

Área de Conocimiento de Tecnología de la Información y  
Comunicación

**“Implementación de recursos didácticos  
que faciliten el proceso de enseñanza-  
aprendizaje en la temática: procesamiento  
digital de imágenes médicas”**

TRABAJO MONOGRÁFICO PARA OPTAR AL TÍTULO DE  
INGENIERO ELECTRONICO

**Elaborado por:**

Br. Néstor Manuel  
Rivera Carrión  
Carnet: 2016-0383U

**Tutor:**

TeknL. Marco  
Antonio Munguía  
Mena

29 de mayo de 2024  
Managua, Nicaragua



## **Dedicatoria**

Agradezco primeramente a Dios por brindarme sabiduría y entendimiento en el transcurso de mi carrera, por darme siempre fortaleza en los momentos que más lo necesitaba y brindarme la capacidad de adquirir los conocimientos necesarios que me trajeron hasta aquí, a mis padres por siempre apoyarme en todos los aspectos y enseñarme a nunca rendirme a pesar de todas las adversidades por las que pase a lo largo de mi carrera, a todos mis amigos y familiares que me ofrecieron su apoyo incondicional siempre que lo necesite. También a mi tutor y profesor Marco Munguía que siempre estuvo ahí brindando su apoyo e información y el soporte para culminar este trabajo.

## **Agradecimiento**

Primeramente, agradecer a Dios nuestro señor por permitir llegar a este momento único y especial, por darnos salud, sabiduría para lograr nuestros objetivos.

A mis padres por brindar ese apoyo en todo momento, por su motivación en el día a día, por todo el sacrificio realizado y por todo su amor brindado para lograr culminar una etapa más en nuestra vida.

Agradecer a nuestro tutor, maestro, amigo Marco Munguía por la orientación, disposición, dedicación al brindar su tiempo para la realización de este trabajo.

## **Resumen**

El presente documento muestra el resultado del desarrollo de recursos didácticos en la temática de procesamiento digital de imágenes médicas que sirvan de respaldo y apoyo en la asignatura Tratamiento Digital de señales en el Técnico Superior en Biomedicina. A lo largo del documento se aborda información clara y precisa para comprender mejor el procesamiento de imágenes.

La herramienta computacional utilizada es Matlab que nos permite realizar el desarrollo de los scripts, además de eso posee Toolbox o librerías específicas en procesamiento digital de imágenes, en este trabajo se utiliza Image Processing Toolbox que nos proporciona una amplia gama de algoritmos estándar de referencia y apps de flujo de trabajo para procesar, visualizar y analizar imágenes, y desarrollar algoritmos. Este Toolbox nos permite realizar tareas como segmentación de imágenes, perfeccionamiento de imágenes, reducción de ruido, transformaciones geométricas y registro de imágenes utilizando Deep Learning y técnicas tradicionales de procesamiento de imágenes.

Este documento también describe y detalla los recursos desarrollados que comprende etapas de preprocesamiento aplicando filtros para mejorar la calidad de las imágenes y segmentación de imágenes o de un conjunto de imágenes (Dataset), aplicando técnicas de segmentación basadas en regiones, bordes y textura y segmentación basada en aprendizaje automático utilizando una red neuronal previamente entrenada.

## **Abstract**

The following document shows the result of the development of didactic resources on the topic of digital processing of medical images that serve as support and assistance in the Digital Signal Processing subject in the Higher Technician in Biomedicine. Throughout the document, clear and precise information is provided to better understand image processing.

The computational tool used is Matlab, which allows us to develop scripts and has specific toolboxes or libraries for digital image processing. In this work, the Image Processing Toolbox is used, providing a wide range of standard reference algorithms and workflow apps for processing, visualizing, and analyzing images, as well as developing algorithms. This Toolbox enables us to perform tasks such as image segmentation, image enhancement, noise reduction, geometric transformations, and image registration using Deep Learning and traditional image processing techniques.

This document also describes and details the developed resources, which include preprocessing stages applying filters to improve the quality of the images and image segmentation of a single image or a set of images (Dataset), applying segmentation techniques based on regions, edges, and texture, as well as segmentation based on machine learning using a pre-trained neural network.

## **CONTENIDO**

CAPITULO I. INTRODUCCIÓN.....	1
ANTECEDENTES .....	2
JUSTIFICACION .....	4
OBJETIVOS .....	6
Objetivo General .....	6
Objetivos Específicos.....	6
CAPITULO II. MARCO TEÓRICO.....	7
2.1. Imagen digital.....	7
2.2. Imagen Médica.....	7
2.3. Tipos de Imágenes.....	8
2.3.1. Imágenes Binarias .....	8
2.3.2. Imágenes en escala de grises .....	8
2.3.3. Imágenes RGB (Red Green Blue) .....	8
2.4. Tipos de imágenes medicas.....	9
2.4.1. Imágenes por resonancia magnética (MRI).....	9
2.4.2. Tomografías computarizadas .....	10
2.4.3. SPECT.....	10
2.4.4. Tomografía computarizada por emisión de positrones (PET).....	11
2.4.5. Mamografía .....	11
2.5. Procesamiento Digital de Imágenes.....	12
2.5.1. Orígenes.....	12
2.5.2. Definición.....	13
2.5.3. Pre-procesamiento de la imagen.....	14
2.5.4. Extracción de características .....	15
2.5.5. Segmentación de imágenes. ....	15
2.5.6. Clasificación.....	15

2.5.7. Áreas de Aplicación .....	16
2.6. Conceptos básicos de MATLAB.....	20
2.6.1. Formatos disponibles en MATLAB .....	21
2.6.2. Digital Imaging and Communications in Medicine (DICOM) .....	21
2.7. Biomedicina.....	22
2.7.1. Ingeniería biomédica .....	22
2.8. Clases principales de procesado digital de imágenes.....	23
2.8.1. Mejora o realce de la imagen .....	23
2.8.2. Restauración de la imagen .....	23
2.8.3. Segmentación de la imagen .....	23
2.9. Preprocesamiento de imágenes.....	23
2.9.1. Filtros.....	23
2.9.2. Filtros lineales.....	24
2.9.3. Filtros no lineales.....	24
2.10. Técnicas de segmentación en aplicaciones medicas .....	25
2.10.1. Segmentación basada en Umbralización .....	26
2.10.1.1. Cálculo del umbral optimo .....	26
2.10.1.2. Método Otsu.....	27
2.10.2. Segmentación basada en bordes.....	28
2.10.2.1. Operadores basados en la primera derivada (Gradiente) .....	28
2.10.2.2. Operadores Prewitt y Sobel.....	29
2.10.2.2.1. Tamaño y dirección del gradiente .....	29
2.10.2.3. Operador Sobel .....	30
2.10.2.4. Operador Prewitt .....	30
2.10.2.5. Operador Roberts.....	30
2.10.2.6. Operadores basados en la Segunda derivada .....	31
2.10.2.7. Detección de bordes con la segunda derivada.....	31

2.10.2.8. Filtro de Canny .....	33
2.10.2.9. Detección de Contornos .....	34
2.10.3. Segmentación basada en regiones .....	35
2.10.3.2. Crecimiento de Regiones .....	36
2.10.3.3. Algoritmo Región Growing.....	37
2.10.3.4. Procesamiento basado en Regiones de Interés (ROI) .....	38
2.10.4. Técnicas de agrupamiento o clustering.....	39
2.10.5. Algoritmo de Agrupamiento (C-means) .....	40
2.10.6. Segmentación basada en texturas .....	42
2.10.6.1. Matriz de Co-ocurrencia .....	42
2.10.6.2. Medidas Estadísticas de la Textura.....	43
2.10.7. Morfología de imágenes.....	44
2.10.7.1. Transformaciones básicas.....	44
2.10.8. Segmentación basada en aprendizaje automático .....	46
2.10.8.1. Redes Neuronales.....	46
2.10.8.2. Redes Neuronales Convolucionales (CNNs/ConvNets).....	47
2.10.8.3. Red Neuronal Convolutiva SynthSeg .....	47
2.11. Recursos Didácticos. ....	49
2.12. Desarrollo de Recursos Didácticos .....	50
2.12.1. Etapa de selección.....	50
2.12.2. Etapa de composición.....	50
2.12.3. Etapa de evaluación .....	50
2.13. Sistema Nacional de Evaluación para el Aprendizaje (SNEPA) .....	51
Capítulo III. ANALISIS Y PRESENTACION DE LOS RESULTADOS .....	52
3.1. Diseño Metodológico.....	52
3.2. Estructura de los recursos didácticos (guías de laboratorio).....	52
3.3. Diseño de los recursos didácticos.....	53

3.4. Implementación de los Recursos Didácticos.....	57
3.5. Evaluación de las guías de laboratorio mediante encuesta .....	57
Capítulo IV. CONCLUSIONES Y RECOMENDACIONES.....	61
4.1. Conclusiones.....	61
4.2. Recomendaciones .....	62
BIBLIOGRAFÍA .....	63

## Indice de Figuras

Figura 1: Sistema de procesamiento digital de imágenes .....	13
Figura 2: Espectro electromagnético .....	16
Figura 3: Tomografía por Emisión de Positrones (PET) .....	17
Figura 4: Espermatozoides de gacela Mohor observados con microscopía electrónica de barrido.....	17
Figura 5: imagen satelital banda infrarroja .....	18
Figura 6: Resonancia Magnética.....	18
Figura 7: Ultrasonido .....	19
Figura 8: Microscopía Electrónica .....	19
Figura 9: Umbral óptimo para la binarización de dos objetos.....	27
Figura 10: Tomografía de dimensiones M*N .....	27
Figura 11: Proceso de segmentación de 2 distribuciones mediante el método Otsu.....	27
Figura 12: Proceso de correspondencia entre la matriz V y la vecindad .....	36
Figura 13: Proceso después de formar una región segmentada.....	37
Figura 14: Muestras representativas de los escaneos 3D sintéticos.....	48
Figura 15: Resumen de primera etapa de entrenamiento .....	49

## **CAPITULO I. INTRODUCCIÓN**

El procesamiento digital de imágenes se ha convertido en una herramienta fundamental, que sirve de apoyo a diversas disciplinas orientadas a proporcionar elementos certeros para la adecuada toma de decisiones. Una de las disciplinas más importante en las que se usa y aplica esta importante herramienta es en la Medicina, en donde las imágenes juegan un rol importante en los diagnósticos médicos [1]. Por otro lado, se han desarrollado distintas técnicas de digitalización mediante diferentes estándares y protocolos que ofrecen mejoras notables en la toma de las imágenes médicas y por ende proporcionan al personal de salud mejor información para la toma de decisiones.

La universidad Nacional de Ingeniería en su misión se plantea la búsqueda permanente de la excelencia académica. Para lograr su misión la universidad debe de asegurar que sus graduados tengan un buen nivel de competitividad como profesionales. Un recurso didáctico bien diseñado, es una valiosa herramienta que contribuye a reforzar la enseñanza y en el que los alumnos pueden lograr una mayor comprensión de la parte teórica y su aplicación práctica.

Así mismo, la Universidad Nacional de Ingeniería siempre en vanguardia con las necesidades de la sociedad nicaragüense, ofreció un técnico superior en tecnología biomédica, en el cual se atendió estudiantes del personal del ministerio de salud [2]. Dentro de este, ellos reciben el curso de procesamiento digital de bioseñales, el cual ha estado enfocado a la parte de electrocardiografía, electroencefalografía y sonidos del corazón. Sin embargo, en la asignatura de Procesamiento Digital de Bioseñales se identifica la falta de recursos didácticos, que permitan al estudiante fortalecer el proceso de enseñanza-aprendizaje en la temática procesamiento digital de imágenes médicas.

Por tal motivo, el presente trabajo muestra una propuesta de recursos didácticos que combinan la teoría y la práctica, todo esto con el fin de complementar y mejorar el proceso de enseñanza-aprendizaje para que los estudiantes puedan adquirir el conocimiento necesario y puedan formarse como profesionales en la asignatura de procesamiento digital de bioseñales del técnico superior en tecnología biomédica.

## **ANTECEDENTES**

Desde la invención de los primeros sistemas y métodos para obtener una imagen médica siempre se ha detectado que gran parte de dichas imágenes no pueden ser interpretadas correctamente, por ello se han desarrollado algoritmos y técnicas que busquen disminuir este margen de error y con ello lograr disminuir dichos errores. Con el desarrollo de algunos software y nuevos sistemas de imágenes médicas se ha logrado disminuir este margen de error, sin embargo, aún sigue existiendo [3].

En el contexto educativo superior nacional y regional, se realizó un proceso de búsqueda y recopilación de información orientados a verificar cuantos trabajos de este nivel se han realizado en relación al diseño de recursos didácticos y al procesamiento digital de imágenes médicas, encontrando trabajos de investigación relacionados al procesamiento digital de señales (DSP) y diseño de guías de estudio para distintas asignaturas en la carrera de Ingeniería Electrónica de la Universidad Nacional de Ingeniería.

En *“Desarrollo de un sistema de reconocimiento de imágenes utilizando Raspberry Pi y MATLAB que contribuya al aprendizaje del tratamiento digital de señales”* trabajo monográfico realizado en el área de procesamiento digital de señales en el año 2016, el cual su enfoque consiste en desarrollar e implementar guías de laboratorio enfocados en el procesamiento digital de imágenes con propósitos académicos, con el fin de que los estudiantes obtengan y puedan desarrollar habilidades en esta área [4].

En *"Aplicaciones de procesamiento digital de imágenes y videos con propósitos académicos"*, trabajo monográfico realizado en el área de procesamiento digital de señales en el año 2017. En el cual a lo largo del documento se encuentra información acerca del procesamiento digital de imágenes y videos. Se desarrollan algoritmos para procesar imágenes y videos en Matlab. Todo esto con el propósito de realizar guías de laboratorio que tendrán como objetivo contribuir al desarrollo de los estudiantes en el área de procesamiento digital de señales [5].

En “*Método para la detección de cáncer de mama en mamografías usando Convolutional Neural Networks (CNN)*”, trabajo monográfico realizado en el área de procesamiento de imágenes digitales en el año 2021. En el proyecto a como lo llaman los autores, hacen uso de diferentes arquitecturas presentes en Deep Learning que, combinadas con un framework, ofrecerán un sistema auxiliar de referencia para la detección y localización de cáncer de seno, para que radiólogos puedan reducir su carga de trabajo interactuando a través de una WebApp [6].

En “Implementación de guías de laboratorio para realizar mediciones y análisis de eventos en la banda de 850 MHz de la tecnología WCDMA”, trabajo monográfico realizado en el área de Telecomunicaciones en el año 2016. Este documento consiste en la implementación de 10 guías de laboratorio para realizar mediciones y análisis de la tecnología WCDMA, de esta forma contribuir al proceso de enseñanza de la UNI [7].

En “Creación de prácticas de Laboratorios de centrales privadas PBX para la asignatura de Redes Telefónicas”, trabajo monográfico realizado en el área de Telecomunicaciones en el año 2011. Este tiene como objetivo principal, la elaboración de prácticas de laboratorios que brinden un componente práctico actualizado a la disciplina de Redes Telefónicas con lo que se pretende lograr la consolidación de los conocimientos asimilados durante la asignatura [8].

En “Segmentación digital de imágenes médicas para el mejoramiento del diagnóstico de anomalías en los centros radiológicos de la ciudad de Ambato-Ecuador”, trabajo realizado previo a la obtención de título en Ingeniería en Electrónica y Telecomunicaciones en el año 2013, en el documento se plantea la elaboración de un programa que desarrolle segmentación de imágenes en áreas específicas con el fin de diagnosticar anomalías en centros radiológicos que ayude al tratamiento y análisis de las imágenes utilizadas y a más de eso conocer el modelo matemático que se utiliza para ejecutar cada uno de los procesos [9].

## **JUSTIFICACION**

El análisis y procesamiento digital de imágenes médicas en los últimos años ha tenido un gran avance y se han desarrollado diferentes algoritmos que agilizan procesos que permiten tener un mejor desempeño en cuanto a brindar un diagnóstico. Los médicos son los que interpretan dichas imágenes y demandan herramientas que les permitan localizar (segmentar) órganos y tejidos con mayor precisión y rapidez, así como la identificación y caracterización cuantitativa de las patologías presentes en ellos. Es por ello que surge la necesidad de indagar y conocer acerca del conocimiento empleado y el papel importante que juega la ingeniería, así como los conocimientos computacionales.

La Ingeniería Biomédica es una disciplina que aplica los principios y técnicas de la ingeniería al campo de la medicina o las llamadas, ciencias de la vida, que combina los criterios de diseño en ingeniería y las herramientas de análisis provenientes de las matemáticas, la física y la química a la resolución de problemas en medicina, biología, biotecnología, farmacia, etc.

En la Facultad de Electrotecnia y Computación de la Universidad Nacional de Ingeniería, en coordinación con el MINSA se desarrolló un Técnico Superior en Tecnología Biomédica el cual tuvo un desempeño exitoso y de tal manera se ha propuesto que se implemente una ingeniería biomédica, esto significa que se requiere de más profesionales en esta área, por tal razón en pro del desarrollo del aprendizaje se propuso elaborar recursos didácticos para procesamiento digital de imágenes médicas usando Matlab en la asignatura Procesamiento Digital de Bioseñales, teniendo en cuenta que en dicha asignatura no existen guías de laboratorios y solo solo se han tomado casos de estudio haciendo uso de Matlab orientado a señales de audio, señales de encefalograma y de electrocardiogramas, no así para imágenes médicas.

Debido a la importancia que presenta el técnico superior de ingeniería biomédica para formar profesionales en el sector salud y para el desarrollo de la biomedicina del país, los estudiantes de este técnico necesitan desarrollar habilidades que les permitan desempeñarse en este campo. Una forma es a través de la realización de prácticas de laboratorios que abarquen los contenidos fundamentales establecidos en el programa de la asignatura, logrando que los

estudiantes cuenten con una mejor preparación y de esta manera aportar conocimientos que ayuden en el entorno laboral.

Es por esto que este documento tiene como propósito fundamental contribuir en la creación de prácticas de laboratorio para mejorar el proceso de enseñanza-aprendizaje en el Técnico Superior en Biomedicina usando el entorno de desarrollo integrado que ofrece Matlab para el Procesamiento Digital de imágenes a fin de dar un aporte que sirva como base para el desarrollo de las asignaturas impartidas por los docentes o para futuras investigaciones de los estudiantes.

## **OBJETIVOS**

### **Objetivo General**

- Implementar recursos didácticos para la asignatura Procesamiento Digital de Bioseñales del Programa del Técnico Superior en Tecnología Biomédica que faciliten el proceso de enseñanza-aprendizaje en la temática: tratamiento digital de imágenes médicas.

### **Objetivos Específicos**

- Estudiar las técnicas y fundamentos teóricos empleadas en el procesamiento digital de imágenes que permiten su visualización en formato digital.
- Implementar etapas de procesamiento de imágenes que comprendan el uso de técnicas como: extracción de características que eliminen los componentes indeseados, segmentación para la extracción de datos relevantes de áreas específicas.
- Diseñar recursos de laboratorio como medio de enseñanza-aprendizaje para los estudiantes del Técnico Superior en Biomedicina con el propósito que amplíen sus conocimientos de procesamiento digital de imágenes.
- Evaluar los recursos de laboratorio mediante encuestas a estudiantes del técnico superior en biomedicina con el fin de la medición del impacto que estas tuvieron en el proceso de enseñanza-aprendizaje.

## **CAPITULO II. MARCO TEÓRICO**

### **2.1. Imagen digital.**

Se define una imagen como una función  $f(x, y)$  bidimensional generalmente de intensidad de luz donde  $x$  e  $y$  representan las coordenadas espaciales de un punto, y  $f(x, y)$  es la intensidad o nivel de gris de la imagen en ese punto. Cuando las coordenadas espaciales son un número de elementos finito y la amplitud cubre un rango de valores finito, se dice que es una imagen digital. Por tanto, una imagen digital puede entenderse como una matriz obtenida mediante un muestreo de función bidimensional  $f$  y de cuantificación de los resultados muestreados. La imagen digital resultante suele estar representada por una matriz bidimensional [10].

### **2.2. Imagen Médica.**

Se llama imagen medica al conjunto de técnicas específicas y procesos usados para la adquisición y reconstrucción de imágenes del cuerpo humano por las múltiples tecnologías disponibles, con propósitos clínicos. Estas abarcan diferentes modalidades y procesos para obtener imágenes del cuerpo humano con fines de diagnóstico y tratamiento y, por lo tanto, desempeñan un papel importante en las iniciativas para mejorar la salud pública para todos los grupos de población [11].

La imagen médica no puede ser tratada de igual manera que otras imágenes de escenas naturales. Presenta una problemática específica, que varía dependiendo de la técnica mediante la que se ha generado la imagen. En general, se puede hablar de imágenes en niveles de gris, con ruido, poco contraste, bordes mal definidos y borrosos, y, por tanto, aparecen problemas en la diferenciación de los órganos representados en la imagen. Si, además, se añade el hecho de que el principal objetivo de la imagen médica es el diagnóstico y el conocimiento de lo que sucede dentro del cuerpo humano, la precisión y exactitud de lo que se identifica y mide resulta de vital importancia.

## **2.3. Tipos de Imágenes**

La elección de un formato de imagen se puede determinar, en su mayor parte, no solo por el contenido de la imagen sino también por el tipo de datos que la imagen contiene, a continuación, se mencionan algunos de los principales tipos de imágenes:

### **2.3.1. Imágenes Binarias**

Una imagen binaria es aquella que consta de píxeles que pueden tener exactamente dos colores, generalmente blanco y negro. Las imágenes binarias también se denominan bi-level o two-level, Pixelart hecho de dos colores a menudo se denomina 1-Bit o 1bit. Esto significa que cada píxel se almacena como un único bit, es decir, un 0 o un 1. Los nombres blanco y negro, B&N, monocromático o monocromático suelen ser utilizado para este concepto, pero también puede designar cualquier imagen que tenga solo una muestra por píxel, como las imágenes en escala de grises [12].

### **2.3.2. Imágenes en escala de grises**

Es una matriz cuyos valores han sido escalados para representar un determinado número de intervalos. Si la imagen es del tipo uint8, entonces los datos que la conforman se encuentran en el intervalo [0, 255]. Si la imagen es del tipo double, entonces los datos que la constituyen son del tipo flotante y están en el intervalo [0, 1] [13].

### **2.3.3. Imágenes RGB (Red Green Blue)**

Son arrays de píxeles de color de tamaño M-por-N-por-3, donde cada pixel está formado por una tripleta de valores correspondientes a las componentes roja, verde y azul de la imagen en la posición determinada. El tipo de dato de las componentes determina el rango de valores. Por ejemplo, si la imagen RGB es de clase double, su rango irá de 0 a 1, o si es de clase uint8, tendrá valores numéricos entre 0 y 255.

## **2.4. Tipos de imágenes medicas**

### **2.4.1. Imágenes por resonancia magnética (MRI).**

El cuerpo humano se compone principalmente de agua y, por lo tanto, contiene muchos núcleos de hidrógeno. Las resonancias magnéticas adquieren una imagen al alterar el equilibrio magnético de los núcleos de hidrógeno en el cuerpo. Luego, el escáner mide el tiempo que tardan los núcleos de hidrógeno en recuperar el equilibrio, que varía según la composición del órgano del que se están tomando imágenes. Las resonancias magnéticas son particularmente útiles para obtener imágenes de tejidos blandos como el cerebro, la médula espinal, los nervios, los músculos, los ligamentos y los tendones, ya que los tejidos blandos tienen más contenido de agua que los huesos. A diferencia de otras modalidades de radiología, las resonancias magnéticas no utilizan radiación ionizante. Sin embargo, los profesionales médicos deben asegurarse de que el paciente que se somete a las exploraciones no tenga ningún metal en el cuerpo que pueda ser atraído por el campo magnético.

Hay varias formas de resonancia magnética, según la naturaleza de las partículas y el tipo de propiedad de magnetización medida, incluida la resonancia magnética ponderada en T1, la resonancia magnética ponderada en T2, la resonancia magnética de difusión y la resonancia magnética funcional. Los diferentes tipos de MRI brindan diferentes conocimientos sobre el cuerpo humano.

Matemáticamente, un escáner de resonancia magnética genera una imagen en el dominio de Fourier, también conocido como espacio k. Cada escaneo generalmente consta de una colección de cortes 2-D representados en el espacio k. El escáner transforma la imagen del espacio k en el dominio espacial, lo que le permite observar la anatomía de la imagen. El resultado final del escáner de resonancia magnética es un volumen tridimensional en el dominio espacial con detalles de localización espacial. Las imágenes de resonancia magnética son propensas a degradaciones en forma de ruido de adquisición, artefactos de submuestreo y artefactos de movimiento del paciente.

### **2.4.2. Tomografías computarizadas**

La tomografía computarizada (CT) es una técnica de escaneo no invasivo ampliamente aplicada en sectores como la medicina, la industria y la geología. Esta técnica permite la reconstrucción tridimensional de la estructura interna de un objeto que es iluminado con una fuente de rayos-X. La reconstrucción se forma con imágenes bidimensionales de cortes transversales del objeto. Cada corte se obtiene a partir de las medidas de fenómenos físicos como la atenuación, la dispersión y la difracción de los rayos-X, como resultado de la interacción con el objeto [14].

En general, la adquisición de las medidas se realiza con métodos basados en alguno de estos fenómenos y empleando diversas arquitecturas clasificadas en generaciones. Estos cortes realizados se llaman imágenes tomográficas y contienen información más detallada que los rayos X convencionales. Una vez que la computadora de la máquina recolecta varios cortes sucesivos, se pueden “apilar” digitalmente para formar una imagen tridimensional del paciente que permita más fácilmente la identificación y ubicación de las estructuras básicas, así como de posibles tumores o anomalías [15].

