

“ANÁLISIS DE IMÁGENES MÉDICAS PARA LA EXTRACCIÓN  
DE BIOMARCADORES MEDIANTE EL ALGORITMO LOCAL  
BINARY PATTERN.”

Que presenta:

ING. MARIO IRAM GARCÍA QUEZADA

Para obtener el grado de:

MAESTRO EN CIENCIAS DE LA COMPUTACIÓN

Con la dirección de:

DR. DAVID ASAEL GUTIÉRREZ HERNÁNDEZ

Y co-dirección de:

DR. JULIO CÉSAR SALGADO RAMÍREZ



Instituto Tecnológico de León  
División de Estudios de Posgrado e  
Investigación

"2021: Año de la Independencia"

León, Gto. 15/enero/2021

**C. ING. MARIO IRAM GARCÍA QUEZADA  
PRESENTE**

De acuerdo al fallo emitido por la Comisión Revisora, integrada por los: **Dr. David Asael Gutiérrez Hernández, Dr. Julio César Salgado Ramírez, Dr. Manuel Ornelas Rodríguez y MCS. Claudia Leticia Díaz González,** y considerando que llena todos los requisitos establecidos en los Lineamientos Generales para la Operación del Posgrado del Tecnológico Nacional de México, **se autoriza la impresión** del trabajo de tesis titulado: **"Análisis de imágenes médicas para la extracción de biomarcadores mediante el algoritmo Local Binary Pattern"**. Lo que hacemos de su conocimiento para los efectos y fines correspondientes.

**ATENTAMENTE**

Excelencia en Educación Tecnológica®  
Ciencia Tecnología y Libertad

  
  
**DR. DAVID ASael GUTIÉRREZ HERNÁNDEZ**  
**JEFE DE LA DEPI**

C.c.p. Archivo



RP/IL-072  
2017-04-10 - 2021-  
04-10

Av. Tecnológico s/n Fracc. Industrial  
Julián de Obregón C.P 37290  
León, Gto. México Tel. 01 (477) 711-2200  
e-mail: tecleon@leon.tecnm.mx

tecnm.mx | leon.tecnm.mx



León, Gto., a 18 de diciembre del 2020

**C. ING. LUIS ROBERTO GALLEGOS MUÑOZ**  
**JEFE DE SERVICIOS ESCOLARES**  
**PRESENTE**


Por este medio hacemos de su conocimiento que la tesis titulada **“Análisis de imágenes médicas para la extracción de biomarcadores mediante el algoritmo Local Binary Pattern”**, ha sido leída y aprobada por los miembros del Comité Tutorial para su evaluación por el jurado del acto de examen de grado al alumno **C. Mario Iram García Quezada**, con número de control **M19240007** como parte de los requisitos para obtener el grado de Maestro en Ciencias de la Computación (MCCOM-2011-05).

Sin otro particular por el momento, quedamos de Usted.

**ATENTAMENTE**  
**COMITÉ TUTORIAL**

  
Dr. David Asael Gutiérrez Hernández

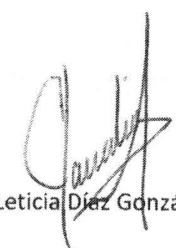
**DIRECTOR**

  
Dr. Julio César Salgado Ramírez

**CODIRECTOR**

  
Dr. Manuel Ornelas Rodríguez

**REVISOR (a)**

  
MCS. Claudia Leticia Díez González

**REVISOR (a)**



## DECLARACION DE AUTENTICIDAD Y DE NO PLAGIO

Yo, **Mario Iram García Quezada** identificado con No. Control **M19240007**, alumno (a) del programa de la **Maestría en Ciencias de la Computación**, autor (a) de la Tesis titulada: **“Análisis de imágenes médicas para la extracción de biomarcadores mediante el algoritmo Local Binary Pattern.”** DECLARO QUE:

1.- El presente trabajo de investigación, tema de la tesis presentada para la obtención del título de **MAESTRO (A) EN CIENCIAS DE LA COMPUTACIÓN** es original, siendo resultado de mi trabajo personal, el cual no he copiado de otro trabajo de investigación, ni utilizado ideas, fórmulas, ni citas completas “stricto sensu”, así como ilustraciones, fotografías u otros materiales audiovisuales, obtenidas de cualquier tesis, obra, artículo, memoria, etc. en su versión digital o impresa.

2.- Declaro que el trabajo de investigación que pongo a consideración para evaluación no ha sido presentado anteriormente para obtener algún grado académico o título, ni ha sido publicado en sitio alguno.

3.- Declaro que las pruebas o experimentos derivados de esta investigación fueron realizados bajo el consentimiento de los involucrados y con fines estrictamente académicos conforme a criterios éticos de confidencialidad.

Soy consciente de que el hecho de no respetar los derechos de autor y hacer plagio, es objeto de sanciones universitarias y/o legales por lo que asumo cualquier responsabilidad que pudiera derivarse de irregularidades de la tesis, así como de los derechos sobre la obra presentada.

Asimismo, me hago responsable ante el Tecnológico Nacional de México/Instituto Tecnológico de León o terceros, de cualquier irregularidad o daño que pudiera ocasionar por el incumplimiento de lo declarado.

De identificarse falsificación, plagio, fraude, o que el trabajo de investigación haya sido publicado anteriormente; asumo las consecuencias y sanciones que de mi acción se deriven, responsabilizándome por todas las cargas pecuniarias o legales que se deriven de ello sometiéndome a las normas establecidas en los Lineamientos y Disposiciones de la Operación de Estudios de Posgrado en el Tecnológico Nacional de México.

León, Guanajuato a 15 de Enero del 2021

Mario Iram García Quezada



## ACUERDO PARA USO DE OBRA (TESIS DE GRADO)

A QUIEN CORRESPONDA

PRESENTE

Por medio del presente escrito, **Mario Iram García Quezada** (en lo sucesivo el AUTOR) hace constar que es titular intelectual de la obra denominada: **“Análisis de imágenes médicas para la extracción de biomarcadores mediante el algoritmo Local Binary Pattern.”**, (en lo sucesivo la OBRA) en virtud de lo cual autoriza al Tecnológico Nacional de México/Instituto Tecnológico de León (en lo sucesivo TECN/IT León) para que efectúe resguardo físico y/o electrónico mediante copia digital o impresa para asegurar su disponibilidad, divulgación, comunicación pública, distribución, transmisión, reproducción, así como digitalización de la misma con fines académicos y sin fines de lucro como parte del Repositorio Institucional del TECN/ITLeón.

De igual manera, es deseo del AUTOR establecer que esta autorización es voluntaria y gratuita, y que de acuerdo a lo señalado en la Ley Federal del Derecho de Autor y la Ley de Propiedad Industrial el TECN/IT León cuenta con mi autorización para la utilización de la información antes señalada, estableciendo que se utilizará única y exclusivamente para los fines antes señalados. El AUTOR autoriza al TECN/IT León a utilizar la obra en los términos y condiciones aquí expresados, sin que ello implique se le conceda licencia o autorización alguna o algún tipo de derecho distinto al mencionada respecto a la “propiedad intelectual” de la misma OBRA; incluyendo todo tipo de derechos patrimoniales sobre obras y creaciones protegidas por derechos de autor y demás formas de propiedad intelectual reconocida o que lleguen a reconocer las leyes correspondientes. Al reutilizar, reproducir, transmitir y/o distribuir la OBRA se deberá reconocer y dar créditos de autoría de la obra intelectual en los términos especificados por el propio autor, y el no hacerlo implica el término de uso de esta licencia para los fines estipulados. Nada de esta licencia menoscaba o restringe los derechos patrimoniales y morales del AUTOR.

De la misma manera, se hace manifiesto que el contenido académico, literario, la edición y en general de cualquier parte de la OBRA son responsabilidad de AUTOR, por lo que se deslinda al (TECN/ITLeón) por cualquier violación a los derechos de autor y/o propiedad intelectual, así como cualquier responsabilidad relacionada con la misma frente a terceros. Finalmente, el AUTOR manifiesta que estará depositando la versión final de su documento de Tesis, OBRA, y cuenta con los derechos morales y patrimoniales correspondientes para otorgar la presente autorización de uso.

En la ciudad de León, del estado de Guanajuato a los 18 días del mes de Enero del 2021.

Atentamente,



Mario Iram García Quezada

---

# Dedicatoria

*El presente trabajo de investigación está dedicado a mi familia por haber sido mi apoyo a lo largo de toda mi carrera profesional y toda mi vida. A todas las personas especiales que me acompañaron en esta etapa como amigos y a mi novia Tona que siempre confió en mis capacidades.*

*De igual forma dedico mi trabajo a la memoria de mi gran amigo Saúl, el cual vio en mí a una persona fuerte y dedicada, el siempre confió en mí en todo momento y aun que ya no está con nosotros él siempre me decía: "Nosotros jamás nos rendimos".*

---

# Agradecimientos

Le agradezco al Dr. David, director de proyecto por confiar en mis ideas y valores, por permitirme trabajar en un uno de sus tantos proyectos, de la misma forma agradezco el apoyo que me han ofrecido mis integrantes de comité con sus consejos y guías.

Consejo Nacional de Ciencia y Tecnología (*CONACYT*) por el apoyo económico brindado durante estos 24 meses. El trabajo fue duro, pero siempre que se trate de ciencia será una bonita forma de estar ocupado.

De igual manera, mi agradecimiento eterno al Instituto Tecnológico Nacional de México, campus León, por permitirme mejorar mis actitudes y aptitudes dentro del ámbito profesional en estos dos años de esfuerzo, sacrificios, dedicación y grandes alegrías vividas en esta casa de estudios, muchas gracias.

---

# Índice de Contenido

Índice de Contenido	VII
Índice de tablas	XI
Índice de figuras	XII
Acrónimos	XIX
Resumen	XX
Abstract	1
<b>Introducción</b>	<b>2</b>
Definición del problema . . . . .	2
Justificación . . . . .	3
Hipótesis . . . . .	3
Objetivos . . . . .	4
Objetivo General . . . . .	4
Objetivos Específicos . . . . .	4
Estructura de tesis . . . . .	4
Alcances y contribuciones del proyecto . . . . .	6
Contribuciones del proyecto . . . . .	6
<b>1. Marco teórico</b>	<b>7</b>
1.1. Principios básicos de la imagen digital . . . . .	8



1.2.	Modelo matemático de una imagen digital . . . . .	9
1.3.	Procesamiento digital de imágenes . . . . .	11
1.4.	Visión artificial . . . . .	13
1.5.	Visión artificial & Procesamiento digital de imágenes. . . . .	17
1.5.1.	Visión de bajo nivel . . . . .	18
1.5.1.1.	Adquisición . . . . .	18
1.5.1.2.	Preprocesamiento . . . . .	21
1.5.1.3.	Realce o manipulación del contraste . . . . .	22
1.5.1.4.	Suavizado o eliminación del ruido . . . . .	23
1.5.1.5.	Detección de bordes . . . . .	24
1.5.2.	Visión de nivel intermedio . . . . .	26
1.5.2.1.	Segmentación . . . . .	26
1.6.	Técnicas de segmentación dentro del procesamiento digital de imágenes 28	
1.6.1.	Método basado en bordes . . . . .	29
1.6.2.	Método de umbral . . . . .	30
1.6.2.1.	Binarización por umbral . . . . .	32
1.6.3.	Método basado en la región . . . . .	32
1.6.3.1.	Crecimiento de la región . . . . .	33
1.6.3.2.	División y fusión de regiones . . . . .	34
1.6.4.	Método basado en Wavelets . . . . .	35
1.6.5.	Método basado en agrupamiento . . . . .	37
1.6.6.	Redes neuronales artificiales . . . . .	38
1.6.7.	Visión de alto nivel . . . . .	41
1.6.7.1.	Reconocimiento e Interpretación . . . . .	42
1.7.	Histograma de intensidades . . . . .	43
1.7.1.	Ecualización del histograma . . . . .	44
1.8.	Ecualización de histograma adaptativo de contraste limitado (CLAHE) 47	
1.9.	Filtro Guiado . . . . .	49
1.10.	Filtro Wiener (Wiener Filter) . . . . .	50
1.11.	Métrica Peak signal-to-noise ratio (PSNR) . . . . .	51

1.12. Patrón binario local (Local Binary Pattern) . . . . .	53
1.13. Procesamiento de imágenes médicas digitales . . . . .	56
1.13.1. Tipos de imágenes médicas . . . . .	56
1.13.1.1. Imágenes radiográficas . . . . .	56
1.13.1.2. Tomografía axial computarizada (TAC) . . . . .	59
1.13.1.3. Imágenes por ultrasonido . . . . .	60
1.13.1.4. Imágenes de resonancia magnética (MRI) . . . . .	60
1.13.2. Clasificación de técnicas . . . . .	62
1.14. Mecanismos visuales del ser humano . . . . .	64
1.14.1. Ojo . . . . .	64
1.14.2. Retina . . . . .	65
1.14.3. La corteza visual . . . . .	67
1.15. Herramientas computacionales utilizadas . . . . .	69
1.15.1. FIJI . . . . .	69
1.15.1.1. Trainable Weka Segmentation . . . . .	70
1.15.2. MATLAB . . . . .	71
<b>2. Estado del Arte</b>	<b>72</b>
2.1. Antecedentes . . . . .	72
2.2. Antecedentes tecnológicos sobre la obtención de las características sanguíneas . . . . .	73
2.3. Aplicaciones de visión artificial . . . . .	74
2.4. Aplicaciones de salud en el campo del procesamiento digital de imágenes	77
2.5. Propiedades ópticas de los tejidos . . . . .	81
2.5.1. Interacción de la luz con el tejido . . . . .	81
2.5.2. Absorción . . . . .	83
<b>3. Metodología</b>	<b>85</b>
3.1. Metodología general de la propuesta . . . . .	86
3.2. Adquisición de imagen . . . . .	87

3.2.1.	Captura de la imagen por medio del dispositivo propuesto . . .	87
3.2.2.	Interfaz de captura diseñada por el software MATLAB . . . . .	90
3.3.	Etapa de preprocesamiento . . . . .	91
3.3.1.	Región de interes (ROI) . . . . .	91
3.3.2.	Conversión de RGB a escala de grises . . . . .	93
3.4.	Etapa de reconstrucción de la imagen . . . . .	94
3.4.1.	Método de Ecuilización de Histograma (HE) . . . . .	95
3.4.2.	Ecuilización de Histograma Adaptativo de Contraste Limitado (CLAHE) . . . . .	96
3.4.3.	Filtro Guiado (Guided Filter) . . . . .	97
3.4.4.	Filtro Wiener (Wiener Filter) . . . . .	98
3.5.	Indice PSNR . . . . .	98
3.6.	Extracción de características . . . . .	100
<b>4.</b>	<b>Análisis de resultados</b>	<b>102</b>
4.1.	Etapa de adquisición de la imagen . . . . .	103
4.2.	Etapa de preprocesamiento . . . . .	109
4.3.	Etapa de reconstrucción de la imagen . . . . .	111
4.3.1.	Experimento 1. Ecuilización de Histograma . . . . .	111
4.3.2.	Experimento 2. Histograma Adaptativo Ecuilizado (CLAHE) . . . . .	113
4.3.3.	Experimento 3. Filtro Guiado . . . . .	114
4.3.4.	Experimento 4. Filtro de Wiener . . . . .	115
4.4.	Evaluación de reconstrucción por medio del índice PSNR . . . . .	116
4.5.	Extracción de características . . . . .	118
<b>5.</b>	<b>Conclusiones y Recomendaciones</b>	<b>120</b>
5.1.	Trabajo a futuro . . . . .	122
	<b>Bibliografía</b>	<b>123</b>
	<b>Anexo</b>	<b>135</b>

---

# Índice de tablas

1.	Tabla de Acrónimos . . . . .	XIX
1.1.	Niveles para el reconocimiento de biomarcadores en imágenes médicas.	63
4.1.	Promedios del índice PSNR, para cada experimento propuesto. . . . .	117

---

# Índice de figuras

1.1. Representación de la reflexión de la luz sobre la superficie de un objeto. Fuente: Imagen tomada y adaptada de [Sossa., 2012]. . . . .	8
1.2. Fotografía de Lena Söderberg utilizada por el <i>Society for Imaging Science and Technology</i> como imagen base del <i>DIP</i> . Fuente: Fotografía cortesía de [Roberts, 1962] ) . . . . .	9
1.3. Ilustración esquemática del proceso de obtención de imágenes qVRI en DPI. Fuente: Imagen desarrollada por [Kallepitis et al., 2017]. . . . .	12
1.4. Esquema general de visión por computadora. La imagen de entrada es procesada para extraer los atributos, obteniendo como salida una descripción de la imagen analizada. Fuente: Elaboración propia. . . . .	14
1.5. Arquitectura de un sistema de visión. Fuente: Imagen cortesía de [Sucar and Gómez, 2018] . . . . .	15
1.6. Esquema del proceso de adquisición de una imagen. Fuente: Elaboración propia . . . . .	20
1.7. Preprocesamiento y registro de imágenes médicas. Fuente: Imagen cortesía de [Bayonas, 2010]. . . . .	21
1.8. TC craneal basal en los cortes superiores con hipodensidad en la sustancia blanca. Fuente: Imagen cortesía de M. L. Parra Gordo. Universitario Politécnica La Fe, Valencia, España. . . . .	22
1.9. Fuentes de error en una imagen donde podemos ver la imagen original con ruido gaussiano, impulsional y multiplicativo. Fuente: Imagen cortesía de MATLAB® . . . . .	23

1.10. Contornos subjetivos de Kanizsa. Fuente: Imagen cortesía de MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a>	24
1.11. Bordes de una escena de bodegón. Fuente: Imagen cortesía de MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a>	25
1.12. Bordes ideales. Fuente: Imagen cortesía de MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a>	25
1.13. Laboratorio virtual para el procesamiento digital de imágenes. Fuente: Imagen cortesía de [Castillo Atoche et al., 2014]	27
1.14. Técnicas de segmentación para imágenes digitales. Fuente: Elaboración propia.	28
1.15. Técnica de segmentación por medio del método basado en bordes utilizando el operador Sobel. Fuente: Imagen cortesía de MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a>	29
1.16. Técnica de segmentación por umbral a imágenes microscópicas donde A) Imagen original, B) Imagen con ruido gaussiano, C) Imagen resultante de la segmentación por umbral, C) Imagen con tratamiento final por medio del método otsu. Imagen cortesía de MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a>	31
1.17. Técnica de segmentación por umbral a imágenes de monedas, donde A) Imagen original, B) Imagen segmentada utilizando descriptores de región. Imagen cortesía de MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a>	33
1.18. Mejores y peores resultados de los algoritmos basados en wavelets para tumor: a) imagen original y región de interés, b) Mejor realce y alto contraste , c) Procesado en frecuencias de bajo nivel por píxel , d) Segmentación de píxeles en regiones heterogéneas del estudio en cáncer de mama. Fuente: Imagen cortesía de [Valdés Santiago et al., 2015].	36

1.19. Primer modelo matemático de una neurona artificial, creado con el fin de llevar a cabo tareas simples, presentado en el año 1943 en un trabajo conjunto entre el psiquiatra y neuroanatomista Warren McCulloch y el matemático Walter Pitts. Imagen cortesía de Caparrini,2001. . . . .	39
1.20. Proceso de visión de alto nivel. Fuente: Imagen cortesía de [Sucar and Gómez, 2018] . . . . .	41
1.21. Reconocimiento de caracteres en base a su codificación radial. Fuente: Imagen cortesía de [Sucar and Gómez, 2018] . . . . .	41
1.22. Ejemplos de histogramas: (a) Imagen con varias intensidades. (b) Su histograma mostrando un rango amplio de grises o alto contraste. (c) Imagen oscura. (d) Su histograma presenta un rango de grises reducido, es decir menor contraste. Fuente: Imagen tomada y adaptada de [Markou and Singh, 2003]. . . . .	43
1.23. Histograma de una imagen con poco contraste, esto debido a una toma fuera de foco. Fuente: Imagen cortesía de [Sucar and Gómez, 2018]. . . . .	44
1.24. Histograma de una imagen con la aplicación de rango dinámico y aumento de contraste debido a la aplicación del histograma ecualizado. Fuente: Imagen cortesía de [Sucar and Gómez, 2018]. . . . .	46
1.25. Proceso de trabajo del filtro guiado, donde se puede ver la comparación que se hace entre la imagen de entrada con la imagen de salida. Fuente: Imagen tomada y adaptada de [He et al., 2016]. . . . .	49
1.26. Diagrama a bloques de la representación del filtro con el enfoque moderno. Fuente: Imagen tomada y adaptada de Simon HayKin. "Adaptive Filter Theory Second Edition". Prentice Hall . . . . .	50
1.27. Funcionamiento del operador LBP (a) muestra de una imagen de 3x3 (b) equivalente binario de LBP (c) pesos asignados para cada píxel. Fuente: Imagen cortesía de [Alvarado and Fernández, 2012]. . . . .	53

1.28. Distribución de los vecinos para LBP. (a) R=1, P=8, (b) R=2, P=8, (c) R=3, P=8. Fuente: Imagen cortesía de [Alvarado and Fernández, 2012]. . . . .	54
1.29. Distribución de los vecinos para LBP. (a) R=1, P=2, (b) R=1, P=4, (c) R=1, P=8. Fuente: Imagen cortesía de [Alvarado and Fernández, 2012]. . . . .	55
1.30. Imágenes médicas de radiografías para uso dental y quiropráctico. Fuente: Imagen tomada y adaptada de [Ramírez, 2010]. . . . .	57
1.31. Imágenes médicas radiográficas del tórax, utilizadas para el diagnóstico del virus SAR-COVID 19. Fuente: Imagen tomada y adaptada de [Garzón et al., 2009]. . . . .	58
1.32. Estudio por imagen mediante TAC en el ictus en la fase aguda. Imagen tomada y adaptada de Boehringer Ingelheim International GmbH © 2020. . . . .	59
1.33. Principios físicos e indicaciones clínicas del ultrasonido doppler. Fuente: Imagen tomada y adaptada de [Paola Paolinelli, 2013]. . . . .	60
1.34. Examen imagenológico que utiliza imanes y ondas de radio potentes para crear imágenes del cuerpo. Fuente: Imagen tomada y adaptada de [Vera et al., 2016]. . . . .	61
1.35. Sistema de imagen médica completo en el que se identifican los distintos tipos de técnicas puestos en juego: generación, procesamiento, análisis e interpretación. Fuente: Imagen tomada y adaptada de [Yoo, 2004]. . . . .	63
1.36. Vista esquemática del ojo. Fuente: Imagen tomada y adaptada de Google ®. . . . .	64
1.37. Representación de los conos y bastones del ojo humano. Fuente: Imagen tomada y adaptada de Google ®. . . . .	65
1.38. Respuesta de las células corticales a un rectángulo blanco. Fuente: Imagen tomada del trabajo de investigación Brain Mechanisms of Vision [Hubel and Wiesel, 1979] . . . . .	68



1.39. Fiji es un paquete de procesamiento de imágenes, una distribución de ImageJ. Fuente: Imagen tomada del trabajo [Schindelin et al., 2012]	69
1.40. Logo de entrenable Weka Segmentación de la Universidad de Waikato, Nueva Zelanda. Fuente: Imagen tomada del trabajo [Arganda-Carreras et al., 2017b]	70
1.41. Logo de MATLAB®, Fuente: Imagen tomada de Google®	71
2.1. Mecanismos de interacción entre luz y tejidos. Fuente: Imagen tomada del trabajo [González et al., 2012]	82
2.2. Atenuación de la luz a través de un medio no esparcidor. Imagen tomada del trabajo [Tuchin, 2002]	84
3.1. Esquema de la metodología propuesta. Fuente: Elaboración propia.	85
3.2. Prototipo del dispositivo para la captura de muestras. Figura: Elaboración propia.	87
3.3. Imágenes de la estructura del prototipo para la obtención de muestras. Fuente: Elaboración propia.	88
3.4. Cámara web Microsoft® HD Life cam. Imagen proporcionada por Microsoft®. Fuente: Elaboración propia.	89
3.5. Imagen de la interfaz de MATLAB durante la configuración de una interfaz guide. Imagen proporcionada por MATLAB®. Fuente: Elaboración propia.	90
3.6. Manejo de la herramienta ROI en las imágenes de la base de datos. Fuente: Elaboración propia.	92
3.7. Conversión de una imagen RGB a escala de grises con MATLAB. Fuente: Elaboración propia.	93
3.8. Relaciones del operador LBP con otros métodos de textura. Imagen proporcionada por MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a>	101

3.9. Esquema del proceso de trabajo del algoritmo LBP. Imagen proporcionada por MATLAB®. URL: <a href="https://la.mathworks.com/products/matlab.html">https://la.mathworks.com/products/matlab.html</a> . . . . .	101
4.1. Mecanismos de interacción entre luz y tejidos. Fuente: Imagen tomada del trabajo [González et al., 2012] . . . . .	103
4.2. Vista de la interfaz desarrollada en MATLAB® e interior del dispositivo. Fuente: Elaboración propia. . . . .	104
4.3. Captura del dispositivo propuesto. Fuente: Elaboración propia . . . .	104
4.4. Recorte de la región de interés (ROI). Fuente: Elaboración propia. . .	109
4.5. Conversión de imagen RGB original en una imagen en escala de grises a través de MATLAB®. Fuente: Elaboración propia. . . . .	110
4.6. Histograma de la imagen original con recorte ROI en escala de grises. Fuente: Elaboración propia. . . . .	111
4.7. Resultado de la implementación del algoritmo HE. Fuente: Elaboración propia. . . . .	112
4.8. Implementación del algoritmo CLAHE, que nos permite observar una imagen más estable. Fuente: Elaboración propia. . . . .	113
4.9. Implementación del filtro guiado, por medio de una operación de vecindad entre los píxeles de la imagen. Fuente: Elaboración propia. .	114
4.10. Implementación del filtro wiener, por medio de una operación de vecindad entre los píxeles de la imagen. Fuente: Elaboración propia. .	115
4.11. Ordenamiento por carpetas de cada experimento, para obtener el índice PSNR de cada imagen por experimento. Fuente: Elaboración propia. . . . .	117
4.12. Implementación del filtro wiener, por medio de una operación de vecindad entre los píxeles de la imagen. Fuente: Elaboración propia. .	118
4.13. Implementación del algoritmo LBP en una de las imágenes de la base de datos. Fuente: Elaboración propia. . . . .	118

4.14. Espacio de trabajo en MATLAB, donde podemos observar la variable que guarda las características de la imagen. Fuente: Elaboración propia.119

---

# Acrónimos

La Tabla 1 muestra los acrónimos utilizados en este trabajo de investigación.

Tabla 1: Tabla de Acrónimos

<i>Acrónimo</i>	<i>Significado</i>	<i>Español</i>
PSNR	Peak Signal-to-Noise Ratio	Proporción Máxima de Señal a Ruido
mm	millimeters	Milímetros
A/D	analog-digital conversion	conversión analógica-digital
RAM	Random Access Memory	Memoria de acceso aleatorio
DPI	Digital Processing Image	Procesamiento Digital de Imágenes
LBP	Local Binary Pattern	Patrón Binario Local
IS&T	Information Systems and Technology	Los sistemas y tecnología de la información
HDR	High Dinamic Range	Alto rango dinámico
CLAHE	Contrast Adaptive Histogram Equalization	Ecuación de Histograma Adaptativo de Contraste Multicapa
ROI	Region of interest	Región de interes
RGB	Red Green Blue	Rojo Verde Azul
MA	Metaheuristic Algorithm	Algoritmo Metaheurístico
MSE	Mean Square Error	Error Cuadrático Medio
FCM	Fuzzy C Means	Difuso C-Medias
SF	Soft Computing	Informática suave
AHE	Adaptative Histogram Ecuation	Ecuación Adaptativa de Histograma

---

# Resumen

Con el avance tecnológico que se tiene actualmente, se han desarrollado diversos procedimientos para caracterizar los aspectos morfológicos de la sangre y patológicos de la misma, esto debido a la implementación de técnicas en inteligencias artificial.

El objetivo esencial de este trabajo fue desarrollar una propuesta metodológica en el campo del procesamiento digital de imágenes médicas y visión artificial, que nos permitiera visualizar el cambio de absorción de luz láser incidente en el dedo índice debido a la hemoglobina, para de esta manera ver los cambios que se producen en la absorción de este tipo de luz en la sangre.

La metodología propuesta se enfoca en una base sólida de conceptos físicos, métodos matemáticos y algoritmos computacionales que permitieron caracterizar la absorción de luz láser en la hemoglobina, a través de las siguientes etapas: etapa para la adquisición de la imagen, etapa de preprocesamiento digital de imágenes, etapa de reconstrucción digital y extracción de características por medio del algoritmo *LBP*.

---

# Abstract

With the current technological advancements, various procedures have been developed to characterize the morphological and pathological aspects of the blood, this due to the implementation of techniques in artificial intelligence.

The essential objective of this work was to develop a methodological proposal in the field of digital processing of medical images and artificial vision, which would allow us to visualize the change in absorption of incident laser light on the index finger due to hemoglobin, to see the changes that occur in the absorption of this type of light in the blood.

The proposed methodology focuses on a solid base of physical concepts, mathematical methods, and computational algorithms that allowed characterizing the absorption of laser light in hemoglobin, through the following stages: the stage for image acquisition, stage of digital preprocessing of images, digital reconstruction stage, and feature extraction by means of the *LBP* algorithm.

---

# Introducción

## Definición del problema

En los últimos años, las imágenes médicas se han convertido en una potente herramienta de ayuda para el diagnóstico, además de ser muy importantes para los profesionales del sector salud. Es valioso mencionar que estas imágenes se obtienen en formato análogo, por lo cual es necesario digitalizarlas para su proceso, en seguida, se muestran algunos ejemplos:

- Radiografías.
- Ultrasonidos.
- Imágenes de resonancia magnética (*MRI*).
- Tomografía axial computarizada (*TAC*).
- Fotografía convencional.

Para entender estas imágenes digitalizadas es necesario utilizar el "Procesamiento digital de imágenes" que puede definirse como un conjunto de procedimientos que se realizan sobre una imagen (*señal obtenida mediante un dispositivo conectado a la computadora: cámara*) para su almacenamiento, transmisión o tratamiento. Con lo anterior se pueden extraer u obtener biomarcadores, medidas de procesos biológicos que sirven como indicadores para una población.

Al desarrollar una exploración en los proyectos de investigación relacionados con el procesamiento digital de imágenes médicas, encontramos un camino amplio de aplicaciones dentro del sector salud, para el diagnóstico a ciertas enfermedades o padecimientos, al ser un camino siempre en constante investigación se llegó a la conclusión de aplicar una metodología dentro del tratado de imágenes a un nuevo tema que explorar. El problema se concentra en la siguiente pregunta: ¿Con imágenes del dedo índice, incidido por luz láser es posible extraer biomarcadores (*características*) que permitan visualizar el cambio de absorción de luz láser en la hemoglobina?

## **Justificación**

La implementación de una metodología basada en técnicas de visión artificial y procesamiento de imágenes, que permita visualizar el cambio de absorción de luz roja en la hemoglobina, a través de una etapa en adquisición de imágenes, preprocesamiento, reconstrucción y extracción de características para obtener biomarcadores de estas imágenes, supone un proyecto multidisciplinario que se adapte perfectamente con los retos de la ingeniería biomédica y el área de tratado de imágenes médicas.

La investigación aportaría un avance al tema de detección temprana en enfermedades sanguíneas, de esta manera se podrán mejorar los tiempos de diagnóstico.

## **Hipótesis**

Es posible desarrollar una metodología para el análisis de imágenes médicas con incidencia de luz láser, que permita la extracción de biomarcadores mediante el algoritmo Local Binary Pattern.



# Objetivos

A continuación se presenta el objetivo general y específicos del presente trabajo.

## Objetivo General

Desarrollar una metodología a través del procesamiento digital de imágenes y visión artificial, que nos permita caracterizar el proceso de absorción de luz láser incidente en el dedo índice debido a la hemoglobina mediante la implementación del algoritmo *LBP* (Local Binary Pattern) en imágenes médicas.

## Objetivos Específicos

- Desarrollar un sistema optoelectromecánico para la adquisición de imágenes médicas.
- Analizar un conjunto de imágenes médicas utilizando métodos de procesamiento de imágenes y visión artificial.
- Comparar los diferentes métodos para la reconstrucción de imágenes médicas por medio del índice *PSNR*.
- Establecer una serie de pasos a seguir para el tratamiento de imágenes médicas.

## Estructura de tesis

### Capítulo 1

Se explicarán los términos y conceptos utilizados durante el desarrollo experimental del proyecto y que darán la formalidad necesaria a este documento; la estructura contenida en este capítulo se organizara en dos apartados.

El primero de ellos menciona los procesos utilizados del área en ciencias computacionales comenzando por el modelo matemático de una imagen digital, seguido del procesamiento digital de imágenes, el uso de imágenes médicas en esta área, el algoritmo *LBP*, los mecanismos visuales del ser humano, la hematología médica y los procesos biológicos de la hemoglobina.

## **Capítulo 2**

En este capítulo se expondrán los trabajos de investigación recopilados y analizados que sirvieron como base para el desarrollo del proyecto, algunos antecedentes relevantes dentro del estudio clínico sanguíneo, el procesamiento digital de imágenes médicas, así como también técnicas de visión artificial en el área clínica, estas dos últimas siendo herramientas utilizadas dentro del área de inteligencia artificial (*IA*).

## **Capítulo 3**

En el presente capítulo se detallan los resultados de cada una de las etapas implementadas en la investigación, como lo son: etapa de adquisición de la imagen, etapa de preprocesamiento, etapa de reconstrucción de la imagen y etapa de extracción de características.

## **Capítulo 4**

En este capítulo se reportan los resultados obtenidos tras la implementación de los métodos descritos en el capítulo 3. A través de figuras y tablas se exponen los alcances de cada método.

## **Capítulo 5**

En este último capítulo se exponen las conclusiones a las que se llegó en este trabajo de investigación y se enuncian las recomendaciones para dar seguimiento a esta tesis.

## Alcances del proyecto

Los alcances y contribuciones del presente proyecto titulado: “**Análisis de imágenes médicas para la extracción de biomarcadores mediante el algoritmo Local Binary Pattern.**”, son los siguientes:

- El proyecto plantea una metodología dentro del procesamiento digital de imágenes y visión por computadora, que consta de los siguientes pasos: adquisición de la imagen, etapa de preprocesamiento, reconstrucción de la imagen y etapa de extracción de características.
- Desarrollo de un dispositivo optoelectromecánico que permita adquirir imágenes del dedo índice con incidencia de luz láser, sin que el láser sature la toma de la cámara.
- El proyecto analizará imágenes, donde se visualizara el cambio de absorción de luz láser incidente en el dedo índice a causa de la cantidad de hemoglobina en el torrente sanguíneo.
- Se utilizarán diferentes métodos de reconstrucción digital en imágenes, los cuales serán comparados a través del índice PSNR.

## Contribuciones del proyecto

- Investigación de las características sanguíneas por medio del procesamiento digital de imágenes médicas a través de un dispositivo no invasivo.
- Disminuir los tiempos en el laboratorio clínico para la investigación de propiedades sanguíneas y su implementación para el diagnóstico de enfermedades.
- Manejo del índice PSNR para la comparativa de los siguientes métodos: Filtro de Wiener, CLAHE, Ecualización de histograma y Filtro guiado, dentro del análisis de imágenes médicas.

---

# Capítulo 1

## Marco teórico

En este apartado se explicarán los términos y conceptos utilizados durante el desarrollo experimental del proyecto y que darán la formalidad necesaria a este documento; la estructura contenida en este capítulo se organizara en dos apartados, donde el primero de ellos mencionara los procesos utilizados del área en ciencias computacionales comenzando por el modelo matemático de una imagen digital, seguido del procesamiento digital de imágenes, el uso de imágenes médicas en esta área, el algoritmo *LBP*, los mecanismos visuales del ser humano, la hematología médica y los procesos biológicos de la hemoglobina.

