), debido al alcance del proyecto, ya que solo se busca detectar tempranamente trastornos en el sistema gástrico (primer anillo posterior a la pupila en el mapa de Jensen), por lo que el resto de zonas del iris no presentan relevancia para este estudio y deben ser descartadas en la segmentación.

Segmentar adecuadamente una sección de la imagen resulta a menudo difícil debido a múltiples factores como, por ejemplo: el ruido, la iluminación, contraste de color en la imagen, y para este caso en particular la forma de la pupila y el movimiento del ojo al tomar la imagen. Por estas razones el primer paso a seguir debe ser el determinar los bordes del objeto, luego localizar el interior del mismo y clasificar los píxeles en el borde como parte o no del objeto.

2.6.3. Metodologías para localización de áreas circulares

Como se ha mencionado anteriormente, el proceso de segmentación es una de las tareas más complejas e importantes dentro del campo de la visión artificial, por lo que la localización de los círculos concéntricos que representan la pupila y el iris suele tornarse compleja.

Debido a que no todos los iris tienen una forma regular o sus límites no son fácilmente localizables. A continuación, se menciona varios métodos que se suelen emplear para el proceso de segmentación del iris.

2.6.3.1. Metodología de J. Daugman y derivadas

La metodología de J. Daugman fue la primera técnica de segmentación de iris funcional, la cual fue propuesta e implementada en 1992 (Daugman, 1993). Esta técnica tiene la premisa de que tanto la pupila como el iris deben tener una forma circular, y una particularidad de este método es que puede identificar las regiones de

los párpados superiores e inferiores (Washington Patente n° 5,291,560, 1994), realiza su segmentación mediante un modelado de contornos.

La ecuación que describe este método es la siguiente:

$$\left| (\sqrt{2\pi} \cdot \sigma) e^{-|(r-r_o)^2/2\sigma^2|} * \frac{\delta}{\delta r} \cdot \oint_{r,x_c,y_c} \frac{I(x,y)}{2\pi r} ds \right| \quad (1)$$

Donde, r_o representa el centro de la función radial gaussiana, σ es la desviación estándar que permite el ajuste a las irregularidades que puede existir en los bordes de la pupila o iris, * indica convolución, $I(x,y)$ considera la intensidad lumínica de la imagen, r es el radio de las circunferencias localizadas y el término $2\pi r$ normaliza la integral.

El método de Daugman se encarga de evaluar siguiendo un camino circular con radio r , y centro (x_c, y_c) los cambios máximos en el valor de los píxeles para determinar el área a segmentar. La metodología de Daugman aplica una binarización a la imagen, ya que utiliza un umbral para mejorar el contraste entre las áreas de interés.

2.6.3.2. Metodología de R. Wildes y derivados

Es una metodología de Wildes propuesta en 1997 (Wildes, 1997), se basa en la búsqueda de contornos, mediante los siguientes pasos:

- Obtención de imagen de bordes binaria (sólo niveles blancos/negro) mediante cálculo del módulo del gradiente.
- Detección de contornos mediante la transformada Hough.

El módulo del gradiente viene dado por la siguiente ecuación:

$$|\nabla G(x,y) * I(x,y)| \quad (2)$$

Siendo el gradiente igual a:

$$\nabla = \left(\frac{\partial}{\partial x}, \frac{\partial}{\partial y} \right) \quad (3)$$

Y la función $G(x, y)$ que representa una función gaussiana bidimensional con centro en (x_0, y_0) y desviación estándar σ' para mejorar la discriminación de bordes, igual a:

$$G(x, y) = \frac{1}{2} \pi \cdot \sigma'^2 \cdot e^{-\frac{(x-x_0)^2+(y-y_0)^2}{2\sigma'^2}} \quad (4)$$

2.6.3.3. Transformada de Hough

La transformada de Hough fue propuesta en 1962 (Washington, DC Patente n° 3,069,654, 1962), y es una herramienta que permite el reconocimiento de patrones geométricos que puedan ser representados como rectas, circunferencias o elipses dentro de una imagen (Galipienso, 2003).

Para el presente trabajo se requiere principalmente un reconocimiento de patrones circulares, la ecuación que define una circunferencia se muestra a continuación:

$$(x' - x'_0)^2 + (y' - y'_0)^2 = r^2 \quad (5)$$

Donde, (x'_0, y'_0) representa las coordenadas del centro de la circunferencia y r el radio de la misma. Al evaluar los pixeles de contorno se define todas las posibles circunferencias que pasan por el pixel (familia de circunferencias).

Se discrimina entre la familia de circunferencias cuando una de ellas pasa por gran cantidad de puntos de contorno, en la Figura 10 se muestra gráficamente el proceso de la transformada de *Hough*.




Figura 10 Transformada de Hough circular

Fuente: (Parchkoohi, 2015)

Los puntos rojos en la Figura 10 definen los píxeles de contorno, las circunferencias con líneas entrecortadas representan a la familia de circunferencias que puede tener cada píxel de contorno, la circunferencia con línea continua representa la circunferencia que pasa por mayor número de puntos de contorno y se procede a definir el centro que es el punto de color verde.

La transformada requiere que un gran número de incidencias caigan en la celda correcta, en otras palabras, la eficiencia de la transformada de Hough depende de los parámetros de entrada (detección de bordes), y además incluir un umbral para la discriminación de patrones (Ballard, 1981).

La Transformada de Hough requiere implementar un detector de bordes para definir si los píxeles de contorno preliminares forman parte de la figura geométrica buscada o no.

La detección de bordes se realiza mediante el detector de Canny, el cual fue propuesto en 1986 y se basa en tres criterios principales (Rebaza, 2007):

- Intenta obtener bordes muy puntuales, de aproximadamente un píxel de ancho.
- Aplica una función de histéresis basada en umbrales con la finalidad de evitar falsos positivos en la detección de bordes.
- Cerrar los contornos que pudieron quedar abiertos por problemas de ruido en la imagen (pestañas o parpados).

2.6.3.4. Comparación entre metodologías

La Tabla 3 muestra el rendimiento de cada metodología, donde se toma en cuenta la correcta segmentación de imágenes con usuarios no-cooperativos (Proença, 2006), los usuarios cooperativos miran fijamente el lente (resitúan adecuadamente el iris) se emplea la base de datos UBIRIS v1.

Tabla 3
Comparativa de metodologías con la base de datos UBIRIS v1

Método	% de Acierto
Daugman	95,22±0,015
Daugman, binarización	96,79±0,014
Camus y Wildes	96,78±0,013
Wildes	98,68±0,008

Fuente: (Proença, 2006)

Como se puede ver en la Tabla 3 el método que da mejor resultado es el de Wildes, teniendo un 98,68% de acierto con un 0,008 % de error. En base a esto, el presente trabajo de titulación emplea el método de Wildes para la localización de la pupila en el iris.

2.7. Aprendizaje de máquina

El Aprendizaje de Máquina (*Machine Learning*) es una tecnología interdisciplinaria porque maneja matemáticas, estadísticas, ciencias de la computación e inteligencia artificial (Tuya, 2007); los cuales trabajando en conjunto buscan generalizar comportamientos o procesos en determinados estudios (García, 2011).

Los algoritmos de aprendizaje de máquina encuentran patrones en los datos que permiten describir su estado actual y próximos estados ayudando a tomar mejores decisiones y predicciones (Alpaydin, 2014).

El aprendizaje de máquina se utiliza todos los días para tomar decisiones críticas en el diagnóstico médico, el mercado de valores, la previsión de la carga de energía, etc (Mathworks, 2017). Los sitios web hacen sus recomendaciones de canciones, películas o anuncios en base a los patrones de comportamiento detectados en el consumidor (Bell, 2007).

El aprendizaje de máquina utiliza dos tipos de técnicas: el aprendizaje supervisado, entrena un modelo en base a los datos de entrada y salida conocidos para que pueda predecir los resultados futuros (es similar a la metodología empleada en el área académica) (Chapelle, 2009); y el aprendizaje no supervisado, encuentra patrones

ocultos o estructuras intrínsecas en los datos de entrada (es similar a como una persona aprende a hablar) (Montesdeoca, 2016) por lo cual es capaz de definir tendencias o comportamientos para dar un vector respuesta.

En la Figura 11 se encuentra los casos de uso más frecuentes para cada técnica del *machine learning*.



Figura 11 Técnicas de aprendizaje de máquina

Fuente: (Mathworks, 2017)

Para el presente trabajo se emplea una base de datos de imágenes del iris y el criterio de un doctor experto en el tema para aportar con un diagnóstico (datos de salida); entonces se debe realizar un proceso de clasificación entre pacientes sanos y enfermos, por esta razón se debe implementar técnicas de aprendizaje supervisado.

2.7.1. Clasificadores

Un algoritmo de aprendizaje supervisado toma un conjunto conocido de datos de entrada y respuestas conocidas a los datos (salida) para entrenar un modelo y generar predicciones razonables para la respuesta a nuevos datos (Tuya, 2007).

Las técnicas de clasificación predicen respuestas discretas, por ejemplo, si un correo electrónico es genuino o spam, o si un tumor es canceroso o benigno. Las aplicaciones típicas incluyen imágenes médicas, reconocimiento de voz y tendencias en la bolsa de valores o estado crediticio de una persona (Mathworks, 2017).

Los pasos en el aprendizaje supervisado son: preparar los datos de entrada, elegir un algoritmo adecuado para el tipo de datos a estudiar, ajustar el modelo (elegir las mejores características descriptivas), elegir un método de entrenamiento (generalmente *k-fold*), realizar ajuste en las características del clasificador hasta estar satisfecho con los resultados obtenidos (Caruana, 2006).

Hay docenas de algoritmos y cada uno adopta un enfoque diferente para aprender (Matworks, 2016). Encontrar el algoritmo correcto es en parte sólo prueba y error, sin embargo, la selección de algoritmos también depende del tamaño y tipo de datos con los que esté trabajando y de cómo se utilizarán esos conocimientos (Matworks, 2016). En la Figura 12 se muestra un cuadro resumen para la selección de un algoritmo según la técnica de aprendizaje de máquina que se esté empleando.



Figura 12 Selección de algoritmo en el aprendizaje de máquina

Fuente: (Matworks, 2016)

El aprendizaje supervisado se usa para resolver problemas de clasificación, y dentro de este grupo se puede resaltar a los siguientes métodos como los más relevantes: árboles de decisión, vecinos más cercanos, máquinas de soporte vectorial y redes neuronales (Blanes, 2012).

2.7.2. Árboles de decisión

Los árboles de decisión, predicen las respuestas en función a los atributos de entrada y el vector respuesta. Un árbol de decisión es un clasificador que realiza una discriminación consecutiva, que va desde lo general a lo particular (respuesta) (Maimon, 2005). En la Figura 13 se puede ver la representación gráfica del árbol de decisión donde, cada hoja representa un valor de la variable de destino.

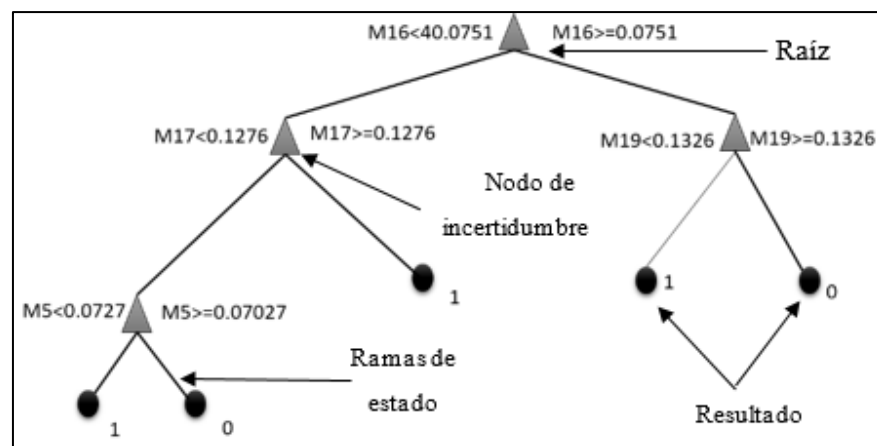


Figura 13 Estructura de árbol de decisión

Fuente: Elaboración propia

En la Figura 13 se muestra un árbol de decisión y sus partes, como se puede ver discrimina las características y da como resultado una respuesta nominal, que para este caso en particular es binaria. Para el presente trabajo se emplea resultados binarios que expresan la presencia o no de la enfermedad.