### **2.4.3. SPECT**

La tomografía por emisión de fotón único, SPECT (del inglés Single Photon Emission Computerized Tomography), este tipo de imágenes proporciona información metabólica y funcional sobre el órgano cardíaco. Consiste en inyectar radios trazadores en el torrente sanguíneo que muestran las imágenes a medida que fluyen a través de varios órganos. A través de esta técnica, se puede determinar si un paciente tiene o no alguna enfermedad cardiovascular. Lo ideal es que se realice cuando el paciente está en reposo o durante una prueba de esfuerzo nuclear.

El procedimiento también incluye una imagen de perfusión que generalmente se realiza una vez en reposo y la segunda vez después del estrés cardíaco. La sonda utilizada tiene una vida media de seis horas, lo que da tiempo suficiente para que los tecnólogos realicen las imágenes. La decadencia del radio trazador se combina en miles de rayos gamma, lo que da como resultado la formación de una imagen adecuada para el diagnóstico [16].

#### **2.4.4. Tomografía computarizada por emisión de positrones (PET)**

El PET scanner proporciona imágenes tomográficas y medidas analíticas de las concentraciones tisulares de un trazador inyectado y de sus productos marcados. Esto se obtiene usando los principios de la TC. Sin embargo, en contraste a la TC, la cual utiliza radiación transmitida, el PET utiliza radiación emitida de compuestos marcados que han sido administrados al paciente. Esta técnica utiliza, por una parte, un aparato computarizado de reconstrucción de imágenes tomográficas, y por otra parte un aparato acelerador de partículas que produce radioisótopos que van a ser introducidos en el organismo por vía intravenosa o inhalatoria.

El PET ha aumentado nuestro conocimiento sobre la bioquímica cerebral debido

- Las bases de todas las funciones cerebrales son químicas.
- Una de las maneras de saber si un tejido es normal, es por determinación de su función bioquímica.
- La detección de anomalías químicas proporciona una identificación muy precoz de la enfermedad, aun en el estadio presintomático, antes que el proceso patológico haya consumido las reservas químicas o sobrepasado los mecanismos compensatorios del cerebro.
- La valoración y restauración de las funciones químicas proporciona una medida objetiva para la determinación de la eficacia de la intervención terapéutica [16].

#### **2.4.5. Mamografía**

La mamografía es un tipo específico de imágenes que utiliza un sistema de dosis baja de rayos X para examinar las mamas. Un examen de mamografía, llamado mamograma, se utiliza para asistir en la detección temprana y el diagnóstico de las enfermedades mamarias en las mujeres. Un rayo X (radiografía) es un examen médico no invasivo que ayuda a los médicos a diagnosticar y tratar las condiciones médicas. La toma de imágenes con rayos X supone la exposición de una parte del cuerpo a una pequeña dosis de radiación ionizante para producir imágenes del interior del cuerpo. Los rayos X son la forma más antigua y de uso más frecuente para producir imágenes médicas. Dos recientes avances a la

mamografía tradicional incluyen la mamografía digital y la detección asistida por computadora.

La Mamografía digital, también llamada mamografía digital de campo completo (MDCC), es un sistema de mamografía en el que la película de rayos X es reemplazada por detectores en estado sólido que transforman los rayos X en señales eléctricas. Estos detectores son similares a los que tienen las cámaras digitales. Las señales eléctricas se utilizan para producir imágenes de las mamas que pueden verse en una pantalla de computadora o ser impresas en una película especial similar a los mamogramas convencionales. Desde el punto de vista del paciente, tener una mamografía digital es esencialmente lo mismo que tener mamograma convencional de pantalla-película.

Los sistemas de detección asistida por computadora (AC) utilizan una imagen mamográfica digitalizada que puede obtenerse ya sea de un mamograma convencional de película o un mamograma adquirido digitalmente. El software de la computadora entonces busca áreas anormales de densidad, masa o calcificación que puedan indicar la presencia de cáncer. El sistema de detección asistida por computadora resalta estas áreas en las imágenes, alertando al radiólogo de la necesidad de análisis adicionales [17].

## **2.5. Procesamiento Digital de Imágenes**

### **2.5.1. Orígenes**

Los antecedentes históricos del procesado digital de imágenes se remontan a la impresión de periódicos en 1921. En aquella época la codificación y transmisión de datos se realizaba por cable submarino entre las ciudades de Londres y Nueva York, en donde se reconstruía e imprimía. En 1922 se mejoró el proceso al emplear una técnica basada en la reproducción fotográfica a través de cintas perforadas en las terminales telegráficas receptoras que permitía obtener 5 niveles de gris. Hacia 1929 la técnica se mejoró de nuevo hasta obtener 15 niveles de gris en la reproducción de una fotografía. A pesar de estos avances, las imágenes que se produjeron con esas técnicas no se consideran los inicios del PDI debido a que su creación no involucró el uso de la computadora. Hubo que esperar hasta los años 60, con la llegada de los grandes ordenadores y del programa espacial estadounidense para ver las primeras técnicas de procesado

digital de imágenes por computador. Concretamente hasta el año 1964 en el Laboratorio de Propulsión de la NASA, cuando se procesaron las imágenes de la Luna enviadas por el satélite Ranger 7 para corregir distorsiones propias de la cámara.

A partir de los años 60 el Procesamiento Digital de Imágenes no ha parado de beneficiarse de los continuos avances tecnológicos, entre los que se encuentran principalmente la invención del transistor en los Laboratorios Bell en 1948, el desarrollo de los lenguajes de programación de alto nivel, la invención del Circuito Integrado por Texas Instrument en 1958, el desarrollo de los sistemas operativos, la introducción del ordenador personal en 1981 (IBM), y la continua miniaturización de componentes y desarrollo de sistemas de almacenamiento.

### 2.5.2. Definición

El procesamiento digital de imágenes se refiere a procesar las imágenes del mundo real de manera digital por medio de un computador. Este es un tema bastante amplio, en el cual se ven involucrados temas de física, matemáticas, ingeniería electrónica, en computación, etc. Esta disciplina estudia los fundamentos conceptuales de la adquisición y algorítmicos del procesamiento como tales. Tiene, además, como objetivo mejorar el aspecto de las imágenes y hacer evidentes ciertas características importantes.

Un sistema de procesamiento digital de imágenes está compuesto de un conjunto de equipos físicos (Cámaras, sensores, computadoras, etc.) y también de algunos softwares que desarrollan diversas funciones.

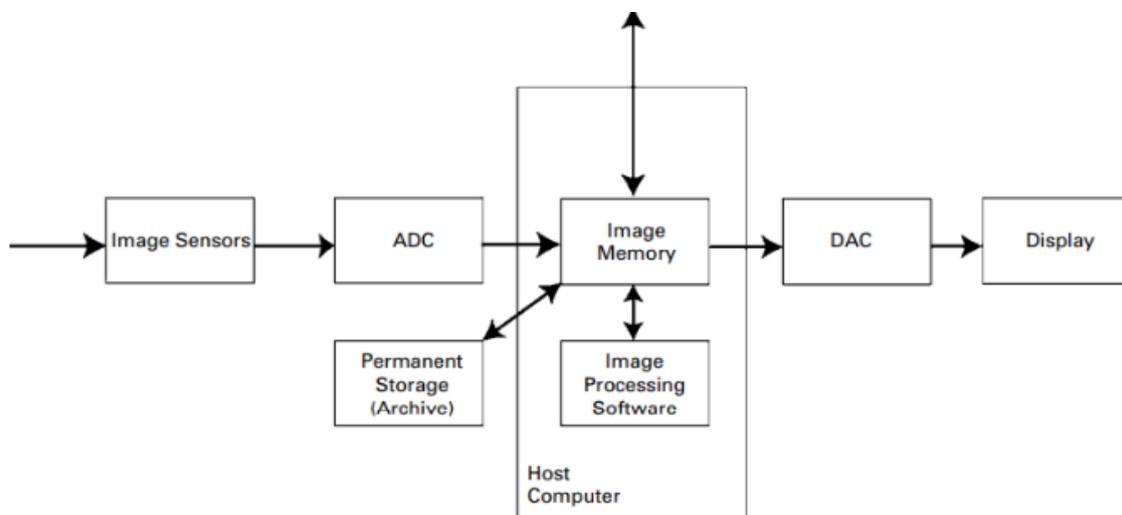


Figura 1: Sistema de procesamiento digital de imágenes

[https://www.researchgate.net/figure/Diagrama-de-bloques-que-representa-las-etapas-del-procesamiento-digital\\_fig2\\_341055684](https://www.researchgate.net/figure/Diagrama-de-bloques-que-representa-las-etapas-del-procesamiento-digital_fig2_341055684)

En la figura 1 se observa el diagrama en bloques que describe el procesamiento digital de una imagen desde su adquisición, usando sensores apropiados para detectar el tipo de radiación o campo que genera la imagen y de este modo poder capturar las imágenes de interés en la mejor manera posible. Si la imagen detectada es una imagen continua esta posteriormente pasa por un convertidor analógico-digital. Después cuenta con almacenamiento de acceso aleatorio utilizando RAM (Random Access Memory) o de manera permanente utilizando medios magnéticos (Discos duros), medios ópticos (CD ROM o DVD) o incluso memorias Flash [18].

Una vez que la imagen está disponible, debe procesarse. El procesamiento de imágenes incluye todas o parte de las siguientes secuencias: mejora y calidad de las imágenes, extracción de características, segmentación, cuantificación y clasificación. En el caso de imágenes médicas, puede ser necesaria una operación de registro si se procesan múltiples imágenes de la misma área física. Generalmente, cada etapa incluye:

### **2.5.3. Pre-procesamiento de la imagen**

La calidad de una imagen médica es variable dependiendo de la técnica y equipo de adquisición. Pueden encontrarse determinadas características tales como; ruido no homogéneo, iluminación no uniforme, bordes difusos y bajo contraste entre los elementos presentes por ello, la extracción de información de la imagen se convierte en una tarea ardua y difícil. La mejora de la calidad de una imagen consiste en abordar uno o varios problemas, como la eliminación del ruido, el aumento del contraste, el enfatizado de los bordes y de estructuras relevantes, la detección de puntos de interés, la uniformización de la iluminación, la eliminación de artefactos de adquisición, etc. [19].

En el caso de las imágenes de resonancia magnética, los filtros genéricos no resultan suficientes para realizar un correcto enfatizado de las imágenes, ya que, aunque permiten una mejor visualización de la misma, eliminan muchos de los detalles en ellas contenidas. Es necesario abordar técnicas más avanzadas, filtros no lineales o filtros adaptativos, capaces de detectar las zonas de ruido y uniformizarlas, y al mismo tiempo, identificar los bordes y resaltarlos. De esta

manera no se pierde nitidez en los límites de los órganos. Es lo que se denomina filtrado no homogéneo en todas las direcciones, como son los filtros de difusión anisotrópicos o los filtros de Wiener [19].

#### **2.5.4. Extracción de características**

Comprende el conjunto de técnicas para la identificación y extracción de características y descriptores relevantes de la imagen, que permitan representar y diferenciar unas zonas de otras. Estas características de la imagen dependen de los niveles de gris, de su distribución estadística (histogramas), de sus gradientes (bordes), y de la textura en la vecindad de cada píxel.

#### **2.5.5. Segmentación de imágenes.**

La segmentación de imágenes es la identificación y el aislamiento de una imagen en regiones que, se espera, correspondan a unidades estructurales. Es decir, son técnicas que permiten separar diferentes elementos en una imagen. Es una operación especialmente importante en el procesamiento de imágenes biomédicas, ya que se utiliza para aislar estructuras fisiológicas y biológicas de interés.

Los enfoques generales de segmentación se pueden agrupar en tres clases: métodos basados en píxeles, métodos regionales y métodos basados en bordes. Los métodos basados en píxeles son los más fáciles de entender e implementar, pero también son los menos poderosos y, dado que operan en un elemento a la vez, son particularmente susceptibles al ruido. Los métodos basados en la continuidad y en los bordes abordan el problema de la segmentación desde lados opuestos: los métodos basados en los bordes buscan diferencias, mientras que los métodos basados en la continuidad buscan similitudes [20].

#### **2.5.6. Clasificación**

Las técnicas de clasificación permiten, a partir de un conjunto de datos obtenidos de la región segmentada, la asignación de dicha región a un grupo u otro, lo que se denomina clase. Esta asignación a una clase, en el caso de imagen médica puede ser la identificación de un tipo de tejido o lesión. Además, se pueden añadir operaciones de medida y cuantificación sobre la imagen para obtener

datos más exactos, que sean de valor en el diagnóstico, la planificación de tareas de cirugía o en el tratamiento posterior.

### 2.5.7. Áreas de Aplicación

Además de su aplicación en los programas espaciales, las técnicas de procesado digital de imagen comenzaron a utilizarse en una gran variedad de ámbitos y problemas que compartían la necesidad de mejora de las imágenes para su interpretación y análisis.

Actualmente existe una inmensa gama de áreas donde el Procesamiento digital de imágenes se utiliza de manera habitual. Un criterio de clasificación habitual para diferenciar cada una de las áreas implicadas es el de la fuente de las imágenes. La principal fuente de energía de las imágenes es el espectro electromagnético (ver Figura 2), especialmente la banda de rayos X y la del espectro visible. Otras fuentes son la acústica, la ultrasónica, y la electrónica.

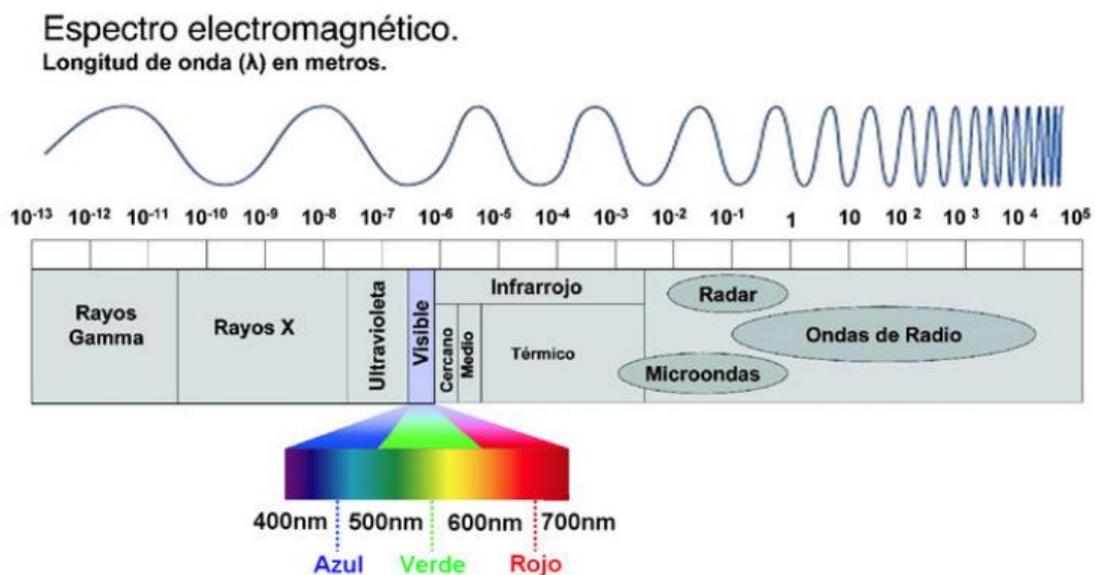
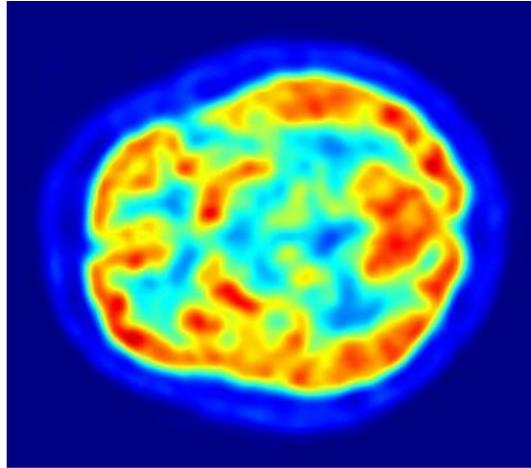


Figura 2: Espectro electromagnético  
<https://www.vilab.cl/p/espectro-electromagnetico>

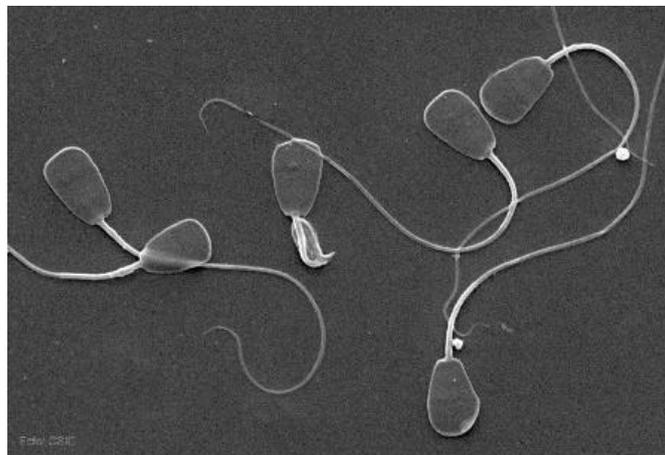
Los rayos gamma, existen numerosas aplicaciones para procesar imágenes que vienen de este tipo de fuentes de imagen en la medicina nuclear, como por ejemplo la Tomografía por Emisión de Positrones (Ver Figura 3), donde se inyecta un isotrópico radioactivo al paciente que emite rayos gamma que posteriormente se capturan, también tenemos las observaciones astronómicas donde se detecta la radiación natural de rayos gamma de los astros. En la siguiente banda, la de los rayos X, tiene como principales aplicaciones en

medicina (radiología, angiografía, Tomografía Axial Computarizada (TAC), etc., pero también en astronomía e industria, como en el control de calidad de placas circuito impreso o de alimentos.



*Figura 3: Tomografía por Emisión de Positrones (PET)*  
<https://farmacosalud.com/la-tomografia-pet-ayuda-predecir-el-nivel-de-recuperacion-en-un-coma/>

También es posible obtener imágenes empleando la banda ultravioleta del espectro electromagnético, teniendo como principales aplicaciones la litografía, la inspección industrial, la microscopía (Ver Figura 4), los láseres, las imágenes biológicas y la astronomía.



*Figura 4: Espermatozoides de gacela Mohor observados con microscopía electrónica de barrido.*  
<https://www.dicyt.com/viewItem.php?itemId=21661>

Respecto a las imágenes captadas en la banda visible e infrarroja, estas son por mucho las aplicaciones más numerosas. La banda infrarroja se utiliza habitualmente en conjunto con la banda de espectro visible, por ejemplo, en microscopía, astronomía, detección remota (con varias bandas que detectan

diferentes detalles del terreno cada una), controles de calidad en la industria y en las aplicaciones de identificación de la policía (Ver Figura 5).



Figura 5: imagen satelital banda infrarroja  
[https://eos.com/wp-content/uploads/2021/09/color\\_infrared\\_img\\_03.png.webp](https://eos.com/wp-content/uploads/2021/09/color_infrared_img_03.png.webp)

La banda de microondas tiene como principal aplicación el radar debido a que este puede obtener datos de virtualmente cualquier región y en cualquier momento, sin importar las condiciones climáticas o luz ambiental (puede penetrar nubes, vegetación, hielo, arena) utilizando pulsos de microondas para obtener imágenes a partir de energía reflejada. Las imágenes de la banda de radio tienen su mayor aplicación en astronomía y medicina. En medicina las ondas de radio se usan principalmente en Imágenes de Resonancia Magnética (Ver Figura 6).



Figura 6: Resonancia Magnética  
[https://www.deidiagnostico.com/resoancia\\_magnetica\\_de\\_cerebro/](https://www.deidiagnostico.com/resoancia_magnetica_de_cerebro/)

Otras formas de obtener imágenes, en este caso imágenes acústicas, es a través del sonido. Se aplica en exploración geológica (petróleo y minerales), en la industria y en medicina. El ejemplo más notorio es el ultrasonido (Ver figura 7), con el que se puede realizar un seguimiento al embarazo, o captar imágenes de partes del cuerpo como la tiroides o las capas musculares.



Figura 7: Ultrasonido  
<https://merida.cmahospital.mx/ultrasonidos-merida/>

En las imágenes electrónicas, como las de la microscopía electrónica, la microscopía de escaneo de electrones (SEM) y la microscopía de transmisión de electrones (TEM) (Ver Figura 8), se utilizan rayos de electrones enfocados en vez de rayos de luz como los microscopios ópticos. A través de esta técnica es posible captar un filamento de tungsteno o detectar un circuito integrado dañado.

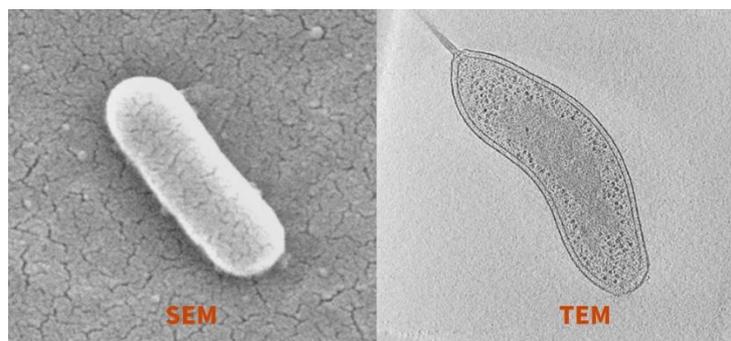


Figura 8: Microscopía Electrónica  
<https://www.nanofab.com.cn/es/vision-2/application/tem-sem-diferencia/>

## 2.6. Conceptos básicos de MATLAB

MATLAB (Abreviatura de MATrix LABoratory) "Laboratorio de matrices" es un software matemático que nos ofrece un entorno de desarrollo integrado (IDE) con un lenguaje de programación propio (Lenguaje M). Disponible para todas las plataformas Unix, Windows y Mac OS. Entre sus principales prestaciones encontramos la manipulación de matrices, la representación de datos y funciones, la implementación de algoritmos, la creación de interfaces de usuario (GUI) y la comunicación [21].

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, esto nos permite la resolución de problemas en un tiempo menor. Cuando trabajamos con matrices podemos describir infinidad de variables de manera altamente flexible y matemáticamente eficiente. Por ejemplo, una imagen se puede describir como una matriz de píxeles, un sonido como una matriz de fluctuaciones.

En MATLAB una imagen a escala de grises es representada por medio de una matriz bidimensional de  $m \times n$  elementos en donde  $n$  representa el número de píxeles de ancho y  $m$  el número de píxeles de largo. El elemento  $v_{11}$  corresponde al elemento de la esquina superior izquierda, donde cada elemento de la matriz de la imagen tiene un valor de 0 (negro) a 255 (blanco). Por otro lado, una imagen de color RGB (la más usada para la visión computacional, además de ser para MATLAB la opción default) es representada por una matriz tridimensional  $m \times n \times p$ , donde  $m$  y  $n$  tienen la misma significación que para el caso de las imágenes de escala de grises mientras  $p$  representa el plano, que para RGB puede ser 1 para el rojo, 2 para el verde y 3 para el azul.

## 2.6.1. Formatos disponibles en MATLAB

Tabla 1: Formatos disponibles en MATLAB

Formatos	Descripción	Extensión
BMP	Bit Mapped Picture	.bmp
GIF	Graphics Interchange Files	.gif
JPEG JPG	Joint Photographic Experts Group	.jpeg
PNG	Portable Network Graphics	.png
TIFF TIF	Tagged Image File Format	.tiff
DICOM	Digital Imaging and Communications	.dcm

## 2.6.2. Digital Imaging and Communications in Medicine (DICOM)

DICOM es un estándar desarrollado en 1983 como iniciativa del Colegio Estadounidense de Radiología (ACR) y la Asociación Nacional de Fabricantes Eléctricos (NEMA). Este estándar describe el formato de archivos y la especificación de los datos primordiales de un paciente en la imagen, así como el encabezado requerido, describiendo un lenguaje común a distintos sistemas médicos. Además de los atributos de la imagen normal o comprimida, se agregan datos demográficos y de identificación del paciente, información acerca de las condiciones de adquisición y, en algunos casos, información del examen, serie a la que pertenece la imagen y orden que guarda en un estudio. De esta forma las imágenes vienen acompañadas de mediciones, cálculos e información descriptiva relevante para diagnósticos [22].

## **2.7. Biomedicina**

La biomedicina es el estudio de los aspectos biológicos de la medicina. Su objetivo fundamental es investigar los mecanismos moleculares, bioquímicos, celulares y genéticos de las enfermedades humanas. Esta disciplina ha ayudado a comprender muchas enfermedades y lesiones para proponer soluciones capaces de evaluarlas, prevenirlas y desarrollar técnicas que reduzcan el daño.

La biomedicina es la disciplina que se ocupa de estudiar los movimientos del cuerpo humano, bajo circunstancias y condiciones diferentes. Además, analiza la energía y las cargas mecánicas involucradas en dichos movimientos [23].

### **2.7.1. Ingeniería biomédica**

Aplicación de principios eléctricos, mecánicos, químicos, ópticos y demás principios de ingeniería para entender, modificar o controlar sistemas; así como para diseñar y producir herramientas de asistencia en el proceso de diagnóstico, vigilancia y tratamiento de pacientes. Se dedica fundamentalmente al diseño y construcción de productos sanitarios y tecnologías sanitarias tales como: equipos médicos, prótesis, dispositivos médicos, dispositivos de diagnóstico (imagenología médica) y de terapia [24].

Por lo general, las imágenes médicas se guardan como archivos dicom (el estándar Digital Imaging and Communications in Medicine: imágenes digitales y comunicaciones en medicina). Los archivos dicom utilizan la extensión de archivo .dcm. La compañía MathWorks ofrece una caja de herramientas adicional, llamada caja de herramientas para imágenes que puede leer esos archivos, lo que hace que sus datos estén disponibles para procesamiento en MATLAB. La caja de herramientas para imágenes también incluye un amplio rango de funciones de las que muchas son especialmente apropiadas para las imágenes médicas. Un conjunto limitado de datos MRI ya convertidos a un formato compatible con MATLAB se incluye con el programa MATLAB estándar. Este conjunto de datos le permite probar algunas de las funciones de generación de imágenes disponibles tanto con la instalación estándar de MATLAB como con la caja de herramientas para imágenes expandida, si la tiene instalada en su computadora [25].