Para el segundo apartado se hablarán de los softwares utilizados en el proyecto, los cuales nos permitieron desarrollar el trabajo de investigación y que se encuentran utilizados en la metodología planteada dentro del capítulo 3. De esta manera se estructurarán cada uno de los términos y conceptos utilizados en la investigación, lo que permitirá comprender la utilización de los procesos computacionales para describir, entender y analizar sistemas biológicos en los seres humanos.

## 1.1. Principios básicos de la imagen digital

Durante la historia de la humanidad una de las características más importantes con las cuales fue dotado el ser humano es la vista, ya que con ella podemos ver todo los cambios a nuestro alrededor y no solo es un mecanismo de supervivencia, hoy en día sabemos que lo que nosotros vemos contiene cierta información que puede ser usada con fines científicos, a todo esto podemos dar significado al concepto de imagen digital. Por lo tanto una imagen es la representación óptica de uno o más objetos iluminados por una o más fuentes de radiación. Así en general, "los elementos que forman parte del proceso de formación de una imagen son los siguientes: objeto u objetos, fuente o fuentes de iluminación y sistema de formación de la imagen" [Sossa., 2012].

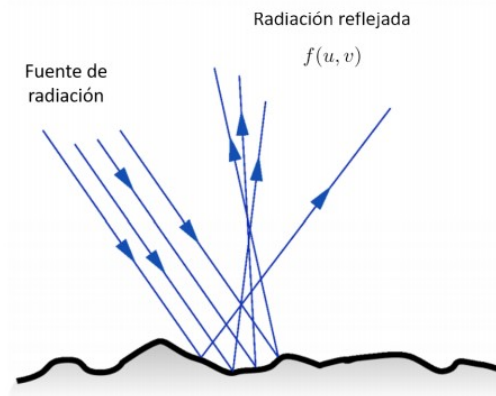


Figura 1.1: Representación de la reflexión de la luz sobre la superficie de un objeto. Fuente: Imagen tomada y adaptada de [Sossa., 2012].

"Es importante tomar en cuenta que la radiación reflejada  $f(u, v)$ , representa una porción pequeña del objeto, siendo la integración de todas estas porciones, acorde a la longitud de onda de la radiación incidente, la que conforma el objeto en su totalidad" [Sossa., 2012]. En la Figura 1.1, la luz reflejada  $f(u, v)$  (se supondrá por simplicidad, la descripción al caso de luz visible reflejada sobre un objeto en una sola dirección) es la imagen óptica que sirve de entrada al sistema de formación de la imagen digital.

## 1.2. Modelo matemático de una imagen digital

Antes de poder definir el procesamiento de imágenes debemos definir la palabra imagen. Como se mencionó anteriormente sobre los principios básicos de una imagen digital, también podemos definir de manera biológica el término imagen, entonces decimos que "Una imagen es una representación, sin parecido, o imitación de un objeto o cosa, es decir una descripción gráfica, algo introducido para representar alguna otra cosa más" [Friedrich, 2013]. Otra definición de imagen, orientada a una imagen gráfica, la define como "Una representación hecha por medio de dibujos, pinturas o fotografía" [Sossa., 2012]. La Figura 1.2 muestra una de las primeras imágenes utilizadas para el procesamiento digital de imágenes.



Figura 1.2: Fotografía de Lena Söderberg utilizada por el *Society for Imaging Science and Technology* como imagen base del *DIP*. Fuente: Fotografía cortesía de [Roberts, 1962] )

Sin embargo, dentro del ámbito matemático: "Una imagen es una función bidimensional de la intensidad de luz,  $f(x, y)$ , donde  $x$  e  $y$  indican las coordenadas espaciales y el valor de  $f$  en cualquier punto  $(x, y)$  es proporcional a la luminosidad (o nivel de gris) de la imagen en dicho punto" [Ramírez, 2006].

Esto debido a que la luz es una forma de energía,  $f(x, y)$ , por lo que podemos decir que esta se encuentra bajo el siguiente rango.

$$0 < f(x, y) < \infty \quad (1.1)$$

Ya que la naturaleza básica de  $f(x, y)$  puede estar caracterizada por dos componentes:

1. La cantidad de luz incidente proveniente de la fuente, (componente de iluminación,  $i(x, y)$ ).
2. La cantidad de luz reflejada por los objetos de la escena, (componente de reflectancia,  $r(x, y)$ ).

Por lo tanto decimos que las funciones  $i(x, y)$  y  $r(x, y)$  se combinan en un producto para dar la función de imagen bidimensional siguiente:

$$f(x, y) = i(x, y)r(x, y) \quad (1.2)$$

donde,

$$0 < i(x, y) < \infty \quad (1.3)$$

y

$$0 < r(x, y) < 1 \quad (1.4)$$

A la intensidad de una imagen monocroma  $f(x, y)$ , en las coordenadas  $(x, y)$ , se le denomina nivel de gris ( $g$ ). Por lo tanto resulta evidente que ( $g$ ) está en el rango.

$$\text{lím inf} < g < \text{lím sup} \quad (1.5)$$

Al intervalo  $[\text{lím inf}, \text{lím sup}]$  se le denomina escala de grises y generalmente adopta los valores  $[0, g]$ [Palomino, 2009].

Una imagen para ser utilizada en procesamiento de imágenes por medio de una computadora, su función  $f(x, y)$  debe ser digitalizada espacialmente en su amplitud. La digitalización de las coordenadas espaciales se define con dos conceptos: "Muestreo de la imagen y la digitalización de la amplitud, se conoce bajo el nombre de cuantificación del nivel de gris" [Rosario and Martín-Landrove, 2017].

Una imagen continua se describe de forma aproximada por una serie de muestras igualmente espaciadas organizadas en forma de una matriz es una cantidad discreta:  $N \times M$  como se muestra.

$$f(x, y) = \begin{pmatrix} f(0, 0) & f(0, 1) & \cdots & f(0, M-1) \\ f(1, 0) & f(1, 1) & \cdots & f(1, M-1) \\ \vdots & \vdots & \ddots & \vdots \\ f(N-1, 0) & f(N-1, 1) & \cdots & f(N-1, M-1) \end{pmatrix} \quad (1.6)$$

### 1.3. Procesamiento digital de imágenes

El procesamiento digital de imágenes (*DPI*) ha adquirido, en años recientes, un papel importante en las tecnologías de la información y el cómputo. Actualmente, es la base de una creciente variedad de aplicaciones que incluyen el diagnóstico médico, percepción remota, exploración espacial, visión por computadora, etc. Esto se debe a que agrupa varias ciencias, tales como óptica, electrónica, matemáticas, fotografía e informática.

A lo cual decimos, que el *DPI*: "Es el conjunto de técnicas y procesos que transforman una imagen digital en un conjunto de datos de medición que nos da como resultado una versión modificada de la misma imagen" [Domínguez Torres, 2019].



El *DPI* es un área de investigación muy específica en computación y está muy relacionada con el procesamiento digital de señales. ”Esta relación estriba en el hecho de que en esencia el *DPI* es una forma muy especial del procesamiento digital de señales en dos o tres dimensiones” [Kulkarni, 2011].

El *DPI* se basa en tres principios de aplicación primordiales:

1. Importar la imagen a través de herramientas de adquisición de imágenes.
2. Analizar y manipular la imagen.

Por lo tanto, para crear una imagen que sea digital, necesitamos convertir los datos continuos en forma digital. Hay dos pasos indispensables para llegar a esto: el muestreo y cuantificación. La frecuencia de muestreo determina la resolución espacial de la imagen digitalizada, mientras que el nivel de cuantificación determina el número de niveles de gris en la imagen digitalizada. ”El número de niveles de cuantificación debe ser lo suficientemente alto para la percepción humana de detalles finos de sombreado en la imagen” [Kulkarni, 2011].

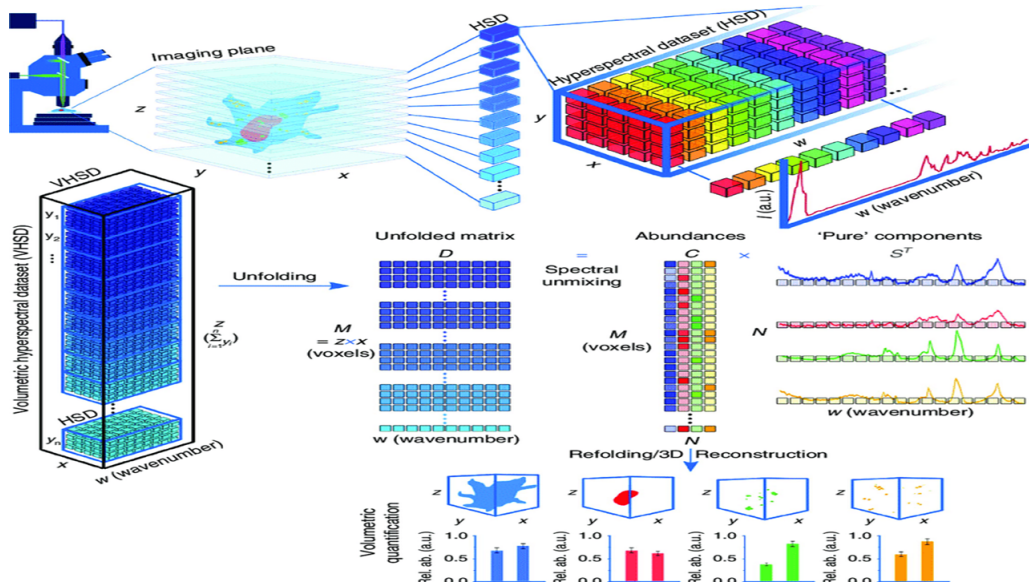


Figura 1.3: Ilustración esquemática del proceso de obtención de imágenes qVRI en DPI. Fuente: Imagen desarrollada por [Kallepitis et al., 2017].

## 1.4. Visión artificial

”La ventana al mundo de muchos organismos, esa es la visión para los seres vivos de este planeta, ya que su función principal es reconocer y localizar objetos en el ambiente, mediante el procesamiento de las imágenes obtenidas diariamente por los mecanismos naturales de nuestro cuerpo” [Sucar and Gómez, 2018].

La visión computacional es el estudio de estos procesos, para entenderlos y construir máquinas con capacidades similares a los procesos de obtención, caracterización e interpretación de información de imágenes. “La visión computacional es el estudio del proceso de localización y reconocimiento de objetos en un medio ambiente” [Sucar and Gómez, 2018]. Sin embargo existen varias definiciones de visión, entre estas podemos mencionar las siguientes:

- “Visión es saber que hay y donde mediante la vista” (Aristóteles).
- “Visión es recuperar de la información de los sentidos (vista) propiedades válidas del mundo exterior” [Ben-Ze’ev, 1981].
- “Visión es un proceso que produce a partir de las imágenes del mundo exterior una descripción que es útil para el observador y que no tiene información irrelevante” [Kitcher, 1988].

Cada una de estas definiciones es sumamente correcta, sin embargo la definición de Kitcher se acerca más a la idea actual sobre visión artificial.

En esta definición hay tres aspectos importantes que hay que tener presentes: ”(1) visión es un proceso computacional, (2) la descripción a obtener depende del observador y (3) es necesario eliminar la información que no sea útil (reducción de información)” [Rosenfeld, 1993].

Un área muy ligada a la de visión computacional es la de procesamiento de imágenes, ya que el objetivo de la visión computacional es extraer características de una imagen para su descripción e interpretación por la computadora para obtener los siguientes puntos:

- Determinar la localización y tipo de objetos en la imagen.
- Construir una representación tridimensional de un objeto.
- Analizar un objeto para determinar su calidad.
- Descomponer una imagen u objeto en diferentes partes.

En la visión artificial se busca obtener descripciones útiles para cada tarea a realizar esto permitirá modificar ciertos atributos como se puede ver en la Figura 1.4.

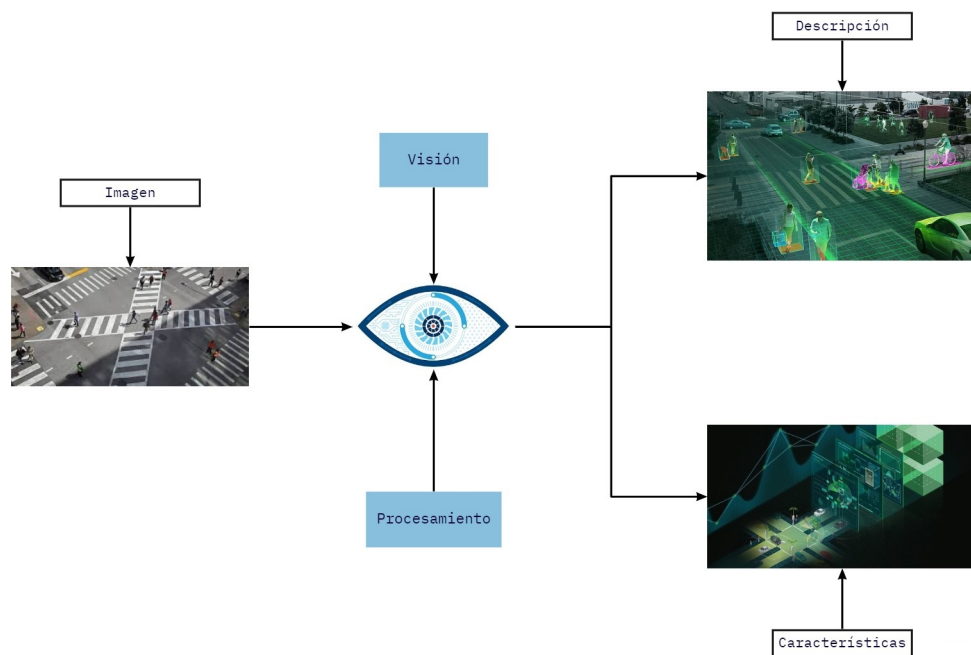


Figura 1.4: Esquema general de visión por computadora. La imagen de entrada es procesada para extraer los atributos, obteniendo como salida una descripción de la imagen analizada. Fuente: Elaboración propia.

Los sistemas de visión por computadora, de manera clásica está constituida por un dispositivo de captura y de 4 componentes más los cuales son: "Un dispositivo de conversión de analógico a digital (A/D), una memoria de video, un elemento de procesamiento y un monitor" [Davies, 2012]. En el siguiente listado se describen los principales elementos y en la Figura 1.5 se muestra la arquitectura básica de un sistema de visión:

- Dispositivo de captura: Dispositivo físico que es sensible a una determinada banda del espectro electromagnético.
- Conversión A/D: Convierte la señal obtenida del dispositivo de captura en una señal digital.
- Memoria de video: Memoria semiconductora (RAM) en la que se almacena la imagen digitalizada. Normalmente la conversión A/D y la memoria de video se agrupan en un módulo conocido como *frame grabber* (captura de imágenes).
- Procesador: La memoria de video se acopla a un procesador de propósito general que permite operar sobre la imagen.

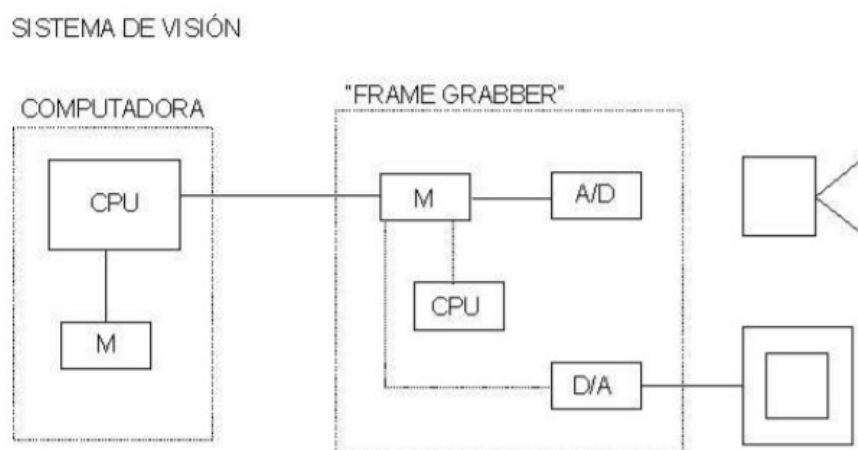


Figura 1.5: Arquitectura de un sistema de visión. Fuente: Imagen cortesía de [Sucar and Gómez, 2018]

Actualmente existen múltiples aplicaciones prácticas de la visión computacional, entre estas podemos mencionar las siguientes [Gatos et al., 2004]:

- Robótica móvil y vehículos autónomos: Se utilizan cámaras y otros tipos de sensores para localizar obstáculos, identificar objetos y personas, encontrar el camino, etc.
- Manufactura: Se aplica visión para la localización e identificación de piezas, para control de calidad, entre otras tareas.
- Interpretación de imágenes aéreas y de satélite: Se usa procesamiento de imágenes y visión para mejorar las imágenes obtenidas, para identificar diferentes tipos de cultivos, para ayudar en la predicción del clima, etc.
- Análisis e interpretación de imágenes médicas: La visión se aplica para ayudar en la interpretación de diferentes clases de imágenes médicas como rayos X, tomografía, ultrasonido, resonancia magnética y endoscopia.
- Interpretación de escritura, dibujos, planos: Se utilizan técnicas de visión para el reconocimiento de textos, lo que se conoce como reconocimiento de caracteres. También se aplica a la interpretación automática de dibujos y mapas.
- Análisis de imágenes microscópicas: El procesamiento de imágenes y visión se utilizan para ayudar a interpretar imágenes microscópicas en química, física y biología.
- Análisis de imágenes para astronomía: Se usa la visión para procesar imágenes obtenidas por telescopios, ayudando a la localización e identificación de objetos en el espacio.
- Análisis de imágenes para compresión: Aunque la compresión de imágenes ha sido tradicionalmente una sub-área del procesamiento de imágenes, recientemente se están desarrollando técnicas más sofisticadas de compresión que se basan en la interpretación de las imágenes.

## 1.5. Visión artificial & Procesamiento digital de imágenes.

Un área muy ligada a la de visión computacional es la del procesamiento de imágenes. Aunque ambos campos tienen mucho en común, el objetivo final es diferente.

- El objetivo de procesamiento de imágenes es mejorar la calidad de las imágenes para su posterior utilización o interpretación.
- El objetivo de la visión computacional es extraer características de una imagen para su descripción e interpretación por la computadora.

Sin embargo, "ambos procesos son utilizados en trabajos de investigación científica adaptando sus objetivos a intereses comunes, ya que permiten abstraer la realidad de diferentes maneras" [Davies, 2012].

Al conformar ambas áreas la información de una imagen en un mundo tridimensional se obtiene con los procesos de obtención, caracterización e interpretación que a su vez están subdivididos en cinco áreas:

- Adquisición.
- Preprocesamiento.
- Segmentación.
- Representación y descripción.
- Reconocimiento e interpretación.

Estos procesos son de suma importancia en el tratamiento de imágenes y dan incluso lugar a nuevas áreas de investigación como machine learning o deep learning.

”Generalmente es conveniente agrupar estas áreas de acuerdo con la complicación y el grado de detalles que lleva aparejada su implementación de esta manera consideramos tres niveles de procesamiento” [Sucar and Gómez, 2018]:

1. Visión de bajo nivel.
2. Visión de nivel intermedio.
3. Visión de alto nivel.

### **1.5.1. Visión de bajo nivel**

La visión de bajo nivel la asociaremos con aquellos procesos que son primarios en el sentido de que pueden considerar reacciones automáticas sin requerir de ningún tipo de inteligencia. Estos serian la adquisición y el preprocesamiento.

#### **1.5.1.1. Adquisición**

Debido a que las computadoras solo pueden procesar imágenes digitales, es necesario convertir las mismas a esta forma. El equipamiento necesario para la digitalización es lo que transforma una simple computadora en un sofisticado equipo de procesamiento de imágenes.

Para este tipo de aplicaciones no solo es importante la captación o adquisición de la imagen, sino que también lo es el sistema de presentación de imágenes involucrado. ”Un digitalizador de imágenes debe ser capaz de dividir la imagen en pequeñas regiones llamados elementos de imagen o píxeles, medir el nivel de gris de la imagen para cada píxel (*intensidad*), cuantizar esa medición continua para producir un valor entero y luego escribir estos datos en un dispositivo de almacenamiento. De esta forma la imagen es subdividida en líneas horizontales constituidas por un cierto número de píxeles adyacentes (*muestras*)” [Domínguez Torres, 2019].

Es por esto que un digitalizador debe tener cinco elementos fundamentales:

1. Un muestreador, que le permita acceder a cada píxel individualmente.
2. Un mecanismo de barrido que le permita recorrer toda la imagen.
3. Un sensor (*transductor*) que mida la brillantez de la imagen en cada píxel. Este sensor convierte intensidad de luz en señales eléctricas.
4. Un cuantificador encargado de convertir la señal eléctrica entregada por el sensor en valores enteros proporcionales a la intensidad de luz, típicamente es un circuito electrónico llamado: *Conversor Analógico Digital*.
5. Un digitalizador como medio de salida.

Existen dos filosofías de digitalización de imágenes, llamadas digitalización *scan-in* y *scan-out*. Básicamente en un sistema *scan-out* el objeto completo es iluminado continuamente y la apertura del muestreador le permite al sensor ver solo un píxel a la vez. "En un sistema *scan-in* solo una pequeña porción del objeto es iluminada, y toda la luz transmitida es recogida por el sensor" [Sossa., 2012]. En este caso el objeto es barrido con el haz de luz.

La iluminación de la imagen es un factor importante que suele afectar a la complejidad de los algoritmos de visión. La iluminación general del entorno no suele ser aceptable pues se obtienen imágenes con muy bajo contraste, reflexiones especulares, sombras y detalles espurios.

Un sistema de iluminación bien diseñado ilumina una imagen de forma tal que la complejidad del gráfico que se obtiene sea mínima, aumentando a la vez la información necesaria para la detección y extracción de los objetos de interés. En la Figura 1.6 se ve el proceso completo de adquisición de una imagen.



Las técnicas de iluminación muestran el camino a seguir para la selección óptima de la fuente de luz. Las técnicas más frecuentemente utilizadas son:

- Iluminación Difusa: Utilizada para objetos con superficies suaves y regulares.
- Iluminación Posterior: Produce imágenes en blanco y negro, sin matices.
- Iluminación Direccional: Es útil para la inspección de superficie de objetos.
- Láser: El mas comúnmente empleado es el de baja potencia ( $1-5mW$ ) de helio-neon, empleados como fuentes de luz estructurada, siendo en forma de banda estrecha normalmente.

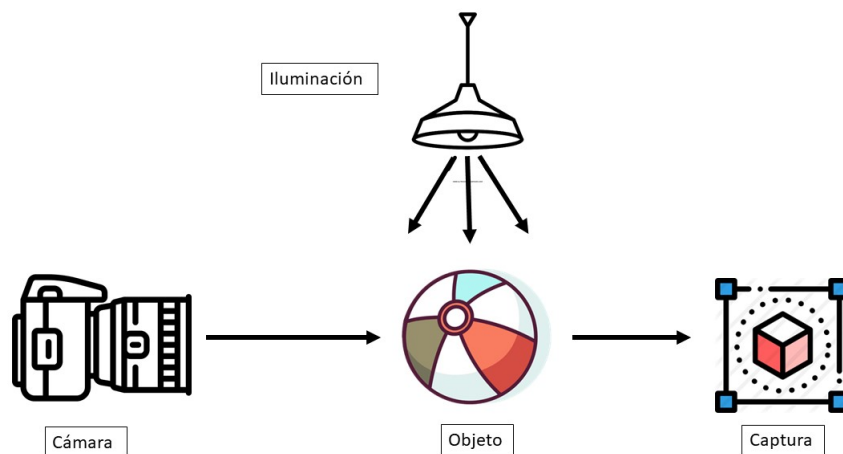


Figura 1.6: Esquema del proceso de adquisición de una imagen. Fuente: Elaboración propia

En algunos sistemas de visión esta pérdida de intensidad lumínica puede causar mal funcionamiento dependiendo de la complejidad de la tarea realizada. Para evitar esto se tienen dos soluciones: el empleo de una cámara con control automático de ganancia y de iris, elegir algoritmos de procesamiento de imágenes insensibles a los cambios en el nivel de iluminación.

### 1.5.1.2. Preprocesamiento

”El preprocesamiento de imágenes consiste en el conjunto de técnicas que buscan mejorar la apariencia visual de una imagen a una forma más adecuada para el observador humano o análisis artificial, como se puede apreciar en la Figura 1.7. No hay una teoría unificada para el preprocesamiento hasta el presente porque no hay un estándar de la calidad de la imagen que pueda servir como criterio de diseño para el proceso” [Platero, 2009].

En este proceso se incluyen técnicas de eliminación de ruido y realce de detalles (*en este caso el realce se logra mediante la iluminación*). En cualquier caso, debe ser posible dividir la imagen de acuerdo a una característica de homogeneidad predefinida. Entre las técnicas para realizar esto, está la binarización de imágenes (*thresholding*), y técnicas de detección de bordes.




Figura 1.7: Preprocesamiento y registro de imágenes médicas. Fuente: Imagen cortesía de [Bayonas, 2010].

Las técnicas de preprocesamiento se basan bien en técnicas derivadas del procesamiento digital de señales, vistas en el capítulo anterior, o bien en un conjunto de procedimientos heurísticos que han dado resultados satisfactorios.

Estos algoritmos se pueden catalogar en función de las pretensiones de sus transformaciones en alguna de las siguientes facetas: realce o aumento del contraste (*enhancement*), suavizado o eliminación del ruido (*denoising*) y Detección de bordes (*edge detection*).

### 1.5.1.3. Realce o manipulación del contraste

Las técnicas de realce pretenden aumentar el contraste de las imágenes. No en el sentido estricto de aumentar la calidad radiométrica, sino de mejorar algunas de sus características visuales para las siguientes etapas del análisis automático de las imágenes. "Las causas de aplicar estos algoritmos se deben bien a una falta de iluminación uniforme en la escena o bien al deseo de aumentar el contraste entre los objetos presentes en la imagen" [Sossa., 2012].

Estas técnicas de realce también se aplican cuando se pretende utilizar técnicas de segmentación. El objetivo de este procesado es facilitar las tareas de partición de la imagen. Con este fin se aumenta el contraste entre los objetos de la imagen. Muchas de las aplicaciones de realzado se fundamentan en operaciones punto a punto, es decir, no tienen en cuenta el entorno de vecindad del píxel. En la Figura 1.8 se muestra una de las aplicaciones de estas técnicas de realce.




Figura 1.8: TC craneal basal en los cortes superiores con hipodensidad en la sustancia blanca. Fuente: Imagen cortesía de M. L. Parra Gordo. Universitario Politécnica La Fe, Valencia, España.

Para su estudio se requiere introducir los conceptos de histograma, brillo y contraste. Los fundamentos de estas técnicas están en la adecuación del rango dinámico de la imagen y en la ecualización del histograma.

#### 1.5.1.4. Suavizado o eliminación del ruido

Las técnicas de suavizado de las imágenes intentan eliminar el nivel de ruido presente en la imagen. En el proceso de formación de la imagen se ha generado ruido que se ha sumado a la señal. "Este ruido se explica como una variable aleatoria que sigue una función de densidad determinada. El origen del ruido es múltiple y existen tres tipos básicos: gaussiano, impulsional y multiplicativo" [Seijas, 2011].

El ruido más común se origina en el proceso de captación al convertir los fotones en carga eléctrica, debido al carácter no determinista de esta transformación. Este tipo de ruido se explica mediante el modelo de función de densidad normal o gaussiana. "El segundo tipo de perturbación se consigue como consecuencia de la saturación de carga que recibe un píxel ya sea por exceso o por defecto. A este tipo de ruido se le denomina de sal y pimienta" [Seijas, 2011]. La saturación se produce debido a la sensibilidad de las cámaras al infrarrojo y al encontrar sobre el escenario objetos que están calientes.




Figura 1.9: Fuentes de error en una imagen donde podemos ver la imagen original con ruido gaussiano, impulsional y multiplicativo. Fuente: Imagen cortesía de MATLAB®

”Este error es como si la imagen estuviera formada por la multiplicación de dos imágenes, por un lado la imagen que refleja la intensidad de iluminación sobre los objetos y de otro la función de refracción de los cuerpos vistos en la escena” [Seijas, 2011]. A esta categoría de ruido se le ha relacionado con los filtros homomórficos. En la Figura 1.9 se pueden observar la aplicación de los ruidos anteriormente mencionados y que pueden estar presentes en las imágenes adquiridas por los sistemas de procesamiento.

### 1.5.1.5. Detección de bordes

”Estudios sobre el procesamiento visual humano indica que para la percepción de las escenas, el córtex visual utiliza información como el color de los objetos, de sus texturas, de las sombras, pero sobre todo de los contornos o bordes de los objetos” [Paredes, 2009]. En la Figura 1.10 se muestra una imagen relacionada con las pruebas psicométricas (*contornos subjetivos de Kanizsa*).




Figura 1.10: Contornos subjetivos de Kanizsa. Fuente: Imagen cortesía de MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>

Este subsistema biológico es capaz de completar bordes parcialmente ocluidos o explícitamente eliminados. En los contornos subjetivos de Kanizsa, Figura 1.11, en esta misma se observa como al visualizarlos quedan completos, aunque los objetos geométricos estén inacabados. Estos aspectos son aplicados y emulados en la visión artificial.

”La detección automática de bordes es una tarea esencial en muchas aplicaciones de interpretación de las imágenes. Suele ser una etapa muy empleada para las tareas de segmentación o para la búsqueda de objetos geométricos más complejos como líneas, elipses, esquinas, etc” [Paredes, 2009].




Figura 1.11: Bordes de una escena de bodegón. Fuente: Imagen cortesía de MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>

”Se entiende como borde aquella región donde aparece una fuerte variación del nivel de intensidad en los píxeles adyacentes” [Sossa., 2012]. Su causa principal es originada por la intersección de varios objetos, con diferentes niveles de reflectancia, que al ser proyectados sobre la cámara generan discontinuidades de intensidad en los píxeles correspondidos. Sin embargo, estas discontinuidades también aparecen de forma no deseada por la presencia del ruido, por el efecto de sombras sobre los propios objetos o por una iluminación no uniforme dentro la escena.

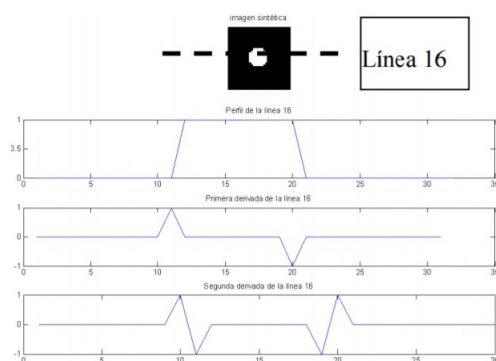


Figura 1.12: Bordes ideales. Fuente: Imagen cortesía de MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>

El fundamento para la detección de los bordes está en la aplicación del operador derivada en un entorno de vecindad. "Si se construye una imagen sintética con franjas de alto contraste y se adquiere una fila de la imagen, se observará una fuerte variación de la intensidad en el entorno de los bordes de las franjas" [Paredes, 2009].

Al aplicar el operador derivado, se observa que esta toma un valor de máximo o mínimo justamente cuando en la transición se pasa de cóncavo a convexo o viceversa, esto es, en el punto de inflexión del borde. "Si en vez de emplear la primera derivada se realiza con la segunda, el punto de inflexión de la primera deriva coincidirá con un paso por cero (*zero-crossing*). Ambos razonamiento son empleados para la detección de los bordes" [Paredes, 2009].

## **1.5.2. Visión de nivel intermedio**

### **1.5.2.1. Segmentación**

"La segmentación se refiere al proceso de dividir una imagen en regiones, segmentos manipulables o también llamadas regiones significativas. Los resultados de esta serán utilizados en etapas sucesivas para su descripción, reconocimiento e interpretación" [Palomino, 2009].

Se utiliza en el análisis de imágenes para separar de la imagen propiedades o regiones de una textura dada. Esto es importante para la clasificación de la imagen y es el primer paso en el análisis automático de imágenes y reconocimiento de patrones. El término regiones significativas depende del problema que se esté considerando. "Así, por ejemplo, en el caso de escenas 3-D, el objetivo de la segmentación podría ser identificar regiones que correspondan a objetos físicos" [Domínguez Torres, 2019].

La segmentación se basa en alguna de las dos propiedades siguientes de la imagen:

- **Discontinuidad:** La segunda propiedad segmenta la imagen en regiones de discontinuidad donde existe un cambio abrupto en los valores de los niveles de gris. Esto se utiliza para detectar las fronteras o bordes en la imagen y es consecuentemente conocida como detección de bordes. En términos sencillos, esta detección hace uso de operadores diferenciales para detectar cambios en los gradientes de los niveles de gris.
- **Similitud:** La primera propiedad segmenta la imagen en regiones que tienen niveles de gris dentro de un rango predeterminado.

”Los métodos de la segmentación asumen que las regiones a extraer poseen algunas características homogéneas distintivas. Pueden existir límites físicos entre regiones similares que no aparecen como tales en la imagen” [Castillo Atoche et al., 2014]. De igual manera pueden aparecer límites que no corresponden a límites físicos, la textura y el ruido causan problemas adicionales. Como se puede ver en la Figura 1.13 podemos apreciar la segmentación de una imagen médica del corazón, donde se ve un proceso de segmentación para poder exaltar las venas y arterias que lo rodean.

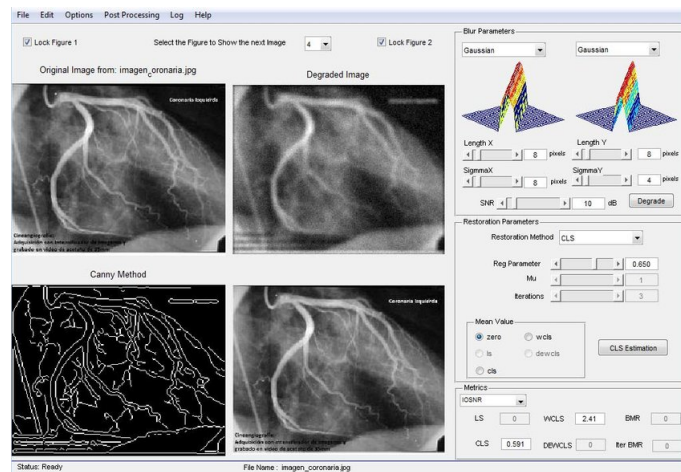


Figura 1.13: Laboratorio virtual para el procesamiento digital de imágenes. Fuente: Imagen cortesía de [Castillo Atoche et al., 2014]



## 1.6. Técnicas de segmentación dentro del procesamiento digital de imágenes

”Las diferentes técnicas o algoritmos de segmentación de imágenes digitales; se basan en dos propiedades fundamentales, la discontinuidad y similitud como menciona” [Domínguez Torres, 2019]. La discontinuidad y la subdivisión se realiza sobre la base de cambios bruscos en los niveles de intensidad o niveles de gris de una imagen. En este método, el interés se centra principalmente en la identificación de puntos aislados, líneas y aristas. En el grupo basado en la similitud, los píxeles que son similares de alguna manera incluyen enfoques como el umbral, el crecimiento regional y la división y fusión de regiones.

Los trabajos de investigación de [Sivakumar and Meenakshi, 2016], [Sharma et al., 2018] y [Ghosh et al., 2019] llevan a cabo una recapitulación de técnicas de segmentación más utilizadas en imágenes. A continuación en la Figura 1.14 son mostrados.