Un árbol de decisión permite predecir las respuestas a los datos siguiendo las decisiones en el árbol desde la raíz (inicio) hasta una hoja (nodo). Un árbol consiste en umbrales de ramificación donde el valor de un predictor se compara con un valor (peso) entrenado. El número de ramas y los valores de pesos se determinan en el proceso de entrenamiento.

Entre los aspectos positivos, se tiene que los árboles de decisión son fáciles de interpretar, son rápidos para el ajuste y la predicción, además presenta un bajo uso de memoria, pero pueden tener una baja precisión en predicción debido al sobre-ajuste (Quinlan, 1986).

El sobre-entrenamiento o sobre ajuste es cuando se añade varios niveles al árbol, clasifica muy bien los datos de entrenamiento, pero luego no sabe generalizar al conjunto de prueba. Este fenómeno se da debido a que se adapta a las regularidades del conjunto particular de entrenamiento (Deng, 2011) y ya no puede ajustarse a un nuevo conjunto de prueba.

Una forma para solucionar el sobre-entrenamiento es realizar una poda de árbol, esto consiste en eliminar un sub-árbol anidado en ese nodo transformándolo en una hoja y asignándole la clasificación más común de los ejemplos de entrenamiento considerados en ese nodo. Por lo general un árbol poco profundo puede ser más robusto y más fácil de interpretar.

2.7.3. Máquinas de soporte vectorial (SVM)

Los SVM fueron desarrollados por Vapnik en los años 90 (Carmona, 2014), originalmente los SVM fueron empleados en la resolución de problemas binarios, aunque actualmente son usados para resolver diversos tipos de problemas como: multi-clasificación, regresión, etc.

Dentro de los clasificadores, los SVM clasifican los datos encontrando el límite de decisión lineal (hiperplano) que separa todos los puntos de datos de una clase de los de la otra clase.

Dado un conjunto de datos $D = \{(X_0, Y_0), \dots, (X_{n-1}, Y_{n-1})\}$ donde n representa el número total de datos, $X_i \in \mathbb{R}^d$ que son las características extraídas del modelo e $Y_i \in \{1, -1\}$ que indica el vector salida (respuesta); solamente con esta consideración se consigue delimitar varios hiperplanos como funciones lineales capaces de separar el conjunto de datos sin error (Carmona, 2014). En la Figura 14 se muestra gráficamente los posibles hiperplanos que pueden separar los datos

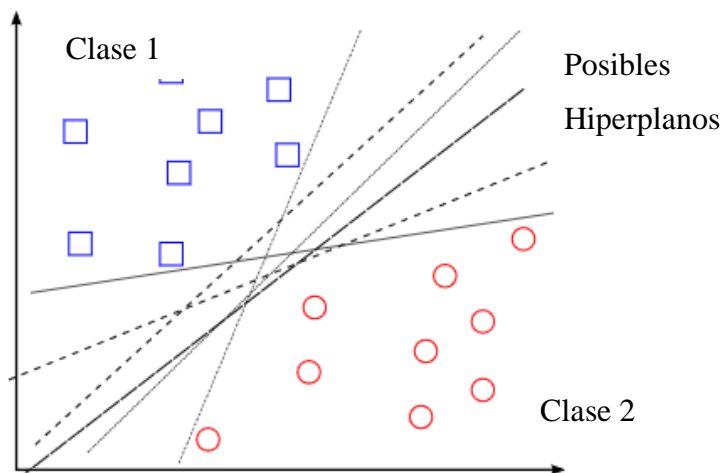


Figura 14 Ejemplo de los hiperplanos de separación para el conjunto de datos

Fuente: (Carmona, 2014)

La función lineal que puede describir lo representado en Figura 14 es:

$$D(x) = (w_0X_0 + \dots + w_{n-1}X_{n-1}) + c \quad (6)$$

Donde, w y c son factores reales, que deben cumplir las siguientes condiciones para definir correctamente la separación entre las dos clases.

$$\begin{aligned} \langle w, X_i \rangle + c &\geq 0 & \text{si } Y_i = +1 \\ \langle w, X_i \rangle + c &\leq 0 & \text{si } Y_i = -1 \end{aligned} \quad (7)$$

Al verificar que los hiperplanos cumplen con las condiciones descritas en la ecuación 6, se procede a seleccionar uno específico de la infinidad de planos separables con el margen.

Los SVM buscan separadores lineales que equidisten de los datos más cercanos de cada clase, para seleccionar el hiperplano adecuado se opta por el que tenga mayor margen (Hongzong, 2007); el margen está relacionado con la capacidad de generalización del sistema. En la Figura 15 se muestra gráficamente el hiperplano óptimo de separación entre clases.

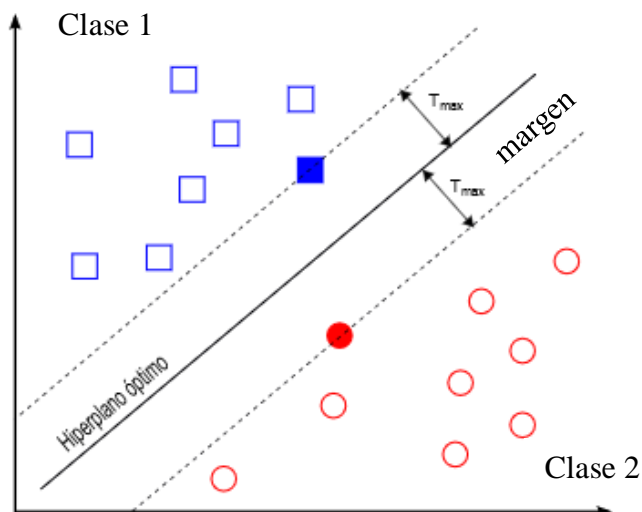


Figura 15 Margen de separación óptimo que define el hiperplano de separación

Fuente: (Carmona, 2014)

En la Figura 15 se puede ver una separación entre clases sin errores, ya que los datos que definen el margen (vectores soporte) se encuentran a una distancia adecuada permitiendo definir un hiperplano que divida perfectamente ambas clases.

El mejor hiperplano para un SVM es el que tiene el mayor margen entre las dos clases, cuando los datos son linealmente separables. Los SVM usan a veces una transformación del kernel para transformar datos no linealmente separables en dimensiones más altas ($R^2 \rightarrow R^3$) donde se puede encontrar un límite de decisión lineal. En la Figura 16 se muestra el uso que tiene el kernel para diferenciar entre las clases de datos.

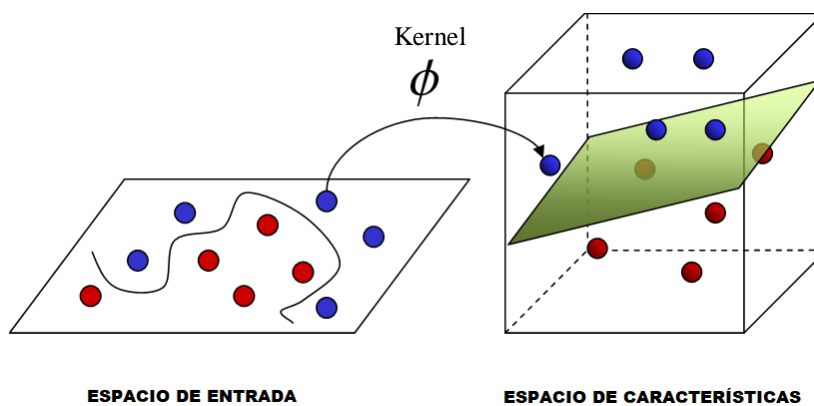


Figura 16 Uso del kernel para la división de clases

Fuente: (Marín, 2006)

La formulación matemática de los SVM varía dependiendo de la naturaleza de los datos; es decir, existe una formulación para los casos lineales y, no lineales (Carreras, 2004). Pese a los excelentes resultados obtenidos, las SVM tienen algunas limitaciones (Ortiz, 1999):

- La elección de un kernel adecuado es todavía un área abierta de investigación.
- La complejidad temporal y espacial, tanto en el entrenamiento como en la evaluación, son también una limitación.

2.7.4. K-Vecinos más cercanos (K-Nearest Neighbors)

Es un método de aglomeración jerárquica, cuya particularidad está en determinar la distancia mínima (más cercano) entre los grupos de datos (vecinos). Este método tiene propiedades contractivas sobre el espacio, ya que a medida que el grupo crece, los datos tienden a moverse de forma más adyacente (Herrera, 2000).

Suele tener una buena precisión predictiva en las dimensiones bajas. Tienen una alta velocidad de ajuste, y la velocidad de predicción es rápida para las dimensiones bajas, pero tienen un alto uso de memoria y no son fáciles de interpretar (Mora-Florez, 2008). Entre sus limitaciones se destaca que es muy sensible a los atributos irrelevantes, al ruido y tiene problemas con la dimensión. En la Figura 17 se muestra un ejemplo de un espacio con tres posibles clases (puntos, cruces y asteriscos).




Figura 17 Distribución de tres grupos de datos con KNN

Fuente: (Pelegrín, 2004)

Como se puede ver en la Figura 17, el círculo azul representa $K = 1$ vecinos donde, al tener una única referencia se clasificaría el dato como parte de la clase “puntos”, en el círculo verde con $K=3$ se puede ver que el dato sería clasificado al grupo de las cruces y con $K=20$ se tiene las 3 posibles clases (puntos, cruces y asteriscos), pero las cruces representan mayoría y su distancia es más corta al dato a clasificar, por lo tanto, el dato “?” va a ser clasificado dentro del grupo de las cruces.

2.7.5. Redes Neuronales

El primer modelo matemático que define el comportamiento de las neuronas biológicas fue propuesto por *Warren McCulloch* y *Walter Pitts* en 1943 (López, 2008), el cual intenta imitar el manejo de información del sistema nervioso (cerebro) ante casos concretos (Matich, 2016).

Una red neuronal consiste en redes altamente conectadas que relacionan las entradas con las salidas deseadas. La red es entrenada modificando iterativamente los pesos de las conexiones de modo que se llegue a la respuesta correcta (Mathworks, 2017).

Las características más relevantes de las redes neuronales se mencionan a continuación:

- Son unidades de procesamiento que se interconectan en paralelo y se les entrega información, por esta razón, es que en las redes neuronales se puede observar casos donde algún problema inicialmente no puede ser resuelto, pero luego del intercambio de información con el conjunto de neuronas se puede “aprender” a resolverlo/clasificarlo.
- Se utilizan para reconocer patrones.
- Tienen la capacidad de mejorar su rendimiento en base al aprendizaje.

Generalmente las neuronas se suelen agrupar en estructuras que se denominan “capas”, en la Figura 18 se muestra la estructura básica de una red neuronal con una conexión unidireccional (*feedforward*).




Figura 18 Ejemplo de red neuronal completamente conectada

Fuente: (Matich, 2016)

Como se puede ver en la Figura 18, existen 3 tipos de capas, que son: de entrada, ocultas y salida. La capa de entrada (sensorial) es la que recibe directamente la información proveniente de alguna fuente externa.

Las capas ocultas son las responsables de definir la topología de la red neuronal y entregar información para que la capa de salida pueda dar un resultado.

La capa de salida muestra directa o indirectamente la decisión a tomar.