## **2.8. Clases principales de procesamiento digital de imágenes**

Conviene clasificar los diferentes procesos involucrados en el procesamiento digital de imágenes para tener una visión general más estructurada. Podemos englobar la mayor parte de tareas en tres categorías, cada una de ellas con diferentes algoritmos involucrados:

### **2.8.1. Mejora o realce de la imagen**

Procesado de la imagen para que el resultado sea más apropiado para una aplicación en particular. Tareas habituales: mejora de la nitidez o aclarado de imágenes desenfocadas, eliminación del ruido, mejora del contraste, mejora del brillo, detección de bordes, etc.

### **2.8.2. Restauración de la imagen**

Se puede considerar como revertir el daño ocasionado a la imagen por una causa conocida. Tareas habituales: eliminar el desenfoque por movimiento, eliminar distorsiones ópticas, eliminar interferencia periódica, etc.

### **2.8.3. Segmentación de la imagen**

Subdivide la imagen en partes o aísla ciertos objetos de una imagen. Tareas habituales: búsqueda y selección de formas determinadas en la imagen, máscaras de la imagen, etc.

## **2.9. Preprocesamiento de imágenes**

### **2.9.1. Filtros**

Puede definirse un filtro como un sistema cuya función es modificar, deformar o manipular en general, el espectro en frecuencia de una señal de entrada de acuerdo con unos determinados requerimientos (especificaciones). Los filtros se emplean para atenuar o amplificar componentes de la entrada con frecuencias dentro de un determinado rango, o para rechazar o aislar componentes en frecuencias específicas. Puesto que un filtro puede considerarse un sistema de transmisión de señales con la habilidad de dejar pasar ciertas frecuencias y de rechazar ciertas otras.

### **2.9.2. Filtros lineales**

Las técnicas de procesamiento lineal son herramientas muy importantes que son usadas extensivamente en el procesamiento digital de imágenes y señales. Los filtros lineales sirven para suavizar o realzar detalles de la imagen, o inclusive minimizar efectos de ruido. Su simplicidad matemática y la existencia de una teoría de unificación de sistemas lineales hacen su diseño e implementación fácil. Además, las técnicas de procesamiento lineal ofrecen una ejecución satisfactoria para una variedad de aplicaciones.

Los filtros lineales se basan en los conceptos que afirman que la función de transferencia y el impulso o función de distribución puntual de un sistema lineal son transformadas de Fourier inversas una de otra, la idea general del filtrado lineal es mucho más atractiva e intuitiva en el dominio de la frecuencia.

Los filtros lineales, los cuales fueron usados originalmente en aplicaciones de filtrado de imagen, no pueden hacer frente con las no linealidades del modelo de formación de imagen y no pueden tomar en cuenta las no linealidades de la visión humana. Por lo demás, la visión humana es muy sensitiva a la información de alta frecuencia. Los bordes de la imagen y los detalles de la imagen tienen contenido de alta frecuencia y llevan información muy importante para la percepción visual. Los filtros que tienen buenas propiedades de preservación de detalles y bordes de la imagen son altamente convenientes para el filtrado de imágenes digitales. La mayoría de los filtros clásicos digitales lineales de imágenes tienen características pasa bajas. Tienen a borrar bordes y destruir líneas y otros detalles finos de la imagen. Por estas razones se hace cada vez más frecuente el uso de técnicas de filtrado no lineales.

### **2.9.3. Filtros no lineales**

Los filtros no lineales pueden garantizar una ejecución satisfactoria en ciertos de aplicaciones, tales como el filtrado de imágenes digitales, realce de la imagen y detección de bordes. Como resultado, se están sustituyendo continuamente los filtros lineales con los filtros no lineales, especialmente en situaciones donde los filtros lineales se ejecutan pobremente, como en la presencia de ruido multiplicativo y ruido impulsivo o el procesamiento de señales teniendo estadísticas no Gaussianas.

En el procesamiento digital de imágenes, a veces no se conoce el tipo de ruido y de señales las cuales estarán presentes en aplicaciones. Por lo tanto, se deben usar los filtros no lineales los cuales se ejecutan bien en todas las aplicaciones. Los filtros Adaptivos tienen esta capacidad. La ejecución del filtro adaptivo depende de la exactitud de la estimación de ciertas señales y estadísticas del ruido, es decir la media de la señal, la desviación estándar y la desviación estándar del ruido.

La multitud de filtros no adaptivos y adaptivos no lineales a veces hace difícil el saber cuál filtro es el más conveniente para una aplicación de procesamiento de imagen específica, de acuerdo a esto, se toman los siguientes factores: características de filtrado del ruido para diferentes tipos de ruido; preservación de detalles; preservación de detalles finos; complejidad computacional.

## **2.10. Técnicas de segmentación en aplicaciones medicas**

Básicamente, en cualquier imagen se encontrarán presentes uno o varios objetos localizados en un entorno. El objetivo de la segmentación consiste en separar dichos objetos del medio en el que se encuentran y distinguirlos entre sí. En el caso de las imágenes objeto de la investigación este esquema no resulta tan simple, antes bien presenta una enorme cantidad de texturas que dificultan su extracción, en cualquier caso, la segmentación, tanto en su versión simple como compleja se basa en los siguientes principios:

- **Similitud:** cada uno de los píxeles de un elemento tiene valores parecidos con respecto a alguna propiedad determinada.
- **Discontinuidad:** los objetos y más concretamente las regiones que los diferencian destacan del entorno y tienen por tanto unos bordes definidos.
- **Conectividad:** los píxeles pertenecientes al mismo objeto o región tienen que ser contiguos, es decir, tienden a agruparse constituyendo regiones homogéneas.

### **2.10.1. Segmentación basada en Umbralización**

Este es una técnica muy importante dentro de la segmentación de imágenes, el umbral se precisa como una función que convierte una imagen con diferentes tonalidades en una imagen en blanco y negro. Se elige un umbral que permita agrupar los píxeles que hacen parte de los objetos de la imagen, diferenciándolos del fondo. El histograma de una imagen es una función discreta que se plantea como el número de píxeles gris sobre el número de píxeles de la imagen. Por lo tanto, la segmentación por histograma consiste en elegir uno o varios umbrales para poder reunir los puntos de la imagen con respecto a sus características y de acuerdo a sus niveles de gris. El método de la Binarización es muy básico, pero sirve para diferenciar el objeto, del fondo de la imagen; este consiste en que los píxeles que están marcados con 1 corresponden al objeto de la imagen y los píxeles que están marcados con 0 corresponden al fondo de la imagen. Si el objeto es oscuro con respecto al fondo, el proceso es inverso. Existen varios tipos de umbrales; pero hay 3 de ellos que son los más utilizados; estos son: Umbral global, Umbral local y Umbral dinámico.

La Umbralización basada exclusivamente en los niveles de luminosidad se denomina global, mientras que en el caso de la Umbralización local se utiliza información puntual de cada píxel, es decir, propiedades de un píxel que dependen de su localización en la imagen.

#### **2.10.1.1. Cálculo del umbral optimo**

El uso de filtros de mediana no siempre permite el poder eliminar el traslape que se produce entre dos densidades presentes en el histograma de una imagen. En tales circunstancias debe ser calculado un umbral optimo, el cual produce el menor número de pixeles mal clasificados, esto es, pixeles que pertenecen a un objeto A son clasificados como si fueran de un objeto B y viceversa. De esta manera el umbral optimo corresponde a la intercepción entre ambas distribuciones, (Ver figura 9); podemos observar gráficamente el umbral óptimo para un ejemplo hipotético de dos distribuciones A y B, que por sus niveles de intensidad se traslapan en la región T, el punto de intersección ilustra el mejor elemento para decidir la frontera de clasificación para cada uno de los objetos representados por sus respectivas distribuciones.

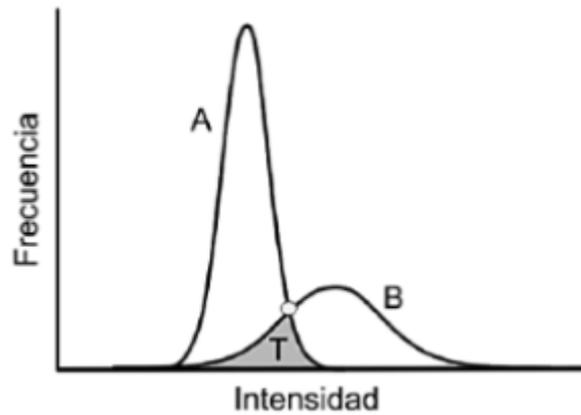


Figura 9: Umbral óptimo para la binarización de dos objetos  
 Tratamiento de imágenes con Matlab <http://www.alfaomega.com.mx>

### 2.10.1.2. Método Otsu

El método de OTSU, es el método más popular para el cálculo del umbral óptimo, ya que permite la Binarización de 2 clases usando el histograma de intensidades de la imagen. El método considera una imagen de dimensión MxN con L-1 escalas de grises (Ver Figura 10). El histograma presenta 2 distribuciones traslapadas, la primera correspondiente al objeto A, donde involucra los valores de intensidad de 0 al valor k, mientras que la segunda integra los niveles de gris de k+1 hasta L-1(Ver Figura 11)

Primeramente, se inicia calculando las probabilidades de cada objeto o clase:

$$P(A) = \sum_{i=0}^k h(i) = w_A(k) = w(k) \quad (1)$$

$$P(B) = \sum_{i=k+1}^{L-1} h(i) = w_B(k) = 1 - w(k) \quad (2)$$

En donde  $h(i)$  representa el número de pixeles de intensidad  $i$  contenidos en la imagen.

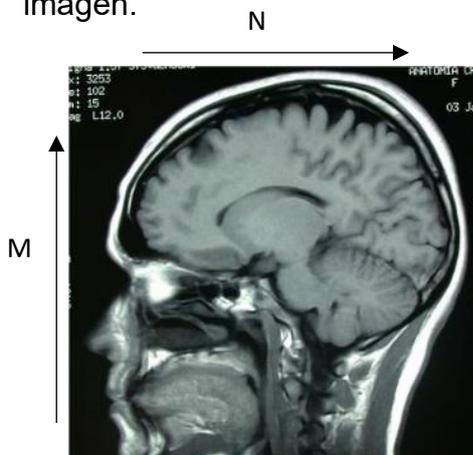


Figura 10: Tomografía de dimensiones M\*N

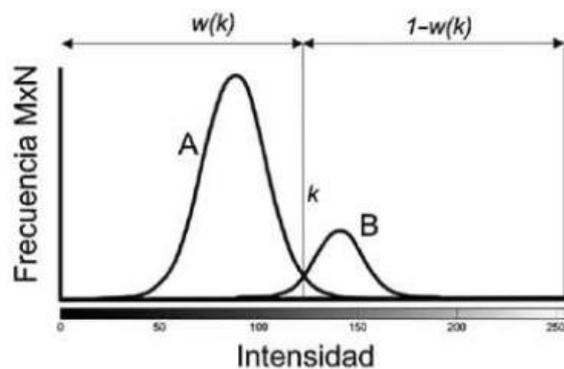


Figura 11: Proceso de segmentación de 2 distribuciones mediante el método Otsu

$$\mu_A(k) = \frac{1}{w_A(k)} \sum_{i=0}^k i \cdot h(i) \quad (3)$$

$$\mu_B(k) = \frac{1}{w_B(k)} \sum_{i=k+1}^{L-1} i \cdot h(i) \quad (4)$$

A partir de estos valores, las varianzas pueden ser obtenidas:

$$\sigma^2_A(k) = \frac{1}{w_A(k)} \sum_{i=0}^k (i - \mu_A(k))^2 \cdot h(i) \quad (5)$$

$$\sigma^2_B(k) = \frac{1}{w_B(k)} \sum_{i=k+1}^{L-1} (i - \mu_B(k))^2 \cdot h(i) \quad (6)$$

La varianza dentro de las 2 clases se puede expresar como:

$$\sigma^2_D = w_A(k) \cdot \sigma^2_A(k) + w_B(k) \cdot \sigma^2_B(k) \quad (7)$$

El método Otsu busca como umbral óptimo el nivel de intensidad  $k$  que minimiza la varianza existente dentro de las 2 clases (ecuación 4). De esta manera la idea es hacer la varianza de cada objeto tan pequeña que pueda minimizar el traslape.

## 2.10.2. Segmentación basada en bordes

Los bordes de una imagen se pueden definir como transiciones entre dos regiones de niveles de gris significativamente distintos. Suministran una valiosa información sobre las fronteras de los objetos y puede ser utilizada para segmentar la imagen, reconocer objetos, etc. La mayoría de las técnicas para detectar bordes emplean operadores locales basados en distintas aproximaciones discretas de la primera y segunda derivada de los niveles de grises de la imagen.

### 2.10.2.1. Operadores basados en la primera derivada (Gradiente)

La derivada de una señal continua proporciona las variaciones locales con respecto a la variable, de forma que el valor de la derivada es mayor cuanto más rápidas son estas variaciones. En el caso de funciones bidimensionales  $f(x, y)$ , la derivada es un vector que apunta en la dirección de la máxima variación de  $f(x, y)$  y cuyo módulo es proporcional a dicha variación. Este vector se denomina gradiente y se define:

$$\nabla f(x, y) = \begin{bmatrix} \frac{\partial f(x, y)}{\partial x} \\ \frac{\partial f(x, y)}{\partial y} \end{bmatrix} \quad (8)$$

$$Mag[\nabla f(x, y)] = \sqrt{\left(\frac{\partial f(x, y)}{\partial x}\right)^2 + \left(\frac{\partial f(x, y)}{\partial y}\right)^2} \quad (8.1)$$

$$\theta = \arctan \frac{\frac{\partial f(x, y)}{\partial x}}{\frac{\partial f(x, y)}{\partial y}} \quad (8.2)$$

Con respecto a (ecuación 6), el ángulo de inclinación del vector gradiente es importante, ya que proporciona información sobre la dirección y la tasa de cambio máxima de la función  $f(x, y)$  en un punto dado.

### 2.10.2.2. Operadores Prewitt y Sobel

Los operadores Prewitt y Sobel representan dos de los métodos más usados en la detección de bordes, los cuales son muy similares entre sí, existen solo algunas particularidades. Ambos operadores utilizan como filtro una matriz de coeficientes 3x3, que facilita la posibilidad de configurarlo; de tal forma que este no sea tan vulnerable al ruido propio de la imagen.

El operador de Sobel tiene un filtro parecido al de Prewitt sin embargo este le da un mayor de peso a la columna central.

$$H_x^P = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad y \quad H_y^P = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \text{ Filtros prewitt}$$

$$H_x^S = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad y \quad H_y^S = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \text{ Filtros Sobel}$$

#### 2.10.2.2.1. Tamaño y dirección del gradiente

Independientemente del caso ya sea un operador Prewitt o Sobel, se caracterizarán los resultados obtenidos para cada uno de los diferentes sentidos:

$$D_x(x, y) = H_x * I \quad y \quad D_y(x, y) = H_y * I \quad (9)$$

Por lo tanto, la magnitud del borde  $(u, v)$ , para ambos casos es definida como:

$$E(x, y) = \sqrt{(D_x(x, y))^2 + (D_y(x, y))^2} \quad (9.1)$$

La dirección del gradiente en cada pixel se define como:

$$\phi(x, y) = \tan^{-1} \left( \frac{D_y(x, y)}{D_x(x, y)} \right) \quad (9.2)$$

### 2.10.2.3. Operador Sobel

El operador Sobel utiliza los filtros descritos para aproximar las derivadas parciales  $\frac{\partial I}{\partial u}$  y  $\frac{\partial I}{\partial v}$ . De la combinación de esas derivadas obtenemos para cada pixel  $(u, v)$  un valor gradiente. Entonces, se dice que un pixel  $(u, v)$  corresponde a un borde de la imagen si el valor de su gradiente es mayor a umbral  $U$  preestablecido como criterio.

La función general utilizada para la detección de bordes que implementa el Toolbox de procesamiento de imágenes en Matlab bajo el método Sobel es el siguiente:

```
BW = edge(I, 'Sobel', threshold, direction)
```

Donde “ $I$ ” es la imagen a la que se le aplica el operador para extraer los bordes, “ $threshold$ ” es un umbral que se especifica como criterio de magnitud del gradiente para clasificarlos, “ $direction$ ” selecciona el filtro a utilizar el cual puede ser “horizontal” o “vertical” o también puede ser “both” en ambas direcciones.

### 2.10.2.4. Operador Prewitt

El operador Prewitt utiliza para la detección de bordes las matrices de coeficientes mostradas anteriormente. La función que implementa el Toolbox es el siguiente:

```
BW = edge(I, 'Prewitt', threshold, direction)
```

Los parámetros de esta función son idénticos a los del caso anterior. Este operador genera resultados un poco más ruidosos, ya que en el caso de Sobel los coeficientes aplicados en sus filtros realizan suavizado sobre los datos, lo cual puede ser observado en los coeficientes con valor 2 en la columna del pixel sobre el que se desea calcular el gradiente.

### 2.10.2.5. Operador Roberts

Este operador es uno de los filtros más antiguos utilizado para la detección de bordes en una imagen, una particularidad de este filtro es que es pequeño y utiliza tan solo una matriz de 2x2 para determinar el gradiente en sus dos diferentes direcciones a lo largo de sus diagonales, definido de la siguiente forma:

$$H_x^R = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix} \quad y \quad H_y^R = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}$$

La función general utilizada para la detección de bordes que implementa el Toolbox de procesamiento de imágenes en Matlab bajo el método Roberts es el siguiente:

```
BW = edge(I, 'Roberts', threshold, direction)
```

Los parámetros son idénticos a los descritos anteriormente, sin embargo, este método al hacer un poco antigua presenta dificultades en cuanto a la detección de bordes, ya que al no ser simétrico no puede detectar bordes que se encuentran en múltiplos de 45°.

### 2.10.2.6. Operadores basados en la Segunda derivada

Los operadores anteriormente basados en la primera derivada para aproximar el gradiente de la imagen, existe otro tipo de operadores que se fundamentan en la segunda derivada de la función de la imagen. En esta segunda derivada pueden ser calculados con el valor de la derivada en una determinada dirección (gradiente máximo), o mediante el paso por 0 de la segunda derivada (Laplaciano) en cualquier dirección.

Los operadores basados en la primera derivada tienen un enfoque para la detección de bordes que resulta en la difícil localización del mismo al ser un método altamente direccional; o bien, cuando el borde no está definido.

Aunque el valor del gradiente permite detectar un borde, en ocasiones es importante tener información sobre si el pixel está en la transición positiva o negativa del gradiente.

### 2.10.2.7. Detección de bordes con la segunda derivada

La técnica utilizada para detectar los bordes se le denomina pasos por cero (zero-crossing), que es la transición de positivo a negativo, o viceversa, y es estimado a partir de la segunda derivada.

La definición de derivada para una función unidimensional puede ser considerada como:

$$\frac{\partial f}{\partial x} = f(x + 1) - f(x) \quad (10)$$

Asimismo, a partir de la ecuación anterior puede decirse que la segunda derivada se define como:

$$\frac{\partial f^2}{\partial x^2} = f(x + 1) - 2f(x) + f(x - 1) \quad (10.1)$$

Por lo tanto, la detección de borde mediante la segunda derivada se basa en el paso por 0 del valor del gradiente en cualquier dirección; la característica de hacer este método insensible a la rotación es llamada isotrópica.

El operador Laplaciano es un filtro isotrópico definido por la siguiente expresión:

$$\nabla^2 I(x, y) = \frac{\partial^2 I(x, y)}{\partial x^2} + \frac{\partial^2 I(x, y)}{\partial y^2} \quad (10.2)$$

Este filtro es lineal al utilizar derivadas, considerando las ecuaciones anteriores, se tiene:

$$\frac{\partial^2 I(x, y)}{\partial x^2} = I(x + 1, y) - 2I(x, y) + I(x - 1, y) \quad (11)$$

$$\frac{\partial^2 I(x, y)}{\partial y^2} = I(x, y + 1) - 2I(x, y) + I(x, y - 1) \quad (11.1)$$

Por lo tanto, si se unen las 2 ecuaciones anteriores tenemos:

$$\nabla^2 I(x, y) = I(x + 1, y) + I(x - 1, y) + I(x, y + 1) + I(x, y - 1) - 4I(x, y) \quad (11.2)$$

Si expresamos la ecuación anterior en términos de un filtro que se utilice en el procesamiento espacial de una imagen, este quedaría definido:

$$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

La función general utilizada para la detección de bordes con la segunda derivada que implementa el Toolbox de procesamiento de imágenes en Matlab bajo el método Laplaciano es el siguiente:

```
BW = edge(I, 'Log', thresh, sigma)
```

Log especifica que se usará el método Laplaciano del Gaussiano, thresh especifica el umbral de sensibilidad del método Laplaciano del Gaussiano en la variable, sigma especifica que se usará el método Laplaciano del Gaussiano usando la variable sigma como la desviación estándar del filtro LoG (Laplaciano

del Gaussiano). El valor por defecto de sigma es 2; el tamaño del filtro es n por n, donde  $n = \text{ceil}(\text{sigma} * 3) * 2 + 1$ .

```
BW = edge(I, 'Zerocross', thresh, h)
```

Especifica que se usará el método de Cruce por cero usando el filtro h con el umbral definido en la variable thresh; si el argumento está vacío ([]), edge elige el umbral automáticamente. Si el umbral es 0, la imagen de salida tendrá contornos cerrados porque incluirá todos los cruces por cero de la imagen de entrada.

### 2.10.2.8. Filtro de Canny

Uno de los métodos más conocidos para la detección de bordes en imágenes, el cual se basa en la aplicación de una serie de filtros en direcciones y resoluciones diferentes, que al final son combinados en un resultado único. Este método intenta alcanzar tres diferentes objetivos:

- Minimizar el número de bordes falsos.
- Mejorar la localización de los bordes en la imagen.
- Entregar una imagen cuyo ancho de bordes es un pixel.

El filtro de Canny está basado en métodos del gradiente; sin embargo, usa también como criterio para la localización de bordes la segunda derivada o filtro Laplaciano. La mayoría de las veces este algoritmo es usado en su forma sencilla, es decir, configurando solamente el parámetro de suavizado  $\sigma$ .

La función general utilizada para la detección de bordes que implementa el Toolbox de procesamiento de imágenes en Matlab bajo el método de Canny es el siguiente:

```
BW = edge (I, 'Canny', thresh, sigma)
```

Especifica que se utilizará el método Canny usando sigma como la desviación estándar del filtro Gaussiano. El valor por defecto de sigma es 1; el tamaño del filtro se elige automáticamente basándose en la variable sigma. thresh define los umbrales de sensibilidad para el método Canny en la variable thresh, un vector de dos elementos en el que el primer elemento es el umbral bajo y el segundo el

alto. Si se especifica un escalar en la variable `thresh`, este valor se usará para el umbral alto y  $0.4 * \text{thresh}$  para el umbral bajo. Si no se usa la variable `thresh`, o `thresh` está vacía (`[]`), `edge` elige su valor automáticamente. El valor para `thresh` es relativo al valor más alto de la magnitud del gradiente de la imagen.

### 2.10.2.9. Detección de Contornos

La detección de contornos es un carácter básico en procesamiento de imágenes pues contiene información útil acerca de los límites del objeto que puede ser utilizado para el análisis, detección del objeto y para aplicaciones del filtrado. De igual forma se emplea para simplificar el análisis de imágenes, realizando una reducción drástica de la cantidad de datos a ser procesados, mientras que al mismo tiempo preservan la información estructural alrededor de los límites del objeto.

Los contornos en una imagen se definen como variaciones locales en la intensidad de la misma, por tanto, un detector de contornos se puede formar a través de técnicas de diferencia de imágenes. De otra manera, un contorno representa un cambio de la intensidad de los niveles de gris presentes en ella. El paso de nivel oscuro a uno brillante, o viceversa, determinan un contorno; el cual depende de la fuente de radiación, la iluminación y la distancia a que se encuentra el objeto; en este sentido, es necesario aplicar a la imagen las operaciones de filtrado que realcen los cambios en los valores de gris y atenúen las áreas donde existan valores de grises constantes, para posteriormente introducir el resultado de esta a un detector de borde por umbral.

Los puntos de contorno son como zonas de pixeles en las que existe un cambio brusco de nivel de gris. Si pensamos una imagen como una función continua  $f(x, y)$ , se visualiza la derivada que tiene un máximo local en la dirección del contorno. Por ello las técnicas máximas usadas en la detección de contornos se basan en la medida del gradiente de  $f$  a lo largo de  $r$  en una dirección  $\theta$ .

$$\nabla f = \begin{bmatrix} f_x \\ f_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (12)$$

El vector gradiente siempre apunta en la dirección de la máxima variación de la imagen  $f$  en el punto  $(x, y)$ . En la detección de bordes es muy importante la

magnitud de este vector, denominado simplemente como gradiente de la imagen, denotado por  $\nabla f$  y dado por:

$$\nabla f = \|\nabla f\| = \sqrt{f_x^2 + f_y^2} \quad (12.1)$$

Esta cantidad representa la variación de la imagen  $f(x, y)$  por unidad de distancia en la dirección del vector. En general, el gradiente se suele aproximar mediante la expresión:

$$\nabla f \approx |f_x| + |f_y| \quad (12.2)$$

El cual es más simple de implementar en la práctica. La dirección del vector gradiente también es una cantidad importante. Sea  $\theta(x, y)$  el ángulo del vector  $\nabla f$ . En el punto  $(x, y)$ . Entonces se tiene que:

$$\theta(x, y) = \tan^{-1} \frac{f_x(x, y)}{f_y(x, y)} \quad (12.3)$$

Donde los ángulos se miden con respecto al eje de abscisas.

El cálculo del gradiente se basa en obtener las derivadas parciales para cada pixel. Las derivadas se pueden implementar digitalmente de varias formas.