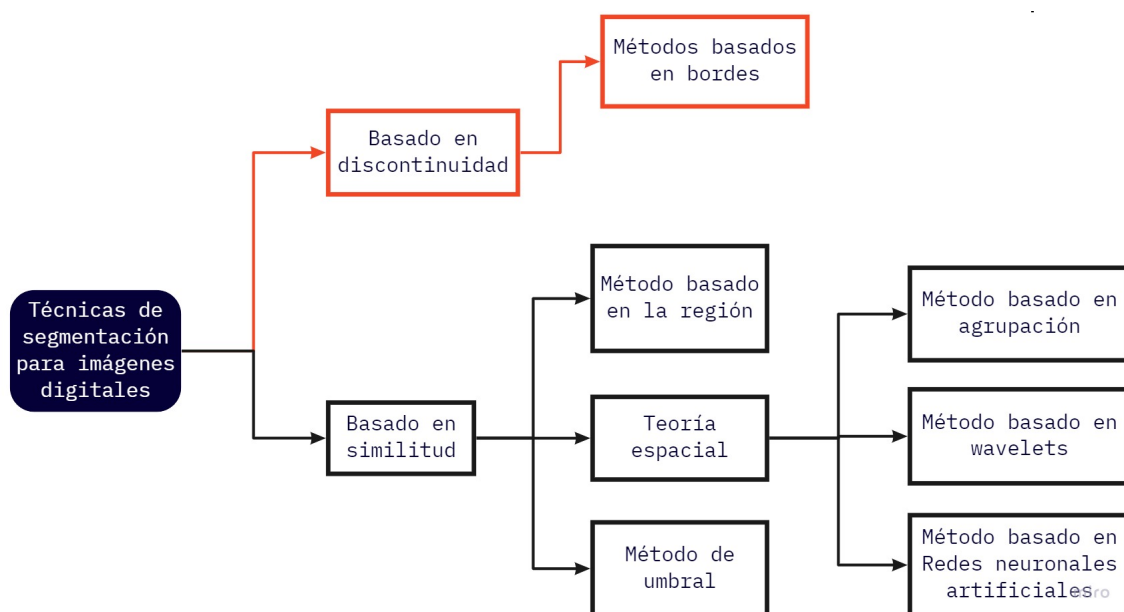


Figura 1.14: Técnicas de segmentación para imágenes digitales. Fuente: Elaboración propia.

### 1.6.1. Método basado en bordes

”Las técnicas de detección de bordes transforman las imágenes en imágenes de bordes que se benefician de los cambios de tonos grises en las imágenes” [Seijas, 2011]. La detección de bordes divide la imagen al observar el cambio de intensidad o píxeles de una imagen. Los bordes son el signo de falta de continuidad y finalización en la imagen o textura de esta, como resultado de esta transformación, la imagen de borde se obtiene sin encontrar ningún cambio en las cualidades físicas de la imagen principal como se puede apreciar en la Figura 1.15.

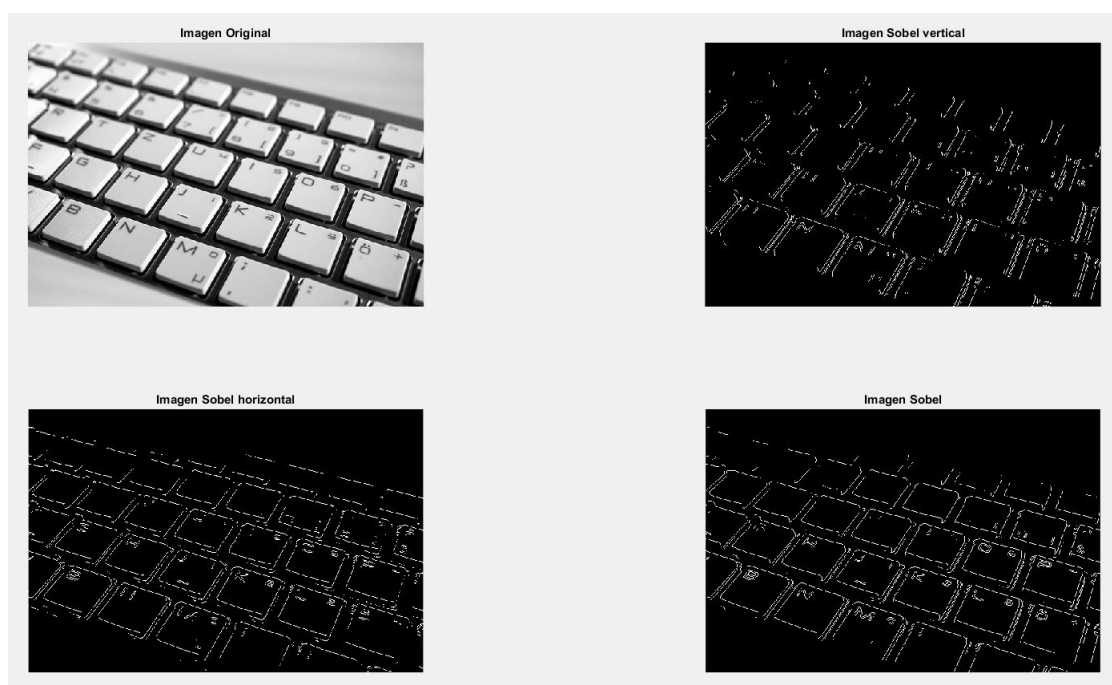


Figura 1.15: Técnica de segmentación por medio del método basado en bordes utilizando el operador Sobel. Fuente: Imagen cortesía de MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>

Un borde en una imagen es un cambio local significativo en la intensidad de la imagen generalmente asociado con una discontinuidad en la intensidad de la imagen o en la primera derivada de la intensidad de la imagen. Un borde es un conjunto de píxeles conectados que se encuentra en el límite entre dos regiones que difieren en valor gris y, por lo tanto, los píxeles en el borde se denominan puntos de borde.

Los bordes se pueden distinguir estimando el gradiente de intensidad. Un borde es un concepto local y no necesariamente tiene que formar un camino cerrado.

”Los tres pasos que se realizan con la detección de bordes son: filtrado (para reducir el ruido), mejora (*para calcular la magnitud del gradiente*) y detección (*para determinar los puntos de borde*)” [Senthilkumaran and Rajesh, 2009]. El histograma gris y el gradiente son dos métodos principales para detectar detecciones de bordes en la segmentación de imágenes.

### **1.6.2. Método de umbral**

En la segmentación de imagen basada en el umbral, una imagen de entrada se divide en dos o más sub-imágenes comparándolas con el valor umbral predefinido.

En la segmentación basada en el umbral, la imagen actual se compara con la imagen de fondo y un valor umbral decide si el píxel difiere lo suficiente como para pertenecer al primer plano. La técnica de umbral realiza la segmentación en función de los niveles de intensidad de píxeles.

Los diversos tipos de métodos de umbral, como local, global y adaptativo, se utilizan para segmentar una imagen en función de las diversas propiedades de una imagen que incluyen nivel de gris, valores de píxeles y vecindad. Si la operación del umbral depende de los niveles de gris, se realiza el umbral global.

El umbral local se realiza según el nivel de gris y las propiedades locales de la imagen. ”El umbral adaptativo se realiza en función de las propiedades de nivel de gris, vecindad y coordenadas de píxeles de la imagen” [Al-amri and Kalyankar, 2010].




Figura 1.16: Técnica de segmentación por umbral a imágenes microscópicas donde A) Imagen original, B) Imagen con ruido gaussiano, C) Imagen resultante de la segmentación por umbral, C) Imagen con tratamiento final por medio del método otsu. Imagen cortesía de MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>.

Esta técnica se utiliza para segmentar imágenes que tienen objetos claros sobre fondo oscuro u objetos oscuros sobre fondo claro, como se puede observar en la Figura 1.16. El algoritmo de umbral debe usar un valor de umbral adecuado para dividir los píxeles de la imagen en varias clases y separar los objetos del fondo.

”Las ventajas de esta técnica son: asignar un píxel de fondo al objeto, asignar un píxel de objeto al fondo y combinar diferentes fuentes de datos asociadas a la imagen. La desventaja de esta técnica es encontrar el valor umbral correcto” [Tobias and Seara, 2002].

### 1.6.2.1. Binarización por umbral

El autor [Labati et al., 2015] menciona: "Que la segmentación de huellas digitales se realiza para eliminar tanto el fondo como las sombras". Para obtener una imagen binaria que fue obtenida por el método tridimensional se estima de la siguiente manera:

$$I_s(x, y) = \begin{cases} 1 & t_l < F(x, y) < t_h \\ 0 & \text{de otra manera} \end{cases} \quad (1.7)$$

A diferencia de las imágenes obtenidas por el método tridimensional, el paso de segmentación en un método dimensional no considera la presencia de sombras de dedos. Entonces, la imagen binaria  $I_s$  se calcula de la siguiente manera:

$$I_s(x, y) = \begin{cases} 1 & F(x, y) > t_o \\ 0 & \text{de otra manera} \end{cases} \quad (1.8)$$

Para resumir lo antes mencionado la ecuación 1.7 sirve para imágenes en tres dimensiones y la ecuación 1.8 es utilizada para imágenes en dos dimensiones.

### 1.6.3. Método basado en la región

"La técnica basada en regiones es un método que funciona según el principio de homogeneidad al considerar el hecho de que los píxeles vecinos dentro de una región poseen características similares y son diferentes a los píxeles en otras regiones. Esta técnica divide una imagen en diferentes regiones según los criterios predefinidos que incluyen color, intensidad u objeto" [Freixenet et al., 2002]. Una región es, a diferencia de un borde, un concepto global y está formada por un camino cerrado. "El objetivo de la segmentación basada en regiones es producir una región homogénea que sea más grande en tamaño y una disposición para observar cualquier cambio considerable en la característica de los píxeles vecinos" [Sivakumar and Meenakshi, 2016].

Los diversos tipos de segmentación basada en regiones incluyen crecimiento regional, división y fusión de regiones y métodos basados en gráficos, como podemos observar en la Figura 1.17 un ejemplo de aplicación.




Figura 1.17: Técnica de segmentación por umbral a imágenes de monedas, donde A) Imagen original, B) Imagen segmentada utilizando descriptores de región. Imagen cortesía de MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>.

### 1.6.3.1. Crecimiento de la región

El método de crecimiento de la región segmenta la imagen en función de la similitud de cada píxel con su píxel vecino al comparar las diversas propiedades de una imagen, como el nivel de gris, la textura, el color y la forma. La idea básica de este método es agrupar la colección de píxeles en una imagen con propiedades similares para formar una región. En este método, la región crece al elegir un punto de inicio llamado píxel inicial.

Luego, la región crece agregando píxeles vecinos similares de acuerdo con cierto criterio de homogeneidad, aumentando paso a paso el tamaño de la región. "El criterio de homogeneidad tiene la función de decidir si un píxel pertenece o no a la región en crecimiento" [Zhu and Yuille, 1996].

El crecimiento de la región se puede procesar en cuatro pasos:

1. Marque el grupo de píxeles semilla en la imagen original.
2. Seleccione un criterio de agrupación como la intensidad del nivel de gris o el color y configure una regla de detención.
3. Expandas las regiones conectándose a cada semilla a los píxeles vecinos que hayan satisfecho las propiedades del clúster similares a los píxeles semilla.
4. Detener el crecimiento de la región cuando ya no haya más píxeles que cumplan con el criterio de inclusión en esa región.

#### **1.6.3.2. División y fusión de regiones**

En la técnica de división y fusión de regiones, una imagen se subdivide en un conjunto de regiones arbitrarias no conectadas. Este método intenta dividir una imagen de entrada en varias regiones más pequeñas de forma recursiva. El método de división y fusión de regiones funciona sobre la base de árboles cuádruples y el objetivo principal es distinguir la homogeneidad de la imagen. Inicialmente, este método considera la imagen completa como una sola región y luego divide la imagen en cuatro cuadrantes en función de ciertos criterios predefinidos. Comprueba los cuadrantes para los mismos criterios definidos y lo divide más en cuatro cuadrantes si el resultado de la prueba es negativo y el proceso continúa hasta que se cumplan los criterios o no es posible una división adicional.

”En lugar de elegir puntos semilla, uno puede dividir una imagen en un conjunto de regiones impulsivas desconectadas y luego fusionar las regiones en un intento de satisfacer las condiciones de segmentación de imagen razonable” [Kaganami and Beij, 2009].

”El proceso de división es un enfoque de arriba hacia abajo y un proceso de fusión es un enfoque de abajo hacia arriba que se utiliza después de cada división que compara las regiones adyacentes” [Kaganami and Beij, 2009].

El método de segmentación basado en la región es útil cuando el criterio de homogeneidad de la región es fácil de definir. La ventaja de esta técnica es hacer un uso completo de la relación de píxeles en función de las propiedades de la imagen. La desventaja de esta técnica es la selección de píxeles basados en la región, ya que un criterio demasiado estricto crea regiones fragmentadas y un criterio indulgente pasa por alto las regiones borrosas.

#### **1.6.4. Método basado en Wavelets**

La transformación Wavelet descompone una imagen por medio de una serie de funciones elementales, creadas a partir de dilataciones y traducciones de la función base conocida como wavelet madre. Las transformaciones Wavelet pueden implementarse mediante el uso de un par de filtros de paso bajo y paso alto que están representados por una secuencia de coeficientes.

En la descomposición wavelet bidimensional, los filtros se aplican a una imagen en dirección horizontal y vertical, seguido de un muestreo descendente. ”Como los coeficientes wavelet en diferentes bandas de frecuencia muestran variaciones en las direcciones horizontal, vertical y diagonal, se ha demostrado que las características de textura se pueden extraer de estos coeficientes” [Andrea Gavlasova, 2006].

Las wavelets son funciones generadas a partir de una sola función por dilataciones y traslaciones. En la Figura 1.18 podemos apreciar una aplicación de la transformación Wavelet en conjunto con técnicas de segmentación, para mejorar el contraste en estas imágenes.



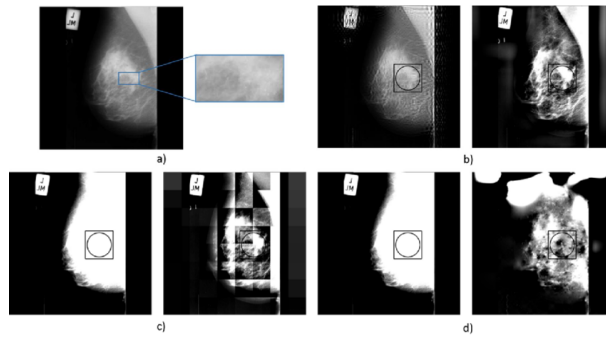


Figura 1.18: Mejores y peores resultados de los algoritmos basados en wavelets para tumor: a) imagen original y región de interés, b) Mejor realce y alto contraste , c) Procesado en frecuencias de bajo nivel por píxel , d) Segmentación de píxeles en regiones heterogéneas del estudio en cáncer de mama. Fuente: Imagen cortesía de [Valdés Santiago et al., 2015].

La segmentación de imágenes basada en el método wavelets se ha llevado a cabo en dos etapas. En la primera etapa, la imagen de entrada se descompone en bloques de píxeles y se aplica una transformación wavelet a cada bloque para identificar regiones homogéneas de la imagen, y luego se asigna todo el bloque a una clase. "La segmentación inicial identifica bloques con características similares, agrupándolos en clases correspondientes. En la segunda etapa, se detectan regiones heterogéneas, por ejemplo, bloques ubicados en las fronteras entre diferentes regiones y, finalmente, las imágenes segmentadas se han identificado con mayor precisión" [Andrea Gavlasova, 2006]. Los diversos pasos necesarios para segmentar una imagen usando wavelets son:

- La primera etapa es ingresar la imagen y descomponer la imagen, como  $n \times n$  bloques.
- Los bloques dentro de la imagen están cambiando a varias posiciones, como horizontal, vertical, diagonal.
- Extracción de características basada en medidas de frecuencia de bajo y alto nivel.
- En la segunda etapa, segmentación de píxeles en regiones heterogéneas y obtener la imagen de segmentación como resultado.

La segmentación de imágenes basada en transformaciones wavelet es útil para extraer características de color y textura de las imágenes. Al utilizar este método primero, las características se extraen de los coeficientes wavelets de pequeñas regiones de la imagen y luego las regiones se agrupan en un conjunto de clases. Finalmente, se aplica una segmentación en píxeles a aquellos píxeles que no fueron segmentados. ” Al usar este proceso de dos pasos, es posible reducir el costo computacional de manera significativa, ya que solo se necesita segmentar un pequeño número de píxeles en la segunda etapa que evita el cálculo de la función para cada píxel en la imagen. La ventaja de la transformación wavelet es que una imagen puede mostrarse a diferentes niveles de resolución y puede procesarse secuencialmente desde baja resolución a alta resolución” [E. J. Stollnitz, 1996].

### **1.6.5. Método basado en agrupamiento**

Los algoritmos de agrupamiento usan un grupo de propiedades similares de la imagen, como píxeles, color y límites para segmentar una imagen. En la segmentación de imágenes basada en clústeres, una imagen de entrada se divide en grupos basados en propiedades similares que incluyen valores de distancia, conectividad e intensidad. Se define un criterio de similitud entre píxeles y luego píxeles similares se agrupan para formar grupos. La agrupación de píxeles en grupos se basa en el principio de maximizar la similitud intraclass y maximizar la similitud entre clases.

”Los algoritmos de agrupamiento no utilizan datos de entrenamiento sino, que iteran entre segmentar la imagen y caracterizar las propiedades de cada clase” [Jain and M. Narasimha Murty, 1999]. Las técnicas de agrupación pueden clasificarse en dos categorías, tales como agrupación dura y agrupación suave.

”En la agrupación rígida, los datos se dividen en una cantidad de agrupaciones únicas donde cada componente de datos pertenece exactamente en una agrupación. Uno de los clústeres duros más populares y más utilizados algoritmos es K-significa algoritmo de agrupamiento” [Acharya et al., 2013].

”En clustering suave, los elementos de datos pueden pertenecer a más de un clúster con cierto grado de ciertos valores de relación. Fuzzy C Means (FCM) clustering es un tipo de algoritmo de clustering suave que se puede usar en situaciones en las que no hay límites definidos entre diferentes objetos en una imagen. La agrupación difusa divide los píxeles de entrada en grupos o grupos en función de varios criterios de similitud, como la distancia, la conectividad y la intensidad” [Chuang et al., 2006].

”La agrupación espectral es un algoritmo que puede dividir cualquier forma en función de la teoría de gráficos espectrales” [Zhao et al., 2014]. El objetivo de la segmentación de imagen basada en el espectro es dividir la imagen de entrada en algún espacio adyacente, regiones homogéneas espectrales similares y separar el objetivo y el fondo.

### **1.6.6. Redes neuronales artificiales**

Las redes neuronales son sistemas de neuronas interconectadas con el fin de comunicarse entre sí y calcular valores. Los valores de entrada a través de alimentación hacia adelante o hacia atrás propagan información a través de la red. Una red neuronal es una representación artificial del cerebro humano que se utiliza para simular las estrategias de aprendizaje del cerebro para el proceso de toma de decisiones. ”La red neuronal que simula los procedimientos de aprendizaje del cerebro humano constituye una gran cantidad de nodos paralelos. Cada nodo puede realizar algo de computación básica” [LeCun et al., 1998].

El proceso de aprendizaje se puede lograr mediante la transferencia de las conexiones entre nodos y el peso de la conexión. Las redes neuronales se han utilizado ampliamente para resolver el problema de la segmentación de imágenes médicas y reduce los requisitos de intervención de expertos durante el proceso de segmentación de imágenes.

”En la segmentación de imágenes basada en redes neuronales, primero la imagen se convierte en minimización de energía y la red neuronal se entrenó con un conjunto de muestras de entrenamiento para determinar la conexión y los pesos entre los nodos” [Petersen et al., 2002].

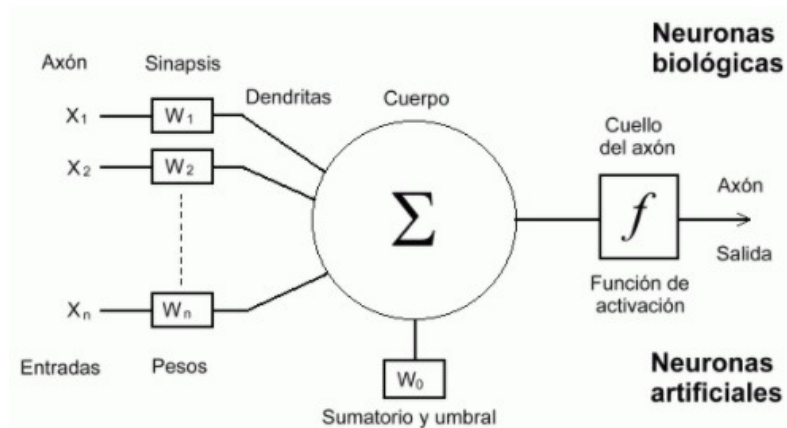


Figura 1.19: Primer modelo matemático de una neurona artificial, creado con el fin de llevar a cabo tareas simples, presentado en el año 1943 en un trabajo conjunto entre el psiquiatra y neuroanatomista Warren McCulloch y el matemático Walter Pitts. Imagen cortesía de Caparrini,2001.

En la red neuronal, cada neurona corresponde al píxel de una imagen y la imagen se asigna a la red neuronal. La imagen en forma de red neuronal se entrena utilizando muestras de entrenamiento, y luego se encuentra la conexión entre las neuronas (es decir, píxeles).

Luego, las nuevas imágenes se segmentan de la imagen entrenada. En la red neuronal, una imagen se ve como una combinación de segmentos en los que los datos de la imagen son homogéneos y los dos factores que se utilizan para determinar los segmentos de la imagen son:

1. Clasificación de todos los píxeles que satisfacen el criterio de homogeneidad.
2. Detección de todos los píxeles en los bordes entre diferentes áreas homogéneas.

La segmentación de la imagen usando la red neuronal se realiza en dos pasos que incluyen la clasificación de píxeles y la detección de bordes. La red neuronal que usa la detección de bordes organiza cada píxel es parte de un borde o no. Todos los bordes juntos forman los contornos de los segmentos y la vinculación de bordes se usa para cerrar los contornos.

Los filtros de detección de bordes se utilizan solo para detectar bordes en diferentes direcciones. Las redes neuronales basadas en píxeles clasifican el contenido de la imagen en función de la combinación de textura y forma local. Las redes neuronales también se han desarrollado para los pasos de procesamiento previo y posterior en relación con la segmentación.

”En este caso, la segmentación se realiza en función de varios procesos, como la delineación de contornos, la conexión de píxeles de borde, la identificación de superficies, la decisión de si un píxel se produce dentro o fuera de un segmento, la resolución de la imagen segmentada, la agrupación de píxeles y la segmentación de movimiento” [Sivakumar and Meenakshi, 2016].

Hoy en día se han creado Redes Neuronales Convolucionales [LeCun et al., 1998]; autoencoders convolucionales [Masci et al., 2011]; redes neuronales recurrentes [Medsker and Jain, 2001]; redes residuales [He et al., 2016]

### 1.6.7. Visión de alto nivel

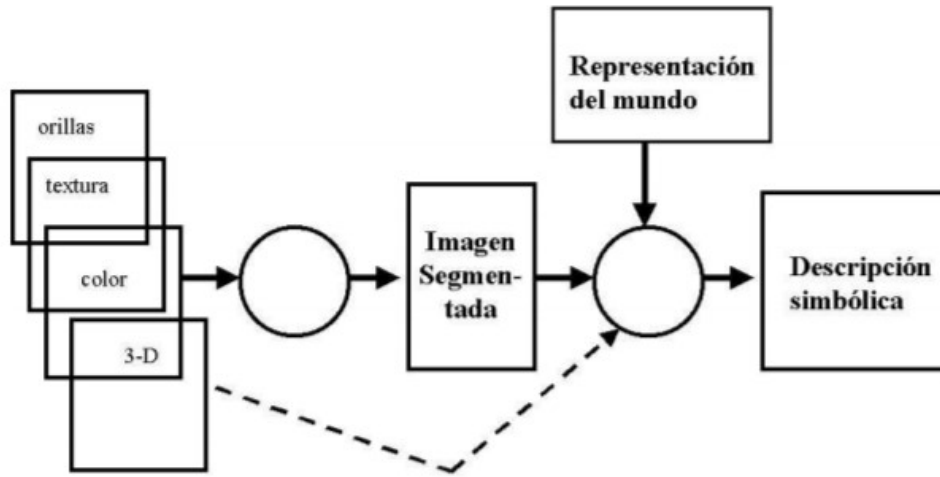


Figura 1.20: Proceso de visión de alto nivel. Fuente: Imagen cortesía de [Sucar and Gómez, 2018]

”La última etapa del procesamiento digital de imágenes incluye la etapa de reconocimiento e interpretación. En el reconocimiento de caracteres, se tiene una representación de cada letra con base en ciertos parámetros. Al analizar una imagen, se obtienen parámetros similares y se comparan con los de los modelos” [Jianbo Shi and Malik, 2000]. El modelo que tenga una mayor ”similitud”, se asigna al carácter de la imagen. Una forma de representar caracteres es mediante una codificación radial como se muestra en la Figura 1.21.



Figura 1.21: Reconocimiento de caracteres en base a su codificación radial. Fuente: Imagen cortesía de [Sucar and Gómez, 2018]

”La forma en que representemos tanto los modelos internos como la información de la imagen tiene una gran repercusión en la capacidad del sistema de visión” [Sucar and Gómez, 2018].

#### **1.6.7.1. Reconocimiento e Interpretación**

Una representación es: ”Un sistema formal para hacer explícita ciertas características o tipos de información, junto con una especificación de como el sistema hace esto” [Marr, 1982]. Hay dos aspectos importantes de una representación para visión:

- Representación del modelo: El tipo de estructura utilizada para modelar la representación interna del mundo.
- Proceso de reconocimiento: La forma en que dicho modelo y la descripción de las imágenes son utilizadas para el reconocimiento.

Las representaciones apropiadas para reconocimiento en visión deben de buscar tener las siguientes propiedades:

- Genéricas.
- Eficientes, en espacio y tiempo.
- Invariantes, independientes de traslación, rotación y escalamiento.
- Robustas, tolerantes a ruido e información incompleta.

”Los sistemas de visión de alto nivel se pueden clasificar en dos tipos principales: (1) Sistemas basados en modelos que utilizan una representación geométrica (*analógica*) y el reconocimiento se basa en correspondencia; y (2) sistemas basados en conocimiento, que usan una representación simbólica y el reconocimiento se basa en inferencia” [Marr, 1982].

## 1.7. Histograma de intensidades

”Un histograma de una imagen es la distribución de cada nivel de intensidad dentro de la imagen, es decir nos da un estimado de la probabilidad de ocurrencia de cada nivel de gris” ( $r$ )[Markou and Singh, 2003].

$$p(r_k) = n_k/n \quad (1.9)$$

Donde  $p(r_k)$  es la probabilidad del nivel  $k$ ,  $n_k$  es el número de píxeles que toma este valor y  $n$  es el número total de píxeles en la imagen.

En la Figura 1.22 se muestra en forma gráfica el histograma de dos imágenes, una con amplio rango de intensidades y otra con un rango reducido.

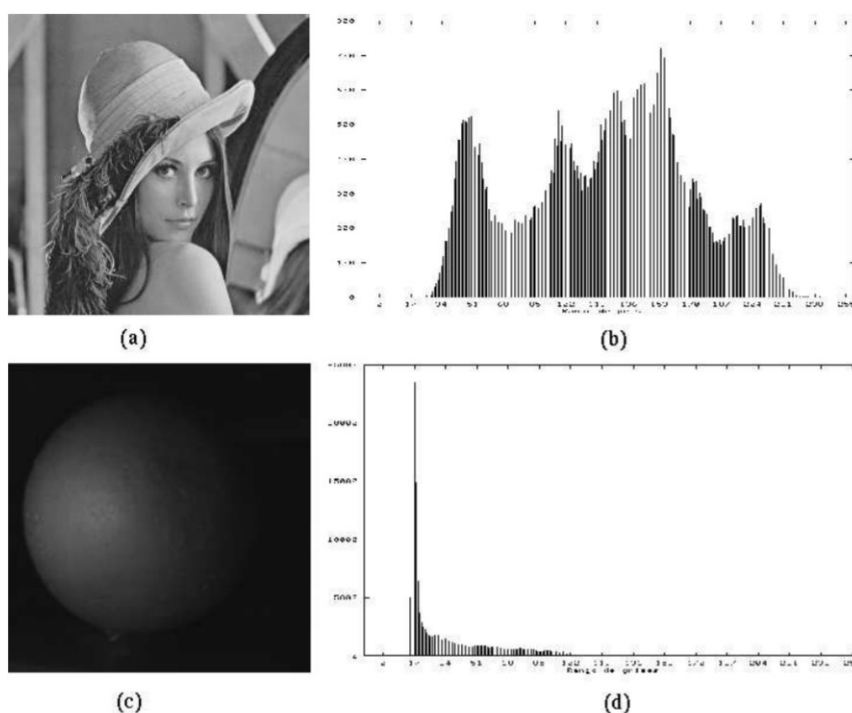


Figura 1.22: Ejemplos de histogramas: (a) Imagen con varias intensidades. (b) Su histograma mostrando un rango amplio de grises o alto contraste. (c) Imagen oscura. (d) Su histograma presenta un rango de grises reducido, es decir menor contraste. Fuente: Imagen tomada y adaptada de [Markou and Singh, 2003].



El histograma nos presenta una descripción global de la imagen y sobre todo nos da una indicación del contraste en la imagen. De aquí que si modificamos el histograma, podemos controlar el contraste en la imagen.

En la Figura 1.23 se observa un histograma estrecho, de bajo rango dinámico, en concordancia con el poco contraste visual de la imagen correspondiente. El objetivo de la ecualización del histograma es ampliar el rango dinámico de los niveles de gris, para acentuar el contraste visual de la imagen.

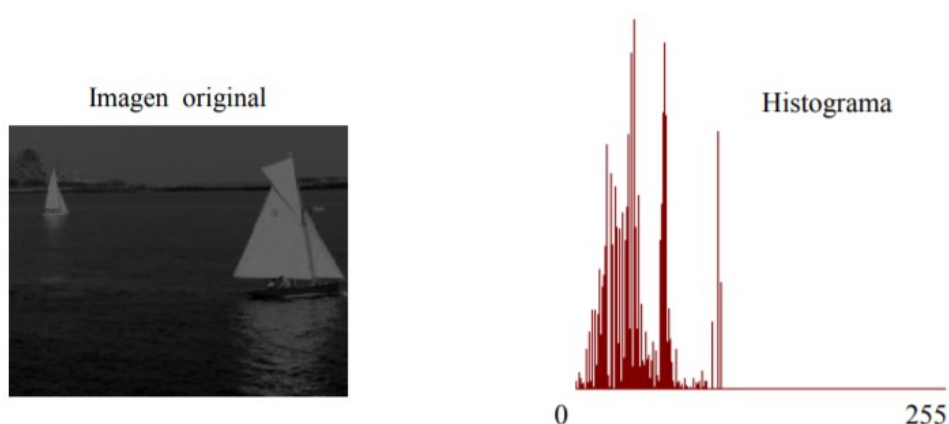


Figura 1.23: Histograma de una imagen con poco contraste, esto debido a una toma fuera de foco. Fuente: Imagen cortesía de [Sucar and Gómez, 2018].

### 1.7.1. Ecualización del histograma

En cualquier función de densidad probabilística que es transformada a uniforme se maximiza la explotación de la información. Este fenómeno que rige a los procesos continuos también se puede aplicar sobre información discreta. "La conversión de cualquier forma de histograma a uno uniforme, no aumentará la información obtenida, si mejorará la imagen para las siguientes etapas. Ya que el valor máximo de la entropía se dará cuando el histograma sea uniforme" [Platero, 2009].

”El fundamento se basa en realizar una conversión en el histograma de forma que la probabilidad de cualquier nivel de gris en la imagen sea idéntica” [Galambos et al., 1999]. Desde el punto de vista del histograma, esta transformación producirá que el número de ocurrencias de un nivel de gris sea el mismo valor siempre que se cumpla lo siguiente:

$$h(i) = \frac{M \cdot N}{I} \quad (1.10)$$

Para obtener esta técnica de preprocesamiento se partirá de la función de distribución de la imagen. Esta se define, para variables aleatorias discretas, como el sumatorio de probabilidades desde el inicio de la variable hasta un valor prefijado.

Por tanto, supongamos que  $s$  es una variable aleatoria con valores en el intervalo continuo  $[0, 1]$ , con función de densidad  $f(s)$  y función de distribución  $F(s)$ . Si queremos definir una nueva variable aleatoria  $r$  que sea función de  $s$  y que tenga distribución uniforme en  $[0, 1]$ , se debe cumplir que:

$$r = F(s) = \int_0^s f(t)dt \quad (1.11)$$

Si el rango de variable  $s$  es estrecho, la transformación expande el rango uniformemente sobre el intervalo  $[0, 1]$ . Si  $f(s)$  es la densidad asociada al histograma, supuesto continuo, hemos obtenido una solución para el caso continuo.

Para el caso discreto, discretizamos la integral, dividiendo  $[0, 1]$  en 256 partes iguales, para obtener una solución correspondiente a una escala de 256 niveles de gris. Lo que nos da la siguiente expresión:

$$F(k) = \sum_{i=0}^k f \frac{i}{256} \cdot \frac{1}{256} \quad (1.12)$$

por lo tanto:

$$P_i = f \frac{i}{256} \cdot \frac{1}{256} \quad \text{con} \quad 0 \leq i \leq 255 \quad (1.13)$$

$$F(k) = \sum_{i=0}^k P_i \quad \text{para } 0 \leq k \leq 255 \quad (1.14)$$

Si se tienen imágenes en escala de grises se trabajan valores entre 0 y 255, por lo que se tomara la siguiente expresión:

$$F(k) = \sum_{i=0}^k P_i \quad \text{para } 0 \leq k \leq 255 \quad (1.15)$$

La transformación  $F$  define una operación puntual que a cada píxel de nivel de gris  $k$ , lo transforma en un píxel de nivel de gris  $F(k)$ , logrando una ampliación del rango dinámico de la imagen dada. Si  $F(0)$  es distinto de cero, mediante la utilización de la siguiente ecuación podemos distribuir los niveles de gris en todo el rango dinámico.

$$G(k) = 255 \frac{F(k) - F(0)}{255 - F(0)} \quad (1.16)$$

La Figura 1.24 que se muestra a continuación, resulta de aplicar el proceso de equalización a la imagen de la figura 1.23. "Puede observarse la ampliación del rango dinámico en el histograma, así como el aumento del contraste visual en la imagen" [Platero, 2009].

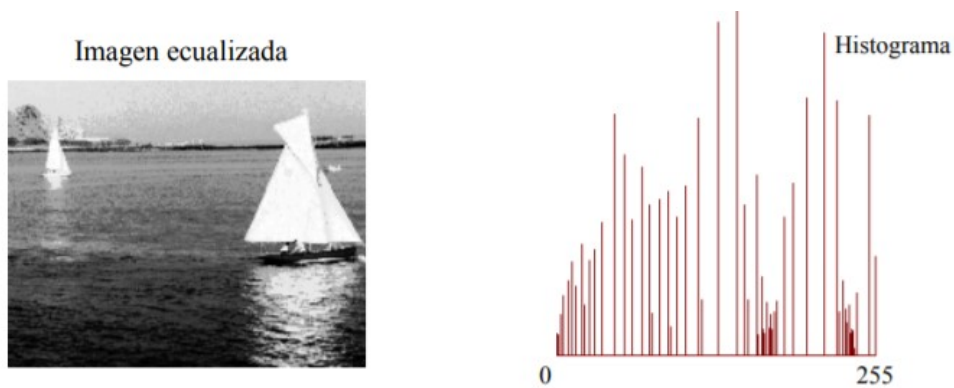


Figura 1.24: Histograma de una imagen con la aplicación de rango dinámico y aumento de contraste debido a la aplicación del histograma ecualizado. Fuente: Imagen cortesía de [Sucar and Gómez, 2018].

## 1.8. Ecualización de histograma adaptativo de contraste limitado (CLAHE)

Alguno de los problemas al trabajar con imágenes es su visibilidad, la cual es dependiente de cómo se realizó la adquisición de la imagen, para esto se utilizan métodos como la ecualización del histograma adaptativo (AHE, Adaptive Histogram Equalization), el problema es que el método realiza una ecualización de histograma normal diferente, en la cual se toman distintas regiones de la imagen y en estas se redistribuye un valor de contraste, en cambio cuando se emplea CLAHE, la distribución es utilizada para definir la forma del histograma que produce el resultado de mejor calidad.