Otra característica importante dentro de este método es que solamente las neuronas que están especializadas en un patrón de entrada son activadas y el resto no, por lo tanto, pueden ser consideradas como ganadoras recopilando la nueva información.

Las ventajas que se pueden resaltar de este método son los siguientes (Matich, 2016): su aprendizaje similar al ser humano (adaptativo), tolerancia a errores, tiempo de ejecución y su adaptación a la tecnología actual, aunque no sean completamente transparentes sus procesos.

2.8. Evaluación de clasificadores

Para determinar la eficiencia de los clasificadores se tendrá en cuenta su grado de exactitud, sensibilidad y especificidad.

2.8.1. Validación cruzada

Al dividir los datos disponibles en conjuntos, se reduce drásticamente el número de muestras que se pueden utilizar para aprender, y los resultados pueden depender de una elección aleatoria particular para el par de conjuntos.

Una solución al problema de pocas muestras es un procedimiento llamado validación cruzada (VC). Un conjunto de prueba todavía debe ser mantenido para la evaluación, pero el conjunto de validación ya no es necesario al hacer VC (Arahal, 2006).

En el enfoque básico, llamado k -fold, el conjunto de entrenamiento se divide en k conjuntos más pequeños. Se sigue el siguiente procedimiento para cada uno de los k "pliegues":

- Un modelo es entrenado usando $k - 1$ de los pliegues como datos de entrenamiento;
- El modelo resultante se valida en la parte restante de los datos.

La medida de rendimiento reportada por la validación cruzada k -fold es entonces el promedio de los valores calculados en todo el proceso (Arahal, 2006). Este enfoque puede ser costoso desde el punto de vista computacional (Lavelli, 2008), pero no desperdicia demasiados datos, lo cual es una ventaja importante en el problema, pero el número de muestras de prueba se hace más pequeño. En la Figura 19 se encuentra una representación del procedimiento de validación cruzada.

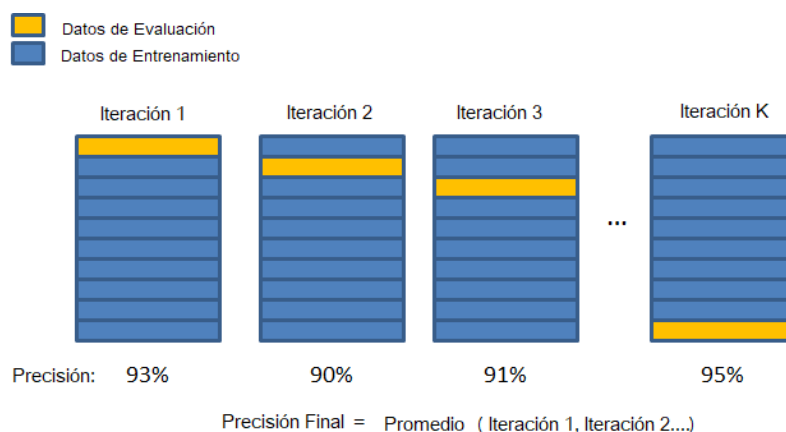


Figura 19 Descripción de validación cruzada

Fuente: (Lavelli, 2008)

La validación cruzada representada en la Figura 19 está en el orden de k , y se encarga de fraccionar los datos de entrada en conjuntos más pequeños. En cada iteración el modelo se entrena con $k - 1$ conjuntos de datos y se evalúa con el restante (uno). El valor final de precisión es el promedio resultante de cada iteración.

2.8.2. Matriz de confusión

Es comúnmente usada para definir la eficiencia de los modelos de aprendizaje de máquina implementados. Contiene información sobre la clasificación actual y la predicha realizada por un sistema. En las celdas dentro de la matriz se especifica cuantitativamente el grado de acierto o fracaso en cada caso (verdaderos positivos, falsos negativos, verdaderos negativos, etc.) (Lewis, 2001). La Tabla 4 muestra la matriz de confusión para un clasificador binario.

Tabla 4
Ejemplo de matriz de confusión

		Predicción	
		SI	NO
Clase Actual	SI	VP	FN
	NO	FP	VN

Fuente: Elaboración propia

Las entradas en la matriz de confusión mostrada en la Tabla 4 tiene el siguiente significado:

- VN (Verdadero negativo) es el número de predicciones correctas de que una instancia es negativa,
- FP (Falso Positivo) es el número de predicciones incorrectas de que una instancia es positiva,
- FN (Falso Negativo) es el número de predicciones incorrectas de una instancia negativa, y
- VP (Verdadero Positivo) es el número de predicciones correctas de que una instancia es positiva.

Uno de los beneficios de las matrices de confusión es que facilitan ver si el sistema está confundiendo dos clases; esta característica es importante cuando se tiene una base de datos que no es equiprobable.

Por ejemplo, si se tiene 200 muestras en total, de las cuales 188 son tipo “paciente sano” y las 12 muestras restantes son tipo “paciente enfermo”, el clasificador puede generalizar todo el conjunto a tipo “paciente sano” y tendría una exactitud del 94%, pero esto no significa que sea un buen clasificador ya que obtuvo un 100% de error en las muestras que representaban a un paciente enfermo, lo que puede conducir a consecuencias más graves.

A continuación, se detalla las fórmulas empleadas para generar la matriz de confusión.

- **Exactitud.** - Es la proporción de los resultados verdaderos (ambos verdaderos positivos y verdaderos negativos) entre el número total de casos examinados.

$$Exactitud = \frac{VP + VN}{VP + VN + FP + FN} \cdot 100\% \quad (8)$$

- **Sensibilidad.** - Muestra la capacidad del modelo para detectar a los pacientes enfermos.

$$Sensibilidad = \frac{VP}{VP + FN} \cdot 100\% \quad (9)$$

- **Especificidad.** - Es el porcentaje de personas sanas que se identificó correctamente como no tener la condición.

$$Especificidad = \frac{VN}{VN + FP} \cdot 100 \quad (10)$$

2.8.3. Curvas ROC (Receiver Operating Characteristic)

La evaluación de las pruebas de diagnóstico es un motivo de preocupación en la medicina moderna no sólo para confirmar la presencia de enfermedad, sino también para descartar la enfermedad en sujetos sanos (Hajian-Tilaki, 2013). La curva ROC es una herramienta fundamental para la evaluación de pruebas diagnósticas. En una curva ROC se representa la tasa verdadera positiva (Sensibilidad) en función de la tasa de falsos positivos (Especificidad) para diferentes puntos de corte de un parámetro (Begg, 1991).

Cada punto de la curva ROC representa coordenada de sensibilidad / especificidad que corresponde a un punto de decisión particular. El área bajo la curva ROC (AUC)

es una medida de lo bien que un parámetro puede distinguir entre dos grupos de diagnóstico (enfermo / normal).

El parámetro que indica la precisión de un modelo es al área bajo la curva ROC, si el área es igual a uno es un predictor perfecto, caso contrario, si el área es menor o igual a 0.5 es una prueba sin precisión diagnóstica (aleatoria) (García, 1997). Una limitación de las curvas ROC es que sólo contemplan dos estados clínicos posibles (sano, enfermo) y no sirven para situaciones en que se trata de discernir entre más de dos estados.

En la Figura 20 se encuentra una representación gráfica de las curvas ROC y su área bajo la curva (AUC) con respecto al valor diagnóstico.

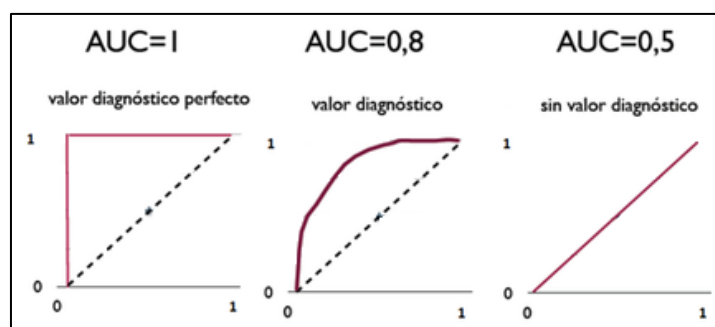


Figura 20 Representación gráfica de las curvas ROC

Fuente: (Fawcett, 2004)

2.9. Lenguajes de programación

2.9.1. OpenCV (Open Source Computer Vision)

OpenCV es una biblioteca de funciones de programación dirigida principalmente a la visión por ordenador en tiempo real (Bradski, 2008). La librería cuenta con más de 2500 algoritmos optimizados, que incluye un amplio conjunto de procedimientos clásicos y de última generación de visión por ordenador y algoritmos de aprendizaje de la máquina.

Los algoritmos implementados en OpenCV pueden ser utilizados para detectar y reconocer rostros, identificar objetos, clasificar acciones humanas en videos, rastrear objetos en movimiento, edición de imágenes y seguir los movimientos oculares, etc. (Bradski, 2008).

Adoptada en todo el mundo, OpenCV tiene más de 47 mil personas de la comunidad de usuarios y el número estimado de descargas supera los 9 millones. Los usos van desde el arte interactivo hasta la inspección de minas, construcción de sitios web o robótica avanzada.

2.9.2. Python

Python fue desarrollado como una licencia de código abierto (aprobada por OSI), lo que permite ser un lenguaje de programación libremente utilizable y distribuible, incluso para uso comercial (Khachatryan, 2015). Python en cierta forma es similar a Java, incluso tiene una máquina virtual (la PVM, *Python Virtual Machine*) y también puede ejecutarse en modo consola de manera parecida a Matlab®.

Python es un lenguaje de programación intuitivo y debido a esta característica cuenta con gran cantidad de módulos para realizar múltiples tareas, la mayoría de ellos son realizados por la fundación Python.

Para utilizar Matlab® se requiere una licencia de varios miles de dólares, mientras que Python es Open Source y es completamente gratuito para aplicaciones científicas y comerciales.

En el presente trabajo se empleó Matlab® inicialmente debido al toolbox que tiene para aprendizaje de máquina, ya que para un primer acercamiento es muy intuitivo y práctico, pero su gran desventaja es el licenciamiento, y por esto se vio la necesidad de buscar otro lenguaje de programación que permita generar similares resultados.

Para el procesamiento digital de imágenes y el aprendizaje de máquina se emplea anaconda2, que es una distribución de alto rendimiento de Python y R, una de sus ventajas es que ya cuenta con los paquetes básicos para el tratamiento de imágenes (OpenCV) y aprendizaje de máquina en Python (librería sklearn).

CAPÍTULO III

PROCEDIMIENTO

3.1. Introducción

Para realizar el prototipo de sistema CAD se requiere un conjunto de imágenes para ser analizadas, pero al momento de elaborar el presente trabajo de titulación no se encontró una base de datos de iridología liberada que contenga el diagnóstico final por parte de un doctor especialista (gastroenterólogo), únicamente se encontró una base de datos de iris. Para dar un diagnóstico se solicitó ayuda al Dr. Telmo de la Torre para localizar posibles anomalías en los iris presentados en la base de datos.

La base de datos total para el presente trabajo de titulación tiene 100 iris. La base de datos Iriso cuenta únicamente con 77 imágenes, donde principalmente los pacientes son cooperativos y las imágenes fueron captadas en un ambiente controlado, presentando toda la base de datos características similares. La cantidad de la base de datos Iriso se consideró reducida por lo que se vio la necesidad de conseguir más imágenes. Las 23 imágenes restantes se las obtuvo gracias a la colaboración de la Dra. Elena Egas (imágenes de 640 x 480 con pacientes no cooperativos) y compañeros de clase (imágenes de 16 megapíxeles con una cámara diferente a la empleada en Iriso) que prestaron su tiempo e iris para el actual estudio. Estas 23 imágenes se las añadió con la finalidad de evaluar la robustez del sistema implementado.

Al tener la base de datos completa de iris se debe seguir el proceso para su segmentación, que en un inicio es muy similar al que se realiza para el reconocimiento de iris en la autenticación biométrica. Se emplea máscaras en forma de anillo para la segmentación del área de interés (En la sección 3.3 Descripción general del algoritmo, se encuentra los diagramas de bloques describiendo el proceso seguido).