Si llamamos  $H$  a una máscara de tamaño  $p \times p$ , se define el producto interno con una imagen  $U$ , en una posición  $(m, n)$  como:

$$(U, H)_{mn} = \sum_i \sum_j h(i, j) u(i + m, j + n) = u(m, n) \otimes h(-m, -n) \quad (12.4)$$

Existen varias técnicas de contornos de igual intensidad en una imagen digital.

### 2.10.3. Segmentación basada en regiones

La segmentación basada en regiones busca dividir la imagen en particiones que comparten ciertas características comunes. El método de crecimiento de región es un algoritmo basado en la integración sucesiva de pixeles relacionados de acuerdo a un criterio de similitud. Mediante el cual, un pixel dentro de la imagen debe ser elegido como punto inicial, a partir de dicho pixel, sus pixeles vecinos son analizados con el objetivo de comprobar si alguno de ellos es similar. Si es así, dicho pixel es incluido como parte de la región segmentada, de lo contrario no se toma en cuenta.

### 2.10.3.1. Pixel Inicial

El primer paso en el método de crecimiento de regiones es seleccionar un pixel inicial o también llamado pixel semilla  $S(x, y)$ . su selección es muy importante ya que debe estar contenido en la región sobre la cual se pretende segmentar. Donde  $x, y$  representan las coordenadas seleccionadas interactivamente con el mouse.

Una vez se ha seleccionado el pixel  $S(x, y)$ , se realiza una búsqueda local alrededor de él añadiendo pixeles similares de manera recursiva, dicha búsqueda se realiza en una vecindad alrededor de los 4 pixeles más cercanos a él. Ya que se ha encontrado un pixel dentro de la vecindad con características similares a la inicial, este ocupa el lugar del pixel semilla y el proceso de búsqueda local vuelve a repetirse. La forma más sencilla para definir una vecindad de búsqueda de 4 elementos es definir una matriz de la forma  $V = \begin{pmatrix} -1 & 0 \\ 1 & 0 \\ 0 & -1 \\ 0 & 1 \end{pmatrix}$  donde cada renglón expresa una localidad de la vecindad (Ver Figura 12), mientras que las columnas indican los desplazamientos en el sentido horizontal ( $\Delta x$ ) y vertical ( $\Delta y$ ).

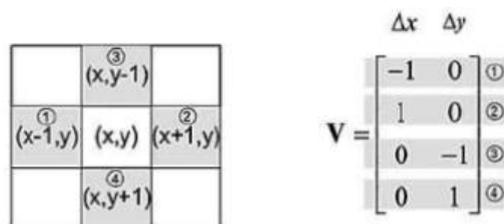


Figura 12: Proceso de correspondencia entre la matriz  $V$  y la vecindad

### 2.10.3.2. Crecimiento de Regiones

El crecimiento de regiones es uno de los métodos conceptuales más simple para la segmentación; los pixeles adyacentes de amplitud similar se agrupan juntos para formar una región segmentada. Sin embargo, en la práctica hay limitaciones, algunas de las cuales son razonablemente simples y deben ser tomadas en cuenta para obtener un patrón de crecimiento que permite obtener resultados aceptables.

(Ver Figura 13), en donde podemos observar dos regiones,  $R_1$  y  $R_2$ , adyacentes con perímetros  $P_1$  y  $P_2$  respectivamente, perímetros que han sido previamente unidos. Después de realizar las etapas iniciales del crecimiento de región debe contener previamente subregiones unidas valores de amplitud.

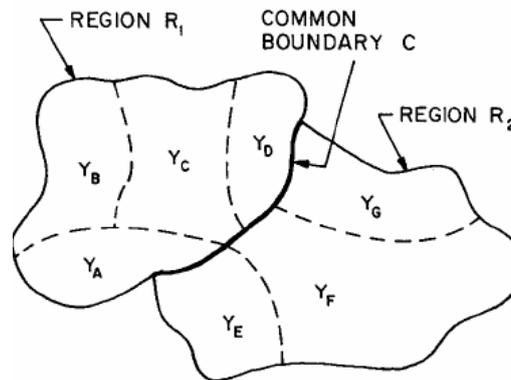


Figura 13: Proceso despues de formar una región segmentada  
 Tratamiento de imágenes con Matlab <http://www.alfaomega.com.mx>

Considerando  $C$  como tamaño de la vecindad común y  $D$  el tamaño de la porción de  $C$  en qué la diferencia de amplitud  $Y$  a través de la región es menor al factor de significancia  $\varepsilon$  que equivale al valor del umbral configurado hasta 20, las regiones  $R_1$  y  $R_2$  están unidas si:

$$\frac{D}{\text{MIN}\{P_1, P_2\}} > (\varepsilon = 20) \quad (13)$$

Al igual que la Umbralización, por lo general no se utiliza la región creciente solamente en una imagen, sino que se utiliza como parte de un conjunto de operaciones de procesamiento de imágenes, particularmente en la delineación de pequeñas y simples estructuras como tumores y lesiones. Su desventaja principal es que requiere interacción manual para obtener el punto semilla. Los algoritmos de división y mezcla (split and merge) están relacionados con la región creciente pero no requieren una semilla. La región creciente también puede ser sensible al ruido, causando que las regiones extraídas tengan agujeros e inclusive que se desconecten.

### 2.10.3.3. Algoritmo Región Growing

El algoritmo de crecimiento de regiones es un método basado en regiones en el que se segmentan las diferentes regiones según sus características. Se coloca

una semilla en un determinado píxel de la imagen y de acuerdo a si similitud con sus píxeles vecinos esta semilla puede hacer crecer una región o no.

En nuestro caso, la diferencia absoluta entre el valor del vecino y el promedio de los valores de los píxeles dentro de la región se utilizarán para que crezcan las imágenes de nivel de grises. Por otro lado, en imágenes RGB el criterio será la distancia euclidiana entre la región y el píxel que se está analizando. Además, este criterio podría usarse para segmentar una imagen de n dimensiones.

Si la región está completamente desarrollada y esto significa que ninguno de los vecinos cumple los criterios deseados, ninguno de ellos se puede agregar a la región, el algoritmo busca en filas un píxel que no se ha agregado a una región y coloca en él una nueva semilla que permite que crezca una nueva región [26].

#### **2.10.3.4. Procesamiento basado en Regiones de Interés (ROI)**

Una región de interés (ROI) es una parte de una imagen que se desea filtrar o procesar de alguna manera. Una ROI se puede representar como máscara binaria. En la máscara, los píxeles que pertenecen a la ROI tienen el valor 1, y los que se sitúan fuera tienen el valor 0. La Toolbox ofrece varias opciones para especificar una ROI y crear máscaras binarias.

La Toolbox es compatible con distintos objetos que pueden usarse para crear ROI de distintas formas, como círculos, elipses, polígonos, rectángulos y formas trazadas a mano alzada. Después de crear los objetos, puede cambiar su forma, posición, apariencia y comportamiento.

La herramienta ROI también es una forma de comprimir, de modo que el área de la imagen perteneciente a la región de interés puede comprimirse utilizando un algoritmo sin pérdida de calidad con el fin de recuperar los datos originales sin alteración. Asimismo, el área externa se comprime a través de un algoritmo con pérdida o irreversible, que igualmente puede alcanzar resultados con disminución de calidad visualmente indistinguible.

El protocolo DICOM introduce la herramienta ROI por las capacidades del estándar de imagen JPEG-2000, permitiendo comprimir sin pérdida la zona de mayor importancia diagnóstica dentro de la imagen y con una pérdida moderada la región restante.

La herramienta ROI puede especificarse a través de un conjunto de coordenadas o como una máscara binaria del mismo tamaño que la imagen.

#### **2.10.4. Técnicas de agrupamiento o clustering**

El “clustering algorithm” o algoritmo de agrupación, trata de dividir un conjunto de datos de entrada en subconjuntos (clúster), de manera que los elementos de cada subconjunto compartan características similares, y su agrupamiento sea llevado a cabo según similitud o cercanía. Entre los métodos de clustering destaca el método k-means, que consiste en fijar un número de clúster y asignar un clúster a cada elemento para después recalculan los clústeres a partir de los datos asignados hasta que se consigue la convergencia, por ejemplo, que los píxeles no cambien de clúster.

Este tipo de segmentación se fundamenta en dos principios: la definición de un patrón o centroide por cada región del espacio de características, y la asignación de cada vector de características al centroide más próximo. Esta forma de proceder es útil cuando no se conocen ni las características de las regiones a buscar ni cuantas categorías hay.

El agrupamiento puede realizarse mediante el algoritmo de las k-medias, que trata de encontrar k prototipos a partir de los vectores de un conjunto dado. Se inicia el método con k muestras aleatorias, se calcula la distancia de cada dato a cada uno de los k representantes y se asigna a aquel con el que guarde mínima distancia. Finalmente, se recalculan los representantes de cada grupo o clase y vuelve a aplicarse de forma iterativa.

El algoritmo de las k-medias supone conocido el número de regiones de la imagen. Pero, puede ocurrir que esto sea desconocido, en este caso, se procede con la división de regiones. En esta técnica se parte de dos centroides (regiones), se aplica un algoritmo de agrupamiento (por ejemplo, k-medias), se define un criterio de homogeneidad para determinar donde separar las regiones vecinas, y si no se satisface el criterio de parada, se dividen las regiones vecinas menos homogéneas y se vuelve a aplicar el algoritmo de agrupamiento; es un proceso iterativo. Es por tanto de vital importancia, la selección de un buen criterio de parada, ya que con él se determinará correctamente el número de regiones.

El proceso para llevar a cabo el algoritmo tradicional de agrupación K-means consiste en:

### 1. Formación de Clústeres

El algoritmo itera sobre el conjunto entero de datos y asigna a cada objeto, un grupo representado por el baricentro más cercano a dicho objeto. El baricentro más cercano se determina, con el uso de la medida de distancias elegida. Por lo tanto, para cada objeto en un conjunto analizado de datos, la distancia mínima cuadrada tiene que ser encontrada como:

$$\min d^2(x_i, c_j) \quad (14)$$

Donde;  $d =$  es la medida de la distancia elegida,  $x_i, i = 1, 2, \dots, n$  es el objeto en el grupo  $j$ ,  $c_j, j = 1, 2, \dots, k$  es el baricentro del grupo  $j$  y  $n_j$ , y  $k$  el número de Clúster o agrupamientos.

### 2. Encontrar el baricentro de cada agrupación

Por cada grupo, el baricentro se determina en base a los objetos pertenecientes a dicho grupo. El algoritmo lo calcula, con el objetivo de minimizar de forma objetiva la función, siendo el error de distorsión el siguiente:

$$e(X_j) = \sum_{i=1}^{n_j} d^2(x_j, c_j) \quad (15)$$

#### 2.10.5. Algoritmo de Agrupamiento (C-means)

C-means es un algoritmo iterativo que hace parte de las técnicas de agrupamiento no supervisado y tiene como objetivo encontrar patrones o grupos interesantes en un conjunto de datos dado, de tal manera que tales patrones, estructuras o grupos encontrados sirvan para clasificación, diseño de estrategias, soporte de decisiones, organización de la información, entre otras.

C-means al igual que otras técnicas clásicas de agrupamiento realiza una partición dura del conjunto de datos, tal partición se caracteriza porque cada dato pertenece exclusivamente a un clúster (grupo o clase) de la partición, además, los clústeres deben cubrir totalmente el conjunto de datos, es decir cada dato tiene que pertenecer a alguno de los clústeres; la cantidad de clúster debe ser

definida para inicializar el algoritmo. Una partición dura se define formalmente como sigue:

Sea  $X$  un conjunto de datos y  $x_i$  un elemento perteneciente a  $X$ . se dice que una partición  $P = \{C_1, C_2, \dots, C_c\}$  donde  $c$  es un número entero no negativo que indica la cantidad de clúster, es una partición dura de  $X$  si y solo si:

1.  $\forall x_i \in X \exists C_i \in P \quad \text{tal que} \quad x_i \in C_i$  (16)
2.  $\forall x_i \in X \quad x_i \in C_i \Rightarrow x_i \notin C_j$   
 Donde  $k \neq j, \quad C_k, C_j \in P$

La primera condición asegura que la partición cubra todos los puntos de  $X$ , la segunda garantiza que todos los clústeres sean mutuamente excluyentes.

Los objetivos del algoritmo c-means convencional son: encontrar el centro de cada clúster (este punto central es conocido con el nombre de prototipo del clúster) y determinar cuál es el único clúster al que pertenece cada punto del conjunto de datos.

Para lograr el objetivo de hallar el centro de cada clúster se establece un criterio de búsqueda de dicho centro. Uno de tales criterios es la suma de la distancia entre los puntos de cada clúster y su centro, así:

$$J(P, V) = \sum_{j=1}^c \sum_{x_i \in X} \|X_i - V_j\| \quad (17)$$

Donde  $V$  es un vector de los centros de cada clúster a ser identificados. Este criterio es útil porque un conjunto de centros de los clúster adecuado o correcto brindará un valor mínimo de la función  $J$ .

Como primer paso el algoritmo c-means calcula la partición actual con base a los prototipos actuales, como segundo paso modifica los prototipos actuales usando un método de optimización (Ej. Gradiente óptimo) para minimizar la función  $J$ , luego estos dos pasos se repiten iterativamente hasta alcanzar algún criterio de parada que usualmente es la diferencia de los prototipos entre dos ciclos consecutivos; cuando el algoritmo alcanza su criterio de parada significa que la función  $J$  llegó a un mínimo local.

### **2.10.6. Segmentación basada en texturas**

Dentro del procesamiento de imágenes una característica importante es la textura. Definir qué es la textura no es algo sencillo porque toda persona tiene un conocimiento intuitivo acerca de ella dado por su experiencia, pero si se le pide a alguien definirla será muy complicado entregar una definición que abarque la amplia gama de texturas existentes tales como texturas finas, granuladas, ásperas, etc. La textura es una propiedad innata de todas las superficies, por ese motivo cuando se desea detectar la presencia de un objeto éste puede identificarse por sus características de textura la cual puede ser evaluada como fina, suave, gruesa o tosca según corresponda.

#### **2.10.6.1. Matriz de Co-ocurrencia**

La matriz de Co-ocurrencia o GLCM (grey level cooccurrence matrix) describe la frecuencia de un nivel de gris que aparece en una relación espacial específica con otro valor de gris, dentro de un área de una ventana predeterminada. La matriz de Co-ocurrencia es un resumen de la forma en que los valores de los píxeles ocurren uno al lado de otro en una pequeña ventana.

La matriz de Co-ocurrencia es una tabla que indica como están relacionadas las distintas combinaciones de los valores de brillo de los píxeles (niveles de grises) que ocurren en la imagen por lo que la matriz de Co-ocurrencia tendrá dimensiones de  $N \times N$  si existen  $N$  niveles de grises. Para una imagen de 256 niveles de grises se tendrá una matriz de Co-ocurrencia de  $256 \times 256$  para cada dirección y ventana.

La matriz de Co-ocurrencia considera la relación espacial entre dos píxeles, llamados píxeles de referencia y píxel vecino. Por ejemplo, si se escoge el píxel vecino que este situado a la derecha de cada píxel de referencia, este se expresa como (1,0): 1 será el píxel en la dirección  $x$  y 0 será un píxel en la dirección  $y$ . Así, cada píxel en la ventana se convierte en el píxel de referencia empezando por el ubicado arriba a la izquierda y finalizando abajo a la derecha. Si observa que los píxeles ubicados en el margen derecho de la imagen original no tienen vecino a la derecha por lo tanto no son usados en el cómputo [27].

### 2.10.6.2. Medidas Estadísticas de la Textura

**Homogeneidad:** Una imagen resulta homogénea si los valores de la diagonal principal de la matriz de Co-ocurrencia son altos, esto porque al observar la ecuación de homogeneidad los valores de probabilidad en la matriz son mayores en la diagonal principal y su peso decae exponencialmente al alejarse de la diagonal.

**Contraste:** Este concepto es totalmente opuesto a la homogeneidad donde el contraste tendrá un valor alto si los valores altos están concentrados lejos de la diagonal principal y el peso de la probabilidad aumenta, pero en forma cuadrática [27].

**Disimilaridad:** Es similar al contraste, un alto contraste indica un valor alto de Disimilaridad, la diferencia está en que su peso se incrementa linealmente.

**Media:** A diferencia de la media aritmética, ésta media corresponde a la frecuencia de que un píxel vecino esté en una combinación con un píxel de referencia.

**Entropía:** La entropía se utiliza en medidas aleatorias (random) de los elementos de una matriz, que para este caso será una imagen. Es la entropía la encargada de medir precisamente la aleatoriedad de los píxeles en la matriz de Co-ocurrencia. Esta idea fue presentada por Shannon, matemático norteamericano, en su artículo de 1948 [28].

Shannon ofrece una definición de entropía que satisface las siguientes afirmaciones:

1. La medida de información debe ser proporcional (continua). Es decir, un pequeño cambio en una de las probabilidades de aparición de uno de los elementos de la señal (imagen para este caso) debe cambiar poco la entropía. Por lo que se espera que una imagen suave tenga una baja entropía y una alta entropía será para imágenes toscas.
2. Si todos los elementos de la señal (imagen) son equiprobables a la hora de aparecer, entonces, la entropía será máxima. En resumen, cuando todos los elementos de una matriz son totalmente random, la entropía

tendrá valores altos, por lo tanto, una imagen homogénea tendrá baja entropía siendo está clasificada como tosca.

### **2.10.7. Morfología de imágenes**

La morfología matemática es un enfoque no lineal de procesamiento de imágenes basado en la aplicación de teoría de retículos (lattice theory) a estructuras espaciales. Esta técnica ha probado ser una herramienta poderosa en análisis de imágenes. La morfología matemática se basa en la teoría de conjuntos y retículos, lo que permite construir algoritmos poderosos, basados en la combinación de operadores elementales. La morfología matemática se ha usado exitosamente en muchas áreas de procesamiento de imágenes y especialmente en imágenes médicas. Una extensión de esta teoría es la morfología color. Este enfoque extiende los tradicionales operadores morfológicos a ser aplicados en imágenes a color, permitiendo el modelado de la imprecisión y la incertidumbre, usualmente presente en imágenes médicas color [29].

#### **2.10.7.1. Transformaciones básicas**

La morfología matemática aprovecha las propiedades de los conjuntos de puntos, los resultados de la geometría integral y la topología. La premisa inicial consiste en suponer que las imágenes reales pueden ser modeladas utilizando conjuntos de puntos de cualquier dimensión (por ejemplo, el espacio euclídeo N-dimensional). El espacio euclídeo 2D ( $E^2$ ) y su sistema de subconjuntos es un dominio natural para la descripción de formas planas. Desde la perspectiva de conjuntos se consideran las operaciones habituales en ellos, entre las que se incluyen: inclusión, unión, intersección, complementario o conjunto vacío. La diferencia de conjuntos se define por  $X - Y = X \text{ intersección } Y \text{ complemento}$ .

#### **Dilatación**

La transformación morfológica de la dilatación  $\ominus$  combina dos conjuntos utilizando la adición de vectores. La dilatación  $X \ominus B$  es el conjunto de puntos de todas las posibles adiciones vectoriales de pares de elementos, uno de cada conjunto  $X$  y  $B$ .

$$X \ominus B = \{d \in E^2: d = x\} b \text{ para cada } x \in X \text{ y } b \in B\} \quad (18)$$

## Erosión

La transformación morfológica de la erosión  $\Phi$  combina dos conjuntos usando la sustracción de vectores. Es dual de la dilatación. Ni la erosión ni la dilatación son transformaciones invertibles:

$$X \Phi B = \{d \in E^2: d + b \in X \text{ para cada } b \in B\} \quad (19)$$

Esta expresión dice que cada punto  $d$  del conjunto  $X$ , que para nosotros será la imagen, es comprobado; el resultado de la erosión está dado por los puntos  $d$  para los cuales todos los posibles  $d + b$  están en  $X$  [30].

## Apertura y cierre

La erosión y dilatación son transformaciones no invertibles. Si una imagen es erosionada y luego dilatada, la imagen original no se recupera. En efecto, el resultado es una imagen simplificada y menos detallada de la imagen original.

La erosión seguida de una dilatación crea una transformación morfológica importante llamada apertura. La apertura de una imagen  $X$  por el elemento estructural  $B$  se denota por  $X \circ B$  y se define como:

$$X \circ B = \{X \Phi B\} \Theta B \quad (20)$$

La dilatación seguida de una erosión crea una transformación morfológica llamada **cierre**. El cierre de una imagen  $X$  por un elemento estructural  $B$  se denota por

$$X \cdot B = \{X \Theta B\} \Phi B \quad (21)$$

Si una imagen  $X$  permanece invariable por apertura con respecto al elemento estructural  $B$ , se dice que es abierta con respecto a  $B$ . Análogamente, si una imagen  $X$  permanece invariable por cierre con respecto al elemento estructural  $B$ , se dice que es cerrada con respecto a  $B$ .

La apertura y el cierre con un elemento estructural isótropo se emplea para eliminar detalles específicos de la imagen más pequeños que el elemento estructural. La forma global de los objetos no se distorsiona. El cierre conecta objetos que están próximos entre sí, rellena pequeños huecos y suaviza el contorno del objeto rellenando los pequeños valles mientras que la apertura

produce el efecto contrario. Los conceptos de pequeño y próximo están relacionados con la forma del elemento estructural [30].

#### **2.10.8. Segmentación basada en aprendizaje automático**

La segmentación de imágenes basada en aprendizaje automático es una técnica que se utiliza para identificar y separar diferentes estructuras anatómicas y lesiones en imágenes médicas, como resonancias magnéticas cerebrales y tomografías computarizadas. Esta técnica es útil para los profesionales médicos porque les permite analizar grandes conjuntos de datos de imágenes médicas y obtener resultados precisos y consistentes en la segmentación de estructuras anatómicas y lesiones. Los algoritmos de aprendizaje automático utilizados para la segmentación de imágenes médicas incluyen redes neuronales convolucionales y máquinas de vectores de soporte. La segmentación de imágenes médicas basada en aprendizaje automático tiene aplicaciones en el diagnóstico, la planificación de tratamientos y la investigación médica [31].

##### **2.10.8.1. Redes Neuronales**

Una red neuronal es un modelo de computación cuya estructura de capas se asemeja a la estructura interconectada de las neuronas en el cerebro, con capas de nodos conectados. Una red neuronal puede aprender de los datos, de manera que se puede entrenar para que reconozca patrones, clasifique datos y pronostique eventos futuros.

Las redes neuronales descomponen las entradas en capas de abstracción. Se pueden entrenar con muchos ejemplos para que reconozcan patrones de voz o en imágenes, por ejemplo, igual que el cerebro humano. Su comportamiento está definido por la forma en que se conectan sus elementos individuales, así como por la importancia (o ponderación) de dichas conexiones. Estas ponderaciones se ajustan automáticamente durante el entrenamiento de acuerdo con una regla de aprendizaje especificada hasta que la red neuronal lleva a cabo la tarea deseada correctamente [32].

### **2.10.8.2. Redes Neuronales Convolucionales (CNNs/ConvNets)**

Las redes neuronales convolucionales (CNN) son un tipo especial de redes neuronales de adelanto para el procesamiento de datos que tienen una topología similar a una malla, ejemplos incluyen datos de series de tiempo, el cual puede ser pensado como una malla 1D que toma muestras en intervalos regulares de tiempo y datos de imagen el cual puede ser pensado como una malla 2-D de píxeles. El nombre “redes neuronales convolucionales” indica que la red emplea una operación matemática llamada convolución. Una convolución es un tipo especializado de operación lineal. Las redes neuronales convolucionales son simplemente redes neuronales que usan convoluciones en lugar de multiplicación general de matrices en al menos una de sus capas. Esto junto al desarrollo de GPUs con gran capacidad de memoria que puedan realizar millones de operaciones y el uso conjunto de otras operaciones que serán descritas posteriormente, han permitido un gran rendimiento en aplicaciones prácticas en los últimos años [33].

### **2.10.8.3. Red Neuronal Convolutiva SynthSeg**

SynthSeg es una herramienta de aprendizaje profundo para la segmentación de resonancias magnéticas cerebrales de cualquier contraste y resolución. Es la primera red neuronal que segmenta escáneres cerebrales de una amplia gama de contrastes y resoluciones sin necesidad de volver a entrenarlos.

SynthSeg es la primera red neuronal que segmenta escáneres cerebrales de una amplia gama de contrastes y resoluciones, sin tener que volver a entrenarlos ni ajustarlos. Específicamente, SynthSeg se entrena con escaneos sintéticos muestreados sobre la marcha a partir de un modelo generativo inspirado en el marco de segmentación bayesiano y, por lo tanto, nunca se expone a escaneos reales durante el entrenamiento. Es una estrategia de aleatorización de dominio, donde todos los parámetros del modelo generativo (incluida la orientación, el contraste, la resolución y los artefactos) son completamente aleatorizados. Esto expone a la red a ejemplos muy diferentes en cada mini lote y, por lo tanto, la obliga a aprender características independientes del dominio. Además, aplica un subconjunto aleatorio de operaciones de preprocesamiento comunes a cada ejemplo (por ejemplo, extracción de cráneo, corrección de campo de sesgo), de

modo que SynthSeg pueda segmentar escaneos con o sin preprocesamiento [34].

Con esta estrategia de aleatorización de dominio, este método solo necesita entrenarse una vez. Esta es una mejora considerable con respecto a las CNN supervisadas y las estrategias de adaptación de dominio, que necesitan reentrenamiento o ajuste para cada nuevo contraste o resolución, lo que dificulta las aplicaciones clínicas. Además, el entrenamiento de SynthSeg (Ver Figura 14) se ve facilitado enormemente por el hecho de que solo requiere un conjunto de mapas de etiquetas anatómicas para entrenar (y no imágenes reales, ya que todos los escaneos de entrenamiento son sintéticos). Además, estos mapas se pueden obtener automáticamente (en lugar de manualmente), ya que los escaneos de entrenamiento se generan directamente a partir de sus datos reales y, por lo tanto, están perfectamente alineados con ellos. Esto nos permite mejorar en gran medida la solidez de SynthSeg al incluir mapas de entrenamiento automatizados de poblaciones muy diversas.