Este algoritmo se encarga de mejorar el contraste de la imagen y la precisión de extracción, comparando el histograma local de la imagen, y redistribuyendo el contraste para cambiar el contraste de la imagen y obtener más detalles en el contraste. "En comparación con la ecualización del histograma adaptativo (AHE), CLAHE puede suprimir eficazmente la amplificación de ruido y acelerar el funcionamiento con el algoritmo de interpolación" [Lopez Montiel et al., 2019].

El algoritmo CLAHE es el siguiente:

- Adquisición de la imagen borrosa.
- Obtener los valores de entrada como son, el número de regiones en fila y columna por separado, el rango dinámico (número de bandejas usadas en la función de transformación del histograma), límite del clip, tipo de parámetros de distribución.
- La imagen original es dividida en varias regiones para las entradas preprocesadas.
- Proceso aplicado sobre la región de interés (mosaico).

- Genera mapeo de nivel de grises e histograma recortado. En la región de interés, los números de píxeles se dividen por igual en cada nivel de gris, por lo que el número promedio de píxeles es el nivel de gris que se describe a continuación:

$$N_{avg} = \frac{N_{CR-Xp} \cdot N_{CR-Yp}}{N_{gray}} \quad (1.17)$$

donde

$N_{gray}$  = Número de nivel de gris en la región de interés.

$N_{CR-Xp}$  = Número de píxeles en la dirección X de la región de interés.

$N_{CR-Yp}$  = Número de píxeles en la dirección Y de la región de interés.

Después de lo anterior, calcular el límite actual del clip.

$$N_{CL} = N_{CLIP} \cdot N_{avg} \quad (1.18)$$

- Se hace una interpolación mediante un mapa de escala de grises para generar una imagen mejorada.

”De tal forma que este método modifica el contraste de la imagen original para realizar una mejor clasificación en la red neuronal convolucional” [Yadav et al., 2014]. En CLAHE, la amplificación del contraste en las proximidades de un valor de píxel dado viene dada por la pendiente de la función de transformación.

”La redistribución empujará algunos contenedores por encima del límite del clip nuevamente (región sombreada en verde en la figura), lo que dará como resultado un límite de clip efectivo que es mayor que el límite prescrito y cuyo valor exacto depende de la imagen. Si esto no es deseable, el procedimiento de redistribución puede repetirse de forma recursiva hasta que el exceso sea insignificante” [Yadav et al., 2014].

## 1.9. Filtro Guiado

Derivado de un modelo lineal local, el filtro guiado calcula la salida del filtrado considerando el contenido de una imagen de guía, que puede ser la propia imagen de entrada u otra imagen diferente como se puede ver en la Figura 1.25. El filtro guiado se puede utilizar como un operador de suavizado que preserva los bordes, como el popular filtro bilateral, pero tiene mejores comportamientos cerca de los bordes.

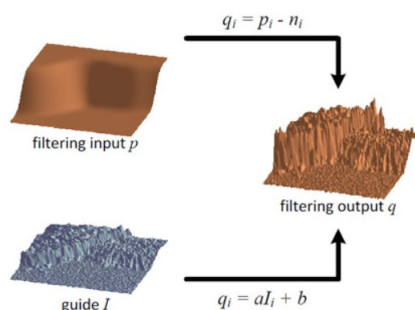


Figura 1.25: Proceso de trabajo del filtro guiado, donde se puede ver la comparación que se hace entre la imagen de entrada con la imagen de salida. Fuente: Imagen tomada y adaptada de [He et al., 2016].

El filtro guiado también es un concepto más genérico más allá del suavizado: puede transferir las estructuras de la imagen de guía a la salida de filtrado, lo que permite nuevas aplicaciones de filtrado como el desvanecimiento y el difuminado guiado. Además, el filtro guiado tiene naturalmente un algoritmo de tiempo lineal rápido y no aproximado, independientemente del tamaño del kernel y del rango de intensidad. Actualmente es uno de los filtros de preservación de bordes más rápidos. "Los experimentos muestran que el filtro guiado es efectivo y eficiente en una gran variedad de aplicaciones de gráficos por computadora y visión por computadora, que incluyen suavizado con reconocimiento de bordes, mejora de detalles, compresión HDR, matizado y difuminado de imágenes, eliminación de neblina, muestreo superior de articulaciones" [He et al., 2016]

## 1.10. Filtro Wiener (Wiener Filter)

El Filtro de Wiener es un filtro propuesto por Norbert Wiener en la década de 1940 y publicado en 1949. "Su propósito es reducir el ruido aditivo presente en la señal observada utilizando métodos estadísticos, de tal modo que la señal estimada a la salida del filtro se aproxime lo más posible a una señal deseada sin ruido" [Reyes-Diaz et al., 2018]. La Figura 1.26 representa un esquema de funcionamiento del filtro wiener.




Figura 1.26: Diagrama a bloques de la representación del filtro con el enfoque moderno. Fuente: Imagen tomada y adaptada de Simon HayKin. " *Adaptive Filter Theory Second Edition* ". Prentice Hall .

"El filtro produce un estimado de la señal deseada aplicando un filtro lineal e invariante en el tiempo de la señal ruidosa observada, asumiendo conocidos el espectro de la señal y del ruido aditivo, minimizando el error medio cuadrático entre la señal estimada y la señal deseada" [Reyes-Diaz et al., 2018]. El filtro de Wiener se caracteriza por:

- Asume que la señal observada contiene ruido aditivo, que la señal y el ruido son procesos estocásticos lineales y estacionarios, que se conocen sus características espectrales, su auto-correlación y su correlación cruzada.
- El criterio de comportamiento es el MMSE: error medio-cuadrático mínimo.

El filtro será un filtro de Wiener si su respuesta impulsiva se elige para minimizar el error cuadrático medio.

## 1.11. Métrica Peak signal-to-noise ratio (PSNR)

Las medidas de señal a ruido (SNR) son estimaciones de la calidad de una imagen reconstruida en comparación con una imagen original. La idea básica es calcular un solo número que refleje la calidad de la imagen reconstruida. Las imágenes reconstruidas con métricas más altas se juzgan mejor. De hecho, las medidas tradicionales de SNR no se equiparan con la percepción subjetiva humana.” Varios grupos de investigación están trabajando en medidas de percepción, pero por ahora usaremos las medidas de señal a ruido porque son más fáciles de calcular” [Horé and Ziou, 2010].

La métrica real que calcularemos es la medida de la señal de pico a la imagen reconstruida que se llama PSNR. Suponga que se nos da una imagen de origen  $f(i, j)$  que contiene  $N$  por  $N$  píxeles y una imagen reconstruida  $F(i, j)$  donde  $F$  se reconstruye decodificando la versión codificada de  $f(i, j)$ . ”Las métricas de error se calculan en la señal de luminancia solo de modo que los valores de píxeles  $f(i, j)$  oscilen entre negro (0) y blanco (255)” [Horé and Ziou, 2010].

Primero, calcula el error cuadrático medio ( $MSE$ ) de la imagen reconstruida de la siguiente manera

$$MSE = \frac{\sum [f(i, j) - F(i, j)]^2}{N^2} \quad (1.19)$$

La suma es sobre todos los píxeles. La raíz del error cuadrático medio ( $RMSE$ ) es la raíz cuadrada de  $MSE$ . Algunas formulaciones usan  $N$  en lugar de  $N^2$  en el denominador de  $MSE$ .



Por lo cual calculamos la métrica  $PSNR$  en decibelios ( $dB$ ) utilizando la siguiente ecuación:

$$PSNR = 20 \log_{10}\left(\frac{255}{RMSE}\right) \quad (1.20)$$

Los valores típicos de  $PSNR$  oscilan entre 20 y 60. El valor real no es significativo, pero la comparación entre dos valores para diferentes imágenes reconstruidas proporciona una medida de calidad. "El comité *MPEG* utilizó un umbral informal de 0,5  $dB$   $PSNR$  para decidir si incorporar una optimización de codificación porque creían que una mejora de esa magnitud sería visible. Algunas definiciones de  $PSNR$  utilizan 255 entre MSE en lugar de 255 entre RMSE. Cualquiera de las dos fórmulas funcionará porque estamos interesados en la comparación relativa, no en los valores absolutos" [Lian, 2019].

La otra técnica importante para mostrar errores es construir una imagen de error que muestre los errores píxel por píxel. El cálculo más simple de esta imagen es crear una imagen tomando la diferencia entre los píxeles reconstruidos y originales. Estas imágenes son difíciles de ver porque la diferencia cero es negra y la mayoría de los errores son números pequeños que son sombras de negro. La construcción típica de la imagen de error multiplica la diferencia por una constante para aumentar la diferencia visible y traduce la imagen completa a un nivel de gris. El cálculo es:

$$PSNR = 2[f(i, j) - F(i, j)] + 128 \quad (1.21)$$

Se puede ajustar la constante (2) o la traducción (128) para cambiar la imagen. Algunos investigadores usan blanco (255) para indicar que no hay error y la diferencia con el blanco como un error, lo que significa que los píxeles más oscuros son errores más grandes [Lian, 2019].

## 1.12. Patrón binario local (Local Binary Pattern)

”El operador de análisis de textura LBP está definido como una medida invariante a la escala de grises, derivado de una definición general de la textura en una vecindad local” [DEL POZO and GARCÍA, 2009].

La propuesta original descrita por Harwood y Ojala [Maenpaa, 2004], ”consiste en la comparación de píxel central con los vecinos, en el cual el píxel central es tomado como el umbral con respecto a sus vecinos, al realizar la comparación del píxel central con el vecino se le asigna un valor de uno “1” si el vecino el mayor o igual, en caso contrario se le asigna un valor de cero “0”, a cada resultado del umbral se le asigna un peso de  $2^n$ , en donde n depende de la posición del vecino con respecto al píxel central, finalmente se realiza una suma de los diferentes pesos obteniendo la representación LBP de píxel”. Este proceso de funcionamiento esta esquematizado en la Figura 1.27.

Muestras	Umbral	Pesos
10	0	1
22	1	2
25	1	4
23	1	128
<b>20</b>		8
21	1	64
9	0	32
17	0	16
20	1	
(a)	(b)	(c)

Figura 1.27: Funcionamiento del operador LBP (a) muestra de una imagen de 3x3 (b) equivalente binario de LBP (c) pesos asignados para cada píxel. Fuente: Imagen cortesía de [Alvarado and Fernández, 2012].

En la ecuación 1.22 se observa el resultado del operador LBP para una matriz de 3x3 utilizando 8 vecinos en el ejemplo de la Figura 1.27.

$$LBP = (0*1)+(1*2)+(1*4)+(1*8)+(1*16)+(0*32)+(0*64)+(1*128) = 158 \quad (1.22)$$

Posteriormente al operador LBP se derivó un operador el cual permite modificar los tamaños del área de interés y las vecindades para píxel de interés descritas por [García-Lamont et al., 2012] "la derivación consiste en el establecimiento de los parámetros denominados  $R$  y  $P$ , donde  $R$  corresponde a la distancia (radio) tomada a partir del píxel de origen y  $P$  el número de vecinos utilizados para el cálculo de  $LBP$ ".

La distancia y la distribución de los vecinos se construyen a partir de una circunferencia simétrica, para valores de  $R > 0$  y  $P > 1$ , al modificar los valores de  $P$  y  $R$  se pueden obtener diferentes medidas de textura del área de interés.

En la Figura 1.28 se puede apreciar la distribución de igual número de vecinos para diferentes distancias.




Figura 1.28: Distribución de los vecinos para LBP. (a)  $R=1$ ,  $P=8$ , (b)  $R=2$ ,  $P=8$ , (c)  $R=3$ ,  $P=8$ . Fuente: Imagen cortesía de [Alvarado and Fernández, 2012].

Los vecinos se encuentran igualmente espaciados y repartidos circularmente, la distribución de los píxeles a partir del píxel central se encuentra expresada matemáticamente en la ecuación 1.23.

$$x = R \sin \frac{2\pi p}{P} \quad ; \quad y = R \cos \frac{2\pi p}{P} \quad (1.23)$$

En la Figura 1.29 se observa la distribución de diferentes números de vecinos para  $R=1$ .




Figura 1.29: Distribución de los vecinos para LBP. (a)  $R=1$ ,  $P=2$ , (b)  $R=1$ ,  $P=4$ , (c)  $R=1$ ,  $P=8$ . Fuente: Imagen cortesía de [Alvarado and Fernández, 2012].

Una vez definidos los parámetros de distancia y el número de vecinos el operador LBP se define matemáticamente para  $R > 0$  y  $P > 1$  como:

$$LBP_{P,R}(X_c, Y_c) = \sum_{P=0}^{P-1} s(g_p - g_c) 2^P \quad (1.24)$$

Donde  $X_c, Y_c$  corresponden a la posición del píxel de interés de la imagen,  $g_p$  es el valor de píxel central,  $g_c$  el valor de los vecinos circulares del píxel central, y  $2^P$  el peso asignado a cada operación entre el píxel central y el vecino, finalmente  $s(g_p - g_c)$  asignan valores de 1 y 0 según la ecuación 1.25.

$$s(g_p - g_c) = \begin{cases} 1 & s(g_p - g_c) \geq 0 \\ 0 & (g_p - g_c) < 0 \end{cases} \quad (1.25)$$

”El método *LBP* puede ser considerado como un verdadero enfoque unificador del modelo estocástico y estructural de la textura. En lugar de tratar de explicar la formación de texturas se asigna un nivel al píxel, correspondiente a los patrones locales” [Maenpaa, 2004]. De esta forma cada píxel se representa como una textura definida anteriormente a la cual coincide con su vecindario. ”Por lo tanto, cada código de LBP puede ser considerada como una microtextura local, las texturas identificadas para LBP son las manchas, áreas planas, bordes, bordes extremos, curvas, entre otros” [Ojala et al., 2000]

## **1.13. Procesamiento de imágenes médicas digitales**

El término procesamiento de imágenes digitales se refiere generalmente al tratamiento por un computador de una tabla de niveles de intensidad luminosa. Desde principios de los setenta este campo ha conocido un gran auge gracias a un mayor acceso a los equipos de computación necesarios para su aplicación y un progresivo abaratamiento de costes. "El tratamiento de imágenes cubre un amplio espectro de aplicaciones, como detección remota vía satélite, transmisión y almacenamiento de imágenes, procesamiento de radar, robótica, control de calidad y, por supuesto, imágenes médicas" [Pérez et al., 2006].

### **1.13.1. Tipos de imágenes médicas**

"Las imágenes médicas se han convertido en ayuda importante para el profesional de la medicina, tanto en campos especializados como en los no especializados. Es importante ilustrar todo lo referente a los tipos de imágenes que se pueden lograr con la tecnología actual" [Velásquez, 1999]. Estas imágenes se obtienen en formato análogo, por lo cual es necesario digitalizarlas para su proceso. Las más conocidas son:

#### **1.13.1.1. Imágenes radiográficas**

Son imágenes monocromáticas que se adquieren generalmente en formato análogo, al capturar la variación de intensidad espacial de los rayos X en una película. "Ésta ha sido una de las tecnologías más ampliamente utilizadas, y es del común conocimiento de casi toda persona que ha requerido radiografías. Adicionalmente, se llevan placas planas análogas de imágenes radiológicas a un formato digital con el fin de poder almacenarlas y utilizarlas en posteriores lecturas" [Ramírez, 2010].

Huesos y dientes.

- Fracturas e infecciones: En la mayoría de los casos, las fracturas e infecciones en los huesos y dientes aparecen con claridad en las radiografías.
- Artritis: Las radiografías de las articulaciones pueden revelar la presencia de artritis. Las radiografías tomadas a lo largo de los años pueden ayudar a tu médico a determinar si tu artritis está empeorando.
- Osteoporosis: Existen tipos especiales de radiografías que pueden determinar la densidad de los huesos.
- Cáncer de huesos: Las radiografías pueden revelar tumores en los huesos.




Figura 1.30: Imágenes médicas de radiografías para uso dental y quiropráctico. Fuente: Imagen tomada y adaptada de [Ramírez, 2010].

## Tórax

- Infecciones o afecciones pulmonares: Mediante una radiografía de tórax, se puede detectar la presencia de neumonía, tuberculosis o cáncer de pulmón.
- Cáncer mamario: Una mamografía es un tipo de radiografía especial que se utiliza para examinar el tejido mamario.
- Corazón dilatado: Este signo de insuficiencia cardíaca congestiva se ve con claridad en las radiografías.
- Vasos sanguíneos obstruidos: La inyección de medios de contraste con yodo puede ayudar a resaltar algunas partes del aparato circulatorio para que sean visibles en las radiografías.




Figura 1.31: Imágenes médicas radiográficas del tórax, utilizadas para el diagnóstico del virus SAR-COVID 19. Fuente: Imagen tomada y adaptada de [Garzón et al., 2009].

### 1.13.1.2. Tomografía axial computarizada (TAC)

Este tipo de imágenes permiten obtener cortes bidimensionales de cualquier parte del organismo humano sobre la pantalla de un tomógrafo y en una película plana en blanco y negro. La exploración por TAC es, por lo general, el mejor método para detectar varios tipos de cánceres, ya que las imágenes le permiten a su médico confirmar la presencia y determinar el tamaño y ubicación de un tumor. "La TC es rápida, indolora, precisa, y no es invasiva. En casos de emergencia, puede identificar lesiones y hemorragias internas lo suficientemente rápido como para ayudar a salvar vidas" [Garzón et al., 2009].




Figura 1.32: Estudio por imagen mediante TAC en el ictus en la fase aguda. Imagen tomada y adaptada de Boehringer Ingelheim International GmbH © 2020.



### 1.13.1.3. Imágenes por ultrasonido

Estas imágenes se generan al procesar la reflexión recibida de las ondas ultrasónicas. Normalmente son imágenes en blanco y negro de baja resolución. El alcance de los equipos para imágenes diagnósticas, entre los que se encuentra además del ultrasonido, los rayos X, la tomografía computarizada y la resonancia magnética, es profundo, ya que son los responsables de acertar, diagnosticar y contribuir a la definición del tratamiento oportunamente, posibilitando el alivio de las molestias que comprometen el bienestar humano [Paola Paolinelli, 2013].

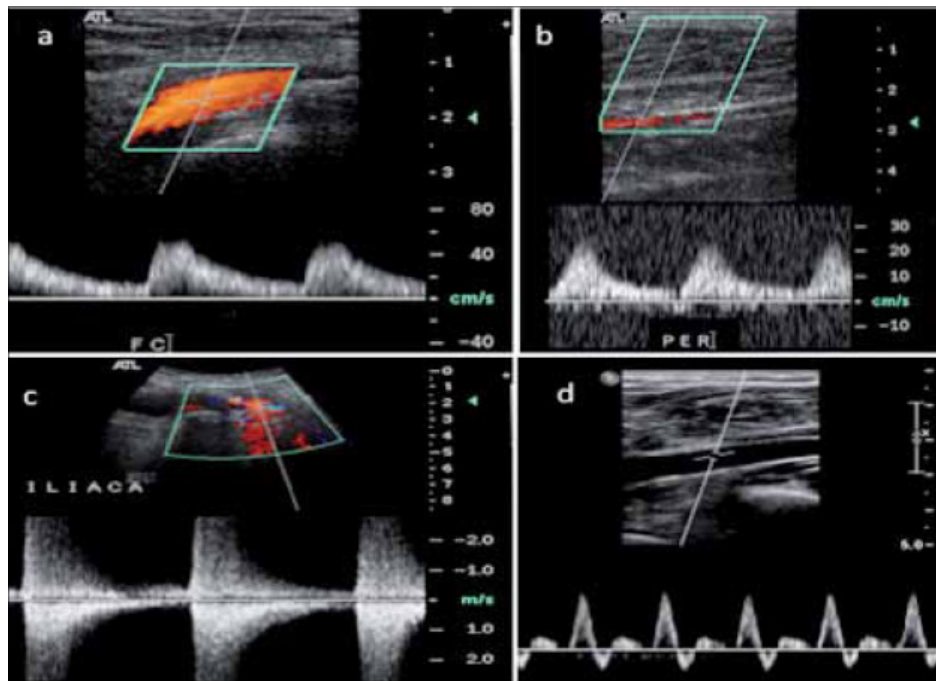


Figura 1.33: Principios físicos e indicaciones clínicas del ultrasonido doppler. Fuente: Imagen tomada y adaptada de [Paola Paolinelli, 2013].

### 1.13.1.4. Imágenes de resonancia magnética (MRI)

Este tipo de imagen se produce al utilizar el spin de los electrones en átomos individuales, con el fin de obtener una imagen de estructuras anatómicas, en blanco y negro con una resolución baja.

”El equipo encargado de crear estas imágenes es la resonancia magnética, conformado por un gran imán con forma de anillo que suele tener un túnel en el centro. Los pacientes se ubican en una camilla que se desliza hacia el interior del túnel” [Vera et al., 2016].

En algunos centros, las máquinas de resonancia son abiertas, es decir que tienen aberturas más grandes y son muy útiles para los pacientes que sufren de claustrofobia.

”Las máquinas de resonancia magnética se encuentran en hospitales y centros radiológicos. En ciertas partes del organismo se prefiere este tipo de imagen a la que resulta de una TAC” [Vera et al., 2016].




Figura 1.34: Examen imagenológico que utiliza imanes y ondas de radio potentes para crear imágenes del cuerpo. Fuente: Imagen tomada y adaptada de [Vera et al., 2016].

### 1.13.2. Clasificación de técnicas

”De entre otras que puedan atender a otros criterios, una posible clasificación de las técnicas de imagen médica hace referencia a en qué etapa se sitúan de una ruta conceptual que va desde el órgano o estructura anatómica o fisiológica a visualizar hasta la interpretación que se puede hacer de lo visualizado” [Yoo, 2004]. El orden en el que se exponen las distintas técnicas de esta clasificación corresponde a su lugar en esa ruta:

- *Formación*: A partir de alguna propiedad física (absorciones, reflexiones, temperaturas, etc.) un sensor recoge la información y la convierte en números binarios (*la digitaliza*). En ocasiones, estos números forman simplemente la imagen; en otras, necesitan un procesamiento laborioso para lograr la imagen. Esta suele ser plana (*2D*) pero también puede ser volumétrica (*3D*).
- *Procesamiento*: Se trata de transformar la imagen original en otra mejorada según determinado objetivo. Esta etapa engloba técnicas como la reducción, eliminación de ruido, mejora de contraste, filtrado, realce de rasgos importantes, detección de bordes y, en una etapa más elevada, la segmentación, detección y aislamiento o registro de los objetos o regiones de interés.
- *Análisis*: Una vez detectados los objetos de interés en la imagen, se procede a un nivel intermedio en el que se crean representaciones simbólicas (*codificación*) y/o cuantitativas (*medición*) de sus estructuras, de forma que se puedan extraer descriptores que los caractericen.
- *Interpretación*: Los niveles anteriores entregan la información a bloques de interpretación de alto nivel de abstracción que, con ayuda de una apropiada base de conocimientos, tratan de interpretar las características para etiquetar los objetos, construir un modelo del mundo observado y llegar a conclusiones, que en el caso de imagen médica, a menudo corresponden a diagnósticos.

Conforme se va avanzando en esta clasificación, las técnicas involucradas son de un mayor nivel de abstracción: desde los fenómenos puramente físicos hasta los conceptos altamente abstractos.

Nivel de abstracción en imágenes médicas			
Etapa	Entrada	Salida	Abstracción
Formación	Fenómenos Físicos	Imágenes digitales	Mínimo: física-electrónica
Procesamiento	Imágenes digitales	Imágenes digitales o representaciones de objetos	Bajo: operaciones con números (usualmente niveles de gris o etiquetas)
Análisis	Representaciones de objetos	Descripciones	Medio: geometrías, texturas, colores, símbolos, etc.
Interpretación	Descripciones	Decisiones	Alto: razonamiento numérico o simbólico

Tabla 1.1: Niveles para el reconocimiento de biomarcadores en imágenes médicas.

Cada etapa puede hacer uso de los resultados de la anterior. Los detalles de cada etapa pueden verse en la Tabla 1.1.

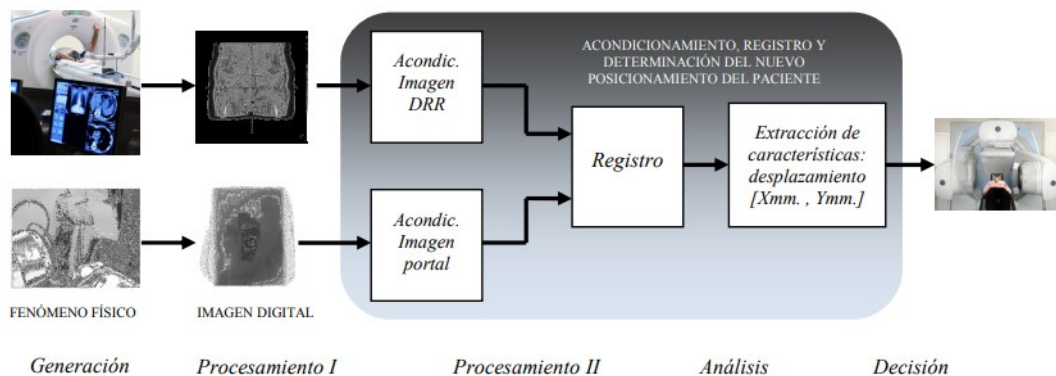


Figura 1.35: Sistema de imagen médica completo en el que se identifican los distintos tipos de técnicas puestos en juego: generación, procesamiento, análisis e interpretación. Fuente: Imagen tomada y adaptada de [Yoo, 2004].

Las imágenes digitales médicas con fines docentes se han convertido en el principal medio con que cuentan las ciencias médicas, ya que reflejan la realidad e incorporan el conocimiento, debido a que se transforman en un nuevo objeto material destinado a comunicar. De esta forma las reproducciones visuales son signos al sustituir al objeto original y presentar sus cualidades necesarias para la comunicación [Marrero Pérez et al., 2016].

## 1.14. Mecanismos visuales del ser humano

### 1.14.1. Ojo

El ojo es para un ser humano un detector de las señales visuales. Efectúa la focalización de las imágenes provenientes del exterior para que la retina pueda recibir la imagen. Esta realiza un pretratamiento de la imagen y enviar la información a la corteza visual a través del nervio óptico y la vida visual en el cerebro. En la Figura 1.36 se muestra los mecanismos básicos de la formación de una imagen sobre la retina.

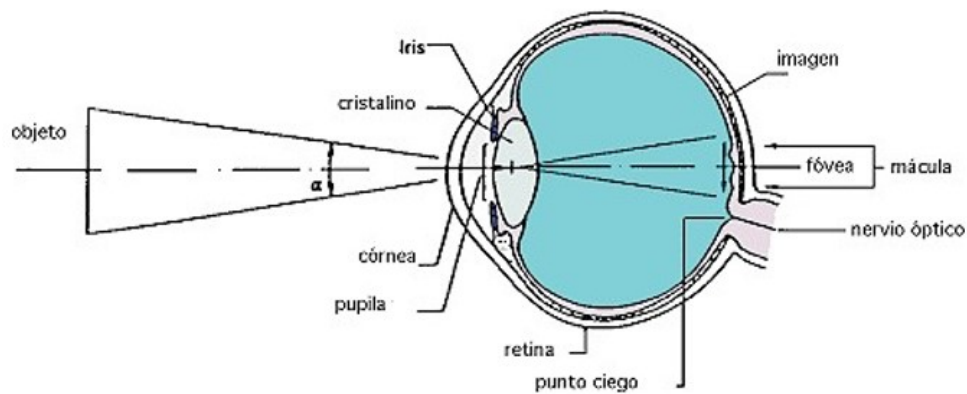


Figura 1.36: Vista esquemática del ojo. Fuente: Imagen tomada y adaptada de Google ®.

La luz pasa a través de la córnea y el humor acuoso antes de penetrar, atravesando la pupila, dentro del cristalino y el humor vítreo. La imagen sufre una refracción debida a todos estos componentes del ojo, antes de que estimule a la retina. Los defectos existentes en el cristalino (existentes aun en personas que tienen una visión normal) producen una aberración esférica que produce imágenes borrosas. Este comportamiento puede considerarse como un filtro pasa bajo bidimensional.

Esta variación puede multiplicar la cantidad de luz que llega a la retina por un factor de 16 para compensar las iluminaciones débiles, pero esta compensación se hace a expensas de la calidad de la imagen retiniana. Esta apertura se puede ver igualmente como un filtro pasa bajo.

”Un agrandamiento progresivo del diámetro produce una frecuencia de corte cada vez más baja. Si la iluminación es suficientemente alta, los fotorreceptores de la retina aumentarían su sensibilidad gracias a una adaptación química y el diámetro de la pupila disminuiría significativamente. Este mecanismo trata de compensar las aberraciones esféricas y cromáticas del ojo y permite que el ojo responda a iluminaciones que comprenden 9 niveles de magnitud” [Simperler and Goldbeck, 2019].

### 1.14.2. Retina

La retina es la capa sensorial del ojo. Ella lleva a cabo la transducción de una señal electromagnética (la imagen) a electroquímica (los impulsos nerviosos) y efectúa un pretratamiento de la información antes de enviarla al cerebro por medio del nervio óptico. ”El tejido retiniano está compuesto de 5 tipos de células que están organizadas en capas. La capa más alejada de la fuente de luz es la capa traductora” [Mansfield and Nunan, 1978]. Esta estructura está compuesta de 2 tipos de células: los conos y los bastones como se puede ver en la Figura 1.37.




Figura 1.37: Representación de los conos y bastones del ojo humano. Fuente: Imagen tomada y adaptada de Google ®.

”Existe alrededor de 130 millones de bastones y 6,5 millones de conos en la retina. Los bastones reaccionan a las formas y las estructuras en movimiento y pueden funcionar con niveles bajos de luminancia (*visión escotópica*). Los conos necesitan niveles elevados de luminancia (*visión fotópica*) y detectan el color y los detalles. Están distribuidos alrededor del eje ocular principalmente” [Mansfield and Nunan, 1978].

En la fovea existen alrededor de 120 conos por grado, lo que da una resolución visual de 1 minuto de arco. Estos 2 tipos de receptores son responsables de la transformación de la luz en señales eléctricas, mientras se efectúa una compresión no lineal del rango dinámico de la señal. ”Esta compresión se puede ver como una curva logarítmica (*ley de Weber-Fechner*), cuando se divide el campo visual con luminancia  $L$  en dos partes y la luminancia de una de estas se incrementa en  $\Delta L$ , hasta que se perciba una diferencia entre las dos partes, la relación

$$\frac{\Delta}{L}$$

se mantiene constante durante grandes variaciones de  $L$ ; para un incremento de la luminosidad percibida  $\Delta B$ , se tiene

$$\Delta B = a \cdot \frac{\Delta L}{L} \tag{1.26}$$

lo que da por integración.

$$B = a \log(L) + b \tag{1.27}$$

Estudios recientes proponen un comportamiento del tipo

$$B = aL^Y \tag{1.28}$$

para escenas complejas, con valores de  $Y = 0.5$  para luminancias de fondo variantes en el tiempo o igual a  $1/3$  para luminancias de fondo estacionarias” [Mansfield and Nunan, 1978].

### **1.14.3. La corteza visual**

La corteza visual primaria ocupa la mayor parte visible de los lóbulos occipitales del cerebro. Está constituida de alrededor de 1010 células organizadas en capas construidas solamente a partir de algunos tipos de neuronas, denominadas neuronas simples, complejas, hipercomplejas e hipercomplejas de orden superior.

Las neuronas corticales "simples" responden a barras luminosas sobre la retina en lugar de responder a discos luminosos.

Estas células se comportan como si su entrada proviniese de muchas células con respuesta del tipo centro-periferia. El campo receptor de este tipo de neurona es elíptico con una respuesta máxima para una orientación específica de luz proveniente de una región particular del campo visual. Si la barra luminosa sufre una rotación, otras células comenzaran a responder de acuerdo con el ángulo de orientación.

A este nivel del sistema visual comienza el procesamiento específico de la información, dependiendo de la orientación de los estimulo. Las células complejas se comportan como si su información proviniera de múltiples células simples, todas con campos receptores de la misma orientación, pero viniendo de localizaciones ligeramente diferentes.

"Las respuestas de las células hipercomplejas son similares, pero además de la orientación específica, debe haber una discontinuidad en su campo receptor, tal como el fin de una línea o una esquina de una figura geométrica" [Hubel and Wiesel, 1979].



La Figura 1.38 muestra la respuesta de estas células a un rectángulo blanco sobre un fondo oscuro.




Figura 1.38: Respuesta de las células corticales a un rectángulo blanco. Fuente: Imagen tomada del trabajo de investigación Brain Mechanisms of Vision [Hubel and Wiesel, 1979]

Un análisis de la corteza muestra una organización en columnas para la dominancia ocular y para la respuesta a la orientación. Un pequeño islote de corteza de 1 mm cuadrado de superficie y 2 mm de espesor puede considerarse como el elemento base de la corteza visual primaria.

El islote contiene un conjunto de hojuelas que corresponden a todas las orientaciones posibles, cuantificadas en treinta direcciones y otro conjunto de hojuelas con dominancia ocular alternadamente izquierda y derecha.

El efecto de la pupila, la aberración esférica del cristalino y la limitación en frecuencia debida al número limitado de fotorreceptores pueden modelarse como un filtro pasa bajas

## 1.15. Herramientas computacionales utilizadas

### 1.15.1. FIJI

Fiji es una distribución del popular software de código abierto ImageJ centrado en el análisis de imágenes biológicas. Fiji utiliza prácticas modernas de ingeniería de software para combinar bibliotecas de software potentes con una amplia gama de lenguajes de secuencias de comandos para permitir la creación rápida de prototipos de algoritmos de procesamiento de imágenes.



Figura 1.39: Fiji es un paquete de procesamiento de imágenes, una distribución de ImageJ. Fuente: Imagen tomada del trabajo [Schindelin et al., 2012]

”Fiji facilita la transformación de nuevos algoritmos en complementos de ImageJ que se pueden compartir con los usuarios finales a través de un sistema de actualización integrado” [Schindelin et al., 2012].

### 1.15.1.1. Trainable Weka Segmentation

”Las herramientas de segmentación entrenables de código abierto, como el complemento de Segmentación de Weka entrenable para ImageJ, combina una colección de algoritmos de aprendizaje automático con un conjunto de características de imagen seleccionadas para producir segmentaciones basadas en píxeles con el uso de algoritmos supervisados de aprendizaje automático se estudia el conjunto de entrenamiento en píxeles que han sido anotaciones de clase asignadas manualmente y usa un clasificador para discriminar de manera confiable entre estas clases” [Arganda-Carreras et al., 2017a].



Figura 1.40: Logo de entrenable Weka Segmentación de la Universidad de Waikato, Nueva Zelanda. Fuente: Imagen tomada del trabajo [Arganda-Carreras et al., 2017b]

El objetivo principal de este complemento es trabajar como un puente entre los campos *Machine Learning* e *Image Processing*. Proporciona el marco para usar y, lo que es más importante, compara cualquier clasificador disponible para realizar la segmentación de imágenes en función de la clasificación de píxeles; se puede considerar el contexto de cada píxel (p. Ej., Intensidad, Textura, Bordes, Entropía), lo que hace que el clasificador sea más robusto para los artefactos de imagen y los cambios de intensidad. ”Después del entrenamiento, se puede guardar un clasificador y utilizarlo para realizar una segmentación objetiva y repetible de grandes cantidades de imágenes procesadas de manera similar ” [O’Mara et al., 2017].

### 1.15.2. MATLAB

”Es una herramienta de software matemático (abreviación de MATrix LABoratory, “laboratorio de matrices”) que ofrece un entorno de desarrollo integrado (IDE) con un lenguaje de programación propio (lenguaje M), basado en matrices que es la forma más natural del mundo para expresar las matemáticas computacionales” [Thompson and Shure, 2009].




Figura 1.41: Logo de MATLAB®, Fuente: Imagen tomada de Google®

MATLAB combina un entorno de escritorio perfeccionado para el análisis iterativo y los procesos de diseño con un lenguaje de programación que expresa las matemáticas de matrices y arrays directamente.