Con el área de interés segmentada (estómago) se procede a la conversión a coordenadas polares para poder retirar la pupila de la evaluación ya que su tonalidad oscura afectaría a los resultados. Luego se procede a la extracción de características de cada imagen (básicamente son características de color).

Con los datos obtenidos se manda a los 4 tipos de clasificadores que son: árbol de decisión, vecinos más cercanos KNN, SVM y redes neuronales. Debido al tamaño de la muestra (100 iris) se requiere emplear validación cruzada (10 *fold*) y se determina los mejores resultados.

3.2. Base de datos

Existen bases de datos de iris públicas para el estudio o investigación del iris como son: *CASIA*, *UTIRIS*, *UBIRIS*, *UPOL*, (Nalla, 2015) entre otras, pero las bases de datos enfocadas únicamente a iridología tienen un costo elevado, debido a la popularidad que ha tomado esta práctica en los últimos años, se ha hecho muy comercial.

Los principales problemas con estas bases de datos públicas, son el tipo de luz que usan (infrarroja) y la resolución de las mismas.

La resolución de las cámaras es un aspecto importante, ya que la iridología se encarga de estudiar las delicadas fibras del iris, por lo que se requiere cámaras que logren detectar esas minúsculas alteraciones, como el anillo de absorción.

Con el tipo de iluminación infrarroja, se está quitando los colores característicos del iris como se muestra en la Figura 21.




Figura 21 Imágenes del Iris: (a) Imagen con luz infrarroja, (b) Imagen a color

Fuente: Imagen (a) (Najafi, 2011) e Imagen (b) base de datos Iriso

3.2.1. Iriso

Para el presente trabajo se empleó la base de datos Iriso (Iriso, 2015), que cuenta con 77 imágenes de iris con diferentes iluminaciones; las imágenes fueron captadas

con una cámara Cannon® de 16 Megapíxeles, la dimensión de la imagen es de 4608x3456 píxeles, en formato jpg con 3 bits comprimidos por píxel.

La base de datos no incluye información del paciente (sexo, edad, historial clínico), tampoco cuenta con información de si el iris captado en la imagen es el izquierdo o derecho. No brinda mayor información sobre las personas que colaboraron en la base de datos debido al secreto profesional. En la

Figura 22 se muestra las diferentes iluminaciones disponibles en la base de datos.




Figura 22 Tipos de iluminaciones disponibles en la base de datos Iriso

Fuente: (Iriso, 2015)

En la

Figura 22 se muestra un mismo iris con diferente iluminación: (a) Iluminación Horizontal, (b) Iluminación Vertical, (c) Iluminación Superior, (d) Iluminación Lateral Derecha, (e) Iluminación Inferior, (f) Iluminación Lateral Izquierda.

Los iris que tienen una sola luz lateral son con la finalidad de destacar las texturas presentes, las luces laterales dobles permiten estudiar áreas precisas comparando las sombras proyectadas y penetrando hasta el fondo de lesiones. En una consulta convencional se usan principalmente los pares horizontal y vertical para tener una iluminación uniforme.

3.2.2. Imágenes adicionales

Dentro del campo práctico de la iridología las imágenes a ser estudiadas no tienen la resolución, iluminación y postura del iris adecuado; por esta razón se decidió incluir 23 imágenes adicionales, para determinar la robustez del sistema ante cambios. Las imágenes añadidas representan un 29,87% de la base de datos original.

Dentro de las 23 imágenes se tiene 8 imágenes de 640 x 480 píxeles, con iluminación lateral horizontal en formato jpg (Ver Figura 23a); 3 imágenes son captadas con una cámara Sony® de 16 megapíxeles de resolución, sin lente de aumento adicional, enfoque automático e iluminación lateral izquierda (Ver Figura 23b) y las 12 imágenes restantes fueron tomadas con un celular Sony® de 16 megapíxeles, un lente de aumento para lograr mayor detalle en la imagen y presentan iluminación lateral (Ver Figura 23c).




Figura 23 Imágenes adicionales con diferente resolución, iluminación y detalle

Fuente: (Iriso, 2015)

Como se puede ver las imágenes mostradas en la Figura 23 no tienen el mismo aspecto y características que presenta la base de datos de Iriso. Al incluir este tipo de

imágenes se debe configurar todo el prototipo para que funcione con la menor resolución de imágenes, que en este caso particular es de 640 x 480 píxeles.

3.3. Descripción general del algoritmo

Para realizar el diagnóstico se puede adquirir una imagen del iris de la base de datos, y en el caso de que se requiera adjuntar una imagen adicional al prototipo, se recomienda tener en cuenta lo siguiente; la imagen debe ser a color, tomada con una cámara de 16 Megapíxeles Cannon® (es con la finalidad de tener imágenes de similares características a las de la base de datos Iriso), las dimensiones de la imagen deben ser de 4608x3456 píxeles, enfoque manual y sin ningún filtro adicional.

Se recomienda tomar la imagen a una distancia de aproximadamente 2 cm. del ojo (entre el lente y el iris), mantener la cámara a una altura cómoda para el paciente y que pueda mirar fijamente, de ser posible emplear lentes de aumento en la cámara y emplear una luz lateral (LED) para iluminar el iris. No se debe mantener la luz muy cercana al ojo ni durante periodos de tiempo extensos (máximo 30 segundos), por último, se recomienda que el paciente este calmado para que pueda ver directamente el lente y no tenga movimientos nerviosos (involuntarios) en la captura de imagen.

Al tener la imagen del iris se procede a efectuar un procesamiento digital de imagen para localizar y segmentar el iris, para obtener varios parámetros de interés de la zona estudiada (zona 1 y 2).

En este prototipo se requiere una etapa de clasificación, donde en base a los parámetros de interés extraídos se determina si el paciente está o no enfermo. Este proceso emplea métodos de aprendizaje de máquina supervisado, ya que se tiene un vector respuesta (diagnóstico del doctor).

Al ser cada iris distinto (varia de persona a persona) debe adquirir experiencia en el diagnóstico en otras palabras debe ser entrenado, por esto se utiliza varios clasificadores donde se evalúa la eficiencia de cada uno y en base a los resultados obtenidos se determina el mejor clasificador para los atributos característicos que presenta el prototipo.

En la Figura 24 se describe el proceso general que realiza el sistema para establecer un diagnóstico.

Captura de imagen



Figura 24 Proceso para la detección y diagnóstico de enfermedades gástricas.

Fuente: Elaboración propia

3.4. Preprocesamiento

El iris es el área esencial de estudio para este trabajo, por esta razón debe ser segmentado de la imagen original adquirida, en otras palabras, se requiere quitar los elementos que no aporten información para la detección de enfermedades en el sistema gástrico, como son: pestañas, esclerótica, lagrimal, marcas en el borde del ojo, entre otras.

La segmentación del iris requiere una localización circular dentro de la imagen original del ojo. Esto significa detectar solamente el borde interno (pupila), ya que el área del estómago es el siguiente sector circular (ver Figura 25).

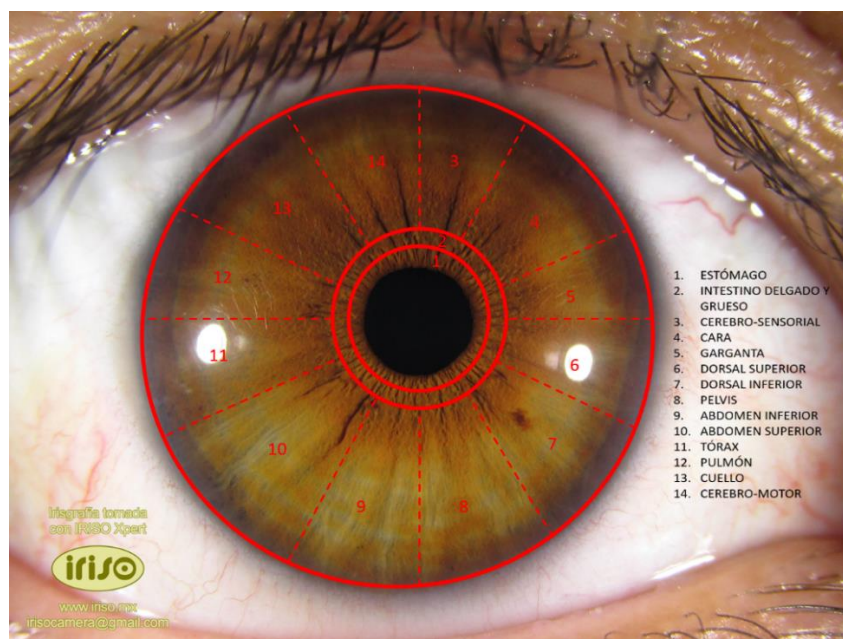


Figura 25 Localización de un mapa de Jensen en un iris real

Fuente: Elaboración propia

Como se puede ver en la Figura 25, no existe necesidad de localizar el borde externo del iris, ya que se encuentra fuera del área de interés, y de esta forma se optimiza el proceso para reducir el tiempo de ejecución.

La descripción general de los pasos que se siguen para el preprocesamiento de imagen, se muestra en la Figura 26.



Figura 26 Preprocesamiento de imagen

Fuente: Elaboración propia

En la Figura 26 el inicio del proceso es la imagen aplicada una redimensión, en el siguiente apartado se explica que aspectos se tomaron en consideración para definir la redimensión óptima para el presente caso de estudio.

3.4.1. Redimensión de imagen

Como primer paso, el sistema adquiere imágenes de la base de datos, para la resolución original de 4608x3456 píxeles el radio mínimo de la pupila es de 225 y el máximo de 467 píxeles, para revisar a detalle el valor de radios por imagen, favor revisar la sección de anexos.

Con las dimensiones de la pupila sistema presenta un tiempo de procesamiento por imagen de 53603,8 segundos (14 h 52 min y 48 s) en realizar un solo proceso de localización, segmentación y extracción de características (sin diagnóstico final - sin clasificador).

Uno de los objetivos del presente trabajo es obtener un diagnóstico ágil que no demande el tiempo que se requiere con otros procedimientos (biopsia, examen de sangre). Al tardar aproximadamente 15 horas en examinar la imagen completa, se ve la necesidad de implementar una redimensión de imagen al proceso.

Debido a las 23 imágenes añadidas se debe tener una redimensión de 640x480 píxeles lo cual implica que solo se está empleando un 1,89% aproximadamente de la imagen original. Al realizar este procedimiento el valor de entropía en la imagen será despreciable ya que está relacionado con el tamaño total de la imagen.

En la Tabla 5 se muestra las características del computador empleado para el presente trabajo de titulación y del cual se obtiene el tiempo de procesamiento:

Tabla 5
Características del computador empleado para las pruebas del prototipo

Componentes	Detalle
Procesador	Intel(R) Core™ i7-5600U
RAM	8Gb
Velocidad	2,60GHz
Sistema operativo	Windows 10 Pro 64 bits
Modelo	Dell Latitude E5450

Fuente: Elaboración propia

Con la redimensión mencionada el prototipo tarda 0,33 segundos en realizar el procesamiento de imagen y entregar las características, con la base de datos completa tarda 33 segundos.

Se debe tener en cuenta que cada vez que se quiera realizar un diagnóstico nuevo el sistema debe estar entrenado para poder dar un resultado. Al ir generando estos estudios se recomienda añadir las imágenes nuevas (img) a la base de datos, con esto el sistema CAD tendrá un conjunto de entrenamiento mayor (100 + img) imágenes.

3.4.2. Localización del área de interés

Posterior a la redimensión de imagen se llama a la subrutina Hough la cual se encarga de realizar la localización circular inicial del área de interés. En base a lo descrito en la sección 2.6.3.4 sobre la comparativa de metodologías, se optó por emplear la detección del iris de *R. Wildes*, por lo tanto, se requiere aplicar un detector de bordes de *Canny* y la Transformada *Hough*.