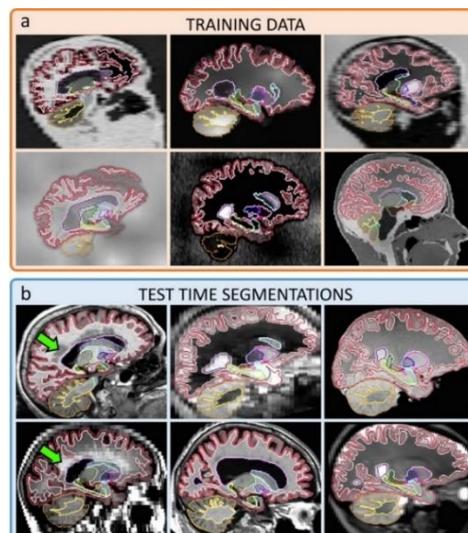


Figura 14: Muestras representativas de los escaneos 3D sintéticos

- a) Entrenamiento de la red neuronal SynthSeg para la segmentación
- b) Segmentaciones de tiempo de prueba para una variedad de contrastes y resoluciones

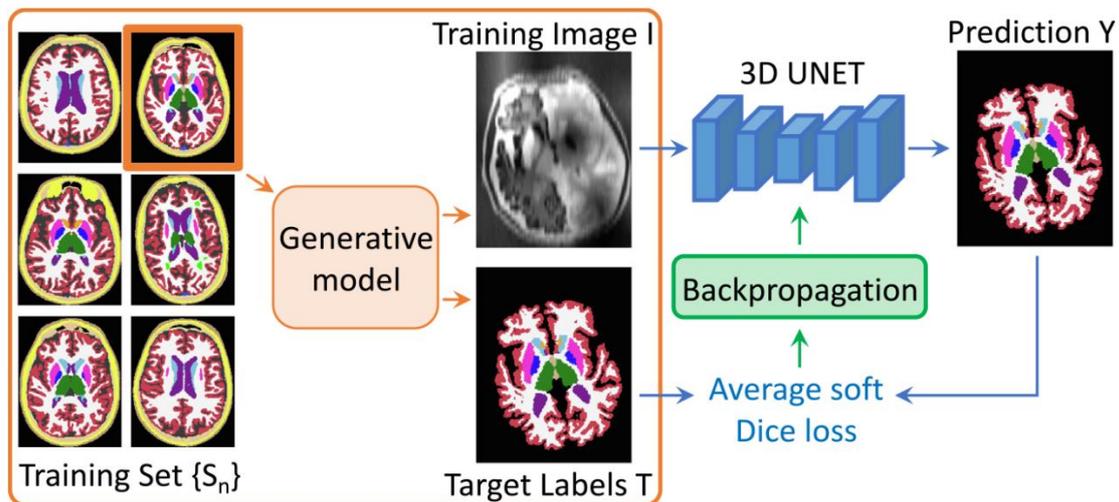


Figura 15: Resumen de primera etapa de entrenamiento

Segmentación de resonancias magnéticas cerebrales de cualquier contraste y resolución sin reentrenamiento  
<https://www.sciencedirect.com/science/article/pii/S1361841523000506>

En cada mini lote, se selecciona aleatoriamente un mapa de etiquetas 3D de un conjunto de entrenamiento (Ver Figura 15) {S<sub>n</sub>} y prueba un par {I, T} del modelo generativo. Luego, la imagen obtenida se ejecuta a través de la red y su predicción Y se utiliza para calcular la pérdida suave promedio, que se propaga hacia atrás para actualizar los pesos de la red.

## 2.11. Recursos Didácticos.

Los recursos didácticos son aquellos materiales o conjunto de elementos educativos que intervienen y facilitan el proceso enseñanza-aprendizaje de los estudiantes, estos materiales pueden ser tanto físicos como virtuales que asumen la condición de despertar el interés en los estudiantes, tienen como resultado activar el rol del estudiante y fortalecer la creatividad del docente.

La importancia de la implementación de los recursos didácticos en las planificaciones docentes ha llevado a reestructurar el campo educativo, ya que son fundamentales para impartir la clase, aunque pareciera que no, sirve de intermediario curricular para elevar el rendimiento escolar [35].

## **2.12. Desarrollo de Recursos Didácticos**

### **2.12.1. Etapa de selección**

Es la primera de las etapas del desarrollo de los materiales o guías, que se dedica a localizar y recuperar los recursos o componentes (contenidos y estrategia pedagógica) más apropiados de acuerdo con los requisitos de creación del material sobre el dominio del conocimiento, pedagógicos y técnicos.

### **2.12.2. Etapa de composición**

La segunda etapa del desarrollo es la composición dedicada a la agregación e integración de los recursos. Durante esta etapa los recursos obtenidos en la etapa anterior son agregados e integrados en una estructura del material definida según los requisitos pedagógicos y que permita cumplir con los requisitos de soporte tecnológico para la entrega y visualización del material.

### **2.12.3. Etapa de evaluación**

La última etapa del desarrollo es la evaluación, ignorada o subestimada en muchas soluciones al desarrollo. En esta etapa se controla que las propiedades del material obtenido cumplan en cierta medida con las expectativas de sus creadores o potenciales usuarios.

Una vez que se ha realizado la composición del material y que los creadores han visualizado su resultado, durante la etapa de evaluación es necesario controlar si las propiedades del material obtenido satisfacen los requisitos iniciales. Deberá entonces inspeccionarse la calidad del material creado vista como su utilidad pedagógica y usabilidad y en aquellos casos en los que dichas cualidades no alcancen niveles aceptables será preciso proceder a rediseñar el material.

Los criterios de evaluación del recurso didáctico es una de las actividades más importantes dentro su desarrollo, porque gracias a ella es posible comprobar si las propiedades del material didáctico satisfacen los requisitos definidos al inicio del proceso de creación, además de obtener información realista sobre su utilidad, de forma que se valida si el material creado permite el logro efectivo de los objetivos de cada uno de los participantes en el proceso educativo. En función de los resultados de la evaluación es posible tomar medidas para el rediseño del material [36].

### **2.13. Sistema Nacional de Evaluación para el Aprendizaje (SNEPA)**

El fortalecimiento de la calidad educativa en nuestro país es un objetivo fundamental de trabajo del Sistema Educativo Nacional. Con el propósito de fortalecer la calidad del aprendizaje de manera armonizada entre los subsistemas representados por el Ministerio de Educación (MINED), Tecnológico Nacional (INATEC), Consejo Nacional de Universidades (CNU) y Subsistema Educativo Autónomo Regional (SEAR) se realizan esfuerzos para la construcción de un Sistema Nacional de Evaluación para el Aprendizaje, que conlleve y se proyecte como un proceso articulado direccionando a la mejora permanente, desde un enfoque por competencias centrado en el aprendizaje del estudiante, que permita a cada institución educativa desarrollar la evaluación para el aprendizaje coherente con los saberes, habilidades y actitudes de los estudiantes, desde su formación inicial, básica, media, técnica y superior; de acuerdo a las normas y políticas establecidas de cada institución y a los estándares internacionales [37].

La evaluación para el aprendizaje es un proceso pedagógico reflexivo, formativo continuo y sistemático que vincula el proceso de enseñanza-aprendizaje en el que se recolecta evidencias y analiza información para validar el aprendizaje, que facilite la toma de decisiones oportunas y pertinentes que conllevan al enfoque formativo.

La finalidad del Sistema de Evaluación para el Aprendizaje es trascender de una evaluación orientada a valorar conocimientos teóricos y memorísticos a una evaluación que centra su atención en los procesos de mejora y se complementa con acciones articuladas en correspondencia al currículo con enfoque por competencias, integrando el uso de las Tecnologías del Aprendizaje y la Comunicación (TAC), estrategias innovadoras, desarrollo de programas integradores y mejoramiento de las normativas de evaluación [38].

## **Capítulo III. ANALISIS Y PRESENTACION DE LOS RESULTADOS**

### **3.1. Diseño Metodológico**

El alcance de este documento es de carácter aplicativo, primeramente, se recopiló información basada en el procesamiento digital de imágenes con el fin de comprender e identificar las técnicas y fundamentos teóricos. Una vez que se ha comprendido los fundamentos teóricos, se procedió a desarrollar y evaluar cada una de las etapas de procesamiento de imágenes que comprenden técnicas como: extracción de características, segmentación y transformaciones morfológicas.

Luego se diseñaron e implementaron recursos didácticos que faciliten la enseñanza-aprendizaje en cuanto al procesamiento digital de imágenes médicas. Las cuales estarán definidas por etapa desde una base introductoria hasta poder aplicar filtro y poder extraer información de suma relevancia.

Para la realización de dichos recursos didácticos se utilizó el software Matlab para visualizar, analizar y manipular los algoritmos para mostrar cada uno de los resultados obtenidos en cada una de las etapas de desarrollo del material didáctico.

Finalmente se evaluaron los recursos didácticos mediante encuestas, a los estudiantes con el fin de medir el impacto que estas tuvieron en el proceso de enseñanza-aprendizaje.

### **3.2. Estructura de los recursos didácticos (guías de laboratorio)**

- **Introducción**

Esta primera parte comprende información básica e introductoria de los conceptos básicos del tema que se va a desarrollar, además se describe en qué consistirá la práctica.

- **Fundamentación Teórica**

Esta etapa es muy importante para el desarrollo de la práctica, en la cual se orienta a la lectura comprensiva acerca de algunos puntos específicos que serán útiles y se corresponden con el contenido teórico y el logro de los objetivos de aprendizaje.

- **Objetivos**

Son muy importantes ya que describen el alcance de los Recursos de apoyo.

- **Desarrollo de la practica**

Se plantean todos los ejemplos acerca de los puntos a abordar, así como también las asignaciones planteadas a realizar por los estudiantes para después realizar su informe y entrega correspondiente al docente.

- **Bibliografía**

Se anexa toda la documentación utilizada para la realización de los recursos, documentos, artículos relacionados con los temas abordados.

### **3.3. Diseño de los recursos didácticos**

Para el diseño de los recursos didácticos, se tomó en cuenta que en la asignatura solo se desarrollaban casos de estudio, en cuanto a procesamiento digital de señales (DSP), por lo tanto y con la facilidad que nos ofrece el software MATLAB, se seleccionaron contenidos oportunos con el propósito de poder emplear recursos de laboratorio en el procesamiento digital de imágenes médicas.

Se diseñaron 6 recursos de apoyo que abarcan principios básicos en cuanto a preprocesamiento de una imagen, siendo este un primer recurso introductorio, seguidamente diferentes técnicas de segmentación utilizadas en análisis médico, que permita al estudiante poder comprender desde la aplicación de filtros hasta poder dividir una imagen en regiones, o extraer características de la misma que se consideren de suma relevancia. Así mismo se elaboró un recurso introductorio en cuanto a segmentación basada en el procesamiento automático.

Los recursos didácticos elaborados se describen a continuación:

#### **Preprocesamiento digital de imágenes en formato Dicom**

El primer script proporcionado para cargar, visualizar y ajustar la intensidad de las imágenes médicas, que se toman directamente precargadas desde el Toolbox Image processing, la línea de código `image_num = 78`; se refiere a la imagen número 78 del volumen de imágenes, para visualizar las imágenes se hace uso de la función `sliceviewer` la cual permite en la ventana de gráficos un

control deslizante para visualizar las imágenes individualmente, también se utiliza la función `orthosliceViewer` para visualizar vistas ortogonales de la imagen original.

En el segundo ejemplo proporcionado se carga un archivo DICOM de una imagen médica utilizando la función `dicomread` y se define el tamaño del filtro utilizando la función `fspecial`, la línea de código `filterSize = [3 3]`, se refiere al tamaño del kernel del filtro que se utilizará para operaciones de convolución o filtrado de la imagen. Un kernel de 3x3 implica que se aplicará un filtro con una ventana de 3x3 píxeles en la imagen, para la aplicación de filtro lineal a la imagen se crea un filtro promedio utilizando la función `fspecial` con el tamaño del filtro especificado `fspecial` se aplica el filtro promedio a la imagen médica utilizando la función `imfilter` y se muestra la imagen médica original y la imagen médica filtrada utilizando la función `imshowpair`. Para el filtro no lineal se utiliza el filtro Wiener.

La ventaja de utilizar filtros lineales y no lineales en la misma imagen radica en la capacidad de cada tipo de filtro para abordar diferentes características y tipos de ruido en la imagen. Los filtros lineales, como el filtro promedio, son efectivos para suavizar la imagen y reducir el ruido gaussiano, mientras que los filtros no lineales, como el filtro de mediana o el filtro Wiener, son más adecuados para preservar los bordes y manejar el ruido impulsivo. o "sal y pimienta" en la imagen. Al combinar ambos tipos de filtros, se puede lograr un procesamiento de imagen más completo, abordando de manera efectiva múltiples tipos de ruido y preservando tanto la suavidad como los detalles importantes en la imagen.

El último script se carga y visualizan imágenes desde un Dataset, se Crea dos matrices tridimensionales de ceros para almacenar las imágenes DICOM: de tamaño 256x256xN y de tamaño 256x256xN, donde N es la cantidad de archivos DICOM encontrados. Luego a través de la función `dicomread` se lee cada imagen utilizando y almacenando en una matriz y después se muestra cada imagen en una nueva figura utilizando la función `imshow` y pausando la ejecución durante 0,2 segundos.

## **Técnicas de segmentación de imágenes basadas en Regiones Y Procesamiento Morfológico.**

En esta segunda etapa se centra en el uso de técnicas de segmentación de imágenes basadas en la división de regiones o segmentos con características similares que nos permiten formar una región de interés, que se desee filtrar o procesar de alguna manera, así también el uso de técnicas como el umbral para separar regiones con umbrales con valores mínimos y umbrales con valores máximos.

El primer script presenta una imagen con dos tipos de ruido que pueden alterar una segmentación: demasiado detalle y variación aleatoria en la intensidad de los píxeles. Los vasos sanguíneos y otras áreas brillantes pueden alterar la segmentación, al igual que la variación aleatoria en la intensidad de los píxeles. El filtrado espacial puede igualar ambos tipos de variaciones no deseadas, para este caso se usa un tamaño de filtro diferente, por ejemplo [15 15], esto cambiará la apariencia de la imagen filtrada y la calidad de la segmentación. Para esta segmentación, el filtro más grande elimina una gran cantidad de primer plano no deseado de la máscara. Un filtro más grande hace que la imagen sea más borrosa.

### **Técnicas de segmentación basada en bordes y textura.**

Comprende una continuación a la etapa anterior, en la cual ahora se estudian técnicas aplicadas a la detección de bordes en las imágenes, el proceso de detección de bordes simplifica el análisis de imágenes al reducir drásticamente la cantidad de datos a procesar, al tiempo que permite conservar información estructural útil sobre los límites de los objetos, así como clasificar y caracterizar texturas, calcular probabilidades conjuntas de aparición de pares de niveles de gris a una determinada distancia y ángulo en la imagen.

Primeramente, se utilizan para la detección de bordes algoritmos específicos como lo son el método Canny, operador Sobel, entre otros que se pide en modo de actividad que el estudiante interactúe y compare el mejor método de detección de bordes dependiendo del área específica en la que se trabaje.

Después se utiliza segmentación basada en textura, la cual utiliza características de textura para distinguir entre diferentes regiones en imágenes. Algunos algoritmos comunes incluyen: Matriz de coocurrencia que calcula la probabilidad de pares de píxeles cercanos en diferentes direcciones y distancias.

### **Procesamiento de imágenes basado en Aprendizaje Automático.**

En la siguiente guía se aborda una introducción a la segmentación de imágenes a través del procesamiento automático utilizando redes neuronales, en este caso se utilizó una red neuronal previamente entrenada Synthseg, la primera red neuronal convolucional para la segmentación de escaneos de resonancia magnética cerebral de cualquier contraste y que no necesita reentrenamiento lo que la hace una herramienta versátil y poderosa para aplicaciones médicas. Synthseg está disponible a partir de MATLAB 2022 y se ha ampliado su accesibilidad y utilidad para la comunidad de usuarios lo que permite aprovechar al máximo las capacidades para la segmentación precisa de escaneos de resonancia magnética cerebral.

La arquitectura de SynthSeg es una red neuronal convolucional (CNN) que se entrena para segmentar imágenes de resonancia magnética (MRI) cerebrales de contraste y resolución arbitrarias sin necesidad de reentrenamiento o fine-tuning. SynthSeg utiliza una única red neuronal que se distribuye con el software. La red neuronal se entrena en un conjunto de datos de entrenamiento que incluye 20 mapas de etiquetas de T1-39, 500 mapas de etiquetas de HCP y 500 mapas de etiquetas de ADNI. La mezcla de estos mapas de etiquetas aumenta considerablemente la variedad morfológica de las imágenes sintéticas y, por lo tanto, aumenta la robustez de SynthSeg a una amplia variedad de imágenes de MRI cerebrales.

### 3.4. Implementación de los Recursos Didácticos

En el desarrollo de evaluación de los recursos didácticos se realizó una invitación a estudiantes de 4to y 5to año de la carrera de ingeniería electrónica debido a que no existe un grupo como tal de ingeniería biomédica o técnico superior, por lo tanto, no hay un grupo de estudiantes activos en el Técnico Superior en Biomedicina.

En la evaluación se contó con la participación de 12 estudiantes en donde se les proporcionaron las guías de laboratorio en formato digital, en esta misma sesión se evaluó el desempeño de los estudiantes que consistió en identificar el comportamiento que presentaron durante el desarrollo de cada una de las guías de laboratorio correspondiente al contenido abordado en las guías, para poder abordar opiniones generadas por los estudiantes.

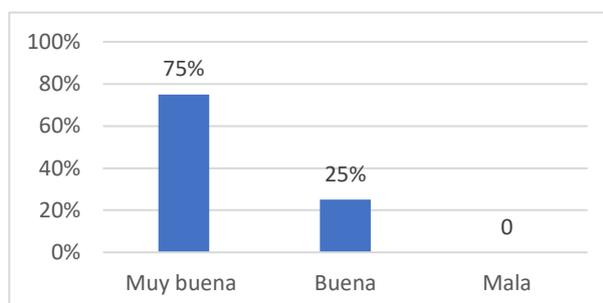
### 3.5. Evaluación de las guías de laboratorio mediante encuesta

Luego de aplicar las guías a los estudiantes se les facilito una encuesta para valorar el impacto que tuvieron y poder evaluar el trabajo realizado. Estas fueron elaboradas basándonos en ejemplos de diferentes guías y prácticas de laboratorio que fueron facilitadas por nuestro tutor, además de la experiencia que tuvimos como estudiantes realizando practicas e informes de laboratorio durante todo el transcurso de nuestra carrera.

#### Encuesta realizada para evaluación

1. ¿Una vez que se le proporcionaron los recursos propuestos para dicha asignatura, como califica la presentación y estructura de la misma?

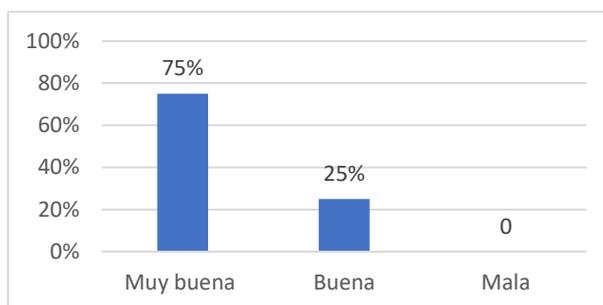
- a) Muy buena
- b) Buena
- c) Mala



En la gráfica anterior se presenta el nivel de aceptación en cuanto a la presentación y estructura de las guías propuestas, siendo los encuestados que evaluaron como Muy buena más del 50% y Buena el resto de los estudiantes. Esto nos indica que el proceso y estructura ha sido desarrollado de la mejor manera, llevando a un orden cronológico y entendible para los estudiantes.

**2. ¿Las guías de laboratorio proporcionan información clara y precisa sobre los procedimientos que se realizan en el procesamiento digital de imágenes médicas?**

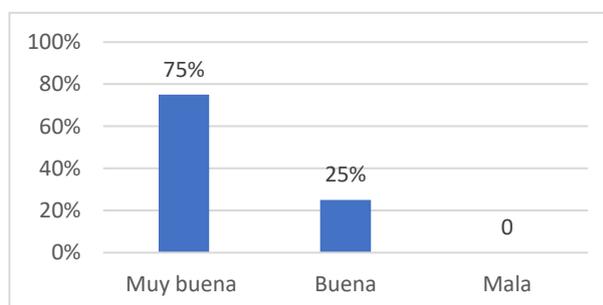
- a) Si
- b) No



En la gráfica anterior se consulta si se proporciona información clara y precisa acerca del proceso que se realiza en el procesamiento Digital de Imágenes (segmentación), que permita sentar bases para el entendimiento claro de los estudiantes, lo cual el 100% marco si en su respuesta lo cual indica que el material proporcionado es claro y fácil de entender, lo que permite un mejor desempeño y desarrollo de la práctica.

**3. ¿Considera que los ejemplos y/o aplicaciones mostradas ayudaran a comprender los conceptos claves del procesamiento digital de imágenes?**

- a) Si
- b) No

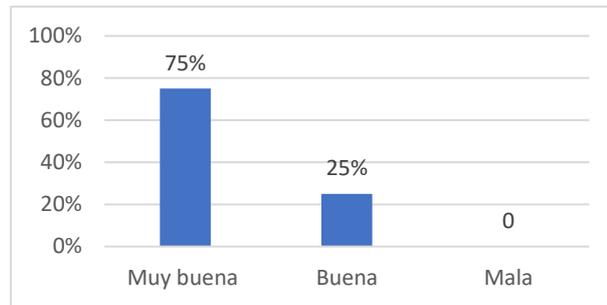


Según la información brindada en el grafico anterior, los estudiantes que realizaron la encuesta observamos que las guías si muestran ejemplos claros y fáciles de manipular en cada una de las guías y en cada una de las técnicas de

segmentación utilizadas en distintas aplicaciones de segmentación que se realizan en el área de medicina, por lo cual ayuda a entender mucho mejor los conceptos bases o principales para el procesamiento digital.

**4. ¿Piensa que serían eficiente las técnicas de segmentación de imágenes propuestas en las guías para establecer un posterior análisis?**

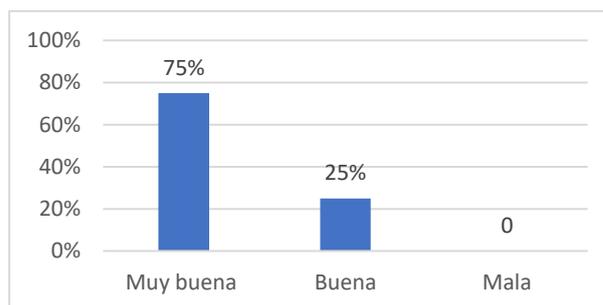
- a) Si
- b) No



En el gráfico mostrado se observa que el 100% de los encuestados considera que el uso de las técnicas mostradas en los recursos propuestos resulta de gran importancia y eficiencia para poder realizar un análisis post-procesamiento para poder determinar resultados de suma relevancia en la medicina.

**5. ¿Qué tan fácil le fue entender los ejemplos en Matlab, para posteriormente realizar las asignaciones propuestas?**

- a) Muy buena
- b) Buena
- c) Mala

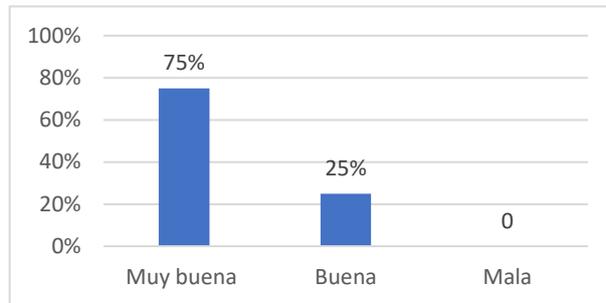


En el grafico generado en base a los resultados obtenidos más del 50% comprendió los temas abordados, los ejemplos mostrados lo cual le resulto útil para poder realizar las asignaciones propuestas en cada una de las técnicas de segmentación lo cual consideraron como muy buena en cuanto a la

comprensión, el otro porcentaje evaluó como buena el comprender y realizar lo propuesto.

**6. ¿Recomendaría estas guías de laboratorio a otros profesionales en el área de procesamiento digital de imágenes médicas?**

- a) Si
- b) No



Según la información brindada por los estudiantes que realizaron la encuesta podemos observar que las guías si tienen impacto en el proceso de enseñanza-aprendizaje de los estudiantes, que luego de aplicar todo el proceso junto con las encuestas y en la retroalimentación que nos dieron, nos informaron que en las guías se abarca contenido nuevo y llamativo y que podrían, en caso de ser aplicadas en los cursos de clase, ayudar un poco en la percepción de lo que es el procesamiento digital de imágenes y que por supuesto que recomendarían las guías a otros profesionales en el campo para que sirvan de base para futuras investigaciones o trabajos de este tipo.

## **Capítulo IV. CONCLUSIONES Y RECOMENDACIONES**

### **4.1. Conclusiones**

En el presente trabajo monográfico se cumplió con los objetivos planteados, se diseñaron recursos didácticos que faciliten el proceso de enseñanza-aprendizaje en la temática: procesamiento digital de imágenes médicas. Primeramente, se realizó búsqueda de información para determinar las técnicas de segmentación utilizadas en el área de medicina, a través de los datos recopilados se procedió a trabajar con los algoritmos a través del software Matlab® ya que ofrece una variedad de funciones y aplicaciones para segmentación de imágenes, eliminación de ruido y análisis de regiones y posteriormente realizar los recursos didácticos con una estructura ordenada.