---

# Capítulo 2

## Estado del Arte

En este capítulo se expondrán los trabajos de investigación recopilados y analizados que sirvieron como base para el desarrollo del proyecto, algunos antecedentes relevantes dentro del estudio clínico sanguíneo, el procesamiento digital de imágenes médicas, así como también técnicas de visión artificial en el área clínica, estas dos últimas siendo herramientas utilizadas dentro del área de inteligencia artificial (*IA*).

Los artículos contextualizarán los procesos de investigación que ayudaron a trabajar la problemática planteada, esto dentro del procesamiento de imágenes médicas, así como la implementación de herramientas computacionales en el área médica.

### 2.1. Antecedentes

Durante la segunda guerra mundial los avances en el área de la detección temprana sobre enfermedades sanguíneas comenzaron a ser relevantes, destacando resultados sobresalientes en trabajos de investigación que desarrolló Helen Mackay en Viena después de la Segunda Guerra Mundial, un hecho que hizo pensar a los investigadores sobre la implementación de tecnología en el diagnóstico de estas enfermedades, ya que la detección de problemas sanguíneos dependía de la agudeza y astucia de los ingenieros químicos y clínicos, una arte estrictamente empírica aún pensando en los avances alcanzados hasta ese momento.

Sin embargo, recientemente se han empezado a entender los aspectos morfológicos de la sangre y patológicos de la misma, esto debido al desarrollo tecnológico con el que contamos hoy en día. En una visión a través de la ingeniería biomédica y las tecnologías emergentes, encontramos herramientas que permiten el estudio superficial e invasivo para el diagnóstico y tratamiento de nuevas enfermedades, es por esto, que la sangre aún siendo un tejido de fácil acceso, ha complicado su integración en procesos tecnológicos modernos, como lo es la Inteligencia Artificial (IA), para poder caracterizar el significado fisiológico de la misma.

## **2.2. Antecedentes tecnológicos sobre la obtención de las características sanguíneas**

Para comenzar con este análisis de investigación, un proyecto de gran importancia realizado por el Instituto de Hematología e Inmunología en el año 2000 titulado *"Utilización de la sangre y sus componentes celulares"* donde el Dr. Lázaro Cortina y la Dra. María del Rosario López nos hablan de los beneficios de la transfusión de componentes celulares como un éxito al tratamiento de problemas hematológicos. "Ya que se han podido comprobar que la refractariedad a la administración de plaquetas ayuda en la hemoterapia" [Cortina Rosales and López De Roux, 2000].

*La técnica de transdiferenciación* desarrollada en el laboratorio del Dr. Wernig durante el 2010, que junto con Koji Tanabe y Cheen Ang, coautores del estudio, demostraron que podían convertir células de piel de ratón en neuronas de roedor sin inducir primero a las células a convertirse en pluripotentes -etapa del desarrollo flexible desde la cual las células pueden convertirse en cualquier linaje celular. "Pero existen numerosos desafíos, particularmente para los investigadores que desean estudiar trastornos mentales genéticamente complejos" [Pang et al., 2011].

*La fotomicrografía* se utiliza desde el siglo XIX para la investigación biológica siendo un apoyo de la visión artificial, entre los pioneros en su uso se encuentra Roman Vishniac y hasta finales del siglo XX era habitual acoplar cámaras SLR al microscopio óptico para obtener las micrografías, sin embargo con el desarrollo del microscopio electrónico se ha conseguido la obtención de imágenes con mayores ampliaciones y con la llegada de la fotografía digital se han desarrollado instrumentos específicos. "La aplicación científica de la fotomicrografía no se limita al estudio y diagnóstico clínico y biológico, sino que abarca campos como la metalografía y otras aplicaciones industriales" [Vishniac, 2012].

En el 2002, tres publicaciones científicas fueron altamente favorables para obtener características sanguíneas en seres humanos, ya que estas han demostrado la existencia de una célula sanguínea capaz de regenerar el hígado y el músculo del corazón. Esto a través del uso de visión artificial y procesamiento de imágenes, obtenidas con rayos x y resonancia magnética, estos hechos han sido corroborados y se ha acuñado el término de "*transdiferenciación*" para definirlos. Un aporte tecnológico sin precedentes [Núñez Espinosa, 2015].

El Dr. Marius Wernig, profesor asociado de Patología y miembro del Instituto Stanford de Biología de Células Madre y Medicina Regenerativa dice: "*La sangre es una de las muestras biológicas más fáciles de obtener*" [Tanabe et al., 2018]. Esta técnica es un avance que abre la posibilidad de aprender de procesos complejos de enfermedades mediante el estudio de un gran número de pacientes.

### **2.3. Aplicaciones de visión artificial**

"La visión por computadora es la capacidad de la máquina para ver el mundo que le rodea, para deducir la estructura y las propiedades del mundo tridimensional a partir de una o más imágenes bidimensionales" [Gonzalo Pájares, 2002].

La implantación de habilidades en una máquina como la de detectar y determinar la identidad de los objetos.

En el 2012, la Mtra. Lola Xiomara publicó en la revista "Gerencia Tecnológica Informática" un sistema computacional para la detección de glóbulos rojos en imágenes microscópicas de células sanguíneas con el fin de brindar soporte al proceso de lectura visual que realiza el especialista por lo cual propuso una metodología de detección basada en el uso de la conceptualización matemática de la visión artificial, a través del diseño e implementación de operadores bajo el paradigma de la programación orientada a objetos. Esto con el fin de brindar otro aporte importante al estudio de la sangre.

En el año 2013 el Ing. Asiel Osorio Valladares desarrolló una metodología en detección de anomalías para imágenes biomédicas mediante el uso de regiones sobresalientes en pruebas de Papanicolaou y de detección de leucocitos en imágenes hematológicas, utilizando herramientas computacionales en el área de visión artificial y procesamiento de imágenes, en donde se lograron estudiar dos métodos de segmentación: "el algoritmo de medidas desplazadas y la transformada de watershed, obteniendo resultados aceptables" [Osorio Valladares, 2013].

En la Universidad Carlos III de Madrid, España el Dr. Juan Carlos Cobos desarrolló un sistema que permite la medición de signos vitales mediante técnicas de visión artificial, el cual se detalla una revisión sistemática de la supervisión de signos vitales. También se analizan los aspectos y conceptos relevantes para la medición de signos vitales mediante técnicas de visión artificial. "Además, se identifican los puntos débiles de los sistemas de medición actuales basados en técnicas de visión artificial. Sobre esta base, desarrollamos algunas soluciones y mejoras para optimizar las medidas" [Torres and Abderrahim, 2018].



El Ing. Justiel Pizarro desarrollo un sistema de clasificación de diferentes formas eritrocitarias mediante el uso de visión artificial y redes neuronales profundas donde menciona: "Que la observación morfológica eritrocitaria tiene un gran valor de diagnóstico, ya que puede ser indicio de diferentes patologías" [Justel Pizarro, 2019]. Por lo que la implementación de un algoritmo automatizado con la capacidad de clasificar adecuadamente y con fiabilidad imágenes de diferentes tipos de células utilizando la técnica de transferencia para aprendizaje con fast.ai, para de esta manera optimizar el tiempo de costo computacional al no utilizar Redes Neuronales Convolucionales. Como podemos darnos cuenta con el apoyo de herramientas computacionales podemos revolucionar el camino de la detección estable y progresiva.

El área de visión artificial se apoya de manera estructurada por otras áreas, como el cómputo evolutivo, es por esto que el trabajo publicado en el 2015 por el Dr. Diego Alberto Oliva Navarro fue aplicar algoritmos metaheurísticos en 3 áreas de aplicación como procesamiento de señales, visión artificial y energías alternativas. Además, para algunas de estas aplicaciones se proponen modificaciones a los AM, con el fin de mejorar su rendimiento.

Utilizando los siguientes algoritmos metaheurísticos: el primero de ellos es el algoritmo *electromagnetism-like (EMO)* usado dentro del proyecto para diseño de filtros *IIR*, donde los parámetros de los filtros se estiman mediante un proceso de optimización; detección de glóbulos blancos en imágenes médicas, aquí el proceso de identificación de leucocitos es analizado desde el punto de vista de la optimización, donde se involucra el uso de la estrategia de aprendizaje conocida como Opposition-Based Learning. De igual manera involucra otros dos métodos, el algoritmo *Harmony Search (HSA)* y el algoritmo *Artificial Bee Colony (ABC)* implementando en las mismas 3 áreas de estudio [Oliva Navarro, 2015].

## 2.4. Aplicaciones de salud en el campo del procesamiento digital de imágenes

Dentro de esta área en específico se concentra gran parte de nuestra investigación, ya que como se menciona en el capítulo 1, el proyecto se centra en desarrollar una metodología sólida y bien sustentada dentro del campo en procesamiento de imágenes médicas, para poder adquirir biomarcadores en cada imagen incidida con la luz de rayo láser y de esta manera observar el efecto de absorción de este tipo de luz por parte de la hemoglobina.

Esto con el fin de poder ver los cambios de absorción en la hemoglobina para cada sujeto de muestra, de esta manera se tomaron en cuenta proyectos que enfocan su investigación a lo que se plantea.

Uno de estos proyectos es el publicado en el año 2007 por la revista de IEEE de avances tecnológicos para la humanidad, que lleva por título "Non-Invasive Estimation of Hemoglobin in Blood Using Color Analysis" [Srinivasan et al., 2006], por medio del cual se logra la estimación no invasiva de hemoglobina en sangre mediante análisis de color, usando el método matemático de regresión lineal en específico.

Por lo que podemos decir que la utilización de redes neuronales (*ANN*) y el procesamiento de imágenes para el tratado estadístico de los datos es un seguimiento favorable para la metodología planteada en el artículo, el proyecto estuvo a cargo del Dr. Srinivasan del departamento en electrónica e ingeniería en comunicaciones de la Universidad de Sathyabhama, en Chennai, India, un proyecto que estudia principios muy similares de estudio con el proyecto planteado.

En la revista IEEE de avances tecnológicos para la humanidad, se publicó una investigación en el año 2012, durante el segundo encuentro portugués de bioingeniería titulado: Los efectos de las técnicas de procesamiento de imágenes médicas en la hemodinámica computacional, donde se habla sobre el uso de estas tecnologías para el reconocimiento de enfermedades que afectan al sistema cardio vascular incluyendo una variedad de trastornos y afecciones que se relacionan con la hemodinámica de la sangre, a cargo del Dr. Ana J. Joao del CEMAT, departamento de matemáticas del Instituto Superior Técnico, en Lisboa, Portugal [João et al., 2012].

De igual manera, el Dr. Carlos Óscar Segura Sorzano, Director Técnico del Centro Instruct de Procesamiento de Imágenes y Prof. en la Univ. San Pablo – CEU publico una investigación en el año 2015 titulada: "Visualizando máquinas Macromoleculares" [Segura et al., 2017] en la cual menciona que nuestro cuerpo está compuesto de unos 80 billones de células y que cada una de esas células contiene alrededor de 2.500 millones de proteínas.

Lo que equivale a que tenemos un millón de veces más proteínas en nuestro cuerpo que la edad del universo expresada en segundos, eso sin contar las proteínas de nuestras compañeras bacterianas que conviven pacíficamente, por lo que el uso de microscopios electrónicos permiten obtener información.

Los ingenieros, físicos y matemáticos deben establecer las ecuaciones que describen cómo se forman las imágenes en el microscopio a partir de la interacción del haz de electrones con la materia, y diseñar algoritmos de procesamiento de imágenes y datos que permitan extraer la escasa información presente en cada fotografía. Para que de esta manera tengamos un diagnóstico más preciso y anticipado.

Durante la Conferencia Internacional sobre Computación de Energía, Información Energética y Comunicación del año 2016, se publicó un proyecto a cargo de la revista IEEE de avances tecnológicos para la humanidad, titulado: Detección de células de poilocitos en la anemia por deficiencia de hierro mediante una red neuronal artificial, en la cual se utilizan técnicas en reconocimiento de patrones, utilizando los datos obtenidos del procesamiento de imágenes micrográficas para detectar los cambios morfológicos de las células sanguíneas.

”Esto a través del uso de redes neuronales para la clasificación de las mismas, proyecto a cargo de la Dra. Megha Tyagi de la Escuela de Ingeniería Biomédica, en el Instituto Nacional de Tecnología, de Kurukshetra, India” [Rana et al., 2018].

Para el 2015, en la revista Panorama de Investigación en la Ingeniería Biomédica publico un trabajo nombrado: Imágenes y reconocimiento de patrones para el diagnóstico hematológico a cargo del Dr. José Rodellar, director del grupo, dinámica y aplicaciones de la Universidad de Catalunya, donde él nos explica la necesidad de poder visualizar de mejor manera las neoplasias hematológicas que constituyen un grupo de enfermedades cancerígenas que afectan a la sangre.

De esta manera se plantea un sistema multidisciplinario que relaciona la Ing. Biomédica con el área hematológica a través de herramientas matemáticas, utilizando técnicas de segmentación y clasificadores de agrupación (*clustering*), lógica difusa, contornos activos, transformada watershed.

”Permitiéndole analizar en las imágenes formas, contornos y relieves (*granulometría*). Lo que le permitiría clasificar estas imágenes con lo que conocemos como aprendizaje automático” [Rodellar et al., 2018].

En este trabajo titulado: *"Un enfoque no invasivo para la estimación de la hemoglobina analizando el flujo sanguíneo en la palma"* publicado el año del 2017 en la revista del Instituto de Ingenieros Eléctricos y Electrónicos, se menciona la importancia de estimar los porcentajes de hemoglobina para el diagnóstico de anemia, ya que es un gran problema de salud pública.

En él se propone un dispositivo de enfoque portátil, fácil de usar, no invasivo y rentable basado en visión artificial y procesamiento de imágenes médicas aprovechando la medida del enrojecimiento de la piel en la palma. Una cámara captura el video de la palma de un sujeto humano antes y después de restringir el flujo sanguíneo a la palma usando un manguito de esfigmomanómetro en el antebrazo cerca de la muñeca.

El video continúa hasta que se libera el flujo sanguíneo después de una liberación repentina y rápida de presión en el brazalete. Al medir el enrojecimiento del color de la piel después de la oclusión y después de la reanudación del flujo sanguíneo a la palma, proponemos un clasificador basado en regresión para predecir el contenido de hemoglobina de la sangre [Santra, 2018].

Para este trabajo publicado en *"Estudio comparativo entre el árbol de decisiones, SVM y KNN para predecir la condición anémica"* en el año 2019 por Nahiyan Bin Noor, un proyecto que vuelve a mencionarse la importancia del estudio para la estimación de porcentajes de hemoglobina en la sangre, está vez para poder enfermedades sanguíneas, por medio de un total de 104 personas (54 hombres y 50 mujeres) son recolectadas con su nivel clínico de hemoglobina en sangre, condición anémica e imagen de conjuntiva palpebral tomada. Donde se toman imágenes micrograficas para utilizar procesamiento de imágenes junto con clasificadores como SVM KNN [Noor, 2019].

Es por todos estos trabajos brillantes que el hecho de desarrollar una metodología para la caracterización de imágenes médicas con incidencia de luz láser que propicie la absorción del mismo por efectos físicos ya comprobados, exaltaría el hecho de verificar los diferentes porcentajes de hemoglobina, por medio de procesos computacionales y herramientas matemáticas supone un proyecto multidisciplinario que se adapte perfectamente con los retos de la ingeniería biomédica y la inteligencia artificial con buenos alcances en el área de investigación.

## **2.5. Propiedades ópticas de los tejidos**

Los principios físicos de la interacción de los fotones con los tejidos para entender el comportamiento de la luz cuando los atraviesa. Hablamos de los procesos de absorción y esparcimiento. Estos dos sumados forman el proceso de atenuación, de igual manera la propiedad óptica conocida como índice de refracción.

### **2.5.1. Interacción de la luz con el tejido**

Son muchos los mecanismos de interacción entre luz y tejidos. Algunas interacciones que alteran la estructura y composición de los tejidos son las siguientes. El mecanismo fotoquímico es el proceso que trata la absorción de luz por las moléculas presentes o añadidas en los tejidos. "El térmico produce efectos biológicos debido a la deposición de energía térmica en el tejido. Este efecto se utiliza ampliamente en la cirugía con láser" [Meyer-Arendt, 1989].

El mecanismo electromecánico ocurre a muy altas razones de flujo, induce a la formación de plasma. La expansión rápida como la del plasma genera una onda de choque la cual puede romper el tejido. En tomografía óptica se escogen las razones de flujo lo suficientemente pequeñas para que estos tipos de cambios destructivos no ocurran en los tejidos.

Por lo tanto, solo consideramos la absorción lineal e invariante en el tiempo y las interacciones de esparcimiento de luz.

La propagación de luz dentro de los tejidos en términos de flujo de fotones. Con esta perspectiva, la fuente de luz inyecta un número dado de fotones por unidad de tiempo, por unidad de volumen, por unidad de ángulo sólido en una posición específica del tejido. Estos fotones viajan dentro del tejido a lo largo de ciertas trayectorias.

Conocemos al movimiento de los fotones a través de estas trayectorias como migración de fotones. Mientras los fotones viajan dentro de los tejidos pueden experimentar diferentes procesos, como absorción, esparcimiento elástico, esparcimiento inelástico (Raman), fluorescencia, entre otros. Cuando un fotón es absorbido desaparece transfiriendo su energía al centro absorbente [Meyer-Arendt, 1989].




Figura 2.1: Mecanismos de interacción entre luz y tejidos. Fuente: Imagen tomada del trabajo [González et al., 2012]

”Cuando un fotón es esparcido elásticamente cambia su dirección de propagación, mientras que su longitud de onda permanece inalterada. Por el contrario, procesos como esparcimiento Raman y fluorescencia ocasionan que la longitud de onda del fotón se alargue debido a la implicación de los niveles de energía vibracionales” [Meyer-Arendt, 1989]. En el trabajo de investigación nos enfocamos en los dos primeros procesos para explicar la incidencia de la luz láser. La absorción y el esparcimiento son dos fenómenos que afectan el paso de luz a través de los tejidos, ocasionando una disminución de la intensidad.

”Ambos procesos, absorción y esparcimiento, son importantes. Juntos los consideramos atenuación. En tejidos el esparcimiento es el proceso dominante. Aun cuando se trata de tejidos delgados, es decir, algunos milímetros, es probable que los fotones inyectados sean esparcidos varias veces antes de que alcancen a llegar a la meta” [Meyer-Arendt, 1989].

La absorción y el esparcimiento son dependientes de la longitud de onda. Además la concentración de algunos absorbentes (*cromóforos*) varía con el tiempo, esto se refleja en cambios fisiológicos del tejido. La hemoglobina, muestra un estado de oxigenación dependiente del perfil de absorción. El índice de refracción varía muy poco en la escala macroscópica y típicamente su valor está alrededor de 1.40 para la mayoría de los tejidos.

### **2.5.2. Absorción**

Cuando la radiación de luz incide en materia que está compuesta por cargas eléctricas discretas, las cargas se ven obligadas a oscilar a la frecuencia del campo eléctrico incidente. ”El intervalo de frecuencias de la radiación infrarroja del espectro electromagnético ( 300 THz-300 GHz) es comparable a la frecuencia natural a la cual los átomos o moléculas vibran en ausencia de un campo aplicado” [Tuchin, 2002].



Así, cuando incide radiación infrarroja en la materia ocurre resonancia alrededor de la frecuencia natural. Esta energía es transferida del campo incidente al sistema (materia) y se incrementa fuertemente la amplitud de vibración. Aunque la vida media del estado excitado es de  $10^{-7}$  a  $10^{-8}$  segundos, los átomos o moléculas usualmente pierden su energía por colisiones entre los unos y otros, más o menos en  $10^{-12}$  segundos.

De este modo alcanzan energías cinéticas de las otras partículas involucradas en las colisiones. Por lo tanto, "la energía asociada con el campo incidente se disipa, a menudo, como calor dentro del medio. Este proceso se conoce como absorción" [Tuchin, 2002].

La absorción es el proceso de la transferencia de energía de la radiación incidente al tejido circundante. Cuando un medio no esparcidor se ilumina con un rayo de luz colimado de intensidad  $I_0$ , como se ilustra en la ecuación 2.1, y de longitud de onda  $\lambda$ , la intensidad de la luz emergente está dada por:

$$I = I_0 e^{-\mu_a d} \quad (2.1)$$

En la ecuación anterior  $\mu_a$  se refiere al coeficiente de absorción del medio y  $d$  es el grosor de la muestra [Tuchin, 2002].




Figura 2.2: Atenuación de la luz a través de un medio no esparcidor. Imagen tomada del trabajo [Tuchin, 2002]

---

# Capítulo 3

## Metodología

En este capítulo se describe la metodología implementada en el procesamiento de imágenes médicas, obtenidas por medio del sistema de adquisición propuesto.

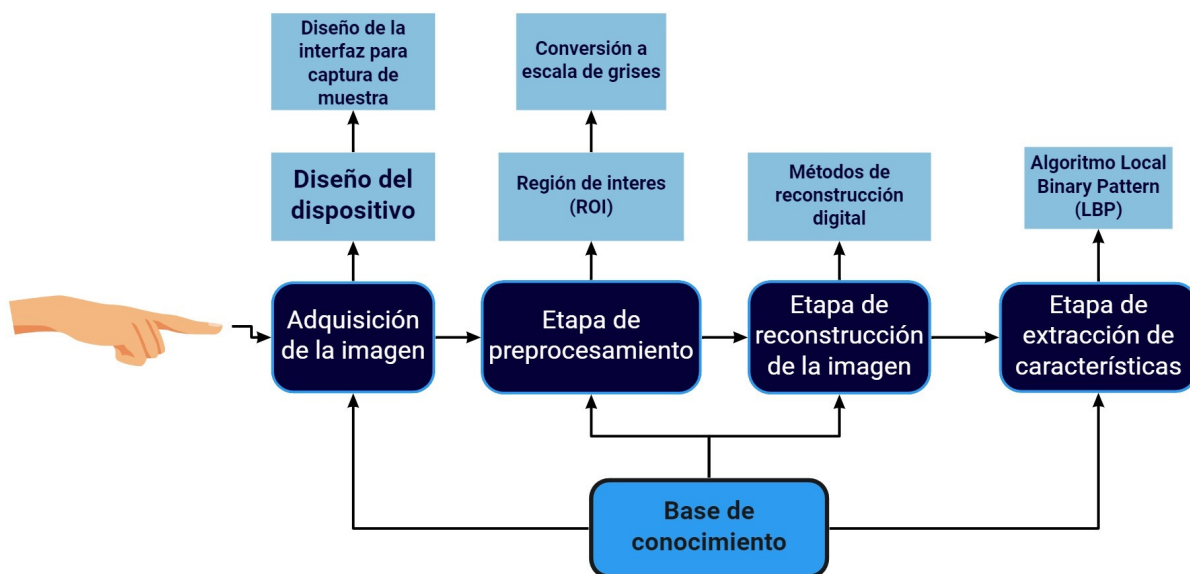


Figura 3.1: Esquema de la metodología propuesta. Fuente: Elaboración propia.

En la Figura 3.1 se esquematizan los métodos y procesos utilizados en el proyecto; en las secciones consecuentes se describirán cada uno de estos procesos.

### 3.1. Metodología general de la propuesta

El propósito esencial de este trabajo es desarrollar una propuesta metodológica en el campo del procesamiento de imágenes médicas y visión artificial, desde un punto de vista computacional.

Se enfoca en una base sólida de conceptos físicos, métodos matemáticos y algoritmos computacionales que permitan visualizar el cambio de absorción de luz láser incidente en el dedo índice debido a la hemoglobina. Las etapas realizadas son:

1. Adquisición de la imagen.
2. Etapa de preprocesamiento.
3. Etapa de reconstrucción digital.
4. Extracción de características.

El proceso permitió obtener biomarcadores (*características*) en estas imágenes, lo que supone un proyecto multidisciplinario que se adapte perfectamente con los retos de la ingeniería biomédica y el área en ciencias de la computación.

Los criterios de diseño en ingeniería y el fuerte conocimiento del tratamiento computacional en bioinformática son sólidos fundamentos en las áreas de biología, medicina, etc.

Por lo tanto, estas tecnologías emergentes son herramientas que permiten el estudio superficial (no invasivo). Identificando cada una de las etapas metodológicas con los objetivos del proyecto y con las bases del conocimiento referenciadas, se realizó un tratamiento óptimo a las imágenes médicas obtenidas.

## 3.2. Adquisición de imagen

Etapa considerada dentro del primer nivel de procesamiento llamado visión de bajo nivel, ya que la asociaremos con procesos primarios que no consideran las reacciones automáticas basadas en inteligencia artificial. Se consideran dos procesos dentro de este apartado:

1. Captura de la imagen por medio del dispositivo propuesto.
2. Interfaz de captura diseñada en el software *MATLAB*®.

### 3.2.1. Captura de la imagen por medio del dispositivo propuesto

El primer proceso de captura para la imagen, se llevó a cabo por medio de un dispositivo adaptado a los requerimientos para la toma de muestras, esto por medio de un diseño propuesto que permite adquirir una toma controlada de la incidencia de luz láser en el dedo índice.



Figura 3.2: Prototipo del dispositivo para la captura de muestras. Figura: Elaboración propia.

Como se puede ver en la Figura 3.2, se muestra el prototipo del dispositivo propuesto, que nos permite obtener una toma controlada de efecto que propicia la incidencia de luz láser a través del dedo índice.

Este diseño nos permite controlar el ruido ambiente que es generado al incidir diferentes haces de luz durante la toma experimental, siendo esta la razón principal por la cual se decidió generar este prototipo.




Figura 3.3: Imágenes de la estructura del prototipo para la obtención de muestras. Fuente: Elaboración propia.

Como se observa en la Figura 3.3 el dispositivo cuenta en su interior con un módulo de luz láser, que apunta al dedo en un ángulo de  $45^\circ$  y una base acolchonada que permite posicionar el dedo en su interior.

Es de esta manera es como el prototipo nos permite obtener imágenes estables de la incidencia láser en el dedo índice.

El dispositivo cuenta con una cámara web que le permite tomar la muestra del individuo, la cual tiene las siguientes características::

- Sensor de alta definición 1080p
- Objetivo de vidrio de alta precisión
- Resolución de imagen: 5 Mpx
- Modos de foco: Manual
- Resolución máxima de imagen: 2880 x 1620
- Sensor de imagen: CMOS

La Figura 3.4 muestra una imagen de la cámara web antes mencionada, este dispositivo fue elegido debido a que cuenta con un sensor de píxeles activos (*CMOS*), el cual detecta la luz ambiente para regular la resolución de la imagen, la tecnología *CMOS* integra un corrector de contraste que permite tomar muestras con incidencia directa de luz láser, lo que nos permite una toma estable del efecto de incidencia antes mencionado.



Figura 3.4: Cámara web Microsoft® HD Life cam. Imagen proporcionada por Microsoft®. Fuente: Elaboración propia.

### 3.2.2. Interfaz de captura diseñada por el software MATLAB

El desarrollo de la interfaz para la captura de muestras se realizó en *MATLAB*®, un entorno de programación lógico matemático que a través de la herramienta llamada *GUIDE*, es posible diseñar interfaces de usuario (*UIs*).

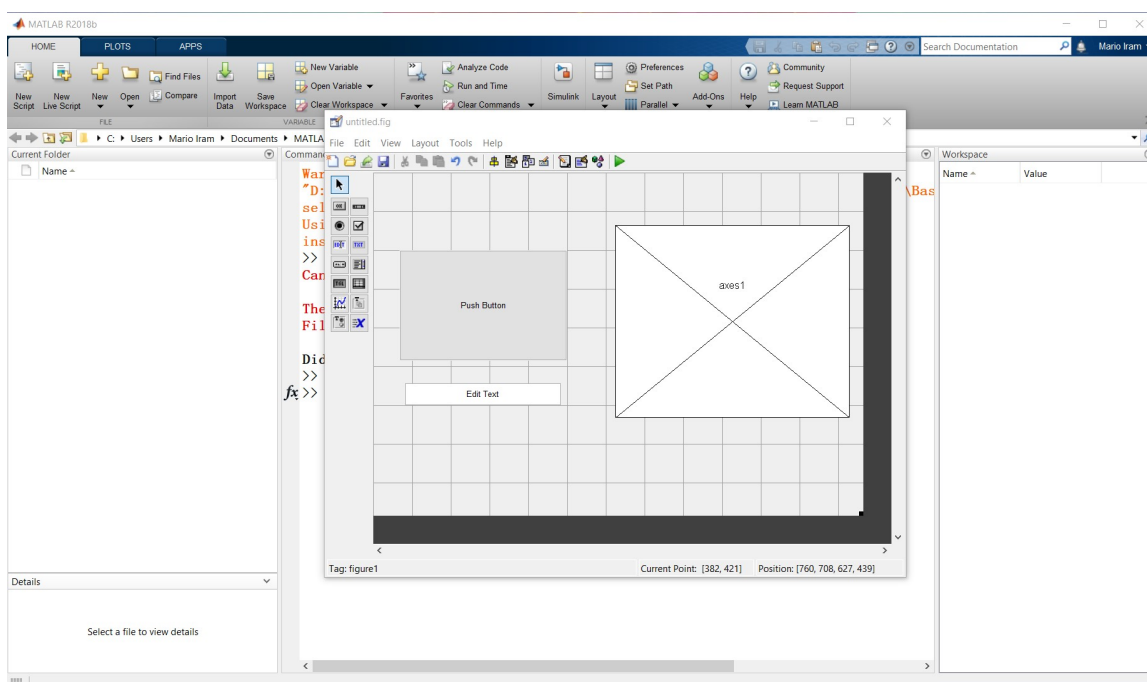


Figura 3.5: Imagen de la interfaz de MATLAB durante la configuración de una interfaz guide. Imagen proporcionada por MATLAB®. Fuente: Elaboración propia.

El desarrollo de la interfaz nos permite utilizar el monitor de la computadora como un panel de observación, para determinar si la posición en la que se tomara la muestra es la correcta, al igual que agregar ciertos datos a la toma, por ejemplo: id del paciente, grupo sanguíneo o género. La Figura 3.5 muestra una captura de como fue parte del proceso de elaboración de la interfaz utilizada.

### 3.3. Etapa de preprocesamiento

”En aplicaciones del área médica, el procesamiento de imágenes es considerado un paso vital para la creación de un sistema de diagnóstico” [Cerquin et al., 2017]; de manera que este sistema pueda asistir al médico especialista actuando como una segunda opinión, esto como uno de sus múltiples usos.

Para este proyecto, una de los procesos cruciales dentro del procesamiento de imágenes es la etapa de preprocesamiento, ya que permite procesar la información obtenida de las imágenes de forma óptima; ayudando en aspectos como:

- Corrección de deficiencias en la adquisición de datos para resultados satisfactorios en etapas posteriores [Yasser, 2010].
- Reducción o eliminación del nivel de ruido contenido en la imagen [Pandey et al., 2016].

Por lo cual el proyecto propone realizar dos apartados en esta etapa, donde se obtendrá la región de interés (*ROI*) de la imagen obtenida por el prototipo, para posteriormente convertir esta imagen *RGB* en formato original de captura a una imagen en escala de grises.

#### 3.3.1. Región de interes (*ROI*)

Una región de interés (*ROI*) es la zona de una imagen en la que desea llevar a cabo los métodos de filtrado y reconstrucción digital. MATLAB nos permite obtener este elemento utilizando la caja de herramientas que admite un conjunto de objetos de *ROI* que puede utilizar para recortar esta región de muchas formas, como círculos, elipses, polígonos, rectángulos y formas dibujadas a mano.



Después de la creación, puede utilizar las propiedades del objeto de ROI para personalizar su apariencia y funcionamiento. En la Figura 3.6 podemos ver la forma en la que se utilizó esta herramienta en MATLAB.

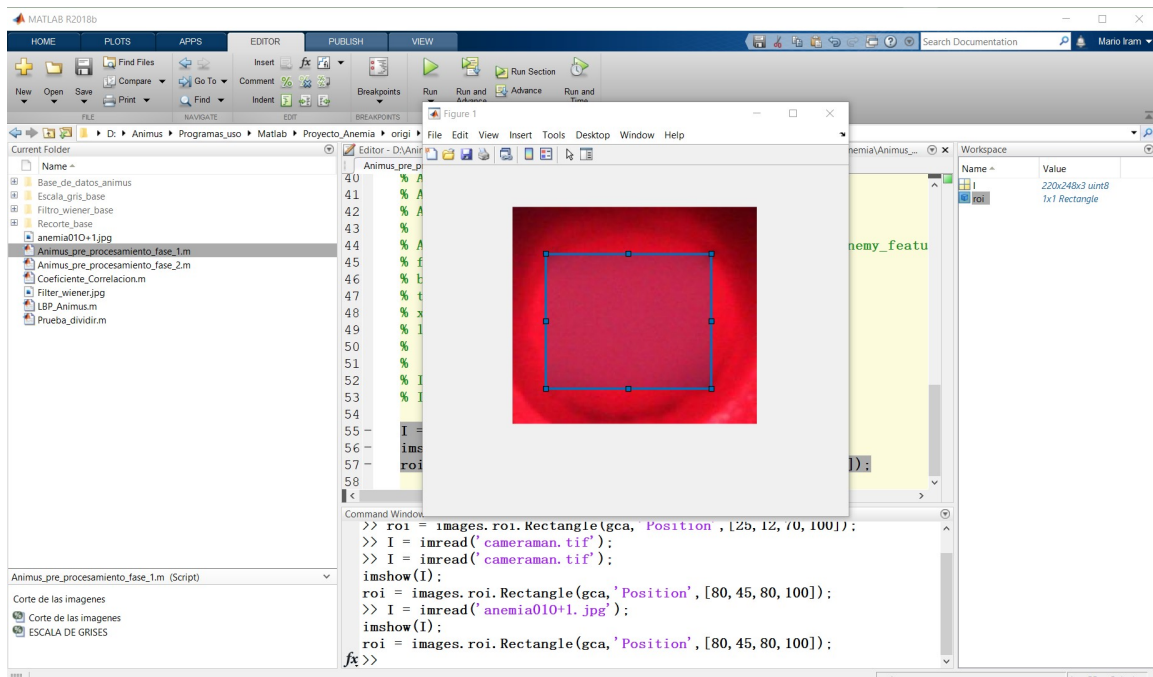


Figura 3.6: Manejo de la herramienta ROI en las imágenes de la base de datos. Fuente: Elaboración propia.

En este caso la zona de interés para nosotros será la zona central del dedo indicé, donde se encuentra la uña. Esto debido a que es una zona que nos permite ver la concentración de la luz láser absorbida por la hemoglobina contenida en la estructura sanguínea.

En este proceso de obtener la región de interés, se optó por desarrollar un algoritmo que nos permitiera extraer de manera automática el *ROI* en cada una de las imágenes, de esta manera el proceso sería más práctico.

### 3.3.2. Conversión de RGB a escala de grises

Una imagen en *RGB* se representa combinando luz de color rojo, verde y azul dentro del amplio espectro visible, resaltando los estudios de Sir. Isaac Newton al ver que la luz se descompone en estos 3 colores primarios, esta es la razón por la cual a una imagen obtenida por un dispositivo digital (*cámara*) se identifica como una imagen *RGB*.

Por otra parte, una imagen o escala de grises utiliza distintos tonos de gris en una imagen. En imágenes de 8 bits, puede haber hasta 256 tonos de gris. Cada píxel de una imagen en escala de grises tiene un valor de brillo comprendido entre 0 (*negro*) y 255 (*blanco*).

En la Figura se puede ver un ejemplo del proceso de conversión de una imagen *RGB* a escala de grises en *MATLAB*®.