Para el presente trabajo no se requirió el detector de bordes de *Canny*, ya que al aplicarlo se localizaban varios círculos (criptas, luz, borde exterior, etc) y por lo tanto se incrementaba el tiempo de procesamiento. Se comprobó que solo con cambiar el espacio de color de RGB a escala de grises era más que suficiente para detectar el borde interior del iris (pupila).

Para usar la transformada *Hough* de OpenCV en Python se requiere la función `cv2.HoughCircles` donde los parámetros de entrada son: la imagen donde se realiza la localización (en escala de grises), método para detección del centro de la circunferencia (actualmente el único método implementado es `CV_HOUGH_GRADIENT` que es básicamente 21HT descrito en (Yuen, 1990)), el radio máximo y mínimo de la circunferencia y la distancia mínima entre los centros de los círculos detectados.

Los radios máximo y mínimo para la localización de la pupila son en tamaño de 66 y 30 píxeles respectivamente (Favor revisar Anexos Tabla A). Estos valores son respecto a la resolución de 480 píxeles.

Si la distancia mínima entre centros es demasiado pequeña (circunferencias localizadas con la transformada *Hough*), varios círculos vecinos pueden ser falsamente detectados además de uno verdadero. En el caso de que sea demasiado grande, algunos círculos pueden ser perdidos, para este caso solo necesitamos encontrar una circunferencia, por lo tanto, se coloca un valor alto como distancia mínima entre centros (la distancia mínima colocada es de 800).

Al localizar la pupila con la transformada *Hough* se procede a dibujar la circunferencia encontrada con la finalidad de validar si el procedimiento ejecutado fue exitoso o no.

Para la localización del área de interés se tiene en mente que la localización del borde interno del iris es de principal importancia, mientras que el borde exterior real para el presente trabajo no es la separación entre el iris y la esclerótica (borde exterior); el borde exterior real es el anillo de absorción en caso de que exista y las zonas 1 y 2 que corresponden al sistema gástrico.

Para seleccionar el área de interés final se tiene en consideración el radio medio de la pupila y del iris, que son 49 y 171 píxeles respectivamente (revisar la sección de Anexos). Con estos valores se saca el tamaño medio del iris que es 122 píxeles.

En los mapas de Jensen se puede ver que la región del estómago son pequeñas áreas concéntricas a la pupila (10-30 píxeles), pero para el presente trabajo de

titulación se tendrá en consideración el peor caso, el cual sería, si el área de interés llega hasta la mitad del iris (61 píxeles).

Se determina la distancia óptima que representa el área de interés en base a la exactitud final del sistema, para esto se hace pruebas con valores de múltiplos de 10 hasta el valor máximo que es de 60 píxeles.

En la Figura 27 se presenta el diagrama de flujo para la localización del área de interés (borde interno del iris y zona del estómago).



Figura 27 Algoritmo de localización para el área de interés en la imagen

Fuente: Elaboración propia

La elección del valor óptimo se encuentra en la sección de resultados, pero para la explicación del procedimiento se utilizará la nomenclatura de L para representar dicho valor.

Después de localizar correctamente el borde interior del iris se suma L píxeles al radio obtenido de la pupila con la finalidad de obtener únicamente las secciones de relevancia mientras se descarta la información innecesaria. El resultado de este proceso se puede verificar en Figura 28.

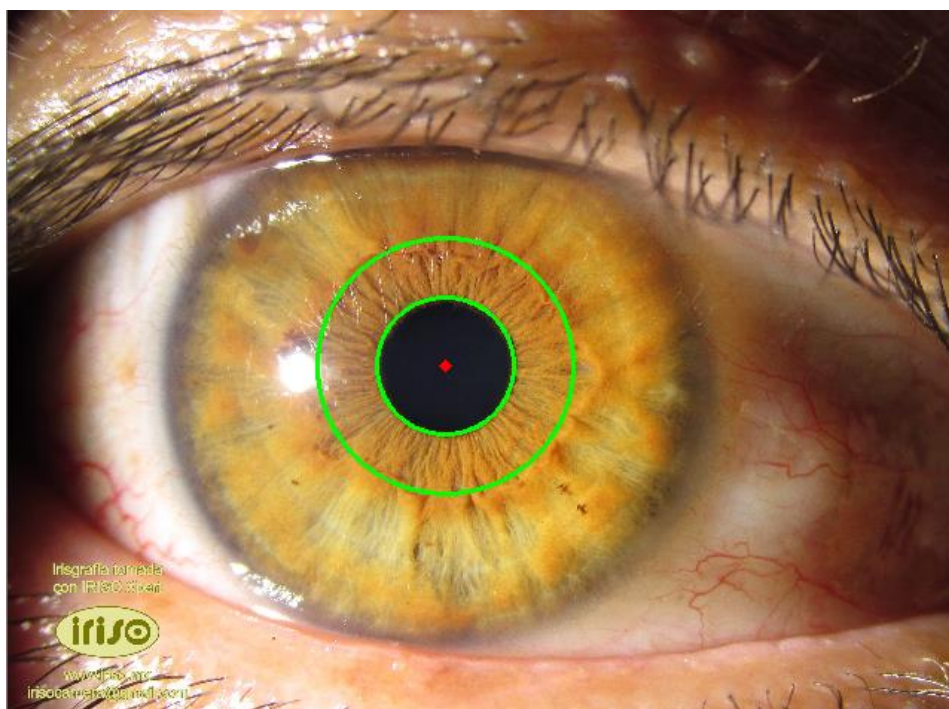


Figura 28 Resultado del proceso de localización de área de interés

Fuente: Elaboración propia

La localización del área de interés es el primer paso, ya que no se puede sacar información útil de la imagen como se muestra en la Figura 28 porque aún están considerada la pupila, el parpado, la esclerótica, entre otros. Entonces, es necesario realizar una segmentación de imagen para tener únicamente las zonas 1 y 2 del mapa de Jensen.

3.4.3. Segmentación del área de interés

La segmentación de imagen se realiza mediante dos máscaras. En la Figura 29 se muestra las etapas del algoritmo empleado para segmentar el área de interés.



Figura 29 Algoritmo para segmentación del area de interes

Fuente: Elaboración propia

La función Mascara recibe la siguiente información como datos de entrada: la imagen con las circunferencias localizadas, el radio de la pupila, radio del área de interés (zona 1 y 2) y el centro de la circunferencia.

Para realizar una máscara de igual dimensión que el área de interés se realiza una matriz de ceros de igual tamaño que la imagen original (640,480,3) y se coloca un área circular llena de unos con las dimensiones (el centro y el radio zona 1 y 2) obtenidas de la subrutina Hough.

Se calcula una máscara por cada imagen, debido a que los radios y centros no coinciden, para la primera imagen de la base de datos su máscara resultante se muestra en la Figura 30.



Figura 30 Máscara resultante para la imagen 1 de la base de datos

Fuente: Elaboración propia

Solo con la máscara mostrada en la Figura 30 no se puede tener el resultado esperado ya que la pupila seguiría presente en la imagen.

Para eliminar la pupila de la imagen se realiza una segunda máscara, se utiliza un círculo con las dimensiones de la pupila, pero esta vez llena de ceros. En la Figura 31 se muestra la máscara final implementada.




Figura 31 Máscara final implementada para la segmentación del iris

Fuente: Elaboración propia

Para extraer solamente la zona 1 y 2 se realiza una operación *AND* (en Python se representa con $\&$) entre la imagen entregada (imagen localizada de la subrutina Hough) y la máscara final, adicionalmente se recorta la imagen para que solo se muestre la zona de interés (tiene forma similar a un anillo), en la Figura 32 se muestra el resultado final de la subrutina máscara.




Figura 32 Imagen resultante de la segmentación

Fuente: Elaboración propia

3.4.4. Transformación de coordenadas

Luego de segmentar la imagen exitosamente, el siguiente paso es transformar de coordenadas rectangulares a polares (i.e., la imagen es cambiada a dimensiones fijas) (Masek, 2003). Para ello se debe tener en cuenta el cambio de dimensiones de la pupila.

La imagen transformada a coordenadas polares es la que se codificará y permita una homogenización en el proceso de detección de características. El modelo reasigna a cada punto dentro del iris a un par de coordenadas polares (Daugman J. , 2004).

Para la transformación a dimensiones fijas se emplea el método de *Daugman* y en la Figura 33 se muestra un ejemplo de normalización.




Figura 33 Ejemplo de normalización por el método de Daugman

Fuente: (Daugman J. , 2004)

Como se mencionó anteriormente entre las imágenes de la base de datos existe diferencias como: la iluminación, el tamaño del iris, tamaño de la pupila, inclinación de la cabeza, entre otras. Para realizar un sistema automático es necesario que las imágenes a ser diagnosticadas presenten la misma forma, por lo cual es de vital importancia realizar una transformación de coordenadas rectangulares a coordenadas polares.

Como primer paso se realiza el cambio a coordenadas (r, θ) empleando las formulas descritas a continuación:

$$r = \sqrt{(x^2 + y^2)} \quad (11)$$

$$\theta = \text{atan}\left(\frac{y}{x}\right) \quad (12)$$

Donde r representa el radio y está en el intervalo entre $[0,1]$, mientras que θ representa el ángulo de apertura, por lo tanto, puede tener valores entre $[0,2\pi]$.

En la Figura 34 se describe el algoritmo para la transformación de coordenadas rectangulares a polares.



Figura 34 Algoritmo para la transformación de coordenadas

Fuente: Elaboración propia

Al tener la imagen en coordenadas polares se debe realizar una transformación adicional para pasarlos a coordenadas de pixeles nuevamente, para lo cual se utiliza las siguientes fórmulas:

$$x = r \cdot \cos \theta \quad (13)$$

$$y = r \cdot \sin \theta \quad (14)$$

Donde (x, y) representan las coordenadas de los pixeles, el resultado de este procedimiento se muestra en la Figura 35 donde se puede notar que existen dos zonas negras que rodean el área de interés. Estas zonas representan al área segmentada de la

pupila y los bordes exteriores resultantes de aplicar la máscara a la imagen (ver Figura 35).




Figura 35 Imagen realizada la transformación de coordenadas

Fuente: Elaboración propia

Para retirar las zonas oscuras que rodean el iris se procede a recortar la imagen, dando como resultado la Figura 36.



Figura 36 Imagen resultante del proceso de cambio de coordenadas

Fuente: Elaboración propia

3.5. Extracción de características

Al tener únicamente la zona de interés se puede proceder con la extracción de características en la imagen, que indican la presencia de alguna anomalía en el iris.

Para que el sistema pueda tomar una decisión se debe tener en cuenta ciertos parámetros que denoten las anomalías dentro de la zona de interés. En total se consideró 20 características, pero no todas son evaluadas ya que no aportaban con información relevante para el estudio. A continuación, se describe todas las características y se explica en ciertos casos porque se las retira del prototipo final.

3.5.1. Media de color

Este parámetro indica el posible intervalo de color normal. En esta característica es necesario aclarar un aspecto, las imágenes empleadas en la base de datos son en su mayoría de tonalidades color café, por lo cual se espera una variación en la distribución de datos en este parámetro para las imágenes de una tonalidad diferente (2 imágenes-

tonalidad azul) ya que evidentemente va a variar el color medio drásticamente entre los dos grupos de imágenes.

3.5.2. Desviación estándar

La desviación estándar muestra la cantidad de desviación que existe entre el color medio y las anomalías presentes en el mismo, ayudando a detectar y diferenciar los cambios que se presentan en cada componente RGB.