La etapa de preprocesamiento es de gran importancia, ya que en esta etapa se resaltan características muy importantes antes de realizar un proceso de segmentación. Se diseñaron cuatro recursos para laboratorio en la asignatura tratamiento digital de bioseñales, las cuales todas fueron enfocadas a trabajar desde la interfaz de MATLAB®, utilizando el Toolbox Image processing, para realizar el análisis y procesamiento de las imágenes, de las cuales la primera orientada a preprocesamiento de imágenes, dos de ellas enfocadas a segmentación (regiones y bordes) y una última enfocada a realizar procesamiento a través de red neuronal previamente entrenada.

En la encuesta realizada a los estudiantes involucrados en este trabajo se reflejó que poseían conocimientos básicos del software MATLAB® pero ninguno tenía conocimientos al trabajar con algoritmos en el área de Procesamiento Digital de imágenes. El aprendizaje y comentarios de los estudiantes fue muy positivo al momento de realizar las actividades y posteriormente estuvieron satisfechos y muy interesados en el tema, lo cual los motiva a poder incursionar y realizar proyectos e investigaciones de alto interés en la temática.

## 4.2. Recomendaciones

Las siguientes recomendaciones son para la continuación de este trabajo:

- Continuar con el desarrollo de recursos que fomenten el interés de los estudiantes en esta temática, ya que es un área con muchos avances día a día que permite ir evolucionando con nuevas investigaciones.
- Validación de los recursos propuestos sobre un conjunto de casos clínicos más amplio, con el objetivo de verificar la fiabilidad de los algoritmos propuestos.
- Desarrollo de nuevos métodos de segmentación basado de aprendizaje profundo.
- Utilización de otro software que realicen procesamiento digital de imágenes.

## BIBLIOGRAFÍA

- [1] E. G. Martínez, «Segmentacion y Clasificacion de imagenes,» Ciudad de Mexico, 2014.
- [2] «Red Comunica,» 23 Febrero 2022. [En línea]. Available: <https://redcomunica.csuca.org/index.php/universidad-nacional-de-ingenieria-uni/uni-ofertara-ingenieria-biomedica/>. [Último acceso: 13 Julio 2022].
- [3] E. Gopi, Digital signal Processing for Medical Imaging Using Matlab, India: Springer, 2013.
- [4] B. P. F. A. Andino, Desarrollo de un sistema de reconocimiento de imágenes utilizando Raspberry Pi y Matlab que contribuyan al aprendizaje del tratamiento digital de señales, Managua, Nicaragua, 2016.
- [5] B. O. A. Duarte y B. J. G. Roque, Aplicaciones de procesamiento digital de imágenes y videos con propósitos académicos, Managua, Nicaragua, 2017.
- [6] C. J. Montenegro Jarquin y L. F. Morales Urbina, Método para la detección de cáncer de mama en mamografías usando Convolutional Neural Networks (CNN), Managua, Nicaragua, 2021.
- [7] B. K. A. R. Bellorin, Implementación de guías de laboratorio para realizar mediciones y análisis de eventos en la banda de 850 MHz de la tecnología WCDMA, Managua, Nicaragua, 2016.
- [8] M. A. Ramos y M. E. Díaz Lacayo, Creacion de practicas de Laboratorio de centrales privadas PBX para la asignatura de Redes Telefonicas., Managua, Nicaragua, 2011.
- [9] M. B. G. Sánchez, Segmentación digital de imágenes médicas para el mejoramiento del diagnóstico de anomalías en los centros radiológicos de la ciudad de Ambato-Ecuador, Ambato-Ecuador, 2013.
- [10] H. S. Gong, Advance Image and Video Processing Using Matlab, China: Springer, 2019.
- [11] «World Health Organization,» 02 febrero 2019. [En línea]. Available: <https://www.who.int/home/cms-decommissioning..> [Último acceso: 21 junio 2021].
- [12] Academia-lab, «Imagen Binaria,» [En línea]. Available: <https://academia-lab.com/enciclopedia/imagen-binaria/>.
- [13] E. Cuevas, M. Díaz y J. Octavio, Tratamiento de Imagenes con MATLAB, Mexico: Alfaomega Grupo Editor, junio 2017.
- [14] Ó. J. M. M. Y. & A. H. Espitia Mendoza, Tomografía computarizada: proceso de adquisición, tecnología y estado actual., Tecnura , 20 (47), 119-135., 2016.
- [15] I. N. d. B. e. I. Biomédicas, «Tomografía Computarizada (TC),» Julio 2013. [En línea]. Available: <http://parkinsoncantabria.com/documentos/tomografia%20computarizada.pdf>.

- [16] D. A. C.-V. D. A. M.-S. D. S. B. D. Dr. Carlos Valencia-Calderòn, «Descripción y Fundamentos del SPECT y el PET,» Barcelona - España, 2016.
- [17] R. S. o. N. America, «Información y recursos adicionales sobre mamografía,» [En línea]. Available: <https://gwcradiology.com/wp-content/uploads/2014/10/mammo-spanish.pdf>.
- [18] G. Dougherty, Digital Image Processing for Medical Applications, New York, 2009.
- [19] A. B. Pérez, Desarrollo de algoritmos de procesamiento de imagen avanzado para interpretación de imágenes médicas., Bilbao, 2016.
- [20] J. L. Semmlow, Biosignal and Biomedical Image Processing. Matlab-Based Applications, New Jersey, U.S.A, 2004.
- [21] Mathworks, «Vision General de Matlab,» [En línea]. Available: <https://la.mathworks.com/products/matlab.html>.
- [22] N. E. M. Association, Digital Imaging and Communications in Medicine (DICOM)., 2008.
- [23] B. Classe Qsl, «Definición Biomedicina, concepto y objetivos.,» 2010. [En línea]. Available: <http://www.encyclopediasalud.com/categorias/ecologia-biologia-ybiomedicina/articulos/que-es-la-biomedicina-definicion-concepto-y-objetivos/>.
- [24] G. G. Glave, «Ingeniería Biomedica,» [En línea]. Available: <http://www.scielo.org/bo/pdf/rcc/n24/v11n24a07.pdf>.
- [25] H. Moore, Matlab para Ingenieros, Pearson Prentice Hall.
- [26] M. S. d. M. - L. M. Z. Henao, «Region Growing - Scene Segmentation,» 4 March 2015. [En línea]. Available: [https://marcelsheeny.files.wordpress.com/2016/06/region\\_growing-report.pdf](https://marcelsheeny.files.wordpress.com/2016/06/region_growing-report.pdf). [Último acceso: 12 June 2023].
- [27] U. N. d. L. Plata, «LA MATRIZ DE CO-OCURRENCIA EN LA CLASIFICACIÓN MULTIESPECTRAL,» La Plata. Buenos Aires. Argentina , 2014.
- [28] B. C. E. SHANNON, A Mathematical Theory of Communication, 1948.
- [29] D. V. L. Ballarin, «Morfología Matemática en Imágenes Médicas desde la Resonancia Magnética a la Ingeniería de Tejidos,» Investigaciones Científicas y Tecnológicas en Electrónica UNMDP- CONICET.
- [30] W. M. M. Krawczuk, «SEGMENTACIÓN DE IMÁGENES MÉDICAS,» Buenos Aires – Argentina .
- [31] N. Roulet, «Segmentación automática multi-tarea de imágenes médicas utilizando redes neuronales profundas,» Buenos Aires, 2018.
- [32] «¿Qué es una red neuronal?,» [En línea]. Available: <https://la.mathworks.com/discovery/neural-network.html>.

- [33] IBM, «¿Qué son las redes neuronales convolucionales?,» [En línea]. Available: <https://www.ibm.com/es-es/topics/convolutional-neural-networks>.
- [34] F. P. ,. B. T. Ronneberger O., «U-Net: Redes convolucionales para segmentación de imágenes biomédicas,» [En línea].
- [35] J. P. A. ESPAÑA, «RECURSOS DIDACTICOS EN EL APRENDIZAJE SIGNIFICATIVO,» GUAYAQUIL, 2019.
- [36] M. G. V. Murillo, «Recursos educativos didácticos en el proceso enseñanza aprendizaje,» 14 junio 2017. [En línea]. Available: [http://www.scielo.org.bo/scielo.php?script=sci\\_arttext&pid=S1652-67762017000100011](http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S1652-67762017000100011). [Último acceso: 06 junio 2022].
- [37] N. Educa, «Lanzamiento del Sistema Nacional de Evaluación del Aprendizaje,» [En línea]. Available: <https://nicaraguaeduca.com/lanzamiento-del-sistema-nacional-de-evaluacion-del-aprendizaje/>.
- [38] M. d. S. S. R. (. Lilliam Esperanza Herrera Moreno, «Evaluación para el aprendizaje, una práctica para la mejora educativa y desarrollo humano pleno,» [En línea]. Available: <https://revistaindice.cnu.edu.ni/index.php/indice/article/view/172>.

**Preprocesamiento digital de imágenes en formato DICOM.**

Nombre y Apellidos	
Fecha: / /	Grupo N.º:

**Introducción**

De acuerdo a la Unidad I: Fundamentos de las señales, sistemas y Procesado digital de señales, abordando los temas aplicaciones del Procesamiento Digital de señales:

En este primer Recurso de laboratorio, se proporciona una introducción a las aplicaciones de técnicas básicas de preprocesamiento haciendo uso de los Toolbox: Image Processing y Medical Imaging. Las aplicaciones ilustran la mejora del contraste, supresión de ruido mediante filtros, mejora de bordes y visualización de imágenes de manera dinámica.

Las imágenes médicas son la adquisición y el procesamiento de imágenes del cuerpo humano para aplicaciones clínicas. Puede utilizar el procesamiento de imágenes médicas para mejorar la calidad de las imágenes médicas, para el diagnóstico de condiciones médicas, para la planificación quirúrgica o para la investigación. Las imágenes médicas permiten el estudio detallado, aunque no invasivo, de la anatomía humana. El éxito de las imágenes médicas requiere la colaboración entre profesionales médicos, como radiólogos, patólogos o médicos, y profesionales de la tecnología capacitados en el procesamiento de imágenes. Los principales tipos de imágenes médicas que puede procesar para aplicaciones clínicas son imágenes de radiología, como resonancias magnéticas, tomografías computarizadas, radiografías, mamografías, ecografías o tomografías PET/SPECT.

Las imágenes médicas a menudo se deterioran por el ruido debido a diversas fuentes de interferencia y otros fenómenos que afectan los procesos de medición en los sistemas de adquisición de datos de imágenes. La naturaleza del sistema fisiológico bajo

investigación y los procedimientos utilizados en la formación de imágenes también disminuyen el contraste y la visibilidad de los detalles. En todo caso, alguna mejora en la apariencia y calidad visual de las imágenes, aunque sea subjetiva, puede ayudar en su interpretación por un médico especialista [1].

Algunas técnicas comunes de preprocesamiento incluyen la eliminación de fondo, eliminación de ruido, sobre muestreo, registro y normalización de intensidad. Si se usan de manera inapropiada, las propias técnicas de realce pueden aumentar el ruido, eliminar pequeños detalles y la nitidez de los bordes. Se debe de tener cuidado para evitar estos problemas en la búsqueda de la mejor imagen mejorada posible [1].

### Objetivos Específicos

- Aplicar el Preprocesamiento en un enfoque específico como imágenes por resonancia magnética y de mamografías en formato DICOM.
- Desarrollar Scripts para la visualización y manipulación de las imágenes.
- Aplicar técnicas básicas de preprocesamiento para reducir o eliminar el nivel de componentes no deseados.
- Corregir las deficiencias en la adquisición de datos para resultados satisfactorios en etapas posteriores.

### Trabajo Previo.

#### Leer acerca de los siguientes conceptos y el uso de funciones en Matlab

- Histograma de una imagen
  - Transformaciones de Intensidad
  - Filtros Espaciales
  - Filtros Lineales
  - Filtros no Lineales
  - Tipo de dato matriz, que contiene una imagen
-

### Desarrollo de la Práctica

Se define una imagen como una función  $f(x, y)$  bidimensional generalmente de intensidad de luz donde  $x$  e  $y$  representan las coordenadas espaciales de un punto,  $f(x, y)$  es la intensidad o nivel de gris de la imagen en ese punto. Cuando las coordenadas espaciales son un número de elementos finito y la amplitud cubre un rango de valores finito, se dice que es una imagen digital. Una imagen digital en dos dimensiones es por tanto una matriz de tamaño  $m \times n$  con un número finito de elementos llamados píxeles [2].

Hay varios formatos de almacenado y compresión de las imágenes digitales como JPEG, GIF, o TIFF, pero se destacará en esta y futuras prácticas de laboratorio el formato DICOM, específico para el uso de imágenes médicas. Matlab además dispone de librerías específicas para la lectura de imágenes en cualquier formato, incluyendo el DICOM.

El estándar DICOM se desarrolló en 1992 para poder intercambiar imágenes médicas en formato digital. Además, es un protocolo que permite la comunicación entre las entidades que generan las imágenes médicas y las entidades que las procesan. Los rasgos principales que caracterizan a este estándar son una cabecera en la que se incluyen datos relacionados con el paciente y otra parte con información de las imágenes que se han tomado del paciente.

### Imágenes por resonancia magnética (MRI).

El cuerpo humano se compone principalmente de agua y, por lo tanto, contiene muchos núcleos de hidrógeno. Las resonancias magnéticas adquieren una imagen al alterar el equilibrio magnético de los núcleos de hidrógeno en el cuerpo. Luego, el escáner mide el tiempo que tardan los núcleos de hidrógeno en recuperar el equilibrio, que varía según la composición del órgano del que se están tomando imágenes. Las resonancias magnéticas son particularmente útiles para obtener imágenes de tejidos blandos como el cerebro, la médula espinal, los nervios, los músculos, los ligamentos y los tendones, ya que los tejidos blandos tienen más contenido de agua que los huesos [3].

---

## Importar y Visualizar Imágenes.

El siguiente ejemplo muestra cómo importar y visualizar una serie de imágenes médicas, ajustar los valores de intensidad y escribir la imagen procesada en un nuevo archivo. El ejemplo lee imágenes de resonancia magnética de muestra que se incluye con el Toolbox de Image Processing.

1. Copie y pegue el siguiente código en un nuevo script y ejecútelo.

```
close all; % Cierra las ventanas graficas
clear; % Limpia el espacio de trabajo
clc; % Limpia la ventana de comandos ;

%Carga un conjunto específico de imágenes médicas (archivos .mat) del
directorio especificado.
load(fullfile(toolboxdir('images'),'imdata','BrainMRILabeled','images','vol
_001.mat'));
Image_Medical = vol; %Asigna los datos de la imagen cargada a la variable
image_num = 78; %Selecciona la imagen numero 78 del volumen de imagenes
figure(); %Crea una nueva ventana de figura para mostrar la imagen.
imshow(Image_Medical(:,:,image_num), []) %Muestra la imagen seleccionada en
la ventana de la figura.
figure();
sliceViewer(Image_Medical); %Crea un visor de cortes 3D para todo el
volumen de imágenes.
image_adjust = repmat(uint16(0),[240,240,128]); %Inicializa una nueva
variable con el mismo tamaño que, llena de ceros
%inicia un bucle for que itera sobre la tercera dimensión (porciones) de
Image_Medical
for i=1:size(Image_Medical,3)
    image_adjust(:,:,i) = imadjust(Image_Medical(:,:,i));
end
figure();
sV = sliceViewer(image_adjust); %Crea un visor de cortes 3D para el volumen
ajustado de imágenes.
sV.SliceNumber = 1; %Establece el número de corte inicial que se mostrará
en el visor de cortes 3D.

% Vistas Ortogonales de las imagenes
figure();
s = orthosliceViewer(vol);
[hXYAxes, hYZAxes, hXZAxes] = getAxesHandles(s);

% Desactiva Crosshair para una mejor visibilidad
set(s, 'CrosshairEnable', 'off');

% Crea una matriz de SliceNumbers en la dirección requerida
% Se Considera la dirección YZ aquí
sliceNums = 1:240;
idxx = 1;
```

```
% Recorre y crea una imagen en la posición del corte.
for idx = sliceNums
    % Actualiza el número de segmento X para obtener el segmento YZ
    s.SliceNumbers(1) = idx;
    s.SliceNumbers(2) = idx;

    if (idx <= 155)
        s.SliceNumbers(3) = idxx;
        idxx = idxx+1;
    end

    % Se utiliza getframe para capturar imágenes
    I = getframe(hYZAxes);

end
```

2. Anexar resultados obtenidos al ejecutar el script anterior.
3. Modifica el código para que el usuario pueda seleccionar la imagen médica a visualizar.

## Eliminación de ruido

Las modalidades de imágenes médicas son susceptibles al ruido, que introduce fluctuaciones de intensidad aleatorias en una imagen. Para reducir el ruido, puede filtrar imágenes en los dominios espacial y de frecuencia.

El filtrado espacial suaviza imágenes, eliminando el ruido y los detalles no deseados. Esto ayuda a que ciertos algoritmos de procesamiento de imágenes produzcan mejores resultados.

## Filtros Lineales y No Lineales

El filtrado lineal es un tipo de filtrado espacial que reemplaza cada píxel con una suma ponderada de los píxeles que lo rodean. Los filtros lineales observan un vecindario alrededor de un píxel de interés y escalan cada valor.

En el siguiente ejemplo aprenderá a utilizar técnicas de filtrado para suavizar y eliminar el ruido en una imagen de mamografía. Se binarizó la imagen identificando píxeles

---

brillantes como primer plano y píxeles oscuros como fondo. Se usan filtros lineales y no lineales con el objetivo de encontrar el mejor resultado.

Dentro del archivo .rar adjunto a la guía se anexo una imagen llamada breast\_00.dcm, debe crear un directorio de trabajo en el cual deberá de guardar la imagen.

1. Cree un nuevo script, copie el siguiente código, guárdelo en la ruta del directorio donde guardó la imagen descargada y ejecute el script.

```
close all; % Cierra las ventanas graficas
clear; % Limpia el espacio de trabajo
clc; % Limpia la ventana de comandos ;

tumor = dicomread("breast_00.dcm"); % Lee un archivo de imagen DICOM
filterSize = [3 3]; % Aplica un filtro mediano no lineal de 3x3 a la imagen

%% Filtros Lineales
% Crea un filtro que promedia los valores de los píxeles vecinos dentro del
tamaño de filtro
avg = fspecial("average",filterSize);
% Aplica un filtro de media a la imagen simétricamente alrededor de cada
píxel
tumorAvg = imfilter(tumor,avg,"symmetric");
figure()
% Muestra las dos imágenes en dos ejes separados dentro de la misma ventana
de figura
imshowpair(tumor,tumorAvg,"montage")

%% Filtros No-Lineales
% Aplica un filtro mediano 2D a la imagen
tumorMed = medfilt2(tumor,filterSize);
figure()
% Muestra la imagen original y la imagen filtrada una al lado de la otra
imshowpair(tumor,tumorMed,"montage")
% Aplica un filtro Wiener 2D a la imagen
tumorW = wiener2(tumor,filterSize);
figure()
% Muestra la imagen original y la imagen filtrada de Wiener una al lado de
la otra
imshowpair(tumor,tumorW,"montage")

%% Filtro en el dominio de la Frecuencia
% Aplica un filtro gaussiano a la imagen con una desviación estándar de 5
tumor_gaus = imgaussfilt(tumor,5);
figure()
imshowpair(tumor,tumor_gaus,"montage")

%% Iluminar la imagen
% Ajusta el brillo de la imagen con factor de 0.5 para mejorar el contraste
tumor_brigh = imlocalbrighten(tumor,0.5);
figure()
imshowpair(tumor,tumor_brigh,"montage")
```

2. Observe los resultados obtenidos al cargar la imagen
  3. Cambie los parámetros del filtro en la línea **tumor\_gaus = imgaussfilt(tumor,5);** compare la imagen antes de y después y como estos afectan la imagen.
  4. Ahora aplique solamente filtro lineal y después no lineal por separado, observe los resultados y explique
- ¿Cuál es la ventaja de usar filtros lineales y no lineales en la misma imagen?

¿Qué ocurre con la imagen al utilizar los filtros por separado?

### Lectura y visualización de Imágenes desde un Data Set

El siguiente script lee un conjunto de imágenes dicom, luego las muestra una tras otra y las convierte en escala de grises.

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

% Obtiene una lista de todos los archivos DICOM en el directorio actual.
names = dir('*.*.dcm');
% Inicializa una matriz 3D con el mismo número de páginas que archivos
DICOM.
% Cada página es una matriz de 256x256 de enteros de 16 bits
Images = repmat(int16(0), [256 256 size(names,1)]);
% Inicializa una matriz 3D con el mismo tamaño 256x256
Images_gray = repmat(int16(0), [256 256 size(names,1)]);
% Este bucle itera sobre cada archivo DICOM.
for i = 1:size(names,1)
    % Lee el i-ésimo archivo DICOM y lo almacena en la i-ésima página de la
matriz
    Images(:,:,i) = dicomread(names(i).name);
    figure(1)
    % Muestra la i-ésima página de la matriz en la ventana de la figura
    imshow(Images(:,:,i))
    pause(.2) % Pausa por 0.2segundos
end

% Elimina cualquier dimensión de la matriz, convirtiéndola en una matriz 2D
Images = squeeze(Images);
for j = 1:size(names,1)
    % Aplica un umbral global a la i-ésima página de la matriz
    % Determina automáticamente el valor del umbral
    Images_gray(:,:,j) =
    imbinarize(Images(:,:,j),graythresh(Images(:,:,j)));
    figure(2)
    imshow(Images_gray(:,:,j),[])
    pause(.2)
end
```

## Asignación

Ahora nos dirigimos a la base de datos de imágenes adjuntas en la carpeta, con las que trabajaremos a continuación:

Una vez tenemos el Dataset en un archivo rar vamos a extraer la carpeta y copiar en la siguiente ruta:

C:\Users\USUARIO\Documents\MATLAB

Realizar un script que permita:

1. Leer todas las de imágenes contenidas en el Dataset antes descargados, usando el método ya mostrado y creando un Datastore (Investigue como crear un Datastore en Matlab).
2. Usando un ciclo for muestre las imágenes una por una con una pausa de 0.5 segundos.
3. Cree un script para leer una sola imagen del Dataset y usando la función `imadjust(I)`, ajuste los valores, muestre el resultado.

`J = imadjust(I, [0.1 0.9], [0.2 0.8]);`

## Bibliografía.

- [1] I. H. Bankman, Handbook of Medical Image Processing and Analysis, San Diego: Elsevier, 2008.
  - [2] H. S. Gong, Advance Image and Video Processing Using Matlab, China: Springer, 2019.
  - [3] E. S. Gopi, Digital Signal Processing for Medical Imaging, Tamil Nadu India: Springer.
-



### Técnicas de segmentación de imágenes basadas en Regiones.

Nombre y Apellidos		
Fecha:        /        /	Grupo N.º:	

### Introducción

De acuerdo a la Unidad II: Discretización de señales en Tiempo Continuo en donde se complementa con la Unidad III: Fundamentos de Filtros Digitales y se abordan los temas: Estructura básicas de Filtros, Aplicaciones y filtrado de imágenes.

El análisis de imágenes consiste en el proceso de extraer información significativa de las imágenes, como buscar formas, contar objetos, identificar colores o medir propiedades de objetos. El Toolbox Image Processing provee un conjunto completo de algoritmos estándar de referencia y funciones de visualización para tareas de análisis de imágenes, como el análisis estadístico y la medición de propiedades.

En general puede decirse que un buen algoritmo de segmentación será aquel que resalte de forma adecuada las regiones conectadas que sean de interés en la imagen, de tal forma que esas regiones puedan ser utilizadas posteriormente en los procesos de análisis reconocimiento de patrones y toma de decisiones.

La segmentación de imágenes es bastante compleja y debe de tener como punto de partida el seleccionar el mejor método de segmentación que pueda satisfacer los requerimientos planteados. En la siguiente guía se presentan algunas técnicas de segmentación aplicadas en imágenes DICOM que nos permita resaltar áreas de interés en las imágenes médicas, así como aportar y extraer información de gran utilidad en este campo.

### Objetivos Específicos

---

- Analizar información científico-técnica sobre los métodos de detección y extracción de características empleando técnicas de procesamiento digital de imágenes.
- Estudiar y comparar las funciones incluidas en el Toolbox para segmentación de imágenes basadas en regiones
- Aplicar distintas técnicas de segmentación basadas en aplicaciones reales
- Comparar y discutir los resultados obtenidos en las diferentes técnicas para comprender sus ventajas y limitaciones en diferentes situaciones.

### Desarrollo de la Práctica

La segmentación se define como el proceso de separar la imagen en diferentes regiones, de tal forma que los píxeles en cada región sean similares (de acuerdo con un determinado criterio), mientras que son diferentes entre las regiones. La idea es distinguir las áreas u objetos de interés con respecto a otros [1].

En la guía de laboratorio 1 se aplicó preprocesamiento a una imagen de mamografía para crear una segmentación de un tumor. Una forma de segmentar una imagen en escala de grises es binarizar la imagen, usando la función de Matlab `imbinarize` la salida es una imagen binaria donde los píxeles de primer plano tienen valor 1 y los píxeles de fondo tienen valor 0.

**Cargue el script 2 de la guía No. 1 (“Preprocesamiento digital de imágenes DICOM”).**

En esta imagen, hay dos tipos de ruido que pueden alterar una segmentación: demasiado detalle y variación aleatoria en la intensidad de los píxeles. El filtrado espacial puede igualar ambos tipos de variaciones no deseadas.

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

% Carga una variable preexistente del archivo
load tumorReducedSize.mat
% Se binariza la imagen
tumorBW = imbinarize(tumor);
% Se aplica un filtro promedio lineal para crear un filtro promedio de
5x5
filterSize = [5 5];
```

---

```
%% Filtro lineal
% Crea un filtro que promedia los valores de los píxeles vecinos dentro del
tamaño de filtro
avg = fspecial("average",filterSize);
% Aplica un filtro de media a la imagen simétricamente alrededor de cada
píxel
tumorAvg = imfilter(tumor,avg,"symmetric");
% Convierte la imagen en escala de grises en una imagen binaria
tumorAvgBW = imbinarize(tumorAvg);

%% Filtro no lineal
% Aplica un filtro de mediana 2D a la imagen
tumorMed = medfilt2(tumor,filterSize);
% Binariza la imagen
tumorMedBW = imbinarize(tumorMed);
% Aplica el filtro Wiener
% Minimiza el error cuadrático medio entre la imagen original y filtrada
tumorW = wiener2(tumor,filterSize);
% Binariza la imagen
tumorWBW = imbinarize(tumorW);
% Crea un montaje de todas las imágenes procesadas.
% Organiza las imágenes en una cuadrícula y las muestra en una ventana de
una sola figura
montage({tumor tumorBW; tumorAvg tumorAvgBW;...
tumorMed tumorMedBW; tumorW tumorWBW})
```

1. Varie el tamaño de filtro, en la línea de código `filterSize = [5 5]`; esto cambiará la apariencia de la imagen filtrada y la calidad de la segmentación.