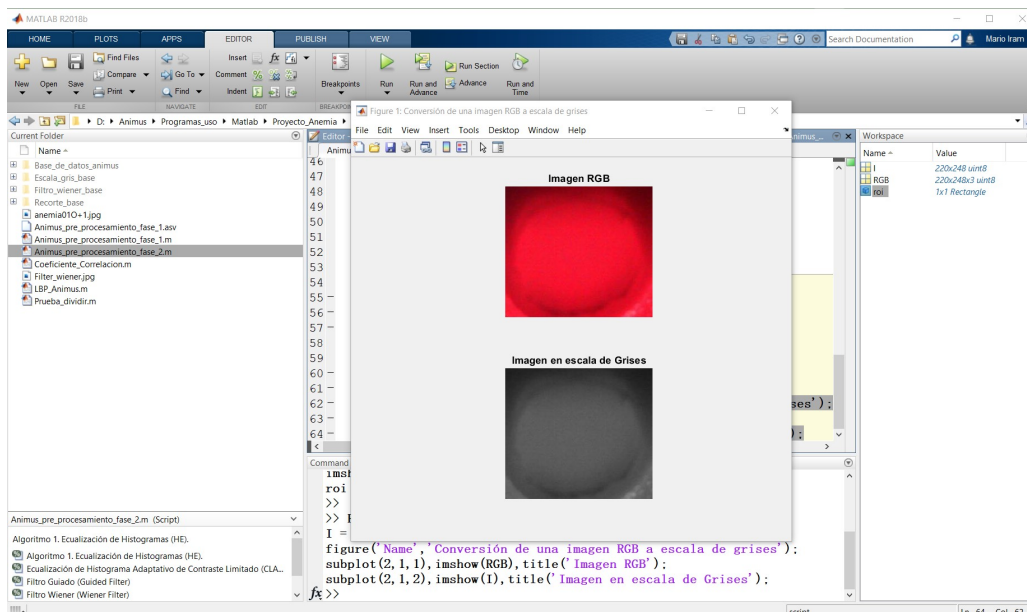


Figura 3.7: Conversión de una imagen RGB a escala de grises con MATLAB. Fuente: Elaboración propia.

Se menciona lo anterior, debido a que el interés de llevar a cabo una conversión de una imagen *RGB* a escala de grises, principalmente a tener la misma luminancia (*luminancia relativa técnica*) que la imagen de color original (*según su espacio de color*). Además de la misma luminancia (*relativa*), este método también asegura que ambas imágenes tendrán la misma luminancia absoluta en pocas palabras podemos decir que son imágenes estables y generan menor ruido que analizar durante el procesamiento de las imágenes. Otra razón fue en cuantificar las diferentes intensidades de los grises al igual que es un proceso estándar durante el *PI*.

### **3.4. Etapa de reconstrucción de la imagen**

En esta sección se presentan la revisión y análisis de los métodos encontrados en la literatura, los cuales son adecuados al caso de estudio. Realizándose posteriormente el análisis de los resultados de la implementación en el capítulo siguiente.

Considerando que los métodos seleccionados preservaran detalles importantes (*bordes, textura, intensidades de píxeles, etc.*) de la imagen obtenida; para obtener una imagen con mayor calidad. Esta etapa se desarrolló con el manejo de 4 experimentos, cada experimento utilizando un método de reconstrucción de imágenes:

- Experimento 1. Ecuación de Histograma.
- Experimento 2. Histograma Adaptativo Ecuado (CLAHE).
- Experimento 3. Filtro Guiado.
- Experimento 4. Filtro de Wiener.

### 3.4.1. Método de Ecuación de Histograma (HE)

Este método se basa en el histograma obtenido a partir de la imagen del dedo índice iluminado con luz láser.

Como se mencionó en el capítulo 2, un histograma es la representación gráfica de cómo se encuentran distribuidos los píxeles de la imagen de acuerdo con su intensidad.

De acuerdo con [Ikhsan et al., 2014], "HE es el tercer método con mayor precisión en cuanto a la magnificación de contraste para imágenes incididas por luces entre el rango de 600 nm a 650 nm", lo que nos permite utilizar este método en el proyecto, ya que el láser que utilizamos tiene una longitud de onda 630 nm. A continuación se muestra el pseudocódigo del método de ecuación por histograma implementado en el proyecto.

---

**Algoritmo 1** Pseudocódigo del algoritmo (HE)

---

**Entrada:** Imagen con incidencia de luz láser de la región de interés (ROI)

**Salida:** Imagen ROI filtrada imagen\_respuesta

- 1: imagen ROI\_original;
  - 2: imagen ROI\_gris  $\leftarrow$  convertir imagen escalaGris(imagen ROI\_original);
  - 3: histograma  $\leftarrow$  cálculo del histograma getHistograma(imagen\_gris);
  - 4: Normalización  $\leftarrow$  funcionNormalizacion(histograma);
  - 5: Ecuación  $\leftarrow$  ecuacionHistograma(histograma);
  - 6: imagen\_respuesta  $\leftarrow$  sustituir nivel gris getNivelGris(ecuación)
-

### 3.4.2. Ecualización de Histograma Adaptativo de Contraste Limitado (CLAHE)

Este método de acuerdo con la literatura [Ikhsan et al., 2014], [Majumdar and Kumar, 2014] "ha demostrado tener resultados satisfactorios en cuanto a precisión en el preprocesamiento de imágenes, lo que se traduce nuevamente como eliminación de ruido a través del estudio computacional". La diferencia entre el HE es que este método considera el contraste global de la imagen, en muchos casos, no es una buena idea, debido a que si hay más píxeles brillantes que oscuros, el resultado sería una imagen con mucho contraste (blanca). Mientras que el CLAHE divide la imagen en pequeños bloques llamados "mosaicos" (8x8 por defecto en OpenCV). Luego, cada uno de estos bloques se ecualiza con el histograma, este proceso se puede ver en el pseudocódigo de la parte inferior.

---

**Algoritmo 2** Pseudocódigo del algoritmo (CLAHE)

---

**Entrada:** Imagen con incidencia de luz láser de la región de interés (ROI)

**Salida:** Imagen ROI filtrada imagen\_respuesta

- 1: imagen ROI\_original;
  - 2: imagen ROI\_gris  $\leftarrow$  convertir imagen escalaGris(imagen ROI\_original);
  - 3: dividir en celdas la imagen grid(imagen\_gris, nro\_bins);
  - 4: **for** k=0 **do** **Entrada:** Inicializar histograma de cada celda  
Evaluar cada celda de la imagen.
  - 5:     **while** K  $\leftarrow$  nro\_bins **do** **hacer**  
      K = k + 1  
      histograma  $\leftarrow$  getHistograma(imagen\_gris)  
      cdf  $\leftarrow$  función de distribución acumulativa cdf(histograma)  
      ecualización  $\leftarrow$  ecualizacionHistograma (histograma, cdf)
  - 6: **Fin**
  - 7: Imagen\_respuesta  $\leftarrow$  sustituir nivel gris getNivelGris(ecualización)
-

### 3.4.3. Filtro Guiado (Guided Filter)

Este método se puede ejemplificar en el pseudocódigo de la parte inferior, de acuerdo a [Kazemini et al., 2015] y [El Mezeni and Saranovac, 2016] es considerado uno de los métodos de preprocesamiento más completos para la eliminación de ruido y detección de bordes en una imagen. Por otro lado, [He et al., 2016] indica que es mejor que el filtro bilateral en la preservación de bordes, ya que no tiene limitaciones de inversión de gradiente y lo más importante es su costo computacional.

---

**Algoritmo 3** Pseudocódigo algoritmo Filtro Guiado

---

**Entrada:** Imagen con incidencia de luz láser de la región de interes (ROI)

**Salida:** Imagen ROI filtro Guiado\_respuesta

- 1: imagen\_original  $\leftarrow$  imagen ROI\_original  
imagen\_Guia  $\leftarrow$  imagen ROI\_original;
  - 2: imagen\_gris\_original  $\leftarrow$  convertir imagen escalaGris(imagen\_original)  
imagen\_gris\_guia  $\leftarrow$  convertir imagen escalaGris(imagen\_guia)
  - 3: promedio\_imagen\_original  $\leftarrow$  filtro\_promedio(imagen\_gris\_original)  
promedio\_imagen\_guia  $\leftarrow$  filtro\_promedio(imagen\_gris\_guia)
  - 4: correlacion\_imagen\_original  $\leftarrow$  filtro\_promedio(imagen\_original)  
correlacion\_imagen\_original\_guia  $\leftarrow$  filtro\_promedio(imagen\_original, imagen\_guia)
  - 5: varianza  $\leftarrow$  varianza entre la correlación y el promedio de la imagen guía
  - 6: covarianza  $\leftarrow$  covarianza entre la correlación de la imagen original y la imagen guía con el promedio de la imagen original y la imagen guía
  - 7: imagen\_original\_aux  $\leftarrow$  filtro\_promedio(varianza) imagen\_guia\_aux  $\leftarrow$  filtro\_promedio(covarianza)
  - 8: imagen\_respuesta  $\leftarrow$  imagen\_original\_aux \* imagen\_original + imagen\_guia\_aux
-

### 3.4.4. Filtro Wiener (Wiener Filter)

El filtro Wiener de acuerdo a [Wang et al., 2008] es más efectivo que el filtro de mediana (*Median Filter*) no solo en áreas de baja frecuencia, sino también en áreas con alta frecuencia, adicionalmente preserva bordes mientras elimina ruido.

A diferencia del filtro mediana; [Wang et al., 2008] indica que el filtro Wiener no solo es efectivo con ruido de impulso sino también con ruido gaussiano. Este filtro nos permite de igual manera eliminar parte del ruido aun existente en la imagen.

---

**Algoritmo 4** Pseudocódigo algoritmo Filtro Guiado

---

**Entrada:** Imagen con incidencia de luz láser de la región de interes (ROI)

**Salida:** Imagen ROI filtro wiener\_respuesta

- 1: imagen\_original  $\Leftarrow$  imagen ROI\_original
  - 2: imagen\_gris  $\Leftarrow$  convertir\_imagen\_escalaGris(imagen\_original)
  - 3: imagen\_estimada  $\Leftarrow$  estimación(imagen\_gris)  
error  $\Leftarrow$  error\_medio\_cuadratico\_min(imagen\_gris, imagen\_estimada)
  - 4: calcular el espectro de potencia de ruido de la imagen estimada
  - 5: calcular el espectro de potencia de la imagen original
  - 6: imagen\_respuesta  $\Leftarrow$  sus\_nivelgris(imagen\_estimada, imagen\_original)
- 

## 3.5. Índice PSNR

Para analizar la calidad de la imagen de respuesta, después de aplicar cada uno de los métodos de pre procesamiento se revisó la literatura y se utilizó la métrica Peak signal-to-noise ratio (*PSNR*). El *PSNR* es calculado generalmente en escala logarítmica; es un uso métrico para medir la calidad de cualquier imagen reconstruida, restaurada o corrompida con respecto a su imagen de referencia o imagen ground truth.

Por consiguiente, las imágenes de entrada cumplen con las características antes mencionadas debido a que las imágenes capturadas con el dispositivo propuesto, carecen de nitidez respecto a su imagen de referencia. De este modo, un PSNR alto significa buena calidad de la imagen y un *PSNR* bajo significa mala calidad de la imagen.

Cabe mencionar que el PSNR está usando un término denominado Error Cuadrático Medio (*MSE*) en el denominador. Por lo tanto, si es bajo el error (*MSE*), alto será el *PSNR*. Definido como se muestra a continuación utilizando la intensidad de señal máxima  $S_{max}$  y el error cuadrático medio *MSE* para la imagen degradada y la imagen de referencia.

$$PSNR = 10 \log_{10} \left( \frac{S^2_{max}}{MSE} \right) \quad (3.1)$$

Así, el *PSNR* se define como en la ecuación 3.1, donde max denota el máximo valor que puede tomar un píxel en la imagen. Para una imagen en formato *RGB*, la definición del *PSNR* es la misma, pero el *MSE* se calcula como la media aritmética de los MSEs de los tres colores (*R*, *G* y *B*).

Los valores típicos que adopta este parámetro están entre 30 y 50 dB, siendo mayor cuanto mejor es la codificación. El uso más habitual del PSNR es como medida cuantitativa de la calidad de la reconstrucción en el ámbito de la compresión de imágenes.



## 3.6. Extracción de características

Para este proceso, se utiliza el algoritmo *LBP* ya que en una imagen puede proveer información invaluable al momento de identificar objetos presentes en ésta, como se puede ver en la Figura 3.8 el proceso de trabajo llevado a cabo por medio del algoritmo *LBP*. El sistema de visión humano no sólo puede distinguir objetos basándose en el color; también puede distinguir la textura.

La principal característica de la textura es la repetición de un patrón o de varios patrones contenidos en una región. El patrón puede repetirse exactamente, o puede comportarse como un conjunto de pequeñas variaciones, esto lo realiza posiblemente como una función de posición.

Un simple y nuevo modelo de textura es el LBP [Ojala et al., 2000], "el cual ha demostrado ser un método adecuado para analizar texturas en imágenes monoespectrales".

El *LBP* se ha convertido en una medida de la textura de una imagen, mostrando excelentes resultados en términos de precisión y complejidad computacional. Para el proyecto, el operador *LBP* puede ser visto como un acercamiento unificador hacia los modelos estadísticos y los modelos estructurales del análisis de texturas.

Tomando como referencia lo anterior, el algoritmo *LBP* se utiliza para encontrar en la imagen las diferentes escalas o intensidades de grises contenidas en cada uno de los píxeles, lo que nos permitirá obtener los biomarcadores que se encuentran en las imágenes de la base de datos. El proceso del algoritmo LBP dará como resultado un vector con 255 valores. Un ejemplo de lo antes mencionado se ilustra en la Figura 3.9.

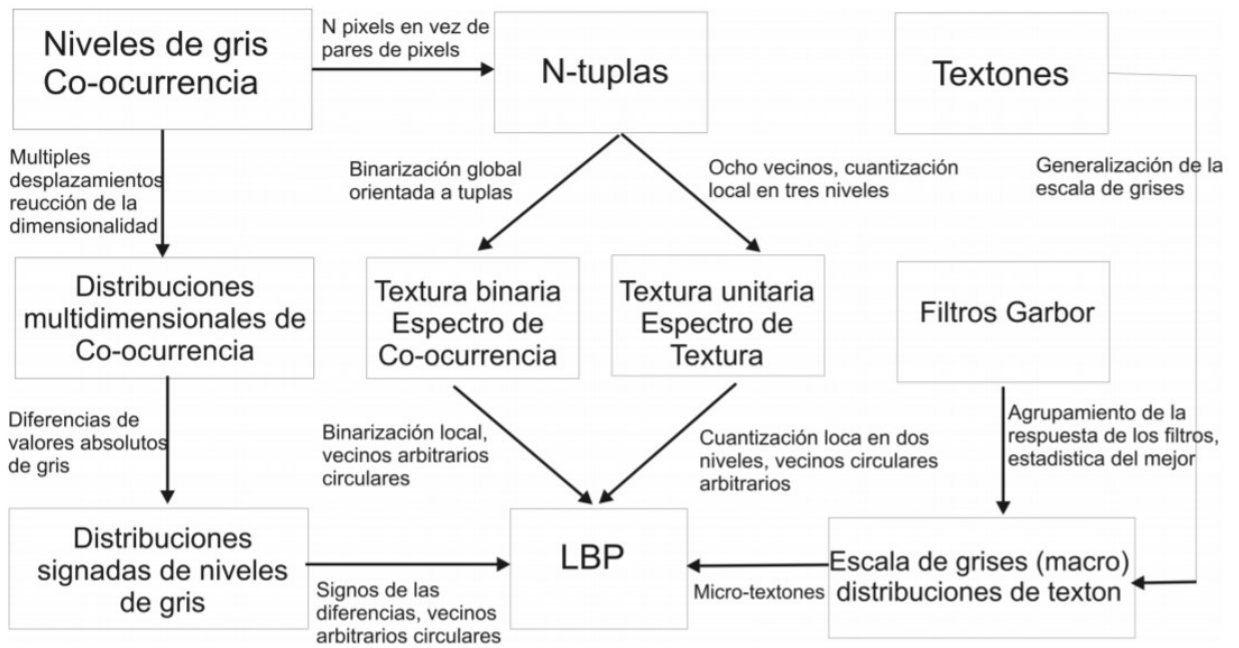


Figura 3.8: Relaciones del operador LBP con otros métodos de textura. Imagen proporcionada por MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>

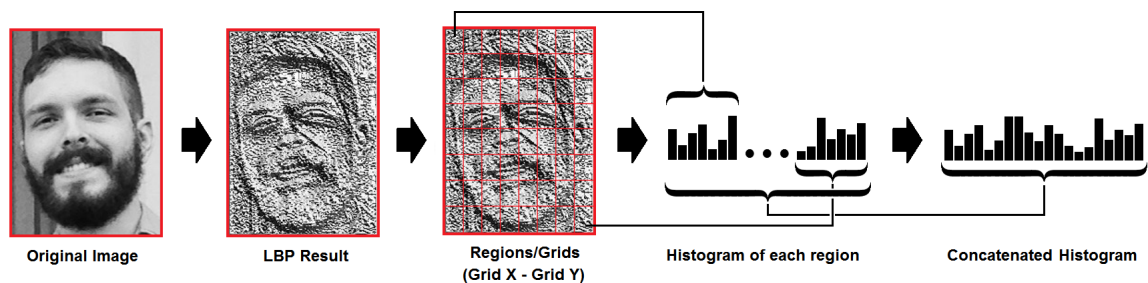


Figura 3.9: Esquema del proceso de trabajo del algoritmo LBP. Imagen proporcionada por MATLAB®. URL: <https://la.mathworks.com/products/matlab.html>

---

# Capítulo 4

## Análisis de resultados

En el presente capítulo se detallan los resultados de cada una de las etapas implementadas en la investigación, como lo son: etapa de adquisición de la imagen, etapa de preprocesamiento, etapa de reconstrucción de la imagen y etapa de extracción de características.

Las herramientas utilizadas para desarrollar cada una de las etapas del proyecto, contaron con las siguientes características:

1. Computadora: Procesador *Intel(R) Core(TM) i7-9750H CPU @ 3.90 GHz 4.50 GHz*, una Memoria RAM de *8GB*, Tarjeta gráfica *NVIDIA GeForce GTX 1650* y sistema operativo de *64 bits Windows 10 premium*.
2. **MATLAB** <sup>®</sup> es un sistema de cómputo numérico que ofrece un entorno de desarrollo integrado (IDE) con un lenguaje de programación propio (lenguaje M).

## 4.1. Etapa de adquisición de la imagen

Los resultados pertinentes a esta etapa serán proporcionados por el prototipo propuesto, así como el uso de la interfaz desarrollada en *MATLAB*. Esta etapa como se mencionó en el capítulo anterior es considerada dentro del primer nivel de procesamiento llamado: visión de bajo nivel.

Sin embargo, es de suma importancia adquirir una excelente toma del proceso de absorción que infringe la incidencia de luz láser en el dedo índice, ya que como se ha mencionado en el capítulo 2, este es el efecto físico entre fotones y tejido, que nos ayuda a entender el comportamiento de absorción que tiene la hemoglobina.

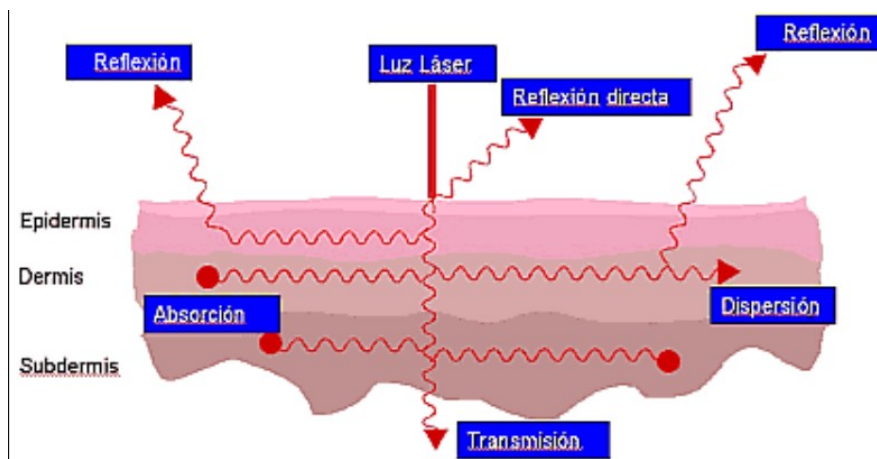


Figura 4.1: Mecanismos de interacción entre luz y tejidos. Fuente: Imagen tomada del trabajo [González et al., 2012]

En la Figura 4.1 se observa el efecto físico que provoca la incidencia de luz láser a tejido vivo, al igual que el nivel celular en donde se da el proceso de absorción. Hay que destacar que este es uno de los procesos físicos más estudiados con teorías sumamente sustentado por grandes científicos e investigadores.

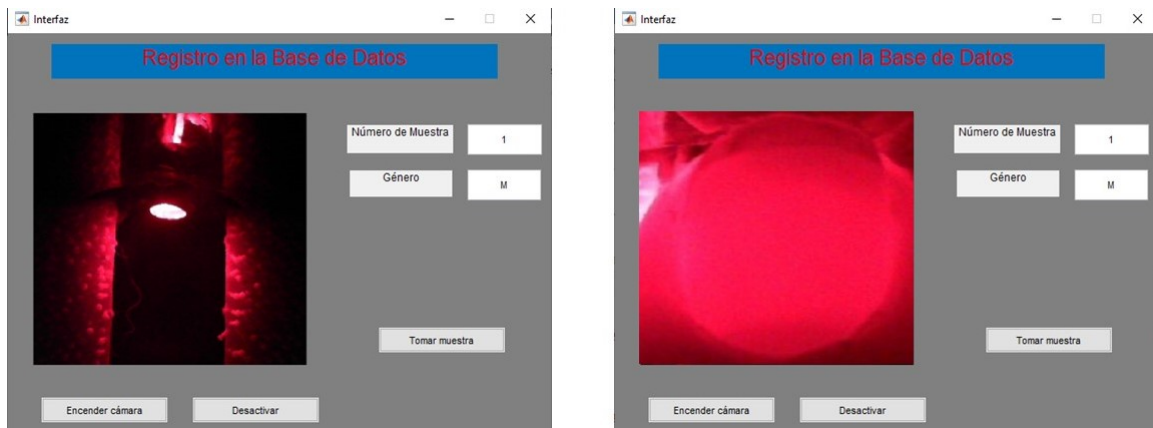


Figura 4.2: Vista de la interfaz desarrollada en MATLAB® e interior del dispositivo. Fuente: Elaboración propia.

En la Figura 4.2 se aprecia la interfaz desarrollada en *MATLAB*, donde se puede observar que solo hay la incidencia de la luz láser en el dedo índice del sujeto, por lo que se tiene una toma controlada y estable, haciendo que el proceso de la Figura 4.1 se cumpla.




Figura 4.3: Captura del dispositivo propuesto. Fuente: Elaboración propia

En la Figura 4.3 se muestra la captura obtenida por el prototipo propuesto. Por otra parte, esta etapa nos proporciona un total de 870 imágenes de 29 pacientes a la base de datos.

Durante el proceso para el llenado de la base de datos, también se contemplaron algunos aspectos de los individuos como su edad, grupo sanguíneo, género, si estaba llevando alguna dieta y si hacen ejercicio los días que le dedicaban, esto con el fin de poder hacer una relación entre estos datos y los resultados que se obtendrían de la investigación. A continuación se muestra la tabla de 20 personas participantes en el proceso de investigación.

Número de muestra	Edad	Género	Grupo sanguíneo	Ejercicio físico	Dieta
1	25	H	ORh+	5 días a la semana	no
2	27	H	ORh+	no	no
3	27	H	ARh+	no	no
4	23	H	ORh+	5 días a la semana	si, sin consumo de azúcares
5	26	M	ORh+	5 días a la semana	si
6	23	M	ORh+	5 días a la semana	si
7	24	H	BRh+	2 días a la semana	no
8	25	H	ORh+	3 días a la semana	no
9	21	M	ARh+	5 días a la semana	si
10	35	H	ARh+	no	no
11	27	M	ORh-	no	no
12	37	M	ARh-	no	no
13	38	H	ORh+	no	no
14	25	H	ORh+	5 días a la semana	no
15	28	M	ORh+	5 días a la semana	no
16	21	H	ORh+	7 días a la semana	no
17	41	M	ARh+	2 días a la semana	no
18	26	H	ORh+	no	si
19	38	H	BRh+	no	no
20	40	M	ORh+	no	si

También se desarrolló el formato de consentimiento informado, esto con el fin de que cada uno de los voluntarios supiera los términos en los cuales se usaría la información proporcionada para la investigación.



**EDUCACIÓN**  
SECRETARÍA DE EDUCACIÓN PÚBLICA

TECNOLÓGICO NACIONAL DE MÉXICO  
INSTITUTO TECNOLÓGICO DE LEÓN  
"Ciencia Tecnología, Libertad"



## CARTA DE CONSENTIMIENTO PARA LA RECOLECCIÓN DE MUESTRAS PARA TESIS EN MAESTRIA DE CIENCIAS COMPUTACIONALES

**Título del estudio: "Aplicación de Técnicas de Inteligencia Artificial para el reconocimiento de patrones en imágenes médicas en la clasificación de Anemias."**

**Nombre del Investigador Principal:**

Mario Iram García Quezada.  
Estudiante de maestría del TECNOLÓGICO NACIONAL DE MÉXICO  
Maestría en Ciencias de la Computación  
LACIT Edificio nuevo de posgrado  
mario.iram.gq@gmail.com

**Institución de Procedencia:**

Tecnológico Nacional de México  
Instituto Tecnológico de León División de  
Estudios de Posgrado e Investigación

**Área:** Laboratorio de Creatividad e  
Innovación Tecnológica

**Asesor:**

David Asael Gutiérrez Hernández Ph.D.  
Jefe de la División de Estudios de Posgrado  
TECNOLÓGICO NACIONAL DE MÉXICO  
Edificio nuevo de posgrado  
david.gutierrez@itleon.edu.mx

**Entidad participante:**

Tecnológico Nacional de México  
Instituto Tecnológico de León

---

**Propósito del estudio:** Caracterizar imágenes micrográficas a través de procesos computacionales y modelos matemáticos, con el propósito de extraer información que permita establecer propiedades para la clasificación de anemias con deficiencia de hierro en adolescentes.

**Razones por las que le pedimos participar:**

Le pedimos participar en este estudio ya que la anemia es una enfermedad que afecta a países desarrollados como también a los no desarrollados por lo tanto es un problema de salud pública. Por lo cual la investigación aportaría un avance en materia de detección temprana en enfermedades sanguíneas, de esta manera podríamos llegar a un cuidado solamente nutricional.

**Justificación del proyecto.**

La implementación de técnicas basadas en inteligencia artificial para la automatización clínica de ciertos padecimientos o enfermedades, las cuales siguen un patrón de detección son usadas en equipo médico para aminorar el error humano es por esto; que desarrollar un perfil de detección a partir de un análisis estadístico en su estructura inicial, complementándolo con un clasificador en su estructura final para la toma de decisión lo colocaría como una herramienta que complementaría el trabajo clínico, para que de esta manera se mejoren los tiempos de revisión hematológica pertinentes y por consiguiente realizar análisis especializados que requieren de un cuantioso tiempo de espera, esto lograría auxiliar al personal médico, pacientes y hospitales que se verán beneficiados.

La investigación aportaría un avance en materia de detección temprana en enfermedades sanguíneas, de esta manera podríamos llegar a un cuidado solamente nutricional.

### **Procedimientos del estudio**

El procedimiento de la investigación es de carácter no invasivo, por lo cual esto quiere decir que no se tomarán muestras biológicas (muestras de sangre o tejido) a las personas que participen en el proyecto. Para el presente proyecto no se presentan incomodidades corporales para el individuo ya que se cuenta con un prototipo de diseño hermético para toma de la muestra, lo que implicaría que el individuo no presentara ninguna incomodidad ni antes o después de la prueba.

### **Criterios a tomar por el participante.**

Tiempo estimado para toma de muestra: 1 a 2 minutos.

Metodología: no invasiva

Edad: indistinta

Alergias: indistinta

Enfermedades: sin problema para la toma de muestra.

Rasgos físicos: Uñas sin esmalte o dañadas preferentemente.

**De igual manera cabe destacar que la decisión de participar en este estudio es completamente voluntaria y no habrá ninguna consecuencia desfavorable en caso de no participar.**

### **Pasos para la toma de muestra.**

En este apartado mencionaremos detalladamente los pasos a seguir para la toma de muestras, de igual manera la forma en que usted podrá participar en él. Por favor consulte, con el investigador principal o con cualquier persona del estudio, cualquier duda que pueda tener.

Paso 1.- En este primer paso hacemos preparación de los equipos a utilizar en la prueba, al ser una prueba no invasiva, los dispositivos a implementar son un computador y el dispositivo para la captura de muestra. Lo cual se le pedirá al participante se relaje y espere unos minutos al encendido de los equipos, que demorará unos 5 minutos.

Paso 2.- Para este segundo paso se procederá a indicarle al participante que introduzca el dedo índice de su mano derecha o izquierda, esto claro dependiendo de su afinidad a sus extremidades inferiores (derecho o zurdo), y mire la pantalla del computador para indicarle la posición en la cual se debe encontrar su dedo índice para la toma de la muestra.

Paso 3.- En este tercer paso se le indicará al participante a quedarse quieto por no más de 4 segundos, esto para que la toma no tenga ningún movimiento en cuanto a la posición de su dedo índice, de esta manera la muestra podrá ser utilizada.

Paso 4.- En este último paso se le indicará al participante a retirar su dedo índice del equipo, esto con el fin de que el encargado de la toma verifique que la imagen es correcta para su uso en la presente investigación.

**Participación Voluntaria/ Retiro del estudio:** *Su participación en este estudio es absolutamente voluntaria. Usted está en plena libertad de decidir qué muestras son las que está de acuerdo en proporcionar o de negarse a participar o de retirar su participación en el estudio en el momento en que desee.*



## Formulario de Consentimiento

Yo \_\_\_\_\_, nacido en \_\_\_\_\_, declaro que he leído y comprendido el presente documento y que mis preguntas han sido respondidas satisfactoriamente; por lo tanto, doy mi consentimiento informado para participar en la investigación llamada **“Aplicación de Técnicas de Inteligencia Artificial para el reconocimiento de patrones en imágenes médicas en la clasificación de Anemias.”**. Estoy de acuerdo en que mi nombre, edad y otros datos antropométricos sean almacenados. Sé que puedo retirarme del experimento en cualquier momento.

**Por favor marque cada uno de los recuadros de abajo para indicar su decisión**

**Mis muestra/ puede ser utilizada solo para este estudio.**

**Mis muestra/ puede ser utilizada para investigaciones futuras.**

**Mis muestras pueden ser almacenadas en un banco de muestra**

## Declaración del Investigador

Yo certifico que le explicado al participante la naturaleza y el objetivo de la investigación, y que el participante entiende en consiste la participación, los posibles riesgos y beneficios implicados. Todas las preguntas que esta persona ha hecho le han sido contestadas en forma adecuada. Así mismo, he leído y explicado adecuadamente las partes del consentimiento informado.

**Aviso de Privacidad Simplificado:** El investigador Mario Iram García Quezada funge como el principal responsable de este estudio, es responsable del tratamiento y resguardo de los datos personales que nos proporcione, los cuales serán protegidos conforme a lo dispuesto por la **Ley General de Protección de Datos Personales en Posesión de Sujetos Obligados**. Los datos personales que le solicitaremos serán utilizados exclusivamente para las finalidades expuestas en este documento. Usted puede solicitar la corrección de sus datos o que sus datos se eliminen de nuestras bases o retirar su consentimiento para su uso. En cualquiera de estos casos le pedimos dirigirse al investigador responsable del proyecto a la siguiente dirección de correo [mario.iram.gq@gmail.com](mailto:mario.iram.gq@gmail.com).

## 4.2. Etapa de preprocesamiento

En esta etapa se busca procesar la información obtenida de las imágenes de una forma más fácil, por lo que en el capítulo 2 se menciona que desarrollaremos dos apartados en esta etapa, en el primero se obtendrá la región de interés (*ROI*) de la imagen obtenida, para posteriormente convertir esta imagen *RGB* a una imagen en escala de grises para el segundo apartado.

En el primer apartado se utiliza el método llamado procesamiento basado en *ROI*, por medio de *MATLAB*, que nos permite delimitar por zonas la imagen que nosotros estemos utilizando, a través de los llamados: objetos *ROI*, que son funciones y eventos objetivos para implementar una selección interactiva, de esta manera podremos seleccionar la región que nos interesa analizar.

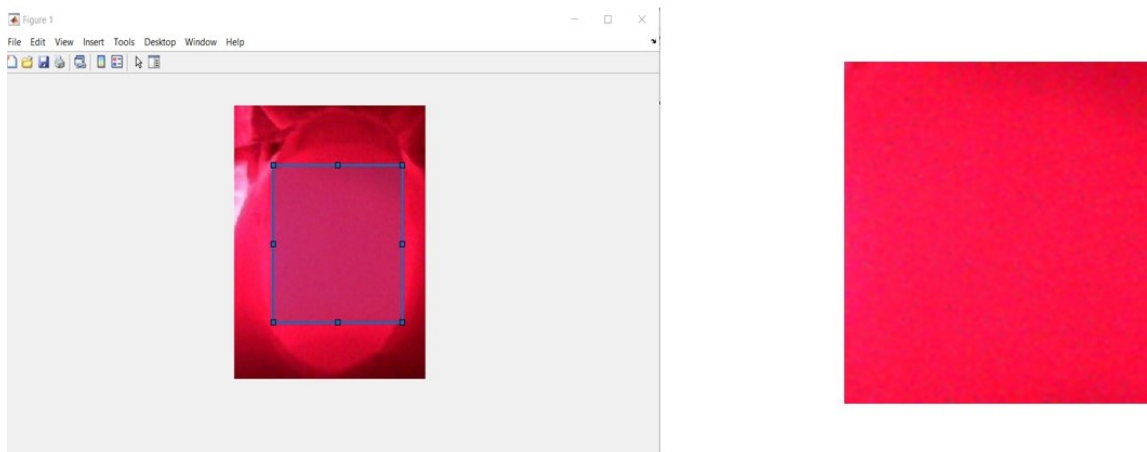


Figura 4.4: Recorte de la región de interés (ROI). Fuente: Elaboración propia.

Como resultado de utilizar esta herramienta, en la Figura 4.4 se aprecia el recorte que se aplica a la imagen obtenida por la etapa de adquisición. Este proceso es aplicado a cada imagen contenida en la base de datos.

Después de obtener la región de interés procederemos a convertir esta imagen *RGB* en una imagen en escala de grises. Por medio de la función `rgb2gray` contenida en *MATLAB*. La función `rgb2gray` convierte las imágenes RGB en escala de grises eliminando la información de matiz y saturación mientras conserva la luminancia.