3.5.3. Intensidad de color según el nivel de afectación

Es una característica propuesta, donde la imagen segmentada es transformada a escala de grises y en base a (Sivasankar, 2012) se establece rangos para determinar el grado de afectación. En la Tabla 6 se muestra los rangos considerados:

Tabla 6
Rango de intensidad según el nivel de afectación

Grado de afectación	Nivel de gris	Intensidad (escala de grises)
Agudo	Blanco	201-255
Sub agudo	Gris claro	151-200
Crónico	Gris oscuro	101-150
Degenerativo	Negro	0-100

Fuente: (Sivasankar, 2012)

En la Figura 37 se muestra gráficamente la distribución de intensidad que tienen las imágenes del iris, las zonas oscuras van a representar el área de anomalías que van a estar de 0-100.



Figura 37 Densidad de anomalías en base al color medio y desviación estándar

Fuente: Elaboración propia

3.5.4. Densidad de anomalías

Se binariza la imagen segmentada y se procede a determinar la cantidad de ceros (áreas afectadas) en la imagen. Se suma los unos presentes en la imagen y se lo divide para el número total de píxeles que tiene la imagen segmentada. Los clasificadores deben definir un umbral para dar un diagnóstico en base a esa información. La imagen binarizada se muestra en la Figura 38.



Figura 38 Imagen de segmentación binarizada

Fuente: Elaboración propia

3.5.5. Detección del anillo de absorción

Esta característica es sobre localización de anillo de absorción, ya que las anomalías presentes en la región de análisis pueden ser confundidas con la pupila debido a su textura y color oscuro. Si existe un valor diferente de cero en este parámetro, significa que hay anomalías oscuras presentes en la zona de interés.

3.5.6. Máxima intensidad de color

La detección de alteraciones en la salud mediante iridología están estrechamente relacionadas con los cambios de color; por esta razón es importante definir las tonalidades máximas que se presentan en la imagen.

Se optó por sacar esta característica del prototipo final debido a que todos los valores eran de 255, lo cual indica hay un punto de luz presente en la imagen estudiada. Pero no representa una característica útil para la clasificación.

3.5.7. Mínima intensidad de color

En esta característica si se evidenció tonalidades mínimas diferentes de cero que se presentan en la imagen, por esta razón si fue tomada en consideración para el prototipo final.

En la Tabla 7 se detalla el nombre de cada parámetro empleado junto con el número de atributos extraídos del mismo.

Tabla 7.
Nombre de parámetros y número de atributos extraídos (implementados).

Nombre de los atributos	Número de atributos extraídos
Media de color	3
Desviación estándar	3
Intensidad de color	1
Densidad de anomalías	1
Anillo de absorción	1
Mínima intensidad de color	3
TOTAL	12

Fuente: Elaboración propia

3.6. Clasificador

Al tener las 12 características por imagen se debe utilizar los clasificadores para definir el diagnóstico. En la Figura 39 se muestra el algoritmo implementado para realizar la clasificación.

El primer paso es implementar validación cruzada (son 100 imágenes se tiene 10 grupos de 10), para lo cual en el programa realizado en Python se requiere incluir la librería *sklearn* ya que se necesita emplear la función *KFold* y las librerías de aprendizaje de máquina. La función *KFold* solo obtiene los índices de los elementos que forman los grupos de datos para entrenamiento y evaluación.

Con los índices de los datos se debe formar los grupos de entrenamiento y llamar a la función *tree.fit* (árbol de decisión), *knn.fit* (vecino más cercano), *svm.fit* (SVM), *mlpc.fit* (redes neuronales).



Figura 39 Algoritmo para los cuatro clasificadores

Fuente: Elaboración propia

Para cada clasificador se evalúa un parámetro en particular. Para árbol de decisión se estudia cual es el nivel de profundidad ideal para el modelo, para vecinos más cercanos se determina el número máximo de vecinos que se debe considerar, en SVM se estudia que *kernel* da el mejor desempeño. En redes neuronales se determina el número óptimo de redes neuronales.

CAPÍTULO IV

RESULTADOS

4.1. Introducción

Una vez obtenidos todos los atributos relevantes, se utiliza los clasificadores y validación cruzada para determinar el rendimiento de cada uno. La nomenclatura para el diagnóstico de cada imagen es: 0 representa que está enfermo y 1 indica que está sano. Para definir las mejores características de entrenamiento se utilizó el número de posibles combinaciones (4095 posibles combinaciones) entre las 12 características para SVM, vecino más cercano y árbol de decisión. Para redes neuronales no se utilizó este proceso.

En esta sección se define el valor óptimo de L (distancia del borde exterior de la pupila al área de interés) en función de la exactitud y el área de la curva ROC (AUC).

4.2. Definición de L

Como se mencionó en el capítulo 3 para la definición de L se tomó en consideración desde los 10 píxeles hasta los 60, en la Tabla 8 se muestra los resultados obtenidos con ese procedimiento.

Tabla 8
Desempeño de los clasificadores según la distancia óptima

Clasificadores		10 píxeles	20 píxeles	30 píxeles	40 píxeles	50 píxeles	60 píxeles
Árbol de decisión	Exactitud	79%	92%	92%	85%	84%	89%
	AUC	0,70	0,88	0,88	0,8	0,76	0,85
Vecinos más ceranos	Exactitud	85%	81%	85%	87%	80%	81%
	AUC	0,78	0,76	0,89	0,74	0,65	0,68
SVM	Exactitud	86%	98%	94%	90%	82%	83%
	AUC	0,83	0,81	0,92	0,89	0,77	0,79
Redes Neuronales	Exactitud	63%	79%	83%	70%	66%	48%
	AUC	0,67	0,85	0,89	0,75	0,71	0,51

Fuente: Elaboración propia

El mejor resultado obtenido en la variación de L fue de 30 píxeles, a continuación, se explica con mayor detalle cada clasificador.

4.3. Resultados con la base de datos de 100 imágenes

4.3.1. Árbol de decisión

En la Tabla 9 se presenta el rendimiento de árbol de decisión con diferentes criterios de clasificación:

Tabla 9
Rendimiento del clasificador árbol de decisión

Criterio de separación	Exactitud	AUC
Entropía	92%	0,88
Gini	87%	0,81

Fuente: Elaboración propia

Con el criterio de ganancia de información se tiene mejores resultados que con el índice de Gini (expresa la desigualdad en las clases).

Se evaluaron los resultados para árboles de decisión con diferentes criterios de separación, en la Figura 40 se muestra la curva de mejor desempeño entre evaluación y entrenamiento del árbol de decisión con un criterio de segmentación de entropía.




Figura 40 Gráfica de ajuste del árbol de decisión con el criterio de entropía

Fuente: Elaboración propia

En la Figura 40 se compara la curva de entrenamiento y evaluación para detectar los puntos donde el árbol puede estar en sobreajuste. Desde el nodo 8 se puede ver que la curva de entrenamiento (roja) no sufre mayor variación y se mantiene constante, esto se debe a que el árbol generalizó el modelo al grupo de datos de entrenamiento.

El nodo 7 tiene un 92% de exactitud y en su transición al nodo superior se puede ver un último crecimiento en la curva de entrenamiento. En la Figura 41 se muestra el árbol de decisión con los umbrales de separación.




Figura 41 Árbol de decisión con umbrales por característica

Fuente: Elaboración propia

Como se puede ver en la Figura 41, para el árbol de decisión, 6 de los 12 atributos no tienen importancia para obtener un diagnóstico final, por esta razón se decide retirarlos de este clasificador para obtener los mejores resultados. El árbol de decisión tiene 7 divisiones y emplea 6 características (no emplea la intensidad de color, detección del anillo de absorción, color mínimo en la componente roja y azul, media de color en verde y la desviación estándar en azul)

4.3.2. Vecino más cercano KNN

En la Figura 42 se muestra el rendimiento del clasificador en base al número de vecinos que considera.

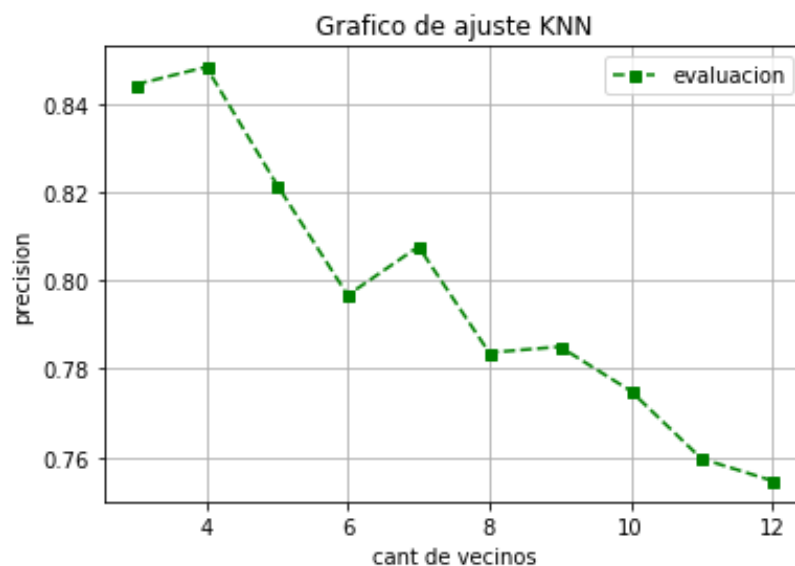


Figura 42 Ajuste KNN en función del número de vecinos que considera

Fuente: Elaboración propia

Con K igual a 4 vecinos se obtiene los mejores resultados, teniendo una exactitud del 85%. Se puede ver que a partir de este punto el clasificador tiene más conflictos en determinar el diagnóstico.

4.3.3. SVM

Para el modelo de SVM se cambia el *kernel* entre las siguientes opciones: SVC (*Support Vector Classifier*), RBF (*Radial Basis Function*), POLY (*kernel* polinómico de grado 3), LIN (*kernel* lineal). El clasificador SVM utilizó 5 de las 12 características, las cuales son; la media de color en la componente red, densidad de anomalías y la desviación estándar de RGB.

En la se muestra el desempeño de SVM con cada kernel, se puede ver que RBF y POLY dan los mejores resultados, mientras que LIN da el desempeño más bajo.




Figura 43 Desempeño de SVM según el kernel empelado

Fuente: Elaboración propia

En la Figura 43 se muestra el valor de exactitud de cada SVM con su respectivo kernel y en la Tabla 10 se encuentra en mayor detalle los resultados obtenidos con el clasificador SVM.

Tabla 10
Desempeño de SVM según el kernel empleado

Tipo de Kernel	Exactitud	AUC
Support Vector Classifier	81%	0,79
Radial Basis Function	94%	0,92
Polinómico	89%	0.87
Lineal	70%	0,63

Fuente: Elaboración propia

4.3.4. Redes Neuronales

Emplea tres conjuntos, uno para validación (30% de la base de datos), otro entrenamiento (30% de la base de datos) y el último para pruebas (40% de la base de datos). De cada etapa obtiene un resultado, pero para el presente análisis solo se tendrá en cuenta como resultado final (análisis global de las respuestas).

4.3.5. Comparativa del rendimiento de clasificadores

Los resultados de la evaluación son presentados en términos de exactitud, sensibilidad, especificidad y capacidad predictiva (área bajo la curva ROC) con la finalidad de entender las características de desempeño de los sistemas propuestos.

Los valores presentados anteriormente representan el valor medio de los valores de clasificación obtenidos durante el *K-fold*.

En la Tabla 11 se presenta el promedio de la exactitud, sensibilidad, especificidad y capacidad predictiva mostrada por cada clasificador.

Tabla 11
Eficiencia de clasificadores

Clasificador	Exactitud	Sensibilidad	Especificidad	Capacidad Predictiva
Tree	92%	75,75%	100%	0,88
Knn	85%	81,48%	86,3%	0,89
Svm	94%	87,87%	97,01%	0.92
Redes neuronales	83%	66,67%	91,04%	0,89

Fuente: Elaboración propia

Los valores de sensibilidad son bajos debido a la base de datos empleada, no es equiprobable. Las personas enfermas son 33, mientras que las personas sanas son 67.