¿Qué efecto ocurre al aplicar un filtro grande?

2. Las opciones para las técnicas de límite son "simétrica", "replicar", "circular" o puede especificar un escalar constante. Cambie la técnica y eplique:

¿Qué fenómeno ocurre con la imagen?

3. Modifica el código anterior para que el usuario pueda seleccionar el tipo de filtro a aplicar a la imagen (promedio, mediana, Wiener). Anexe el código desarrollado:
-

## Segmentación por crecimiento de regiones

Técnica de procesamiento de imágenes que divide una imagen en varias regiones o segmentos, la idea principal es agrupar píxeles que tienen características similares y asignarles una etiqueta común para formar una región. Las imágenes médicas tales como; Resonancia magnética (MRI), tomografía, y ultrasonidos pueden ser muy complejas y contener diferentes estructuras anatómicas superpuestas. La segmentación basada en regiones puede ayudar a separar estas estructuras y detectar patologías en la imagen.

Además, esta técnica de segmentación puede ser utilizada para realizar mediciones cuantitativas de diferentes estructuras anatómicas, como el volumen del cerebro o el tamaño de un tumor, esto ayuda a los médicos en la planificación del tratamiento y seguimiento de la progresión de la enfermedad.

1. Ingrese a la carpeta que contiene la guía, cargar Datasets de imágenes Dicom para el siguiente script.
2. Una vez tenemos la carpeta, copiar en la siguiente ruta:
3. Dentro de la carpeta se encuentra un archivo llamado “regionGrowing.m”, esa es la función que utilizaremos en el siguiente script.

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%

% Obtiene una lista de todos los archivos en el directorio actual
names = dir('*.dcm');
% Crea una matriz con dimensiones de 512x512x264, donde cada elemento
% se inicializa a 0
images_dcm = repmat(uint16(0), [512,512,264]);
% Inicia un bucle que itera sobre los elementos de la matriz
for i=1:size(names,1)
    images_dcm(:,:,i) = dicomread(names(i).name); % Lee un único
% archivo de imagen DICOM
    figure(1)
    imshow(images_dcm(:,:,i), [])
end
```

---

%%

```
% Extrae un único corte de imagen 2D de la matriz 3D . En este caso,
selecciona el segmento número 100
img = images_dcm(:, :, 100);
figure() % Nueva ventana de figura
imshow(img, [])
hold all % Mantiene la imagen
% Segmenta sobre el punto inicial que presiona el usuario
% Devuelve la region segmentada
[p,j] = regionGrowing(img, []); % CLIC en algun espacio sobre la imagen
plot(p(:,1), p(:,2), 'LineWidth', 2)
% Traza la región segmentada en la figura actual.
```

%%

```
% Crea una nueva matriz 2D llamada por multiplicación por elementos de
% la imagen segmentada y la imagen original
lungs_segment = uint16(j).*img;
figure()
imshowpair(img, lungs_segment, "montage")
% Muestra la imagen original y la imagen de los pulmones segmentados
```

5. Intenta seleccionar múltiples regiones haciendo clic en diferentes áreas de la imagen. ¿Como se comporta el algoritmo cuando se seleccionan otras áreas?
6. Con la base de datos obtenidas de la practica 1, adapte el algoritmo de Region Growing y anexe el script aquí abajo y si encontró errores cuales fueron las soluciones.

## Segmentación basada en Umbralización

### Método Otsu

Es una técnica utilizada para separar una imagen en regiones o áreas de interés mediante la aplicación de un umbral o valor limite, esta técnica se basa en la idea de que el histograma de una imagen se puede dividir en 2 partes:

- Una parte correspondiente a los pixeles de fondo que tienen un valor de umbral menor.
  - Otra parte correspondiente a los pixeles de primer plano que tienen un valor mayor o igual al umbral denominados objetos o áreas de interés.
-

## Aplicaciones

- **Detección de tumores**
- **Segmentación de órganos:** resaltar órganos de interés para una mejor evaluación.
- **Análisis de la estructura cerebral:** estructuras cerebrales de interés para una mejor evaluación y diagnóstico de enfermedades neurológicas.

El siguiente script es un ejemplo de aplicación del método Otsu:

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%

imagen_dicom = dicomread('image.dcm'); % Lee un archivo de imagen DICOM
imagen_gris = mat2gray(imagen_dicom);% Convertir la imagen a escala de
grises normalizada
umbral_otsu = graythresh(imagen_gris);% Aplicar el método de Otsu para
obtener el valor óptimo de umbral
tejido_cerebral_segmentado = imagen_gris > umbral_otsu;% Segmentar el
tejido cerebral por el valor de umbral óptimo de Otsu
imagen_negativa = 1 - imagen_gris;% Segmentar los vasos sanguíneos
utilizando el negativo de la imagen
umbral_otsu_vasos = graythresh(imagen_negativa); % Aplica el método de
umbral de Otsu a la imagen negativa
vasos_sanguineos_segmentados = imagen_negativa > umbral_otsu_vasos;%
segmenta los vasos sanguíneos poniendo un umbral en la imagen negativa
según el valor umbral óptimo
figure; % crea una nueva ventana de figura
subplot(2, 2, 1); % Divide la ventana de la figura en una cuadrícula de 2x2
imshow(imagen_gris, []); % Muestra la imagen en escala de grises en la
trama secundaria
title('Imagen DICOM en escala de grises');
subplot(2, 2, 2);
imshow(tejido_cerebral_segmentado);
title('Tejido cerebral segmentado');
subplot(2, 2, 3);
imshow(imagen_negativa, []);
title('Negativo de la imagen');
subplot(2, 2, 4);
imshow(vasos_sanguineos_segmentados);
title('Vasos sanguíneos segmentados');
```

---

### Asignación

1. Acceda al Dataset proporcionado en un archivo .rar con este documento.
2. Cargar y visualizar las imágenes, aplique el método Otsu para obtener la segmentación.
3. Modifique el script anterior y ajuste valores de umbral entre 0 y 255 y observe los resultados, explique los efectos obtenidos.
4. Agrega una opción para que el usuario pueda ajustar los parámetros del método de segmentación.

### Bibliografía.

- [1] E. Cuevas, . M. Diaz y J. O. Camarena Méndez, Tratamiento de Imgenes con MATLAB, México: Alfaomega, 2017.
-

### Técnicas de segmentación de imágenes basadas en Regiones.

**Asignatura:** Procesamiento Digital de Bioseñales

**Técnico Superior en Tecnología Biomédica**

**Objetivo de aprendizaje:** Comprender las principales técnicas de segmentación mediante su aplicación, analizando el fenómeno bajo estudio (Imágenes).

**Actividad a observar:** Analizar la capacidad para la identificación de patrones, características y anomalías en las imágenes analizadas, y su relevancia en el estudio del fenómeno.

**Puntaje de la lista de cotejo:** 20 pts

Escala: A=Avanzado, S=Suficiente y ED= En desarrollo

Nombres y apellidos	Criterios de Evaluación: Evaluar la precisión y fiabilidad de los resultados obtenidos mediante las técnicas de análisis de imágenes, y su coherencia con el fenómeno estudiado.												Nota
	Realizo el trabajo previo asignado antes de realizar la practica			Es capaz de identificar los tipos de ruido en el algoritmo			Es capaz de aplicar las técnicas de extracción de características en las regiones segmentadas			Es capaz de comprender los algoritmos y realizar las asignaciones planteadas			
	A	S	ED	A	S	ED	A	S	ED	A	S	ED	
	3pts	2 pts	1 pts	3pts	2 pts	1 pts	3pts	2 pts	1 pts	3pts	2 pts	1 pts	
<b>Marlon</b>	X				X				X		X		8 pts
<b>Carlos</b>		X		X			X			X			13 pts
<b>Luis</b>													
<b>Marina</b>													

### Técnicas de segmentación de imágenes basadas en Regiones (Clustering).

Nombre y Apellidos			
Fecha:	/	/	Grupo N.º:

### Introducción

De acuerdo a la Unidad IV: Procesamiento Digital de Bioseñales, se abordan el tema casos de estudio en el cual se plantea el uso de técnicas de Segmentación, extracción de características, por lo cual se abordan técnicas basadas en Regiones.

La segmentación de imágenes es crucial para extraer y analizar regiones de interés en imágenes médicas, lo que puede ayudar en el diagnóstico y la planificación del tratamiento. El proceso de segmentación implica dividir la imagen en regiones o segmentos más pequeños, que luego se pueden analizar por separado. Este proceso puede resultar desafiante debido a la complejidad de las imágenes médicas y la necesidad de exactitud y precisión.

La segmentación de imágenes puede ser bastante compleja y debe comenzar con la selección del método de segmentación más adecuado para cumplir con los requisitos especificados. Esta guía presenta algunas técnicas de segmentación utilizadas en imágenes DICOM, que pueden usarse para resaltar áreas de interés en imágenes médicas y proporcionar información valiosa en el campo.

### Objetivos Específicos

- Analizar información científica y técnica sobre métodos de detección y extracción de características mediante técnicas de procesamiento de imágenes digitales.
  - Estudiar y comparar las funciones incluidas en el Toolbox para segmentación de imágenes basadas en regiones
-

### Segmentación basada en el agrupamiento.

La segmentación basada en el agrupamiento o clustering, clasifica y agrupa los datos en función de unas características determinadas. Se hacen llamar técnicas no supervisadas, es decir, no son necesarios conocimientos previos de la imagen a tratar. Solo se requieren las características previas sobre las que se basarán la segmentación. Existen una gran variedad de algoritmos de este tipo, pero el en que nosotros nos centraremos, es el llamado K-means.

K-means divide los datos en grupos, donde k es un parámetro definido por el usuario.

El algoritmo selecciona los puntos iniciales "K" llamados centroides que representa los centros de los clústeres, después asigna a cada punto de datos al clúster cuyo centroide está más cerca (usando como medida la distancia euclidiana), luego recalcula los centroides de cada clúster como el promedio de los puntos de datos asignados a ese clúster. Esto se repite hasta que los centroides converjan o se alcance un número máximo de iteraciones.

El siguiente script es un ejemplo utilizando el algoritmo K-means:

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%

dicom_image = dicomread('image.dcm');
imagen = double(dicom_image); % Convertir la imagen a formato de punto
flotante y normalizar los valores entre 0 y 1
imagen = (imagen - min(imagen(:))) / (max(imagen(:)) - min(imagen(:)));
imshow(imagen);
title('Imagen DICOM original');
vector_caracteristicas = imagen(:); % Convertir la imagen a un vector de
características para el clustering (un solo canal)
num_clusters = 2; % Definir el número de clústeres (regiones) deseados
idx = kmeans(vector_caracteristicas, num_clusters); % Aplicar el
algoritmo k-means para segmentar la imagen en clústeres
mascara_segmentada = reshape(idx, size(imagen)); % Crear una máscara con
las regiones segmentadas
figure;
imshow(mascara_segmentada, []);
title('Imagen DICOM segmentada por agrupamiento');
```

---

```
% Visualizar cada región segmentada por separado (opcional)
for i = 1:num_clusters
    figura = figure;
    % Crea una región de interés mediante la multiplicación de
    elementos de la imagen original con una máscara binaria obtenida
    %comparándola con el índice de grupo actual
    region = imagen .* (mascara_segmentada == i);
    imshow(region, []);
    title(['Región segmentada ' num2str(i)]);
end
```

## Asignación

1. Modifique el script anterior, subir una imagen diferente y aplicar diferentes valores de k (2, 4, 6, 8, etc.), compare los resultados obtenidos para cada valor de k.
2. Indague sobre clustering jerárquico y clustering espectral, compare y contraste el rendimiento del algoritmo y presente sus conclusiones.
3. Cree un nuevo script y cargue la siguiente función llamada (fcmthresh)

```
function [bw,level]=fcmthresh(IM,sw)
% IM una imagen en escala de grises.
% sw un interruptor binario que determina si se segmenta la imagen en
dos o tres regiones
if ( nargin<1)
    error('You must provide an image. ');
elseif ( nargin==1)
    sw=0;
elseif ( sw~=0 && sw~=1)
    error('sw must be 0 or 1. ');
end
% La imagen se transforma en un vector para agruparla utilizando el
algoritmo difuso c-means
data=reshape(IM, [],1);
% La función se llama con 3 clústeres para obtener los centros de los
clústeres
% fcm, center, member
[center,member]=fcm(data,3);
[center,cidx]=sort(center);
member=member';
member=member(:,cidx);
[maxmember,label]=max(member,[],2);
% Dependiendo del valor de , el nivel de umbral se calcula como el
promedio de los valores
% Píxeles máximo y mínimo del primer o segundo y tercer grupo.
if sw==0
    level=(max(data(label==1))+min(data(label==2)))/2;
else
    level=(max(data(label==2))+min(data(label==3)))/2;
end
% La imagen se binariza utilizando la función con el nivel de umbral .
bw=im2bw(IM,level);
```

---

4. El script a continuación se trata de agrupamiento C-means, indague y compare los valores obtenidos entre K-means y C-means. Y mencione cuales son las ventajas y desventajas que observe al comparar los 2 códigos.

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%

workspace; % Muestre el espacio de trabajo
format long g; % Configure el formato para mostrar números
format compact;
fontSize = 16; % Establezca el tamaño de fuente y el tamaño del
marcador
markerSize = 40; % Establezca el tamaño del marcador
im=dicomread('image.dcm'); % Lee la imagen DICOM
fim=mat2gray(im); % Conviérte la imagen a escala de grises
level=graythresh(fim);
% Calcula el nivel de umbral usando el umbral de Otsu
bwfim=im2bw(fim,level);
% Calcula el nivel de umbral utilizando un umbral de medias c difusa
con dos grupos ( ) y tres grupos ( )
[bwfim0,level0]=fcmthresh(fim,0);
[bwfim1,level1]=fcmthresh(fim,1);
%Ventana al máximo.
g = gcf;
g.WindowState = 'maximized';
drawnow;
subplot(2,2,1);
imshow(fim);title('Original');
subplot(2,2,2);
imshow(bwfim);title(sprintf('Otsu,level=%f',level));
subplot(2,2,3);
imshow(bwfim0);title(sprintf('FCM0,level=%f',level0));
subplot(2,2,4);
imshow(bwfim1);title(sprintf('FCM1,level=%f',level1));
```

## Bibliografía.

- [1] E. Cuevas, . M. Diaz y J. O. Camarena Méndez, Tratamiento de Imgenes con MATLAB, México: Alfaomega, 2017.
-



### Segmentación de imágenes y Procesamiento Morfológico

Nombre y Apellidos		
Fecha:        /        /	Grupo N.º:	

#### Introducción

De acuerdo a la Unidad IV: Procesamiento Digital de Bioseñales, se abordan el tema casos de estudio en el cual se plantea el uso de técnicas de Segmentación, extracción de características, por lo cual se abordan técnicas basadas en Regiones de interés (ROI) y Procesamiento Morfológico.

Existen diversas técnicas de segmentación disponibles y la selección del método apropiado depende de la aplicación y los requisitos específicos. Se presentan otras técnicas de segmentación utilizadas en imágenes DICOM, que pueden usarse para resaltar áreas de interés en imágenes médicas.

El procesamiento morfológico es una técnica fundamental en el análisis de imágenes que se centra en la forma y estructura de los objetos en una imagen. Consiste en operaciones como dilatación, erosión, apertura y cierre, que permiten modificar la forma de los objetos en una imagen para resaltar características específicas. Estas operaciones son útiles en diversas aplicaciones, como la eliminación de ruido, la segmentación de objetos y la extracción de características.

En general, el siguiente recurso de Laboratorio proporciona una descripción general completa de diversas técnicas de segmentación y sus aplicaciones en el análisis de imágenes médicas. Al seleccionar el método de segmentación adecuado, los profesionales médicos pueden extraer y analizar regiones de interés en imágenes médicas con mayor exactitud y precisión.

---

### Objetivos Específicos

- Analizar información científica y técnica sobre métodos de detección y extracción de características mediante técnicas de procesamiento de imágenes digitales.
- Estudiar y comparar las funciones incluidas en el Toolbox para segmentación de imágenes basadas en regiones

### Procesamiento basado en Regiones de Interés (ROI)

Una región de interés (ROI) es una parte de una imagen que se desea filtrar o procesar de alguna manera. Una ROI se puede representar como máscara binaria. En la máscara, los píxeles que pertenecen a la ROI tienen el valor 1, y los que se sitúan fuera tienen el valor 0. La Toolbox ofrece varias opciones para especificar una ROI y crear máscaras binarias.

La Toolbox es compatible con distintos objetos que pueden usarse para crear ROI de distintas formas, como círculos, elipses, polígonos, rectángulos y formas trazadas a mano alzada. Después de crear los objetos, puede cambiar su forma, posición, apariencia y comportamiento.

La herramienta ROI también es una forma de comprimir, de modo que el área de la imagen perteneciente a la región de interés puede comprimirse utilizando un algoritmo sin pérdida de calidad con el fin de recuperar los datos originales sin alteración. Asimismo, el área externa se comprime a través de un algoritmo con pérdida o irreversible, que igualmente puede alcanzar resultados con disminución de calidad visualmente indistinguible.

El protocolo DICOM introduce la herramienta ROI por las capacidades del estándar de imagen JPEG-2000, permitiendo comprimir sin pérdida la zona de mayor importancia diagnóstica dentro de la imagen y con una pérdida moderada la región restante.

---

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%
% Carga la imagen MRI desde el archivo
load mrystack.mat
figure() % Crea una nueva figura.
imshow(mrystack(:,:,10)) %Muestra la décima slice de la imagen MRI en
la figura.

%%
%Realiza una segmentación de la slice de la imagen MRI utilizando
% el algoritmo imsegkmeans con 3 etiquetas.
segmentedLabels = imsegkmeans(mrystack(:,:,10),3);
% Crea una máscara a partir de la segmentación, seleccionando las
etiquetas correspondientes
boneMask = segmentedLabels==2;
% Crea una máscara de tejido blando a partir de la segmentación
boneMask1 = segmentedLabels==1;
% Crea una máscara adicional a partir de la segmentación
boneMask2 = segmentedLabels==2;
% Crea una máscara de otro tejido a partir de la segmentación
boneMask3 = segmentedLabels==3;
figure()
% Muestra la imagen MRI y la máscara
imshowpair(mrystack(:,:,10), boneMask, "montage");
figure()
% Muestra todas las máscaras
montage({boneMask1,boneMask2,boneMask3})

%%
% Aplica un filtro de apertura a la máscara para eliminar pequeños
objetos no deseados.
boneMask = bwareafilt(boneMask, 2);
figure()
%Muestra la imagen MRI y la máscara filtrada
imshowpair(mrystack(:,:,10), boneMask, "montage")

%%
% Encuentra los contornos de la máscara
blocations = bwboundaries(boneMask, 'noholes');
% Muestra la imagen MRI sin mostrar los píxeles.
imshow(mrystack(:,:,10), []);
% Iterar sobre cada contorno de la máscara
for ind = 1:numel(blocations)
    % Obtiene la posición del contorno.
    pos = blocations{ind};
    % Invierte la posición horizontalmente para ajustarse a la
herramienta "drawfreehand".
    pos = fliplr(pos);
    % Crea una región de interés (ROI) manualmente ajustando el
contorno.
    drawfreehand('Position', pos);
end
```

```
%%  
  
% Encuentra los objetos de tipo "images.roi.Freehand" en la figura  
actual.  
hfhs = findobj(gca, 'Type', 'images.roi.Freehand');  
% Inicializa una máscara vacía con el mismo tamaño que la slice de la  
imagen MRI.  
editedMask = false(size(mristack(:,:,10)));  
% Iterar sobre cada objeto "images.roi.Freehand"  
for ind = 1:numel(hfhs)  
    % cumula la máscara de la ROI en la máscara editada.  
    editedMask = editedMask | hfhs(ind).createMask();  
    % Obtiene la posición de la ROI.  
    boundaryLocation = hfhs(ind).Position;  
    % Convierte la posición de la ROI a índices lineales  
    bInds = sub2ind(size(mristack(:,:,10)), boundaryLocation(:,2),  
boundaryLocation(:,1));  
    % Incluye los píxeles de la ROI en la máscara editada.  
    editedMask(bInds) = true;  
end  
figure() % Crea una nueva figura  
imshow(editedMask, []) % Muestra la máscara editada en la figura.
```

### Asignación:

1. Ejecute el script anterior y observe los resultados obtenidos.
  2. Edite el script anterior y cargue un conjunto de imágenes (Utilice uno de los Datasets proporcionados).
  3. Identifique y marque Regiones de interés de las imágenes proporcionadas que contengan características relevantes.
  4. Realice mediciones cuantitativas que permita medir el área de la Región mostrada.
-

En el siguiente ejemplo aprenderá a utilizar una nueva técnica de segmentación y combinación de técnicas utilizadas anteriormente que hace uso de procesamiento morfológico para extraer la masa cerebral de una serie de imágenes por resonancia magnéticas

Haciendo uso de un navegador web, acceda al siguiente enlace y descargue un Dataset de MRI

<https://github.com/LABDIP/Lab2>

Primero debe crear un directorio de trabajo en el cual deberá de guardar el Dataset descargado.

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%
% Obtiene una lista de los nombres de archivo de todas las imágenes
DICOM
names = dir("*.dcm");
% Lee el primer archivo DICOM
info = dicominfo(names(1).name);
% Lee la informacion de ese archivo
% Crea una matriz de ceros con el mismo tamaño que las imágenes DICOM
images_dcm = repmat(uint16(0), [info.Rows,
info.Columns, size(names,1)]);
brain_dcm = repmat(uint16(0), [info.Rows,
info.Columns, size(names,1)]);
% Inicia un ciclo for para iterar sobre cada archivo DICOM en la
lista.
for i=1:size(names,1)
images_dcm(:,:,i) = uint16(dicomread(names(i).name));
figure(1) %Crea una nueva figura.
imshow(images_dcm(:,:,i),[]) % Muestra la imagen actual en la figura.
pause(.3) % Espera 3 segundos antes de pasar a la siguiente imagen
end
%%
% Calcula el nivel máximo de intensidad en las imágenes DICOM.
max_level = double(max(images_dcm(:)));
% Crea una copia de la matriz "images_dcm"
images_dcm1 = images_dcm;
% Ignora los píxeles con niveles de intensidad menores o iguales a 40
images_dcm(images_dcm<=40) = 0; %ignore low levels (CSF & air)
% Ignora los píxeles con niveles de intensidad mayores o iguales a
100.
images_dcm(images_dcm>=100) = 0;
% Crea un bloque de unos con el tamaño especificado.
blk = ones([3 7 7]);
```

---

```
%Aplica una operación de erosión a las imágenes DICOM utilizando el
bloque de unos.
images_dcm = imerode(images_dcm,blk);
% Calcula un umbral de intensidad utilizando el método de Otsu.
lev = graythresh(double(images_dcm)/max_level) * max_level;
% Crea una máscara binaria de las imágenes DICOM utilizando el umbral
calculado.
bw = (images_dcm>=lev);
% Etiqueta las regiones binarias en la máscara.
L = uint16(bwlabeln(bw));

%%
% Calcula propiedades estadísticas de las regiones etiquetadas en la
máscara.
stats = regionprops(L,'Area');
% Crea un vector con las áreas de todas las regiones etiquetadas.
A = [stats.Area];
% Encuentra el índice de la región etiquetada con el área máxima.
biggest = find(A==max(A));
% Eliminar los restos más pequeños de la region etiquetada
images_dcm(L~=biggest) = 0;
% Aplica una operación de dilatación a las imágenes DICOM utilizando
el bloque de unos.
images_dcm = imdilate(images_dcm,blk);
figure(2)
imshow(images_dcm(:,:,30),[])
% Cierra los huecos en la región del cerebro utilizando un disco de
estructurante de tamaño 18.
images_dcm=imclose(images_dcm,strel('disk',18));
% Inicia un ciclo for para iterar sobre las primeras 60 slices de las
imágenes DICOM.
for slice= 1:60
% Extraer el cerebro de la imagen original.
brain_dcm(:,:,slice)=images_dcm(:,:,slice).*(images_dcm1(:,:,slice));
figure(3)
imshowpair(brain_dcm(:,:,slice),images_dcm1(:,:,slice),"montage")
pause(.2)
end
```

## Bibliografía.

- [1] E. Cuevas, . M. Diaz y J. O. Camarena Méndez, Tratamiento de Imgenes con MATLAB, México: Alfaomega, 2017.
-

### Segmentación de imágenes y Procesamiento Morfológico

**Asignatura:** Procesamiento Digital de Bioseñales

**Técnico Superior en Tecnología Biomédica**

**Objetivo de aprendizaje:** Desarrollar habilidades para implementar algoritmos de segmentación y procesamiento morfológico.

**Actividad a observar:** Capacidad de análisis e interpretación de los resultados obtenidos de la segmentación de imágenes, identificando áreas de interés y el procesamiento morfológico, demostrando habilidades de pensamiento crítico.