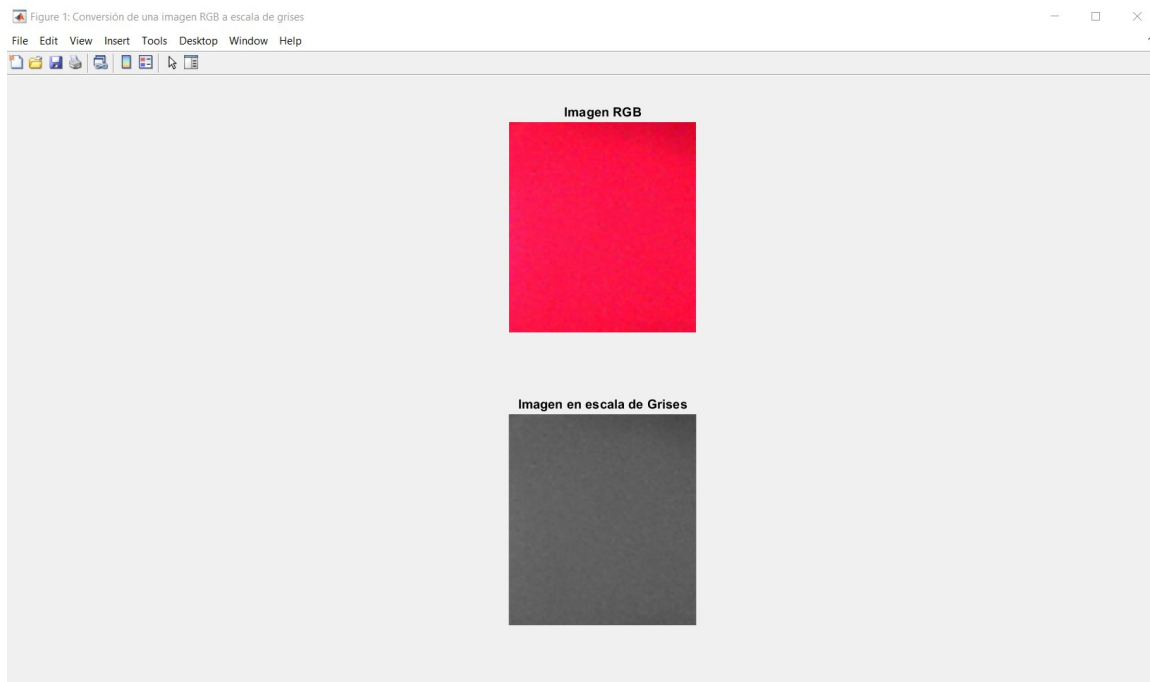


Figura 4.5: Conversión de imagen RGB original en una imagen en escala de grises a través de *MATLAB*®. Fuente: Elaboración propia.

La Figura 4.5 muestra la conversión de la imagen *ROI* original en una imagen en escala de grises, como se mencionó en el capítulo 3, este proceso nos permite disminuir el ruido en la imagen original. Además de la misma luminancia (*relativa*), este método también asegura que ambas imágenes tendrán la misma luminancia absoluta en pocas palabras podemos decir que son imágenes estables.

## 4.3. Etapa de reconstrucción de la imagen

Como se mencionó en el capítulo 3, esta etapa de reconstrucción de la imagen se llevó a cabo por medio de 4 experimentos, en este apartado se presentaran los resultados obtenidos de la aplicación de cada algoritmo, en las imágenes de la base de datos utilizando *MATLAB*. Como se mencionó anteriormente, el resultado de implementar cada algoritmo en las imágenes de la base de datos, será evaluado a través del índice *PSNR*.

### 4.3.1. Experimento 1. Ecuación de Histograma

Como se mencionó en el capítulo 3, el histograma ecualizado es el proceso de ajuste de los valores de intensidad en cada píxel. La ecualización del histograma implica transformar los valores de intensidad para que el histograma de la imagen de salida coincida aproximadamente con un histograma especificado. La Figura 4.6, muestra el histograma de la imagen original del recorte *ROI* en escala de grises. Esto como primer paso del experimento, para llevar a cabo una comparación del histograma de la imagen original, con el del histograma ecualizado de la misma.

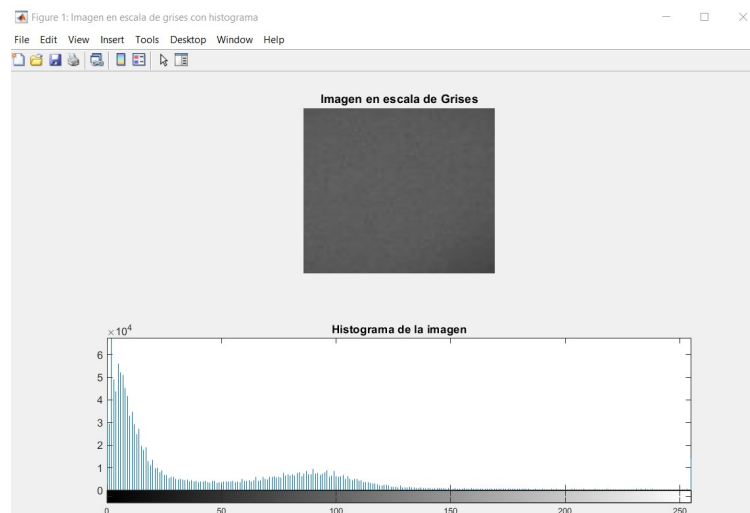


Figura 4.6: Histograma de la imagen original con recorte ROI en escala de grises. Fuente: Elaboración propia.

En la Figura 4.7, se muestra el resultado de utilizar el algoritmo del histograma ecualizado en imágenes de la base de datos, para ajustar el contraste de cada uno de los píxeles, de las mismas.

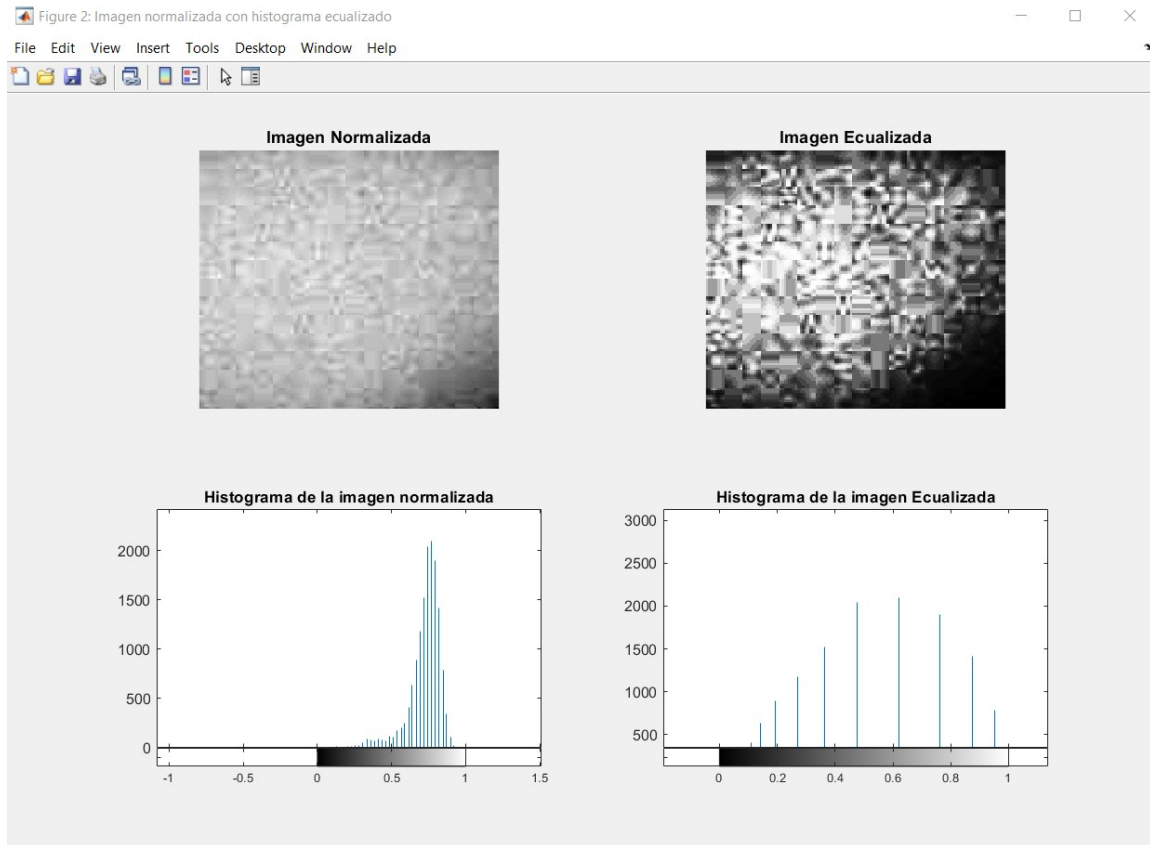


Figura 4.7: Resultado de la implementación del algoritmo HE. Fuente: Elaboración propia.

Como podemos observar el histograma ecualizado, a pesar de ser uno de los modelos básicos para el tratado y reconstrucción en imágenes nos permite visualizar el dominio de absorción en la imagen, donde el láser incide. Sin embargo, la imagen cuenta con demasiado ruido.

### 4.3.2. Experimento 2. Histograma Adaptativo Ecuilizado (CLAHE)

El histograma adaptativo ecualizado como se mencionó en el capítulo 3, se utilizara en este proyecto dentro de las opciones, para obtener el mejor tratamiento de reconstrucción en imágenes digitales, ya que es una técnica de procesamiento de imágenes que se utiliza para mejorar el contraste en las imágenes.

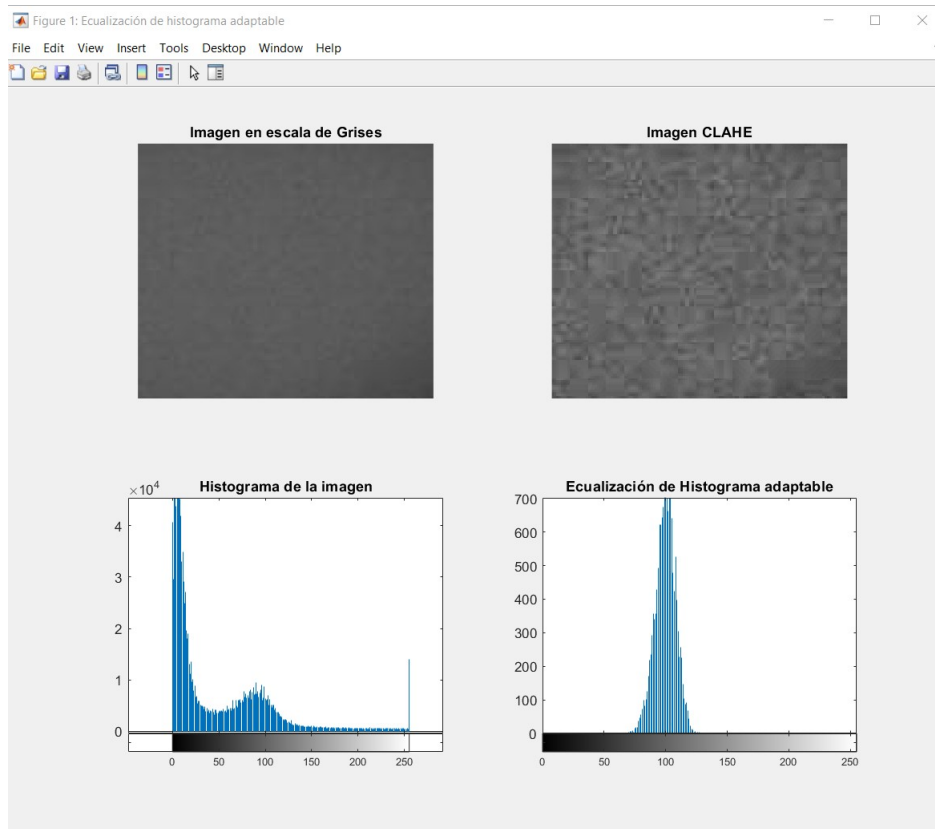


Figura 4.8: Implementación del algoritmo CLAHE, que nos permite observar una imagen más estable. Fuente: Elaboración propia.

En la Figura 4.8 podemos ver la implementación del algoritmo descrito en el capítulo 4, este método se diferencia del histograma ecualizado (*HE*), debido a que el método adaptativo calcula varios histogramas, cada uno correspondiente a una sección distinta de la imagen, y los utiliza para redistribuir los valores de luminosidad de la imagen. Por lo tanto, es adecuado para mejorar el contraste local y mejorar las definiciones de los bordes en cada región de una imagen.

### 4.3.3. Experimento 3. Filtro Guiado

Como pudimos observar en la sección anterior, el ecualizado adaptativo (*CLAHE*) redistribuyó los valores de luminosidad de la muestra contenida en la base de datos, por lo que obtuvimos una imagen estable. Para este experimento se utilizó otro procedimiento de reconstrucción en imágenes digitales, el filtro guiado, un filtro no lineal, preservador de bordes y de reducción de ruido para el suavizado de imágenes.

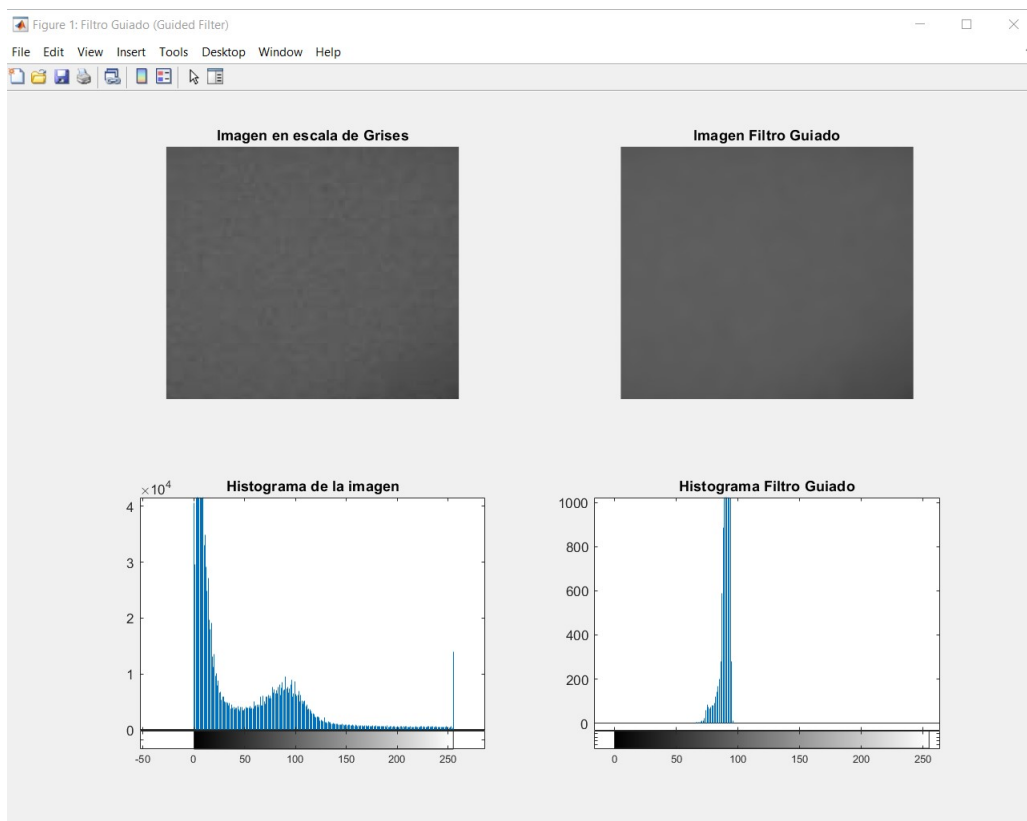


Figura 4.9: Implementación del filtro guiado, por medio de una operación de vecindad entre los píxeles de la imagen. Fuente: Elaboración propia.

Al implementar el algoritmo visto en el capítulo 3, en la sección de etapas de reconstrucción, obtenemos el resultado visto en la Figura 4.9, donde se observa el suavizado de conservación de bordes en la imagen, utilizando el contenido de una segunda imagen, en este caso utilizando la imagen original en escala de gris, produciendo una operación de vecindad al igual que otras operaciones de

filtrado, pero tiene en cuenta las estadísticas de una región en la vecindad espacial correspondiente en la imagen de orientación al calcular el valor del píxel de salida, mencionado en el capítulo 2.

#### 4.3.4. Experimento 4. Filtro de Wiener

Como pudimos observar en la sección anterior, el filtro guiado es un algoritmo muy estable y confiable para poder reconstruir una imagen, sin embargo el experimento 4 resulto tener una técnica de reconstrucción con resultados muy similares a los obtenidos en el filtro guiado.

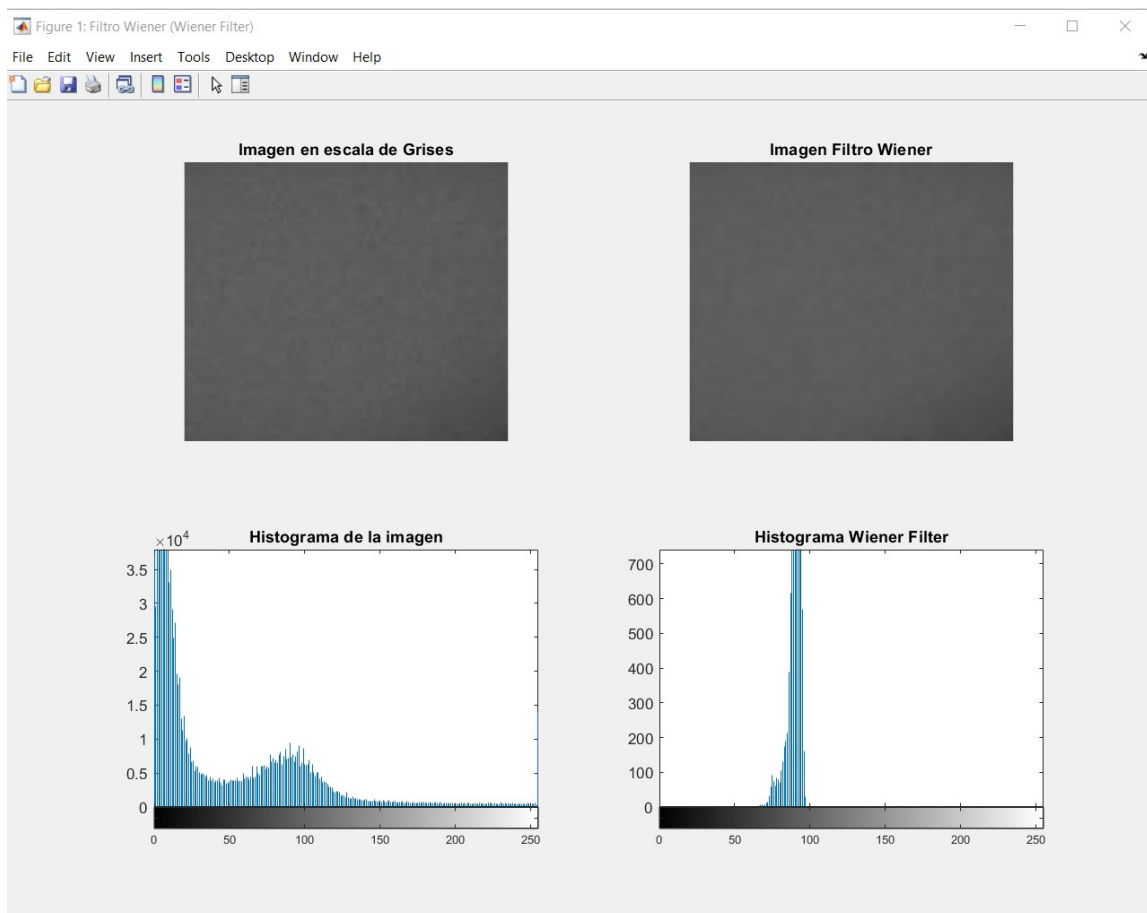


Figura 4.10: Implementación del filtro wiener, por medio de una operación de vecindad entre los píxeles de la imagen. Fuente: Elaboración propia.



En la Figura 4.10 podemos observar como el resultado obtenido al utilizar el filtro wiener es muy similar al del filtro guiado, sin embargo, este tipo de filtro lineal no necesita un trabajo computacional extra, como el filtro guiado al utilizar como comparativo la misma imagen a procesar. El filtro de wiener de igual manera, permite recuperar la información que fue afectada por el ruido digital, por lo que ofrece una imagen de salida estable y sin menor procesamiento.

#### **4.4. Evaluación de reconstrucción por medio del índice PSNR**

Como se menciona en el capítulo 4, al utilizar en el proyecto diferentes técnicas de reconstrucción para el procesamiento digital de imágenes, era necesario elegir el proceso óptimo entre cada uno de estos, es por lo cual, se utiliza el índice PSNR, una métrica de calidad que mide el cuadrado de la máxima intensidad de la señal en lugar del promedio del cuadrado de cada píxel.

El índice PSNR es realmente efectivo y confiable debido a que utiliza la relación entre la máxima energía posible de una señal y el ruido que afecta a su representación, al tener una imagen incidida por luz láser, tenemos una señal con gran rango dinámico, por lo que utilizar este índice nos permite elegir entre los métodos utilizados en los diferentes experimentos de reconstrucción.

Para este apartado, cada imagen reconstruida por los diferentes métodos se guardaron en 4 carpetas, cada una de estas con el nombre del experimento como se observa en la Figura 4.11, para posteriormente implementar un algoritmo que tomara por completo todas las imágenes procesadas por los diferentes experimentos y obtuviera el índice PSNR de cada imagen, de esta manera se procedería a obtener un valor promedio de las 870 imágenes contenidas en la base de datos.

Métrica	Método de pre-procesamiento	Valor (promedio)
PSNR	Experimento 1. Ecuador de Histograma	10.0656
PSNR	Experimento 2. CLAHE	27.6116
PSNR	Experimento 3. Filtro Guiado	46.4747
PSNR	Experimento 4. Filtro Wiener	50.7963

Tabla 4.1: Promedios del índice PSNR, para cada experimento propuesto.

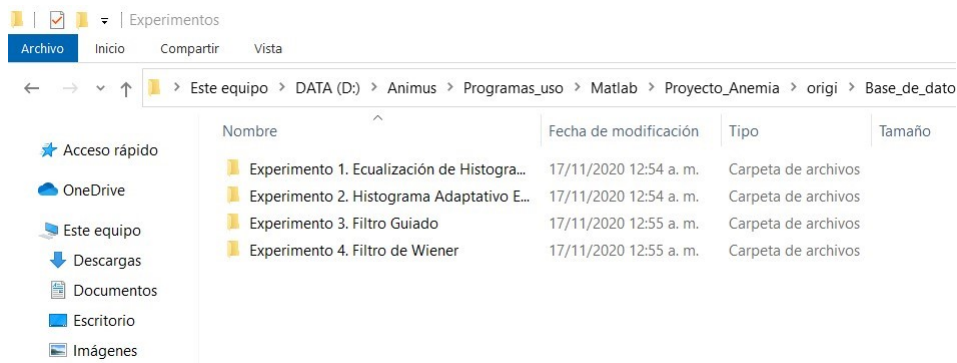


Figura 4.11: Ordenamiento por carpetas de cada experimento, para obtener el índice PSNR de cada imagen por experimento. Fuente: Elaboración propia.

Como se mencionó en el capítulo 3, el valor promedio del índice  $PSNR$ , para cada conjunto de imágenes procesadas en los 4 experimentos debe ser alto para poder elegir el método adecuado. Esto debido a que el  $PSNR$  está usando un término denominado Error Cuadrático Medio ( $MSE$ ) en el denominador. Por lo tanto, si es bajo el error ( $MSE$ ), alto será el  $PSNR$ . El valor promedio Peak Signal-to-Noise Ratio ( $PSNR$ ) para cada imagen de respuesta procesada en los experimentos propuestos se encuentra reflejado en la Tabla 4.1.

Después de analizar los datos obtenidos del promedio resultante de cada experimento, concluimos en utilizar el método del experimento 4: filtro de wiener, como método de reconstrucción para el proyecto, ya que obtuvo un valor promedio de 50.7963 en el índice  $PSNR$ .




Figura 4.12: Implementación del filtro wiener, por medio de una operación de vecindad entre los píxeles de la imagen. Fuente: Elaboración propia.

## 4.5. Extracción de características

Para este último procedimiento, se utilizará el algoritmo LBP como el encargado de extraer las características de cada una de las imágenes en la base de datos (núm. de imágenes = 870), procesadas por el método de filtrado de wiener. El algoritmo *LBP* ha demostrado ser un método adecuado para la extracción de características en imágenes, se ha convertido en una medida de textura para las imágenes, mostrando excelentes resultados en términos de precisión y complejidad computacional.

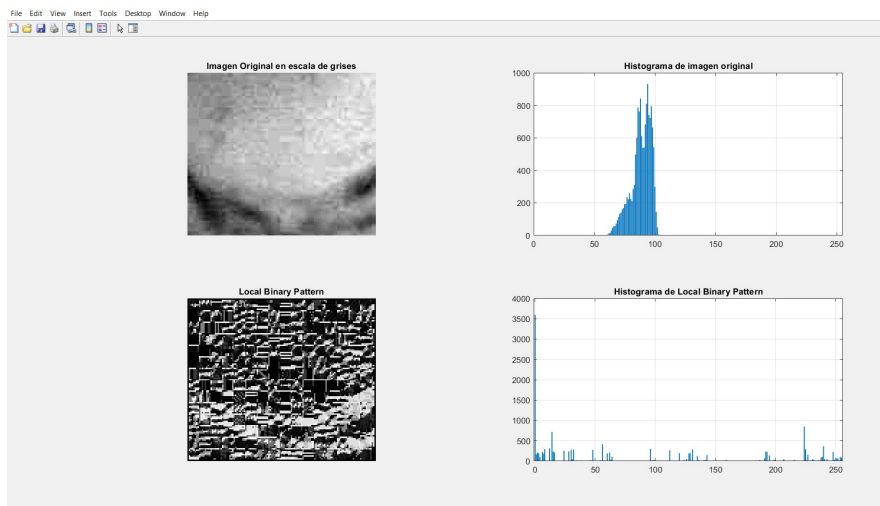


Figura 4.13: Implementación del algoritmo LBP en una de las imágenes de la base de datos. Fuente: Elaboración propia.

La implementación del algoritmo LBP en las imágenes procesadas por el filtro de wiener, nos permitirá obtener como resultado un vector de información con 255 valores, que representa información de intensidades de grises de los vecinos alrededor de un determinado píxel, lo que nos ayudara a obtener lo que se conoce como biomarcadores en imágenes médicas. En la Figura 4.13, podemos observar el resultado obtenido al utilizar el algoritmo LBP en las imágenes de la base de datos.

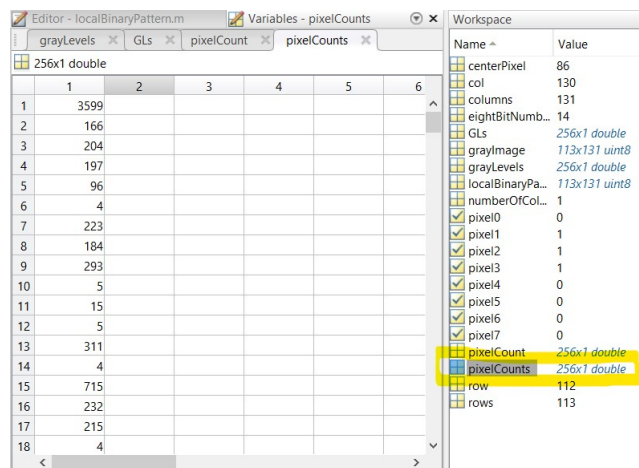


Figura 4.14: Espacio de trabajo en MATLAB, donde podemos observar la variable que guarda las características de la imagen. Fuente: Elaboración propia.

De igual manera, en la Figura 4.14 podemos observar el vector de características resultante al utilizar este algoritmo, la variable para este vector es pixelCounts, nombrada así por el conteo de los 255 valores obtenidos, en la imagen se muestra el tamaño de vector en 256, esto se debe a que *MATLAB* no cuenta con la lectura inicial de 0, por lo cual el conteo empieza por el 1.

Como resultado final del proyecto, se tiene un sistema dentro del procesamiento de imágenes, que nos permite extraer las características en cada una de las imágenes incididas por luz láser, esperando así ver la diferencia de absorción que presentan los diferentes niveles de hemoglobina en cada muestra.

---

## Capítulo 5

# Conclusiones y Recomendaciones

El presente trabajo obtuvo los resultados esperados durante la implementación de la metodología propuesta, las etapas del método implementado son mostradas en la Figura 3.5 dentro del capítulo 2.

Como se menciona en el capítulo 1, los objetivos específicos del proyecto son:

- Desarrollar un sistema optoelectromecánico para la adquisición de imágenes médicas.
- Analizar un conjunto de imágenes médicas utilizando métodos de procesamiento de imágenes y visión artificial.
- Comparar los diferentes métodos para la reconstrucción de imágenes médicas por medio del índice *PSNR*.
- Establecer una serie de pasos a seguir para el tratamiento de imágenes médicas.

Así que, a manera de conclusión, decimos que en el desarrollo del proyecto se han cumplido cada uno de los objetivos específicos propuestos, debido a que se desarrolló un prototipo capaz de obtener imágenes estables de la incidencia de luz láser en el dedo índice, cabe resaltar que ya se cuenta con un diseño en impresión

3D del equipo final, tomando en cuenta nuevas variables de investigación, como lo son: tomar en cuenta el historial clínico de los pacientes, ajustes en los ángulos de incidencia en el dedo índice, tés de piel y mejoras al sistema optoelectromecánico.

De igual manera, el método propuesto dentro del área de procesamiento de imágenes y reconstrucción, nos permitió manipular las imágenes obtenidas a través de herramientas confiables y óptimas, así también el algoritmo local binary pattern nos permitió extraer el vector de características de cada una de las imágenes dentro de la base de datos.

Sin embargo, el verdadero potencial de este proyecto se verá probado, cuando los datos obtenidos sean utilizados dentro de la última etapa del reconocimiento de patrones.

Esta última etapa no se pudo llevar a cabo debido a las circunstancias epidemiológicas en las que nos encontramos, donde el aislamiento social y las altas medidas hospitalarias nos limitan a poder realizar pruebas en pacientes con rasgos marcados en la disminución de hemoglobina en sangre, que nos permitirían comparar ambos grupos. Donde cada dato obtenido, nos proporcionara la veracidad de que el efecto físico-biológico que se desea observar por medio de métodos no invasivos, es posible.

Desde un inicio, el desarrollo de este trabajo pretende descubrir nuevos paradigmas en los componentes de la sangre y alternar métodos que prometan estudios rápidos y seguros. Nos vimos limitados por las circunstancias en las cuales vivimos hoy en día, pero el proyecto y la idea se mantuvo, en ningún momento se perdió el proceso científico de la investigación.

## **5.1. Trabajo a futuro**

Como trabajo futuro, se contempla utilizar cada uno de los vectores característicos obtenidos en la presente investigación para su clasificación, esto a través de métodos supervisados o no supervisados, esto nos permitirá generar grupos de control para su estudio, de igual forma el hecho de incrementar la base de datos con pacientes que presenten anemia en diferentes grados reforzara la idea de una predicción sobre los diferentes niveles de la condición. El uso de algoritmos en deep learning o machine learning es una posibilidad para el estudio de la base de datos.

---

# Bibliografía

- [Acharya et al., 2013] Acharya, J., Gadhiya, S., and Raviya, K. (2013). Segmentation techniques for image analysis: A review. *International Journal of Computer Science and Management Research*, 2(1):1218–1221.
- [Al-amri and Kalyankar, 2010] Al-amri, S. S. and Kalyankar, V. (2010). Image segmentation by using threshold techniques. *Journal of Computing*, 2(5):83–86.
- [Alvarado and Fernández, 2012] Alvarado, J. D. and Fernández, J. (2012). Análisis de textura en imágenes a escala de grises, utilizando patrones locales binarios (lbp). *ENGI Revista Electrónica de La Facultad de Ingeniería*, 1(1).
- [Andrea Gavlasova, 2006] Andrea Gavlasova, Ales Prochazka, M. M. (2006). Wavelet based image segmentation. *Institute of Chemical Technology, Department of Computing and Control Engineering, In Proceedings of the 14th Annual Conference Technical Computing, Prague.*, pages 1–7.
- [Arganda-Carreras et al., 2017a] Arganda-Carreras, I., Kaynig, V., Rueden, C., Eliceiri, K. W., Schindelin, J., Cardona, A., and Sebastian Seung, H. (2017a). Trainable Weka Segmentation: a machine learning tool for microscopy pixel classification. *Bioinformatics*, 33(15):2424–2426.
- [Arganda-Carreras et al., 2017b] Arganda-Carreras, I., Kaynig, V., Rueden, C., Eliceiri, K. W., Schindelin, J., Cardona, A., and Sebastian Seung, H. (2017b). Trainable Weka Segmentation: a machine learning tool for microscopy pixel classification. *Bioinformatics*, 33(15):2424–2426.



- [Bayonas, 2010] Bayonas, P. M. (2010). Preprocesado y registro de imágenes médicas portal con radiografías reconstruidas digitalmente.
- [Ben-Ze'ev, 1981] Ben-Ze'ev, A. (1981). J.j. gibson and the ecological approach to perception. *Studies in history and philosophy of science*, 12:107–39.
- [Castillo Atoche et al., 2014] Castillo Atoche, A., Ortegon, J., Castillo, J., and Rivera, J. (2014). Virtual laboratory for digital image processing. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, 12:1176–1181.
- [Cerquin et al., 2017] Cerquin, L. J. E., Gutierrez, E. G. C., and Obando, J. D. (2017). Propuesta de un método híbrido de pre procesamiento de imágenes de rayos x de la estructura pélvica. In *Global Partnerships for Development and Engineering Education: Proceedings of the 15th LACCEI International Multi-Conference for Engineering, Education and Technology, July 19-21, 2017, Boca Raton, FL, United States*, page 252. Latin American and Caribbean Consortium of Engineering Institutions.
- [Chuang et al., 2006] Chuang, K. S., Tzeng, H.-L., Chen, S., Wu, J., and Chen, T.-J. (2006). Fuzzy c-means clustering with spatial information for image segmentation. *Computerized medical Imaging and Graphics* 30, pages 9–15.
- [Cortina Rosales and López De Roux, 2000] Cortina Rosales, L. and López De Roux, M. d. R. (2000). Utilización de la sangre y sus componentes celulares. *Revista Cubana de Hematología, Inmunología y Hemoterapia*, 16(2):78–89.
- [Davies, 2012] Davies, E. R. (2012). *Computer and Machine Vision, Theory. Algorithms, Practicalities*. Academic Press.
- [DEL POZO and GARCÍA, 2009] DEL POZO, J. S. and GARCÍA, A. R. (2009). Detección de matrículas mediante características binarias locales (lbp).
- [Domínguez Torres, 2019] Domínguez Torres, A. (2019). Procesamiento digital de imágenes. *Perfiles Educativos*.

- [E. J. Stollnitz, 1996] E. J. Stollnitz, T. D. Deroose, D. H. S. (1996). Wavelets for computer graphics. *Morgan Kaufmann Publishers, Inc., San Francisco, CA*.
- [El Mezeni and Saranovac, 2016] El Mezeni, D. and Saranovac, L. (2016). Fast self-guided filter with decimated box filters. *Proc. INFOTEH-JAHORINA*, pages 633–638.
- [Freixenet et al., 2002] Freixenet, J., Muñoz, X., Raba, D., Martí, J., and Cufí, X. (2002). Yet another survey on image segmentation: Region and boundary information integration. In *In European conference on computer vision. Springer.*, pages 408–422.
- [Friedrich, 2013] Friedrich, V. (2013). Transformada de Fourier de una Imagen y filtrado de una imagen en el dominio de la frecuencia. Technical report, Universidad Nacional del Sur, Bahía Blanca, Argentina.
- [Galambos et al., 1999] Galambos, C., Kittler, J., and Matas, J. (1999). Progressive probabilistic hough transform for line detection. *Proceedings. 1999 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (Cat. No PR00149)*, 1:554–560 Vol. 1.
- [García-Lamont et al., 2012] García-Lamont, F., Cervantes, J., and Lopez-Chau, A. (2012). Recognition of mexican banknotes via their color and texture features. *Expert Systems with Applications*, 39:9651–9660.
- [Garzón et al., 2009] Garzón, J. G., Rodríguez, A., and Cabrera, A. (2009). Tomografía por emisión de positrones de cuerpo completo (pet/tac) con 18f-fluorodesoxiglucosa. *Revista Española de Medicina Nuclear*, 28(2):85–89.
- [Gatos et al., 2004] Gatos, B., Pratikakis, I., and Perantonis, S. J. (2004). An adaptive binarization technique for low quality historical documents. In Marinai, S. and Dengel, A. R., editors, *Document Analysis Systems VI*, pages 102–113, Berlin, Heidelberg. Springer Berlin Heidelberg.