4.3.6. Matriz de confusión

En la Tabla 13,14,15 y 16 se muestra las matrices de confusión para obtener los valores de exactitud, sensibilidad, del sistema de árbol de decisión, vecino cercano, SVM y redes neuronales respectivamente.

Tabla 12
Matriz de confusión árbol de decisión.

		Predicción	
		SI	NO
Clase Actual	SI	25	8
	NO	0	67

Fuente: Elaboración propia

Como se puede ver en la Tabla 12, el clasificador no funciona adecuadamente ya que no logra discriminar entre una persona sana de otra enferma. Lo más alarmante de este resultado es que a 8 pacientes enfermos los diagnosticó como sanos, y como se explicó anteriormente las consecuencias de no dar un tratamiento temprano es que se incrementa la predisposición para contraer cáncer del sistema gástrico.

Tabla 13
Matriz de confusión vecino más cercano

		Predicción	
		SI	NO
Clase Actual	SI	22	5
	NO	10	63

Fuente: Elaboración propia

Tabla 14
Matriz de confusión SVM

		Predicción	
		SI	NO
Clase Actual	SI	29	4
	NO	2	65

Fuente: Elaboración propia

Como se puede ver SVM es el que mayor sensibilidad presenta, ya que es el clasificador que mejor detecta a los pacientes enfermos, aunque tenga un error en el diagnóstico de un paciente sano no causa tanto impacto.

Tabla 15
Matriz de confusión redes neuronales

		Predicción	
		SI	NO
Clase Actual	SI	22	11
	NO	6	61

Fuente: Elaboración propia

4.3.7. Curvas ROC

En la Figura 44 se presenta de forma gráfica el área bajo la curva que para el prototipo implementado es de 0,92 y según (Zhu, 2010) la calidad de la prueba diagnóstica es buena.




Figura 44 Curva ROC de SVM con un Kernel RBF

Fuente: Elaboración propia

El 0,92 que muestra la curva significa que existe un 92% de probabilidad de que, ante un par de individuos, uno enfermo y el otro sano, el sistema los clasifique correctamente. En caso de que el prototipo se llegue equivocar en su clasificación, es más probable que muestre al individuo enfermo (aunque este sano) lo cual es menos crítico, ya que la persona va asistir a una consulta médica a corroborar el diagnóstico dado por el sistema.

4.4. Resultados con 77 imágenes de Iriso

4.4.1. Comparativa del rendimiento en los clasificadores

El procedimiento que se sigue en el caso de emplear las 77 imágenes es muy similar pero los resultados varían un poco, ya que las imágenes consideradas para este experimento son uniformes.

Los resultados de la evaluación son presentados en términos de exactitud, sensibilidad, especificidad y capacidad predictiva (área bajo la curva ROC) con la finalidad de entender las características de desempeño de los sistemas propuestos.

En la Tabla 16 se presenta el promedio de la exactitud, sensibilidad, especificidad y capacidad predictiva mostrada por cada clasificador.

Tabla 16 Eficiencia de clasificadores con 77 imágenes

Clasificador	Exactitud	Sensibilidad	Especificidad	Capacidad Predictiva
Tree	94,8%	86,6%	96,77%	0.91
Knn	81,8%	6,66%	100%	0.64
Svm	96,1%	86,66%	98,38%	0.99
Redes neuronales	90,9%	66,66%	96,77%	0,98

Fuente: Elaboración propia

Con las 77 imágenes de Iriso se tiene 14 pacientes enfermos, mientras que las personas sanas son 63.

4.4.2. Matriz de confusión

En la Tabla 17,18,19 y 20 se muestra las matrices de confusión para obtener los valores de exactitud, sensibilidad, del sistema de árbol de decisión, vecino cercano, SVM y redes neuronales respectivamente.

Tabla 17 Matriz de confusión con árbol de decisión

		Predicción	
		SI	NO
Clase Actual	SI	13	2
	NO	2	60

Fuente: Elaboración propia

Tabla 18 Matriz de confusión con vecino más cercano

		Predicción	
		SI	NO
Clase Actual	SI	1	14
	NO	0	62

Fuente: Elaboración propia

Como se puede ver en la Tabla 18, el clasificador no funciona adecuadamente ya que no logra discriminar entre una persona sana de otra enferma. Lo más alarmante de este resultado es que a 14 pacientes enfermos los diagnosticó como sanos, y como se

explicó anteriormente las consecuencias de no dar un tratamiento temprano es que se incremente la predisposición para contraer cáncer del sistema gástrico.

		Predicción	
		SI	NO
Clase Actual	SI	13	2
	NO	1	61

Fuente: Elaboración propia

Como se puede ver SVM es el que mayor sensibilidad presenta, ya que es el clasificador que mejor detecta a los pacientes enfermos, aunque tenga un error en el diagnóstico de un paciente sano no causa tanto impacto.

		Predicción	
		SI	NO
Clase Actual	SI	10	5
	NO	2	60

Fuente: Elaboración propia

4.1 Curvas ROC

En la Figura 23 se presenta la curva ROC, únicamente se presenta la curva ROC del clasificador con el mejor rendimiento integral que para este caso es SVM.




Figura 45 Curva ROC para el sistema con 77 imágenes

Fuente: Elaboración propia

Las causas de que el sistema no detecte de manera óptima son:

1) Las deformaciones en la pupila. Interfieren al momento de realizar la segmentación e identificación de la circunferencia lo cual obstaculiza los pasos posteriores para el diagnóstico.

2) La posición de la iluminación para la captura de la imagen juega un papel primordial ya que si interfiere en el área de interés se está quitando información importante para el diagnóstico.

CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

En un ambiente controlado con las 77 imágenes de similares características se obtuvo un mejor desempeño del prototipo con 96,1% de exactitud y 99% de capacidad predictiva (ROC). Al añadir las 23 imágenes se ingresó un mayor ruido al sistema ya que aquellos iris tienen diferentes características porque no fueron captados en un ambiente controlado y cooperativo, a pesar de esto el prototipo no se vio gravemente afectado debido a que solo baja un 2,1% en exactitud, pero presenta un aumento en lo que es el parámetro de sensibilidad.

Con el clasificador SVM se obtiene mejor resultado para las imágenes bajo el procedimiento descrito en el presente trabajo con un *kernel RBF*. Actualmente el sistema tiene un 94% de diagnósticos correctos, el 87,87% de probabilidad de que un sujeto enfermo obtenga una prueba diagnóstica con un resultado positivo. Estos resultados son favorables para el problema de una falta de detección temprana, ya que si el sistema determina que el paciente tiene alguna enfermedad gástrica; este debe asistir a una consulta médica para corroborar el diagnóstico y recibir el tratamiento adecuado evitando futuras molestias o complicaciones.

En base a los resultados obtenidos con el *kernel* de SVM se determina que la distribución de los datos no es linealmente separable y por esta razón KNN presenta un bajo rendimiento en el sistema, debido a que solamente evalúa la proximidad entre los pacientes.

Las curvas ROC indican que tiene un buen nivel de predicción (valor entre 0.8 - 1), aunque esto puede cambiar debido a que la base de datos empleada no es equiprobable y tiene poca cantidad de muestras.

Es necesario un valor alto en la curva ROC, para esto se determinó que el sistema debe tener un valor elevado en sensibilidad antes que en especificidad ya que es preferible diagnosticar la enfermedad en un paciente sano antes que errar en el diagnóstico de un paciente enfermo, ya que este no va asistir a una consulta médica y

dejara pasar los síntomas hasta que el dolor sea intolerable y tenga mayores complicaciones en el tratamiento.

5.2. Recomendaciones

Actualmente el sistema está enfocado a ojos con ciertas particularidades de color debido a la base de datos con la que fue entrenado el prototipo, ya que la mayoría de iris son de tonalidades cafés. Por esta razón se recomienda incrementar las imágenes en la base de datos con nuevas características de color para que el sistema pueda generalizar mejor su clasificación.

En caso de añadir nuevas imágenes a la base de datos se debe tener el radio de la pupila y el iris para poder setear estos nuevos parámetros dentro del programa.

El principal limitante en este trabajo fue la falta de un diagnóstico por parte de un gastroenterólogo, ya que esto sería de gran importancia porque se realizaría un contraste entre ambas prácticas médicas y se podría desarrollar las posibles ventajas o desventajas que tenga este tipo de medicina bioenergética y el prototipo implementado.

5.3. Trabajos Futuros

Como trabajo futuro se propone emplear métodos de aprendizaje no supervisado para segmentar la imagen de estudio o diferenciar entre áreas adyacentes del iris para determinar su pertenencia o no a una clase.

Como trabajo futuro se propone mejorar el desempeño del sistema para poder ingresarlo de forma embebida en un sistema de acceso biométrico, así las personas estarían en continuo estudio y en caso de detectar alguna anomalía se lo informaría inmediatamente al área correspondiente. Es necesario tener presente que el médico debe realizar una evaluación previa, para levantar su historia médica y otras características que son apoyo en el diagnóstico y de interés dentro del área.

BIBLIOGRAFÍA

- Abreu, L. &. (2007). Gastritis. En *Gastroenterología: endoscopia diagnóstica y terapéutica*. (págs. 166-170). Ed. Médica Panamericana. doi:8479039639
- Acero, Á. R. (2015). Sistema de clasificación por visión artificial de mangos tipo Tommy. *Revista UIS Ingenierías*, 21-31.
- Alpaydin, E. (2014). Introduction to machine learning. *MIT press*, 5-8.
- Arahal, M. R. (2006). Validación cruzada. En *Técnicas de predicción con aplicaciones en ingeniería* (págs. 77-78). Sevilla: Universidad de Sevilla.
- Atherton, J. C. (2006). The pathogenesis of Helicobacter pylori-induced gastroduodenal diseases. *Annu. Rev. Pathol. Mech*, 63-96.
- Ballard, D. H. (1981). Generalizing the Hough transform to detect arbitrary shapes. *Pattern recognition*, 111-116.
- Begg, C. B. (1991). Advances in statistical methodology for diagnostic medicine in the 1980's. . *Statistics in medicine*, 1888-1894.
- Bell, R. M. (2007). Lessons from the Netflix prize challenge. *Acm Sigkdd Explorations Newsletter*, págs. 75-79.
- Berdonces, J. L. (20 de junio de 1999). *El gran libro de iridología grafico*. RBA libros. Obtenido de EL GRAN LIBRO DE IRIDOLOGIA GRAFICO.
- Blanes, C. S. (2012). *Aplicacion de un modelo de red neuronal no supervisado a la clasificacion de consumidores electricos*. Editorial Club Universitario.
- Bradski, G. &. (2008). *Learning OpenCV: Computer vision with the OpenCV library*. " O'Reilly Media, Inc."
- Calot, E. (2008). Reconocimiento de patrones en imágenes médicas basado en sistemas inteligentes. . En *Capitulo 2* (págs. 5-7). Enrique Calot.
- Cañadas, M. M. (2007). Estudios para la optimización de la calidad de imagen en el escáner ClearPET, modificando parámetros del algoritmo IMF-OSEM 3D sobre adquisiciones simuladas con GAMOS. . *CIEMAT*, 1-3.
- Carmona, E. J. (2014). *Tutorial sobre Máquinas de Vectores Soporte (SVM)*. Madrid, España.: Dpto. de Inteligencia Artificial, ETS de Ingeniería Informática, Universidad Nacional de Educación a Distancia (UNEC).
- Carreras, X. M. (2004). Máquinas de Vectores Soporte. En *Introducción a la minería de datos*. Pearson-Prentice Hall.