**Puntaje de la lista de cotejo:** 20 pts

Escala: A=Avanzado, S=Suficiente y ED= En desarrollo

Nombres y apellidos	Criterios de Evaluación: Comprender los conceptos fundamentales de la segmentación de imágenes, incluyendo los diferentes métodos y técnicas utilizados.												
	Realizo el trabajo previo asignado antes de realizar la practica			Aplica con precisión técnicas de segmentación y procesamiento morfológico			Realiza un análisis exhaustivo y crítico de los resultados obtenidos			Comprende y aplica correctamente los algoritmos en otros casos clínicos			Nota
	A	S	ED	A	S	ED	A	S	ED	A	S	ED	
3pts	2 pts	1 pts	3pts	2 pts	1 pts	3pts	2 pts	1 pts	3pts	2 pts	1 pts		
Marlon	X				X				X		X		8 pts
Carlos		X		X			X			X			13 pts
Luis													
Marina													

### Técnicas de segmentación basada en bordes y textura.

Nombre y Apellidos		
Fecha:        /        /	Grupo N.º:	

### Introducción

De acuerdo a la Unidad IV: Procesamiento Digital de Bioseñales, se abordan el tema casos de estudio en el cual se plantea el uso de técnicas de Segmentación, extracción de características, por lo cual se abordan técnicas basadas en la detección de bordes, así como el análisis de textura.

La segmentación de imágenes es un proceso fundamental en el procesamiento de imágenes, esto nos permite identificar, resaltar y delimitar regiones de interés. El proceso de segmentación basada en texturas es una técnica ampliamente utilizada que se basa en la extracción de características de textura en las imágenes para identificar regiones similares [1].

En procesamiento de imágenes digitales, un borde se define como un lugar donde hay un fuerte cambio de intensidad. En diferentes tareas de procesamiento de imágenes y visión por computadora, las técnicas de detección de bordes a menudo se requieren para la segmentación de imágenes, el reconocimiento de patrones, la preservación de propiedades estructurales importantes, etc. Estas tareas son aplicables a campos como la teledetección y la medicina.

El proceso de detección de bordes simplifica el análisis de imágenes al reducir drásticamente la cantidad de datos a procesar, al tiempo que permite conservar información estructural útil sobre los límites de los objetos. Por supuesto, existe una gran diversidad en las aplicaciones de detección de bordes, pero se considera que muchas de estas aplicaciones comparten un conjunto común de requisitos, incluido tener una tasa de error baja durante la detección [2].

---

En esta práctica de laboratorio aprenderemos como realizar segmentación basada en bordes y texturas haciendo uso de herramientas de procesamiento de imágenes de Matlab, para cargar, preprocesar, aplicar filtros de textura con el objetivo de identificar y delimitar regiones de interés en las imágenes.

### Objetivos Específicos

- Analizar información científico-técnica sobre los métodos de detección y extracción de características empleando técnicas de procesamiento basadas en bordes y texturas.
- Aplicar filtros de textura para resaltar características en imágenes Dicom
- Evaluar la efectividad de la segmentación basada en borde y texturas en la identificación de regiones de interés.

### Desarrollo de la Práctica

#### Detección de bordes

En una imagen, un borde es una curva que sigue una trayectoria de cambio rápido en intensidad de imagen [3]. A menudo, los bordes se asocian con los límites de los objetos de una escena. La detección de bordes se usa para identificar los bordes de una imagen. Su aplicación en muchos campos de la medicina tales como:

- Radiología
- Oftalmología
- Patología

Para hallar los bordes, puede utilizar la función `edge`. Esta función busca lugares de la imagen en los que la intensidad cambia rápidamente usando uno de estos dos criterios:

- Lugares en los que la primera derivada de la intensidad tiene una magnitud mayor que el umbral
-

- Lugares en los que la segunda derivada de la intensidad tiene un cruce por cero

### Método Sobel

BW1 = edge(I,'Sobel'); especifica el umbral de sensibilidad del método Sobel.

BW1 = edge (I,'Sobel', 'direction'); especifica la dirección de detección del método Sobel en la variable **direction** especifica si deben buscar en bordes horizontales **horizontal**, verticales **vertical** o ambos **both**.

### Método Prewitt

BW1 = edge(I,'Prewitt'); especifica el método a utilizarse

BW1 = edge (I,'Prewitt', 'direction'); especifica la dirección de detección del método prewitt en la variable **direction** se indica si debe buscar por bordes horizontales **horizontal**, verticales **vertical** o ambos **both**.

### Método Roberts

BW1 = edge (I,'Roberts'); especifica que se usara el método de Roberts

BW1 = edge (I,'Roberts', **thresh**); especifica el umbral de sensibilidad del método Roberts en la variable **e** ignora todos los bordes que no son más fuertes que **thresh**. Si no se especifica la variable **thresh**, Edge elige su valor automáticamente.

### Método Laplaciano del Gaussiano

BW1 = edge (I,'log', 'both'); especifica el método a utilizarse

BW1 = edge (I,'log', **sigma**); la variable **sigma** como la desviación estándar del filtro, el valor por defecto de **sigma** es 2.

### Método de Cruce por cero

BW1 = edge(I,'zerocross'); especifica el método a utilizarse.

### Método de Canny

BW1 = edge(I,'canny'); especifica el método a utilizarse

BW1 = edge (I,'canny' **thresh**); especifica el umbral de sensibilidad, en la variable **thresh** si se especifica un escalar este valor se usará para el umbral más alto y 0.4

\* **thresh** para el umbral bajo

---

### Ejemplo.

1. Encontrar los bordes de una imagen medica utilizando el método Sobel.

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%
I = dicomread('imagen.dcm'); % Leer imagen DICOM
BW1 = edge(I, 'sobel') % Aplicar el detector de bordes Sobel
% Mostrar las imágenes originales y la imagen con bordes detectados
imshowpair(I, BW1, 'montage')
title ('Imagen original y Detección de bordes');
```

### Asignación 1:

1. Editar el script anterior y aplicar todos los métodos de detección de bordes
2. Mostrar en pantalla todos los resultados obtenidos de cada uno de los métodos en una sola ventana.
3. Comparar los resultados variando los valores de cada uno de los filtros para obtener el mejor resultado posible de los bordes principales y destacar cual es el mejor método para la detección de bordes.
4. Desarrolle una función en Matlab donde pueda decirle el nombre del fichero de la imagen, los parámetros del operador de Canny. Aplíquelo sobre la imagen.

### Detección de contornos

Es una técnica utilizada en el procesamiento de imágenes que nos permite separar objetos o áreas de interés. Se resaltan los contornos de una imagen y se utilizan para delinear y separar las regiones de interés.

---

El siguiente script es un ejemplo para detectar los contornos de una imagen y usando el concepto de Umbralización usado en ejemplos anteriores.

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%
workspace; % Make sure the workspace panel is showing.
format long g;
format compact;
fontSize = 16;
markerSize = 40;
% Carga la imagen DICOM desde el archivo
dicom_image = dicomread('imagen.dcm');
subplot(2, 2, 1);
% Muestra la imagen DICOM original en la subfigura seleccionada.
imshow(dicom_image, []);
axis('on', 'image');
title('Imagen DICOM original', 'FontSize', fontSize, 'Interpreter',
'None');
%Ventana al máximo.
g = gcf;
g.WindowState = 'maximized';
drawnow;
subplot(2, 2, 2);
%Muestra los contornos de la imagen en la subfigura seleccionada.
imcontour(dicom_image,3)
axis('on', 'image');
title('Contornos de la imagen', 'FontSize', fontSize, 'Interpreter',
'None');
threshold = 120; % Establece el umbral en 120.
% Crea una máscara binaria a partir de la imagen DICOM original
utilizando el umbral especificado.
mask = dicom_image >= threshold;
subplot(2, 2, 3);
% Muestra la máscara segmentada en la subfigura seleccionada.
imshow(mask);
% Muestra información sobre el pixel seleccionado.
impixelinfo;
axis('on', 'image');
title('Imagen segmentada', 'FontSize', fontSize, 'Interpreter',
'None');
```

1. Modifique el valor de umbral, observe los cambios y explique cómo estos afectan la segmentación.
-

### **Segmentación basada en Texturas**

Es un enfoque de procesamiento de imágenes que se utiliza para separar regiones en una imagen en dependencia de las características de textura que presentan. Las texturas se refieren a los patrones repetitivos de una imagen como la rugosidad, la suavidad, la granularidad, entre otros.

Existen diferentes métodos para realizar segmentación por texturas, pero todos ellos implican la extracción de características de textura de la imagen original, estas características se utilizan luego para clasificar los diferentes elementos de la imagen y según su textura y así separar las regiones.

Este tipo de segmentación es utilizada en:

- Tomografías o resonancias magnéticas que pueden indicar la presencia de tumores, ya que estos presentan una textura diferente a la del tejido.
- Se utiliza para separar los tejidos del cerebro y así detectar enfermedades cerebrales.
- Evaluaciones de daño tisular y monitorizar la evolución de la lesión.
- Patologías cardíacas, la textura del músculo cardíaco puede ser un indicador importante de la salud del corazón.

### **Matriz de Co-ocurrencia (GLCM):**

Es una técnica ampliamente utilizada para caracterizar texturas. Calcula la probabilidad conjunta de aparición de pares de niveles de gris a una determinada distancia y ángulo en la imagen. A partir de una matriz se puede extraer características texturales como contraste, correlación, energía y homogeneidad [4].

---

### Ejemplo:

```
close all; %Cierra las ventanas graficas
clear; %limpia el espacio de trabajo
clc; %Limpia la ventana de comandos

%%
workspace; % Make sure the workspace panel is showing.
format long g;
format compact;
fontSize = 16;
markerSize = 40;
dicomImage = dicomread('imagen.dcm');
adjustedImage = imadjust(dicomImage);
figure;
subplot(2, 2, 1);
imshow(dicomImage, []);
title('Imagen DICOM Original','FontSize', fontSize, 'Interpreter',
'None');
subplot(2, 2, 2);
imshow(adjustedImage, []);
title('Imagen Ajustada','FontSize', fontSize, 'Interpreter', 'None');
%%
% Extraer la matriz de co-ocurrencia (GLCM) de la imagen ajustada
offset = [0 1; 1 0; 1 1; 1 1]; % Definir la dirección de
desplazamiento para calcular la GLCM (horizontal)
glcm = graycomatrix(adjustedImage, 'Offset', offset);
% Calcular estadísticas de textura a partir de la GLCM
stats = graycoprops(glcm, {'Contrast', 'Correlation', 'Energy',
'Homogeneity'});
% Mostrar las estadísticas de textura
disp('Estadísticas de Textura:');
disp(['Contraste: ', num2str(stats.Contrast)]);
disp(['Correlación: ', num2str(stats.Correlation)]);
disp(['Energía: ', num2str(stats.Energy)]);
disp(['Homogeneidad: ', num2str(stats.Homogeneity)]);
% Segmentación mediante umbralización
threshold = graythresh(adjustedImage); % Obtener el valor de umbral
óptimo automáticamente
segmentedImage = imbinarize(adjustedImage , threshold);
% Mostrar la imagen segmentada
subplot(2, 2, 3);
imshow(segmentedImage, []);
title('Imagen Segmentada','FontSize', fontSize, 'Interpreter',
'None');
```

---

### Bibliografía.

- [1] «Segmentación de imágenes texturadas,» [En línea]. Available: <https://www.dc.uba.ar/grupinv/imagenes/archivos/tesisTribujWaisbaum2006.pdf>.
- [2] U. d. Jaén, «Detección de bordes en una imagen,» Departamento de Ingeniería electrónica, Telecomunicación y Automática. .
- [3] «Detección de bordes,» [En línea]. Available: <https://es.mathworks.com/help/images/edge-detection.html>.
- [4] A. C. P. LEAL, «SEGMENTACIÓN DE IMÁGENES POR TEXTURA,» Septiembre 2006. [En línea]. Available: [http://repositorio.udec.cl/bitstream/11594/873/1/TESIS\\_SEGMENTACION\\_DE\\_IMAGENES\\_POR\\_TEXTURA.Image.Marked.pdf](http://repositorio.udec.cl/bitstream/11594/873/1/TESIS_SEGMENTACION_DE_IMAGENES_POR_TEXTURA.Image.Marked.pdf).
-



### Procesamiento de imágenes basado en Aprendizaje Automático

Nombre y Apellidos		
Fecha:        /        /	Grupo N.º:	

### Introducción

Los avances tecnológicos por muchos años llevan revolucionando el campo de la medicina, desde entonces muchas áreas de ingeniería han dedicado esfuerzos en el desarrollo y/o mejoras a métodos que proporcione diagnóstico de enfermedades, tratamiento o incluso en la prevención de las mismas.

La reciente adopción de métodos de aprendizaje automático, un enfoque para lograr la inteligencia artificial (IA), en el análisis de imágenes está cobrando fuerza rápidamente en muchas áreas de investigación. El aprendizaje profundo es parte de un algoritmo de aprendizaje automático más amplio basado en una red neuronal artificial. La estructura de aprendizaje profundo resolvió con éxito problemas de análisis complejo en aplicaciones médicas, patológicas y de adquisición de imágenes biológicas.

Los modelos de aprendizaje automático más efectivos para el procesamiento de imágenes utilizan redes neuronales y aprendizaje profundo. El aprendizaje profundo utiliza redes neuronales para resolver tareas complejas de manera similar a la forma en que el cerebro humano las resuelve.

Se pueden implementar diferentes tipos de redes neuronales para resolver diferentes tareas de procesamiento de imágenes, desde una simple clasificación binaria (si una imagen coincide o no con un criterio específico) hasta la segmentación de instancias. Elegir el tipo y la arquitectura correctos de una red neuronal juega un papel esencial en la creación de una solución eficiente de procesamiento de imágenes basada en IA [1].

---

- **Inteligencia artificial (IA)** – Simulación de procesos de inteligencia humana por sistemas informáticos.
- **Aprendizaje automático (ML)** – Método para lograr la IA utilizando algoritmos para determinar o predecir patrones basados en los datos existentes. Los algoritmos de aprendizaje automático infieren automáticamente las reglas para discriminar las clases.
- **Aprendizaje profundo (DL)** – Subconjunto de métodos de aprendizaje automático que utilizan redes neuronales artificiales (ANN) para aprender relaciones insumo/producto. Las ANN son modelos matemáticos representados por múltiples capas de “neuronas” o células informáticas.

### Objetivos Específicos

- Introducción al aprendizaje automático y las redes neuronales profundas
- Utilizar red entrenada SynthSeg como herramienta de aprendizaje profundo

### Desarrollo de la Práctica

Los métodos de segmentación automatizada más recientes se basan en redes neuronales convolucionales (CNN) [2]. Estos están muy extendidos en la investigación, donde la abundancia de escaneos de alta calidad (es decir, con alta resolución isotrópica y con buenos contrastes entre tejidos) permite a las CNN obtener segmentaciones 3D precisas que luego pueden usarse en análisis posteriores, como el estudio de conectividad.

### Redes Neuronales Artificiales

Una red neuronal artificial es un modelo computacional inspirado en la estructura de las redes neuronales en el cerebro. Los modelos simplificados del cerebro, constan de una gran cantidad de dispositivos informáticos básicos (neuronas) que están conectados entre sí en una red de comunicación compleja, a través de la cual el cerebro puede llevar a cabo cálculos altamente complejos. Las redes neuronales artificiales son construcciones formales de cálculo que se modelan a partir de este

---

paradigma de cálculo. El aprendizaje con redes neuronales se propuso a mediados del siglo XX. Produjo un paradigma de aprendizaje efectivo y recientemente se ha demostrado que logra un rendimiento de vanguardia en varias tareas de aprendizaje.

## Desarrollo del modelo

### SynthSeg

Es la primera herramienta de aprendizaje profundo para la segmentación de escáneres cerebrales de cualquier contraste y resolución. SynthSeg funciona de inmediato sin necesidad de volver a capacitarse y también es sólido para:

- Una amplia gama de poblaciones: desde jóvenes y sanos hasta ancianos y enfermos,
- Escaneos con o sin preprocesamiento: corrección de campo de sesgo, extracción de cráneo, normalización, etc.
- Lesiones de sustancia blanca.

Para el siguiente script se utilizó una red con imágenes sintéticas muestreadas sobre la marcha a partir de un modelo generativo basado en el modelo directo de segmentación bayesiana. Fundamentalmente, adopta una estrategia de aleatorización de dominio en la que aleatoriza completamente los parámetros de generación que se extraen en cada minilote de antecedentes uniformes no informativos. Al exponer la red a datos de entrada extremadamente variables, se le obliga a aprender características independientes del dominio. Como resultado, SynthSeg puede segmentar fácilmente escaneos reales de cualquier dominio objetivo, sin necesidad de volver a entrenar ni realizar ajustes [3].

---

Este ejemplo muestra cómo segmentar una resonancia magnética cerebral utilizando una red neuronal profunda previamente entrenada. Con la red SynthSeg se puede utilizar para segmentar escáneres cerebrales de cualquier contraste y resolución sin necesidad de volver a entrenarlos ni realizar ajustes [4].

En el archivo rar proporcionado con la guía de laboratorio se encuentra el siguiente script, un Dataset de Resonancia magnética, y las funciones:

- postProcessBrainCANDIData.m
- preProcessData.m
- downloadTrainedNetwork.m
- getBrainCANDISegmentationLabels.m

```
close all
clear
clc

% Obtiene una lista de todos los archivos DICOM
names = dir("*.dcm");
info = dicominfo(names(1).name);
% Crea un volumen 3D de 128 imágenes, inicializado con ceros
vol = repmat(uint16(0), [info.Rows, info.Columns, 128]);
% Crea un volumen 3D del mismo tamaño que el número de archivos DICOM,
inicializado con ceros.
brain_dcm = repmat(uint16(0), [info.Rows, info.Columns, size(names,1)]);

for i=1:size(names,1)
    % Lee la imagen DICOM y la almacena en la variable
    images_dcm(:, :, i) = uint16(dicomread(names(i).name));
    vol(:, :, i) = uint16(dicomread(names(i).name));
    figure(1)% Abre una figura.
    % Muestra la imagen DICOM actual.
    imshow(images_dcm(:, :, i), [])
    pause(.3)
end

%%
% Establece el directorio de trabajo
dataDir = "/MATLAB Drive/Lab3_Monografia/Lab3_CNN";
% trainedBrainCANDINetwork_url =
"https://www.mathworks.com/supportfiles/"+ ...
% "image/data/trainedBrainSynthSegNetwork.h5";
% downloadTrainedNetwork(trainedBrainCANDINetwork_url, dataDir);
% Obtiene los nombres y los IDs de las etiquetas de segmentación.
[classNames, labelIDs] = getBrainCANDISegmentationLabels;
% Almacena la información del archivo DICOM en la variable
metaData =info;
```

---

```
%%  
% Establece el resampling en falso.  
resample = false;  
% Establece el tamaño de recorte en 192  
cropSize = 192;  
% Preprocesa los datos del volumen 3D  
[volProc, cropIdx, imSize] = preProcessData(vol, resample);  
% Obtiene el tamaño de la entrada.  
inputSize = size(volProc);  
  
%%  
% Convierte el volumen preprocesado en un arreglo de aprendizaje  
profundo.  
volDL = dlarray(volProc, "SSSCB");  
  
%%  
% Establece la ruta del archivo del modelo entrenado  
modelFile = fullfile(dataDir, "trainedBrainSynthSegNetwork.h5");  
% Importa las capas del modelo entrenado  
lgraph =  
importKerasLayers(modelFile, ImportWeights==true, ImageInputSize==inputSize  
);  
  
%%  
% Encuentra las capas de marcador de posición en la red  
placeholderLayers = findPlaceholderLayers(lgraph)  
  
%%  
% Crea una capa de softmax  
sf = softmaxLayer;  
% Reemplaza la capa de predicción por la capa de softmax  
lgraph = replaceLayer(lgraph, "UNET_prediction", sf);  
% Crea la red neuronal  
net = dlnetwork(lgraph);  
% Muestra el gráfico de la red neuronal.  
layerGraph(net)  
  
%%  
% Realiza la predicción utilizando la red neuronal  
predictIm = predict(net, volDL);  
  
%%  
% Establece el valor de flip en verdadero  
flipVal = true;  
% Voltea la imagen verticalmente  
if flipVal  
    % Voltea la imagen en profundidad  
    flippedData = fliplr(volProc);  
    flippedData = flip(flippedData, 2);  
    flippedData = flip(flippedData, 1);  
    % Convierte la imagen volteada en un arreglo de aprendizaje profundo
```

---

```
flippedData = dldarray(flippedData, "SSSCB");  
% Realiza la predicción utilizando la imagen volteada  
flipPredictIm = predict(net, flippedData);  
else  
    flipPredictIm = [];  
end  
  
%%  
% Realiza el postprocesamiento de los mapas de segmentación  
predictedSegMaps =  
postProcessBrainCANDIData(predictIm, flipPredictIm, imSize, ...  
    cropIdx, classNames, labelIDs);  
  
%%  
% Establece el índice del slice a visualizar.  
sliceIdx = 40;  
% Escala el slice  
testSlice = rescale(vol(:, :, sliceIdx));  
% Obtiene el mapa de segmentación  
predSegMap = predictedSegMaps(:, :, sliceIdx);  
% Superpone el mapa de segmentación sobre el slice  
B = labeloverlay(testSlice, predSegMap, "IncludedLabels", 2:32);  
figure  
montage({testSlice, B})  
  
% Realiza un proceso de visualización y superposición de mapas de  
segmentación en un volumen de datos tridimensional  
B = repmat(uint8(0), [256 256 128]);  
sizevoldata = size(predictedSegMaps, 3);  
for sliceIdx = 1: sizevoldata  
    testSlice(:, :, sliceIdx) = rescale(vol(:, :, sliceIdx));  
    predSegMap(:, :, sliceIdx) = predictedSegMaps(:, :, sliceIdx);  
    B(:, :, sliceIdx) =  
    labeloverlay(testSlice, predictedSegMaps(:, :, sliceIdx), "IncludedLabels", 2:  
    32);  
end  
end
```

Ejecute el siguiente script y espere hasta obtener los resultados de segmentación utilizando una red previamente entrenada. La función **trainNetwork** se utiliza para obtener los mapas de segmentación de la red neuronal previamente entrenada, para pos-procesar los mapas de segmentación y superponer los mapas de segmentación en las imágenes DICOM originales para su visualización.

¿Compare los resultados obtenidos de la segmentación que se realizó con otras técnicas y ahora usando redes neuronales para validar su rendimiento?

---

## Bibliografía

### Bibliografía

- [1] L. Molecular Devices, «Herramientas de IA, aprendizaje automático,» [En línea]. Available: <https://es.moleculardevices.com/technology/ai-machine-deep-learning-cell-image-analysis>.
  - [2] F. P. ., B. T. Ronneberger O., «U-Net: Redes convolucionales para segmentación de imágenes biomédicas,» [En línea].
  - [3] «SynthSeg: segmentación de resonancias magnéticas cerebrales de cualquier contraste y resolución sin reentrenamiento,» [En línea]. Available: <https://www.sciencedirect.com/science/article/pii/S1361841523000506>.
  - [4] «Segmentación de resonancia magnética cerebral mediante la red U-Net 3-D previamente entrenada,» [En línea]. Available: <https://la.mathworks.com/help/medical-imaging/ug/Brain-MRI-Segmentation-Using-Trained-3-D-U-Net.html>.
  - [5] F. P. ., B. T. Ronneberger O., «U-Net,» de *Redes convolucionales para segmentación de imágenes biomédicas*, 2015, pp. 234 - 241.
-

### Procesamiento de imágenes basado en Aprendizaje Automático

**Asignatura: Procesamiento Digital de Bioseñales**

**Técnico Superior en Tecnología Biomédica**

**Objetivo de aprendizaje:** Aplicar algoritmos de aprendizaje automático, como redes neuronales convolucionales, para la segmentación y análisis de imágenes.

**Actividad a observar:** Evaluar la precisión y eficacia de los modelos en la identificación de regiones de interés y características relevantes en las imágenes.

**Puntaje de la lista de cotejo:** 20 pts

Escala: A=Avanzado, S=Suficiente y ED= En desarrollo

Nombres y apellidos	Criterios de Evaluación: Análisis crítico de la integración de técnicas de aprendizaje automático en aplicaciones prácticas de procesamiento de imágenes.												Nota
	Es capaz de cargar correctamente el algoritmo y todas sus funciones			Demuestra interés en la aplicación del aprendizaje automático aplicados al procesamiento de imágenes			Realiza una evaluación de la eficacia y precisión de los modelos en la clasificación y detección de objetos			Es capaz de analizar y evaluar la calidad de segmentación respecto a otras técnicas			
	A	S	ED	A	S	ED	A	S	ED	A	S	ED	
	3pts	2 pts	1 pts	3pts	2 pts	1 pts	3pts	2 pts	1 pts	3pts	2 pts	1 pts	
<b>Marlon</b>	X				X				X		X		8 pts
<b>Carlos</b>		X		X			X			X			13 pts
<b>Luis</b>													
<b>Marina</b>													

## **Encuesta realizada**

- 1. ¿Una vez que se le proporcionaron los recursos propuestos para dicha asignatura, como califica la presentación y estructura de la misma?**
  - a) Muy buena
  - b) Buena
  - c) Mala
- 2. ¿Las guías de laboratorio proporcionan información clara y precisa sobre los procedimientos que se realizan en el procesamiento digital de imágenes médicas?**
  - a) Si
  - b) No
- 3. ¿Considera que los ejemplos y/o aplicaciones mostradas ayudaran a comprender los conceptos claves del procesamiento digital de imágenes?**
  - a) Si
  - b) No
- 4. ¿Piensa que serían eficiente las técnicas de segmentación de imágenes propuestas en las guías para establecer un posterior análisis?**
  - a) Si
  - b) No
- 5. ¿Qué tan fácil le fue entender los ejemplos en Matlab, para posteriormente realizar las asignaciones propuestas?**
  - a) Muy buena
  - b) Buena
  - c) Mala
- 6. ¿Recomendaría estas guías de laboratorio a otros profesionales en el área de procesamiento digital de imágenes médicas?**
  - a) Si
  - b) No