- [Ghosh et al., 2019] Ghosh, S., Das, N., Das, I., and Maulik, U. (2019). Understanding Deep Learning Techniques for Image Segmentation. *Computer Vision and Pattern Recognition*.
- [González et al., 2012] González, H. R., Camelias, C. A., and Equipo, N. (2012). Introducción al láser. *Clínica*, 986(41):41–42.
- [Gonzalo Pájares, 2002] Gonzalo Pájares, J. (2002). Alfaomega visión por computador. *Imágenes Digitales y sus aplicaciones*.
- [He et al., 2016] He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 770–778.
- [Horé and Ziou, 2010] Horé, A. and Ziou, D. (2010). Image quality metrics: Psnr vs. ssim. pages 2366–2369.
- [Hubel and Wiesel, 1979] Hubel, D. H. and Wiesel, T. N. (1979). Brain mechanisms of vision. *Scientific American*, 241(3):150–162.
- [Ikhsan et al., 2014] Ikhsan, I. A. M., Hussain, A., Zulkifley, M. A., Tahir, N. M., and Mustapha, A. (2014). An analysis of x-ray image enhancement methods for vertebral bone segmentation. In *2014 IEEE 10th International Colloquium on Signal Processing and its Applications*, pages 208–211. IEEE.
- [Jain and M. Narasimha Murty, 1999] Jain, K. A. and M. Narasimha Murty, J. P. F. (1999). Data clustering: a review. *ACM computing surveys*, 31(3):264–323.
- [Jianbo Shi and Malik, 2000] Jianbo Shi and Malik, J. (2000). Normalized cuts and image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(8):888–905.
- [João et al., 2012] João, A. J., Gambaruto, A. M., and Sequeira, A. (2012). The effects of medical image processing techniques on the computational

- haemodynamics. In *2012 IEEE 2nd Portuguese Meeting in Bioengineering (ENBENG)*, pages 1–4. IEEE.
- [Justel Pizarro, 2019] Justel Pizarro, J. T. (2019). Detección y clasificación de diferentes formas eritrocitarias anómalas mediante redes neuronales profundas. B.S. thesis, Universitat Politècnica de Catalunya.
- [Kaganami and Beij, 2009] Kaganami, H. and Beij, Z. (2009). Region based detection versus edge detection. *IEEE Transactions on Intelligent Information Hiding and Multimedia Signal Processing*, pages 1217–1221.
- [Kallepitis et al., 2017] Kallepitis, C., Bergholt, M. S., Mazo, M. M., Leonardo, V., Skaalure, S. C., Maynard, S. A., and Stevens, M. M. (2017). Quantitative volumetric raman imaging of three dimensional cell cultures. *Nature communications*, 8(1):1–9.
- [Kazemina et al., 2015] Kazemina, S., Karimi, N., Mirmahboub, B., Soroushmehr, S. M. R., Samavi, S., and Najarian, K. (2015). Bone extraction in x-ray images by analysis of line fluctuations. In *2015 IEEE International Conference on Image Processing (ICIP)*, pages 882–886. IEEE.
- [Kitcher, 1988] Kitcher, P. (1988). Marr’s Computational Theory of Vision. *Philosophy of Science*, 55(1):1–24.
- [Kulkarni, 2011] Kulkarni, S. R. (2011). Introduction to Electrical Signals and Systems. Technical report, Princeton University.
- [Labati et al., 2015] Labati, R. D., Piuri, V., and Scotti, F. (2015). *Touchless fingerprint biometrics*. CRC Press.
- [LeCun et al., 1998] LeCun, Y., Bottou, L. Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE* 86, pages 2278–2324.

- [Lian, 2019] Lian, J.-a. (2019). Image sharpening with optimized psnr. pages 106–110.
- [Lopez Montiel et al., 2019] Lopez Montiel, M., Rubio, Y., Sanchez-Adame, M., and Orozco-Rosas, U. (2019). Algoritmo de procesamiento de imágenes para señales de transito.
- [Maenpaa, 2004] Maenpaa, T. (2004). The local binary pattern approach to texture analysis: Extensions and applications.
- [Majumdar and Kumar, 2014] Majumdar, J. and Kumar, S. (2014). Modified clahe: An adaptive algorithm for contrast enhancement of aerial, medical and underwater images. *International Journal of Computer Engineering and Technology (IJCET)*, 5(11):32–47.
- [Mansfield and Nunan, 1978] Mansfield, R. and Nunan, E. E. (1978). Towards an alternative educational technology. *British Journal of Educational Technology*, 9(3):170–175.
- [Markou and Singh, 2003] Markou, M. and Singh, M. (2003). Neural networks for scene analysis.
- [Marr, 1982] Marr, D. (1982). Fundamentos de la teoría de la visión. *Laboratorio de Inteligencia Artificial del Instituto de Tecnologia de Massachusset (M.I.T)*.
- [Marrero Pérez et al., 2016] Marrero Pérez, M. D., Sánchez Rivero, L. O., Santana Machado, A. T., Pérez de León, A., and Rodríguez Gómez, F. E. (2016). Las imágenes digitales como medios de enseñanza en la docencia de las ciencias médicas. *Revista Educación Médica del Centro*, 8(1):125–142.
- [Masci et al., 2011] Masci, J., Meier, U., Ciresan, D., and Schmidhuber, J. (2011). Stacked convolutional auto-encoders for hierarchical feature extraction. *International Conference on Artificial Neural Networks*, pages 52–59.

- [Medsker and Jain, 2001] Medsker, L. and Jain, L. (2001). Recurrent Neural Networks. *Design and Applications* 5.
- [Meyer-Arendt, 1989] Meyer-Arendt, J. R. (1989). Introduction to classical and modern optics. *itcm*.
- [Noor, 2019] Noor, Nahiyah Bin y Anwar, M. S. y. D. M. (2019). Estudio comparativo entre el árbol de decisiones, svm y knn para predecir la condición anémica. In *2019 IEEE International Conference on Biomedical Engineering, Computer and Information Technology for Health (BECITHCON)*.
- [Núñez Espinosa, 2015] Núñez Espinosa, C. (2015). Exposición intermitente a altitud simulada y ejercicio para la recuperación del daño muscular: células madre circulantes y ajustes hemorreológicos en ratas entrenadas.
- [Ojala et al., 2000] Ojala, T., Pietikäinen, M., and Mäenpää, T. (2000). Gray scale and rotation invariant texture classification with local binary patterns. In *Computer Vision - ECCV 2000*, pages 404–420, Berlin, Heidelberg. Springer Berlin Heidelberg.
- [Oliva Navarro, 2015] Oliva Navarro, D. A. (2015). *Aplicación de algoritmos metaheurísticos en procesamiento de señales, imágenes y energías alternativas*. PhD thesis, Universidad Complutense de Madrid.
- [O'Mara et al., 2017] O'Mara, A., King, A. E., Vickers, J. C., and Kirkcaldie, M. T. K. (2017). ImageSURF: An ImageJ Plugin for Batch Pixel-Based Image Segmentation Using Random Forests. *Journal of open research software*.
- [Osorio Valladares, 2013] Osorio Valladares, A. (2013). *Detección de anomalías en imágenes biomédicas mediante el uso de regiones sobresalientes*. PhD thesis, Universidad Central "Marta Abreu" de Las Villas.
- [Palomino, 2009] Palomino, N. L. S. (2009). Técnicas de Segmentación en Procesamiento Digital de imágenes . *Revista de Ingeniería de Sistemas e Informática*, 6(2):9.

- [Pandey et al., 2016] Pandey, M., Bhatia, M., and Bansal, A. (2016). An anatomization of noise removal techniques on medical images. In *2016 International Conference on Innovation and Challenges in Cyber Security (ICICCS-INBUSH)*, pages 224–229. IEEE.
- [Pang et al., 2011] Pang, Z. P., Yang, N., Vierbuchen, T., Ostermeier, A., Fuentes, D. R., Yang, T. Q., Citri, A., Sebastiano, V., Marro, S., Südhof, T. C., et al. (2011). Induction of human neuronal cells by defined transcription factors. *Nature*, 476(7359):220–223.
- [Paola Paolinelli, 2013] Paola Paolinelli, G. (2013). Principios físicos e indicaciones clínicas del ultrasonido doppler. *Revista Médica Clínica Las Condes*, 24(1):139 – 148. Tema central: Radiología al día.
- [Paredes, 2009] Paredes, D. (2009). *Seguimiento y Caracterización de Componentes del Rostro para la Detección de Expresiones Faciales*. PhD thesis, Tesis de Maestría, Centro Nacional de Investigación y Desarrollo Tecnológico.
- [Pérez et al., 2006] Pérez, P. A. C., García, J. R., and Ibáñez, J. J. R. (2006). *Ingeniería biomédica. Imágenes médicas*, volume 49. Univ de Castilla La Mancha.
- [Petersen et al., 2002] Petersen, M. E., Ridder, D. D., and Handels, H. (2002). Image processing with neural networks- a review. *Pattern Recognition*, 35(10):2279–3301.
- [Platero, 2009] Platero, C. (2009). Apuntes de visión artificial. *Departamento de Electrónica, Automática e Informática Industrial*.
- [Ramírez, 2010] Ramírez, E. (2010). Calibración de imágenes radiográficas. *Lecturas en Ciencias de la Computación. Universidad Central de Venezuela, Facultad de Ciencias, Escuela de Computación. Caracas*.
- [Ramírez, 2006] Ramírez, B. E. (2006). Procesamiento Digital de Imágenes. techreport 1, Universidad Politécnica de Madrid.

- [Rana et al., 2018] Rana, A., Kumari, N., Tyagi, M., and Jagadevan, S. (2018). Leaf-extract mediated zero-valent iron for oxidation of arsenic (iii): Preparation, characterization and kinetics. *Chemical Engineering Journal*, 347:91 – 100.
- [Reyes-Diaz et al., 2018] Reyes-Diaz, F., Gutiérrez, A., Hernández-Sierra, G., and Lara, J. (2018). Filtrado wiener para la reducción de ruido en la verificación de locutores. 12:152–162.
- [Roberts, 1962] Roberts, L. (1962). Picture coding using pseudo-random noise. *IRE Transactions on Information Theory*, 8(2):145–154.
- [Rodellar et al., 2018] Rodellar, J., Alférez, S., Acevedo, A., Molina, A., and Merino, A. (2018). Image processing and machine learning in the morphological analysis of blood cells. *International journal of laboratory hematology*, 40:46–53.
- [Rosario and Martín-Landrove, 2017] Rosario, J. and Martín-Landrove, M. (2017). *Desarrollo de una herramienta gráfica de análisis cuantitativo y semicuantitativo de imágenes por resonancia magnética con realce por contraste dinámico de uso general para radiólogos*. PhD thesis.
- [Rosenfeld, 1993] Rosenfeld, A. (1993). Image analysis and computer vision: 1992. *CVGIP: Image Understanding*, 58(1):85 – 135.
- [Santra, 2018] Santra, Bikash y Mukherjee, D. P. y. C. D. (2018). Un enfoque no invasivo para la estimación de la hemoglobina analizando el flujo sanguíneo en la palma. In *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)*.
- [Schindelin et al., 2012] Schindelin, J., Arganda-Carreras, I., Frise, E., Kaynig, V., Longair, M., Pietzsch, T., Preibisch, S., Rueden, C., Saalfeld, S., Schmid, B., Tinevez, J.-Y., White, D., Hartenstein, V., Eliceiri, K., Tomancak, P., and Cardona, A. (2012). Fiji: An open-source platform for biological-image analysis. *Nature methods*, 9:676–82.



- [Segura et al., 2017] Segura, J., Sanchez-Garcia, R., Martinez, M., Cuenca-Alba, J., Tabas-Madrid, D., Sorzano, C. O. S., and Carazo, J. M. (2017). 3DBIONOTES v2.0: a web server for the automatic annotation of macromolecular structures. *Bioinformatics*, 33(22):3655–3657.
- [Seijas, 2011] Seijas, L. M. (2011). *Reconocimiento de patrones utilizando técnicas estadísticas y conexionistas aplicadas a la clasificación de dígitos manuscritos*. PhD thesis, Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales.
- [Senthilkumaran and Rajesh, 2009] Senthilkumaran, N. and Rajesh, R. (2009). Edge Detection techniques for image segmentation-a survey of soft computing approaches. *International Journal of Recent Trends in Engineering 1*, pages 250–254.
- [Sharma et al., 2018] Sharma, V., Bohra, B., and Shekhawat, S. S. (2018). A review on various image segmentation techniques. *International Journal of Computer Science and Mobile Applications*, 6(4):119–124.
- [Simperler and Goldbeck, 2019] Simperler, A. and Goldbeck, G. (2019). Grain boundary engineering on the atomic scale. Interview with Dr Lorenz Romaner.
- [Sivakumar and Meenakshi, 2016] Sivakumar, P. and Meenakshi, S. (2016). A review on image segmentation techniques. *International Journal of Advanced Research In Computer Engineering & Technology (IJARCET)*, 5(3):641–647.
- [Sossa., 2012] Sossa., R. . (2012). *Procesamiento digital de imágenes*. Editorial Alfaomega.
- [Srinivasan et al., 2006] Srinivasan, K., Lakshmi, D., Ranganathan, H., and Gunasekaran, N. (2006). Non-invasive estimation of hemoglobin in blood using color analysis. In *First International Conference on Industrial and Information Systems*, pages 547–549. IEEE.

- [Sucar and Gómez, 2018] Sucar, L. and Gómez, G. (2018). *Visión Computacional*.
- [Tanabe et al., 2018] Tanabe, K., Ang, C. E., Chanda, S., Olmos, V. H., Haag, D., Levinson, D. F., Südhof, T. C., and Wernig, M. (2018). Transdifferentiation of human adult peripheral blood t cells into neurons. *Proceedings of the National Academy of Sciences*, 115(25):6470–6475.
- [Thompson and Shure, 2009] Thompson, C. M. and Shure, L. (2009). Image processing toolbox [for use with matlab].
- [Tobias and Seara, 2002] Tobias, O. J. and Seara, R. (2002). Image Segmentation by histogram thresholding using fuzzy sets. *IEEE transactions on Image Processing* 11, pages 1457–1465.
- [Torres and Abderrahim, 2018] Torres, E. J. C. C. and Abderrahim, D. M. (2018). *MEDICIÓN DE SIGNOS VITALES MEDIANTE TÉCNICAS DE VISIÓN ARTIFICIAL*. PhD thesis, Universidad Carlos III de Madrid.
- [Tuchin, 2002] Tuchin, V. V. (2002). Handbook of optical biomedical diagnostics. SPIE- The International Society for Optical Engineering.
- [Valdés Santiago et al., 2015] Valdés Santiago, D., Mesejo-León, D., and Leon Mecias, A. (2015). Mejoramiento del contraste en imágenes de mamografía digital / contrast enhancement in digital mammography images.
- [Velásquez, 1999] Velásquez, A. (1999). Procesamiento de imágenes médicas. *Iatreia*, 12.
- [Vera et al., 2016] Vera, M., Molina, V., Huérfano, Y., Vera, M., Del Mar, A., Salazar, W., Wilches-Duran, S., Graterol-Rivas, M., Rojas, J., Garicano, C., et al. (2016). Segmentación automática tridimensional de estructuras ventriculares cerebrales en imágenes de resonancia magnética. *Revista Latinoamericana de Hipertensión*, 11(2):20–24.

- [Vishniac, 2012] Vishniac, R. (2012). *To give them light: the legacy of Roman Vishniac*. Simon & Schuster.
- [Wang et al., 2008] Wang, L., Lu, J., Li, Y., Yahagi, T., and Okamoto, T. (2008). Noise removal for medical x-ray images in wavelet domain. *Electrical Engineering in Japan*, 163(3):37–46.
- [Yadav et al., 2014] Yadav, G., Maheshwari, S., and Agarwal, A. (2014). Contrast limited adaptive histogram equalization based enhancement for real time video system. *2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, pages 2392–2397.
- [Yasser, 2010] Yasser, A. (2010). Preprocessing techniques in character recognition. *Intech. doi*, 10:9776.
- [Yoo, 2004] Yoo, T. S. (2004). *Insight into images: principles and practice for segmentation, registration, and image analysis*. AK Peters/CRC Press.
- [Zhao et al., 2014] Zhao, X., Qu, Y., and Zhang, H. (2014). Sports video segmentation using spectral clustering. *Journal of Multimedia*, 9(7):873–678.
- [Zhu and Yuille, 1996] Zhu, S. and Yuille, A. (1996). Region competition: Unifying snakes, region growing, and bayes/mdl for multiband image segmentation. *IEEE Transactions on Pattern Anal. Machine Intelligence*, 18(9):884–900.

---

## Anexo



# Análisis de imágenes médicas para la extracción de biomarcadores mediante el algoritmo Local Binary Pattern.

Mario García, David Gutiérrez-Hernández,  
Manuel Ornelas-Rodríguez, Claudia Díaz-González and Mario Díaz  
*División de Estudios de Posgrado e Investigación  
Tecnológico Nacional de México – Instituto Tecnológico de León*  
Email: mario.iram.gq@gmail.com, david.gutierrez@leon.tecnm.mx,  
mornelas67@yahoo.com.mx, claudia.diaz@leon.tecnm.mx and israelnv49@gmail.com  
Guanajuato, León, México

Julio Salgado-Ramírez  
*Facultad de Ing. Biomédica  
Universidad Politécnica de Pachuca*  
Email: csalgado@upp.edu.mx  
Hidalgo, México

**Resumen**—Durante la segunda guerra mundial los avances en el área de la detección temprana sobre enfermedades sanguíneas eran enormes, destacando el resultado sobresaliente del trabajo de investigación de anemia en niños que desarrolló Helen Mackay en Viena. Un hecho que hizo pensar a los investigadores sobre la implementación de tecnología en el diagnóstico de estas enfermedades, ya que la detección sanguínea dependía de la agudeza y astucia de los ingenieros químicos y clínicos, una arte estrictamente empírica.

En una visión a través de la ingeniería biomédica, se utilizan aplicaciones de reconocimiento de patrones en el área de medicina, considerando al procesamiento de imágenes como un paso imprescindible para la creación de un sistema de diagnóstico, que pueda asistir al médico especialista para poder entender los aspectos morfológicos de la sangre y patológicos de la misma, esto debido al desarrollo tecnológico con el que contamos hoy en día. Los criterios de diseño en ingeniería y el fuerte conocimiento del tratamiento computacional en bioinformática son sólidos fundamentos en las áreas de biología, medicina, etc, por lo tanto estas tecnologías emergentes son herramientas que permiten el estudio superficial e invasivo para el diagnóstico y tratamiento de nuevas enfermedades.

El objetivo de este artículo es desarrollar un método en procesamiento de imágenes que nos permita visualizar el cambio de absorción de luz roja en la hemoglobina a través de una etapa en adquisición de imagen, pre-procesamiento, segmentación y extracción de características, esto último utilizando el algoritmo local binary pattern para obtener biomarcadores en estas imágenes, lo que supone un proyecto multidisciplinario que se adapte perfectamente con los retos de la ingeniería biomédica y el área de tratado de imágenes médicas.

**Palabras clave**—Ingeniería biomédica, Reconocimiento de patrones, Procesamiento de imágenes, Biomarcadores, Local Binary Pattern.

## I. INTRODUCCIÓN

Actualmente, el reconocimiento de patrones es un área de gran interés para la detección de aristas, texturas y relieves; principalmente por ser un campo multidisciplinario, fundado

en el campo del procesamiento de imágenes. En aplicaciones médicas, el procesamiento de imágenes se considera un paso vital en la creación de un sistema de diagnóstico; para que este sistema pueda ayudar al médico especialista actuando como una segunda opinión. [1]

Las etapas que se realizaron en el método de trabajo son: adquisición de la imagen, pre-procesado y extracción de características.

## II. HERRAMIENTAS UTILIZADAS EN INTELIGENCIA ARTIFICIAL

En los últimos años se ha adquirido un avance importante en la combinación de conocimientos entre la medicina y las ciencias de la computación, específicamente en el ramo de la inteligencia artificial [2]; en adquisición y segmentación de imágenes médicas, de esta manera encontramos avances significativos en el desarrollo de diferentes metodologías, para la implementación cada una de las especialidades médicas, pero para hablar sobre los avances en la detección de enfermedades hematológicas, los desarrollos tecnológicos han sido pocos, no por falta de investigación si no, por que han sido estos 4 años pasados en los cuales los investigadores llevaron a cabo trabajos que relacionan los procesos de medición clínicos con los métodos matemáticos de clasificación estadística que ofrecen procesos como, el procesamiento de imágenes y reconocimiento de patrones, partiendo de la aparente contradicción de como medir un activo intangible como es la sangre y la morfología de sus diferentes componentes celulares [3].

### A. Adquisición de la imagen

La visión por computadora trata de alguna forma de emular la capacidad de visión humana, de forma que, mediante la interpretación de las imágenes adquiridas, por ejemplo, con una cámara, se pueden conocer diversos objetivos en el ambiente y posición en el espacio [3]. La facilidad con la

que “vemos”, llevo a pensar a los primeros investigadores en inteligencia artificial (1960), que deberíamos hacer para que una computadora interpretara imágenes, al inicio pensaron que era realmente fácil, pero no resulto así, y muchos años de investigación han demostrado que es un problema complejo. Dando lugar a una definición de visión por computadora: “Es el estudio de procesos visuales naturales biológicos, para construir una herramienta que pueda extraer información a partir del procesamiento de imágenes, ofreciendo soluciones a problemas del mundo real.” [4]

### B. Pre-procesado

La etapa de pre-procesamiento de imágenes médicas, independientemente de que sean imágenes de rayos X (Rx), tomografías computarizadas (CT) o imágenes de resonancia magnética (MRI), permite procesar la información obtenida de las imágenes de manera más fácil [4]; ayudando en aspectos como: Corrección de deficiencias en la adquisición de datos para resultados satisfactorios en etapas posteriores y reducción o eliminación del nivel de ruido contenido en la imagen [5].

### C. Algoritmo LBP (Local Binary Pattern)

LBP es un operador de textura simple pero muy eficiente que etiqueta los píxeles de una imagen por vecindad de umbral de cada píxel con el valor del píxel central, y considera el resultado como un número binario. Debido a su poder de discriminación y la simplicidad de cálculo, este operador de textura se ha convertido en un método popular que se usa en varios tipos de aplicaciones [6]. Puede ser visto como un enfoque unificador de los modelos tradicionalmente divergentes del análisis de texturas: los estadísticos versus los estructurales. Quizá la propiedad más importante del operador, para aplicaciones del mundo real, es su robustez frente a cambios, en una escala de grises monótona, causados, por ejemplo, por las variaciones de iluminación y frente a rotaciones, en el caso de utilizar códigos circulares. Otra característica importante es su simplicidad computacional, lo que nos permite analizar las imágenes en tiempo real [7].

### D. Procesamiento de imágenes

El tratamiento o procesamiento digital de imágenes (TDI o PDI) es una de las etapas primarias del proceso por visión por computadora. De manera sencilla puede definirse como un conjunto de procedimientos que se realizan sobre una imagen (señal en 2D o 3D) obtenida mediante un captor conectado a la computadora (cámara web) : Para su almacenamiento, transmisión o tratamiento [8].

El PDI es una disciplina que parte de un proceso de más alto nivel denominado análisis automatizado de imágenes. Algunos establecen que el PDI como entrada una imagen  $f(X, Y)$ , y produce de salida una nueva imagen  $g(X, Y)$ , para de esta manera se obtenga nueva información [8].

1. El mejoramiento de una imagen: esto es a través del aumento para el contraste de la imagen de entrada, la

eliminación de ruido en dicha imagen, así como el filtrado espacial y de frecuencia.

2. La restauración de imagen: tiene como objetivo el estudio de fenómenos tales como el desenfoque, así como las alteraciones sobre la imagen causadas por el movimiento y otro tipo de degradaciones que pueden generarle en el momento de captación de una imagen.
3. Reconstrucción: esta área es muy empleada en áreas como la medicina y la geología para la obtención de una imagen tridimensional a través de los diferentes cortes (imágenes y en genes bidimensionales).

No obstante, en la actualidad se han logrado grandes avances teóricos como prácticos (sistemas de caracterización de imágenes) de índole diversa que se aplican a tareas tan complejas que van desde la orientación de misiles, la detección y reconocimiento de fotografías y en áreas de interpretación de imágenes biomédicas. De acuerdo con muchos autores, la problemática de investigación que se debe abordar para el análisis automatizado de imágenes tiene que ver principalmente con:

### III. TÉCNICAS ÓPTICAS PARA DIAGNÓSTICO MÉDICO

La creciente disponibilidad de fuentes estables y consistentes como los láseres, así como de detectores cada vez más precisos, han ayudado al rápido desarrollo de nuevas tecnologías para monitorear y diagnosticar. Esto ayuda al médico a prescribir al paciente lo más seguro y adecuado. Además, las técnicas ópticas ayudan al desarrollo de la investigación biomédica [9].

### IV. METODOLOGÍA

Para comenzar el trabajo planteado utilizando el procesamiento de imágenes, esto para detectar el cambio físico que presenta la hemoglobina al absorber la luz roja emitida por un rayo láser que produce una longitud de onda de 650 nm cuando golpea el dedo índice de un paciente para analizar este proceso, la metodología utilizada para este trabajo se muestra en la Fig.1.

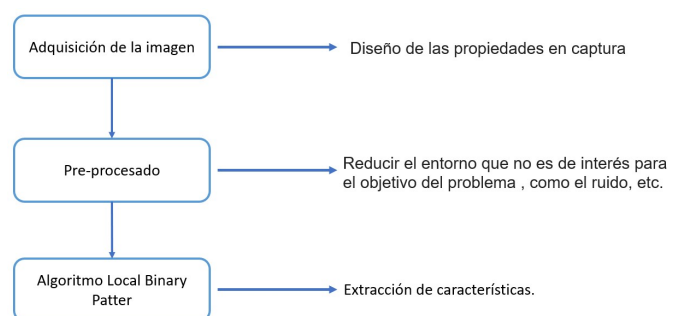


Fig. 1. Metodología planteada.

El proceso de búsqueda de información sobre los efectos físicos implicados en la absorción del rayo infrarrojo con

efecto sobre la hemoglobina es importante para obtener características en imágenes médicas. Se espera identificar una diferencia de color en cada imagen, lo que permitirá distinguir un cambio en la absorción de infrarrojos en cada paciente, utilizando un dispositivo no invasivo para los usuarios.

#### A. Adquisición de la imagen

Para obtener muestras en diferentes pacientes se realiza una captura del dedo índice con incidencia de luz láser, a través de un dispositivo no invasivo que cuenta con webcam y un módulo de luz láser que nos permite tomar las diferentes muestras a cada paciente de forma práctica. El equipo utilizado se muestra en la Fig.2



Fig. 2. Dispositivo de captura con la incidencia de luz láser.

Cabe mencionar que el dispositivo cuenta con un control de iluminación que nos permite realizar tomas controladas, estables y continuas, esta última refiriéndose a la toma de 30 imágenes simultáneas por paciente.

De la misma forma para la presente investigación se trabajó con un grupo control de 29 personas todas sin presencia de ninguna enfermedad al que llamaremos grupo control, de esta forma contamos con un total de 870 imágenes para realizar los 3 procesos propuestos en la metodología. Las características generales de las imágenes son 113x131 en jpg, formato unit8.

Como resultado de la captura de imágenes a través del dispositivo con la incidencia de la luz láser se muestra en la Fig.3.




Fig. 3. Imágenes de la uña del dedo índice afectada por la luz láser.

#### B. Pre-procesado

Para continuar con el esquema de trabajo, procedemos a cortar las imágenes obtenidas mediante MATLAB. Teniendo

como resultado una imagen con el área de interés de nuestro proyecto, como se muestra en la Fig.4.



Fig. 4. Imágenes preprocesadas con incidencia a luz láser para obtener el área de interés.

Al convertir imágenes RGB a escala de grises, se elimina la información de tono y saturación mientras se retiene la luminancia, esto nos permite trabajar con imágenes ya que podemos ver una escala de claridad de intervalos uniformes. Por lo que podemos definir que esta calidad de color puede diferir de un paciente a otro, se puede ver el proceso de conversión de la escala de grises.

El ajuste de la escala de grises consiste en la multiplicación de cada componente por 3 constantes definidas: Alfa, Beta y Gamma. Este proceso resta toda la información de color que contiene cada píxel y nos deja con una separación de 255 niveles entre blanco y negro.

Estas 3 constantes se obtienen como la separación entre los canales RGB y negro:

- Alfa: separación entre rojo y negro. (0,299).
- Beta: Separación entre verde y negro. (0,599).
- Gamma: separación entre azul y negro. (0,111).

El software Matlab, es la herramienta de programación con la que se ha trabajado en este proyecto, tiene funciones específicas ya incorporadas en la caja de herramientas para el procesamiento de imágenes que permite procesar directamente. Sin embargo, es necesario saber cómo funciona cada una de las funciones que se encuentran en la caja de herramientas. El proceso de transformación en escala de grises se muestra en la Fig.5.

$$G = \begin{pmatrix} (g_{11}, g_{11}, g_{11}) & \dots & (g_{1n}, g_{1n}, g_{1n}) \\ \vdots & \ddots & \vdots \\ (g_{m1}, g_{m1}, g_{m1}) & \dots & (g_{mn}, g_{mn}, g_{mn}) \end{pmatrix}$$

Fig. 5. Transformación en escala de grises

Como se puede apreciar en la Fig.6, se muestran imágenes en escala de grises pre-procesadas con un mínimo de ruido, esto es reportable ya que son imágenes con efecto físico de hemoglobina. De esta forma, teniendo el área de interés de nuestra imagen procedemos a pasarla a escala de grises para reducir la incidencia de ruido.



Fig. 6. Imágenes de la región de interes con incidencia de luz láser en escala de grises.

### C. Algoritmo Local Binary Pattern (LBP)

La importancia del algoritmo LBP en el proceso de investigación es fundamental para la extracción de características en la imagen. Este algoritmo, como se mencionó en el apartado introductorio, funciona mediante un mapeo de imágenes obteniendo el porcentaje medio de los píxeles teniendo en cuenta matrices de 3x3 cada una y comparando el resultado de las mismas con un píxel central. Esto se hace mediante imágenes 2D (escala de grises), para obtener un histograma de 255 valores resultante del proceso de escala de grises, esquema que se puede visualizar mejor a través de la Fig.7.

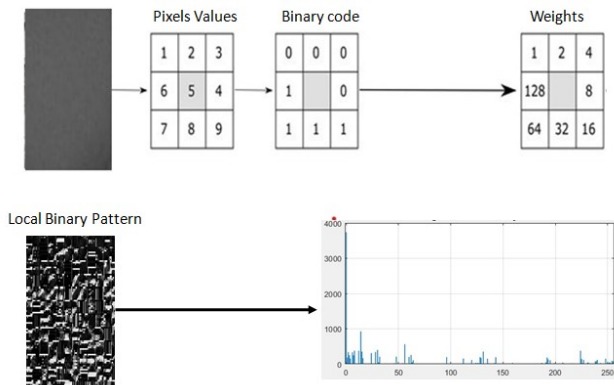


Fig. 7. Esquema de trabajo a través del algoritmo Local Binary Pattern.

## V. RESULTADOS

Los resultados obtenidos a través de la siguiente investigación vienen dados por la implementación del algoritmo LBP para la extracción de características, como un proceso de caracterización de las imágenes con una incidencia de luz láser en el dedo índice de los pacientes.




Fig. 8. Resultados de la etapa de preprocesamiento.

El operador describe cada píxel por los niveles de gris relativos de sus píxeles vecinos; consulte la Figura.8. para

observar el histograma que representa a la imagen en escala de grises con incidencia de la luz laser. Si el nivel de gris del píxel vecino es mayor o igual, el valor se establece en uno, de lo contrario, en cero, esto mencionado anteriormente en el proceso del algoritmo Local Binary Pattern.

El descriptor describe el resultado sobre la vecindad como un número binario (patrón binario), en la Fig.9 puede ver el modelo matemático utilizado para el experimento.

$$LBP_{R,N}(x,y) = \sum_{i=0}^{N-1} s(n_i - n_c)2^i, \quad s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & otherwise \end{cases}$$

Fig. 9. Modelo matemático del Local Binary Pattern.

Donde  $n_c$  corresponde al nivel de gris del píxel central de un vecindario local y  $n_i$  a los niveles de gris de  $N$  píxeles igualmente espaciados en un círculo de radio  $R$ . Dado que la correlación entre píxeles disminuye con la distancia, gran parte de la información de textura se puede obtener de los vecindarios locales.




Fig. 10. Implementación del algoritmo Local Binary Pattern (LBP)

El resultado de usar el algoritmo local binary pattern en la base de datos (imágenes obtenidas por el equipo propuesto) da como resultado la siguiente implementación en la Fig.10

Utilizar el algoritmo local binary pattern nos permitirá extraer las características de la imagen para encontrar los diferentes rangos o escalas de grises que hay en la imagen, sobre todo podemos decir que el estudio de estas imágenes podría darnos una diferencia de absorción en la hemoglobina de manera que de esta forma podemos comenzar a estudiar este fenómeno biológico. Cabe mencionar que este algoritmo nos permite obtener los datos esenciales de la imagen a los cuales en el estudio del estado del arte son denominados biomarcadores, por medio de los mismos nos permitirán pasar a una etapa futura de clasificación o agrupación de estos datos revelando el interés por este proyecto.

## VI. CONCLUSIONES

El presente trabajo obtuvo los resultados esperados en cuanto la implementación del algoritmo local binary pattern, el cual nos permitió extraer el vector de características de cada una de las imágenes de nuestros pacientes, de igual manera el equipo funciono de manera estable al momento de obtener dichas imágenes de trabajo de manera se trabajó sin ningún contratiempo, cabe mencionar que tanto el dispositivo como



nuestra base de datos son de nuestra propia autoría. El desarrollo de este trabajo pretende descubrir nuevos paradigmas en los componentes de la sangre y alternar métodos que prometan estudios rápidos y seguros.

#### VII. TRABAJOS FUTUROS

Como trabajo futuro, se contempla utilizar cada uno de los vectores característicos obtenidos en la presente investigación para su clasificación, esto a través de métodos supervisados o no supervisados, esto nos permitirá generar grupos de control para su estudio, de igual forma el hecho de incrementar la base de datos con pacientes que presenten anemia en diferentes grados reforzará la idea de una predicción sobre los diferentes niveles de la condición. El uso de algoritmos en deep learning o machine learning es una posibilidad para el estudio de la base de datos.

#### REFERENCIAS.

- [1] Giovani Gómez, L. Enrique Sucar,(2017), "Vision Artificial", (Tesis de degree), Instituto Nacional de Astrofísica, Óptica y Electrónica,Puebla. México.
- [2] Roberto Rodríguez Morales. (2012).Processing and Analysis Digital the Images . México: Alfaomega Ra - Ma.
- [3] D. Ballard, C. Brown, Computer vision, New Jersey: Prentice Hall, 1982.
- [4] J. Canny, A computational approach to edge detection. IEEE Trans. on PAMI, vol. 8(6), pp. 679-698, November 1986.
- [5] Timo Ahonen, Abdenour Hadid and Matti Pietik'ainen, Face Recognition with Local Binary Patterns, Machine Vision Group, Infotech Oulu, PO Box 4500, FIN-90014 University of Oulu, Finland.
- [6] Phillips, P.J., Wechsler, H., Huang, J., Rauss, P.: The FERET database and evaluation procedure for face recognition algorithms. Image and Vision Computing 16 (1998) 295-306.
- [7] Ojala, T., Pietik'ainen, M., M'äenp'ä'a, T.: Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE Transactions on Pattern Analysis and Machine Intelligence 24 (2002) 971-987
- [8] J. Schindelin, V. Kaynig, I. Arganda-Carreras, Fiji: An Open-Source Platform for Biological-Image Analysis, Nature America, pp. 676-682, 2012.
- [9] M.J. Jones, J.M. Regh, Statistical color models with application to skin detection. Proc. of the CVPR, vol. I, pp. 274-280, 1999.
- [10] R. S. Michalski, Q. Zhang, M. A. Maloof, E. Bloedorn, The MIST Methodology and its Application to Natural Scene Interpretation, Proceedings of the Image Understanding Workshop, Palm Springs, CA, pp. 1473-1479, February, 1996.