- Caruana, R. &.-M. (2006). An empirical comparison of supervised learning algorithms. *In Proceedings of the 23rd international conference on Machine learning* (págs. 163-168). ACM.
- Ceolin, T. H. (2009). Inserción de terapias complementarias en el sistema único de salud atendiendo al cuidado integral en la asistencia. *Enfermería Global*, 1-2.
- Chapelle, O. S. (2009). Semi-supervised learning. *IEEE Transactions on Neural Networks*, 542.
- Cuenca, E. M. (2006). *Fundamentos de fisiología*. Paraninfo.
- Daugman. (1993). High confidence visual recognition of persons by a test of statistical independence. *IEEE transactions on pattern analysis and machine intelligence* (págs. 1148-1161). IEEE.
- Daugman, J. (2004). How iris recognition works. *IEEE Transactions on circuits and systems for video technology*, 21-30.
- Daugman, J. G. (1994). *Washington Patente n° 5,291,560*.
- Deng, H. R. (2011). Bias of importance measures for multi-valued attributes and solutions. *Proceedings of the 21st International Conference on Artificial Neural Networks (ICANN)*, (págs. 293–300.).
- Esqueada, &. P. (2005). *Fundamentos de procesamiento de imágenes*. Baja California: UABC.
- Fawcett, T. (2004). ROC graphs: Notes and practical considerations for researchers. . *Machine learning, HP Laboratories*, 2-30.
- Galipienso, M. I. (2003). *Inteligencia artificial: modelos, técnicas y áreas de aplicación*. Editorial Paraninfo.
- Garcia, A. G.-P. (2011). Methodology for software development estimation optimization based on neural networks. *IEEE Latin America Transactions*, 384-398.
- García, M. A. (1997). IV Simposio de Metodología de las Ciencias del Comportamiento. *EDITUM*, 77-78.
- Gletsos, M. M. (2003). A computer-aided diagnostic system to characterize CT focal liver lesions: design and optimization of a neural network classifier. *IEEE Transactions Information Technology in Biomedicine*, 153-162.

- Gómez, M. C. (2010). Avances en diagnóstico e intervencionismo mamario. En *Radiología básica de la mama* (págs. 1-9). Madrid: Sociedad Española de Radiología Médica.
- Haigh, R. A. (1999). Reconstructing Paradise: Canada's Health Care System, Alternative Medicine and the Charter of Rights. *Health LJ*, 2-3.
- Hajian-Tilaki, K. (2013). Receiver operating characteristic (ROC) curve analysis for medical diagnostic test evaluation. *Caspian journal of internal medicine*, 627.
- Herlambang, R. A. (2015). Application of liver disease detection using iridology with back-propagation neural network. . In *Information Technology, Computer, and Electrical Engineering (ICITACEE)* (págs. 123-127). IEEE.
- Herrera, A. (2000). La clasificación numérica y su aplicación en la ecología . Santo Domingo.: Instituto Tecnológico de Santo Domingo.
- Hongzong, S. T. (2007). Support vector machines classification for discriminating coronary heart disease patients from non-coronary heart disease. *The West Indian Medical Journal*, 451-455.
- Hough, V. (1962). *Washington, DC Patente n° 3,069,654*.
- Iriso. (1 de Julio de 2015). *Iriso Camera*. Obtenido de Base de datos iris [en línea]: <https://sites.google.com/site/irisocamera/home>
- Jensen, B. (. (1980). En D. B. Jensen, *Ciencia y Practica de la Iridologia*. (págs. 145-146). YUG.
- Jogi. (2014). Methodology of iris image analysis for clinical diagnosis. In *Medical Imaging, m-Health and Emerging Communication Systems (MedCom), 2014 International Conference*, 235-236.
- Khachatryan, V. S. (2015). Precise determination of the mass of the Higgs boson and tests of compatibility of its couplings with the standard model predictions using proton collisions at 7 and 8 TeV. . *The European Physical Journal C*, 75(5), 212-216.
- Lai, C. L. (2010). Health examination based on iris images. In *Machine Learning and Cybernetics (ICMLC), 2010 International Conference* (págs. 2616-2617). IEEE.
- Lavelli, A. C. (2008). Evaluation of machine learning-based information extraction algorithms: criticisms and recommendations. *Language Resources and Evaluation*, 361-393.

- Leal, N. L. (2010). Sistemas de monitoreo de tránsito vehicular basados en técnicas de segmentación de imágenes. *Avances en Sistemas e Informática*, 75-86.
- Lewis, H. G. (2001). A generalized confusion matrix for assessing area estimates from remotely sensed data. *International Journal of Remote Sensing*, 3223-327.
- López, R. F. (2008). Fundamentos Biológicos de las Redes Neuronales Artificiales. En *Las redes neuronales artificiales* (págs. 19-20). Netbiblo.
- Lovesio, C. (2006). El paciente en coma. En *Libro de Medicina Intensiva* (págs. 20-22). Buenos Aires: El Ateneo.
- Luna, S. (2016). *Iridología como herramienta semiología en homeopatía*. Bogotá: Fundación Universitaria Luis G. Páez.
- Maimon, O. &. (2005). *Data mining and knowledge discovery handbook (Vol. 2)*. . New York: Springer.
- Mancebo Pérez, A. (2013). Desarrollo de una interfaz gráfica en Matlab para la aplicación de detección de humos mediante procesamiento digital de imágenes. (*Doctoral dissertation*)., 10-25.
- Marín, J. I. (2006). Reconocimiento de comandos de voz usando la transformada wavelet y máquinas de vectores de soporte. *Scientia et technica*, 10-15.
- Martín, A. &. (2004). *Bioestadística para las ciencias de la salud*. Capitel Editores.
- Martínez Echavarría, M. T. (2008). Helicobacter pylori en pacientes con diferentes enfermedades gastroduodenales. *Revista Cubana de Medicina*, 47(4), 2-4.
- Martínez, P. C. (2003). El valor de la estadística para la Salud Pública. *Salus*, Volumen 4, número 1.
- Mathworks. (11 de Junio de 2017). *Machine Learning with Matlab* . Obtenido de <https://es.mathworks.com/campaigns/products>
- Matich, D. (Diciembre de 2016). *Cátedra de Informática Aplicada a la Ingeniería de Procesos* . Obtenido de Orientación Fac. Regional Rosario. Argentina: https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograis/matich-redesneuronales.pdf#page=1&zoom=auto,-19,852
- Matworks. (2016). How Do You Decide Wich Algoritm to Use? En *Introduction to Machine Learning* (pág. 7). The MathWorks.
- Monar, M. &. (2014). *Aplicación de las Redes Neuronales al Reconocimiento de Objetos en Robots Manipuladores*. Quito: Doctoral dissertation.

- Montesdeoca, T. E. (2016). Sistema inteligente para el diagnóstico de enfermedades. *Bachelor's thesis*, 15-17.
- Mora-Florez, J. M.-E.-C. (2008). Evaluación del clasificador basado en los k vecinos más cercanos para la localización de la zona en falla en los sistemas de potencia. *Ingeniería e Investigación*, 81-86.
- Moreno, M. E. (2013). Epidemiología descriptiva del cáncer de estómago en la Comunidad de Madrid: análisis de supervivencia. *Universidad Complutense de Madrid*.
- Najafi, M. &. (2011). Iris Recognition Based on Using Ridgelet and Curvelet Transform. *Matlab I*.
- Nalla, P. R. (2015). Iris classification based on sparse representations using on-line dictionary learning for large-scale de-duplication applications. *SpringerPlus*, 238-239.
- Nor'aini, A. J. (2013). Classification of iris regions using Principal Component Analysis and Support Vector Machine. *In Signal and Image Processing Applications (ICSIPA) IEEE International Conference*, 134-139.
- OMS, A. M. (7 de Septiembre de 2016). *Organización Mundial de la Salud*. Obtenido de Medicina tradicional: http://apps.who.int/gb/archive/pdf_files/WHA56/sa5618.pdf.
- Ortiz, J. A. (1999). Clasificación con discriminantes: un enfoque neuronal. *Doctoral dissertation, PhD thesis, Departamento de Lenguajes y Sistemas Informáticos Universidad de Alicante*.
- Othman, Z. &. (2010). Preliminary study on iris recognition system: Tissues of body organs in iridology. *In Biomedical Engineering and Sciences (IECBES)* (págs. 115-119). IEEE.
- Palomino, N. L. (2009). Técnicas de segmentación en procesamiento digital de imágenes. *Revista de investigación de Sistemas e Informática*, 9-16.
- Parchkoochi, M. H. (2015). Automatic detection of karstic sinkholes in seismic 3D images using circular Hough transform. *Journal of Geophysics and Engineering*, 746.
- Passariello, G. (1995). *Imágenes médicas. Adquisición, Análisis*. Equinoccio.
- Pelegrín, B. P. (2004). Avances en localización de servicios y sus aplicaciones. EDITUM.

- Proença, H. &. (2006). Iris segmentation methodology for non-cooperative recognition. . *IEE Proceedings-Vision* (págs. 199-202). Image and Signal Processing.
- Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 82-106.
- Rebaza, J. V. (2007). Detección de bordes mediante el algoritmo de Canny. *Escuela Académico Profesional di Informática Universidad Nacional de Trujillo.*, 1-4.
- Ross, L. &. (2011). *The Image Processing Handbook. Microscopy and Microanalysis*. CRC.
- Salcedo, E. (2017). Factores de riesgo asociados a la alteración del reflejo de bruckner en recién nacidos en el hospital de ate-vitarte en el periodo de septiembre-octubre del año 2016. *Medicina Humana*, 5-7.
- Salles, L. F. (2008). The prevalence of iridologic signs in individuals with Diabetes Mellitus. *Acta Paulista de Enfermagem*, 474-480.
- Salud, O. M. (2002). *Estrategia de la OMS sobre medicina tradicional 2002-2005*. 56ª asamblea mundial de la salud: Organización Mundial de la Salud.
- salud., O. M. (2002). Estrategia de la OMS sobre medicina tradicional 2002-2005. 1-10.
- Santamaría, A. (2013). Diseño de un filtro bidimensional configurable de altas prestaciones para procesamiento de imágenes. *Universidad Carlos III de Madrid*, 1-4.
- Sehouli. (2003). Alternative medicine in Germany and worldwide [in German]. *Ratgeber unkonventionelle Krebstherapie*, 51–60.
- Shapiro, L. &. (2001). *Computer Vision*. Prentice Hall. Recuperado el 4 de 1 de 2017
- Sivasankar, K. S. (2012). FCM based iris image analysis for tissue imbalance stage identification. *In Emerging Trends in Science, Engineering and Technology (INCOSSET)* (págs. 210-215). IEEE.
- Sotolongo, A. D. (2013). Combinación de técnicas de procesamiento digital de imágenes e inteligencia artificial para el análisis de imágenes de mamografía. *3C Tecnología*, 1-4.
- Sparber A, W. J. (2001). Use of alternative and complementary cancer therapies. . *Surveys of complementary and alternative medicine: part II*. , 281–287.
- Sulistiyo, M. D. (2014). Iridology-based dyspepsia early detection using linear discriminant analysis and Cascade Correlation Neural Network. *In Information*

- and Communication Technology (ICoICT) 2nd International Conference* (págs. 139-144). IEEE.
- Thews, G. &. (1983). Gastritis. En G. &. Thews, *Anatomía, fisiología y patología del hombre* (págs. 384-386). Reverté.
- Tuya, J. R. (2007). *Técnicas cuantitativas para la gestión en la ingeniería del software*. Netbiblo.
- Valdivia Roldán, M. (2011). Gastritis y gastropatías. *Revista de Gastroenterología del Perú*, 38-48.
- Wildes, R. P. (1997). Iris recognition: an emerging biometric technology. *Proceedings of the IEEE*, 1348-1353.
- Yuen, H. K. (1990). Comparative study of Hough transform methods for circle finding. *Image and vision computing*, 170.
- Zhang, D. L. (2013). Iris-based medical analysis by geometric deformation features. *IEEE journal of biomedical and health informatics*, 223-231.
- Zhu, W. Z. (2010). Sensitivity, specificity, accuracy, associated confidence interval and ROC analysis with practical SAS®. *Implementation NESUG proceedings: health care and life sciences*, 1-9.