



**UNIVERSIDAD POLITÉCNICA SALESIANA
SEDE QUITO**

CARRERA DE INGENIERÍA DE SISTEMAS

**APLICACIÓN MOVIL PARA CLASIFICAR REGIONES EN IMÁGENES
MAMOGRAFICAS DICOM**

Trabajo de titulación previo a la obtención del

Título de Ingenieros de Sistemas

AUTORES: **ANDRÉS ALBERTO LEIME HIDALGO**

JORGE OSWALDO TOCTAGUANO PUGA

TUTOR: **WASHINGTON ARSENIO RAMÍREZ MONTALVAN**

Quito-Ecuador

2022

**CERTIFICADO DE RESPONSABILIDAD Y AUTORÍA DEL TRABAJO DE
TITULACIÓN**

Nosotros, Andrés Alberto Leime Hidalgo, con documento de identificación N° 1721225140 y Jorge Oswaldo Toctaguano Puga con documento de identificación N° 1723345359, manifestamos que:

Somos los autores y responsables del presente trabajo; y, autorizamos a que sin fines de lucro la Universidad Politécnica Salesiana pueda usar, difundir, reproducir o publicar de manera total o parcial el presente trabajo de titulación.

Quito, 9 marzo del año 2022

Atentamente,



Andres Alberto Leime Hidalgo

1721225140



Jorge Oswaldo Toctaguano Puga

1723345359

**CERTIFICADO DE CESIÓN DE DERECHOS DE AUTOR DEL TRABAJO DE
TITULACIÓN A LA UNIVERSIDAD POLITÉCNICA SALESIANA**

Nosotros, Andrés Alberto Leime Hidalgo, con documento de identificación N° 1721225140 y Jorge Oswaldo Toctaguano Puga con documento de identificación N° 1723345359, expresamos nuestra voluntad y por medio del presente documento cedemos a la Universidad Politécnica Salesiana la titularidad sobre los derechos patrimoniales en virtud de que somos el autor y la autora del Proyecto Técnico: “Aplicación móvil para clasificar regiones en imágenes mamográficas dicom”, el cual ha sido desarrollado para optar por el título de: Ingenieros de Sistemas, en la Universidad Politécnica Salesiana, quedando la Universidad facultada para ejercer plenamente los derechos cedidos anteriormente.

En concordancia con lo manifestado, suscribimos este documento en el momento que hacemos la entrega del trabajo final en formato digital a la Biblioteca de la Universidad Politécnica Salesiana.

Quito, 9 marzo del 2022

Atentamente,



Andres Alberto Leime Hidalgo

1721225140



Jorge Oswaldo Toctaguano Puga

1723345359

CERTIFICADO DE DIRECCIÓN DEL TRABAJO DE TITULACIÓN

Yo, Ramírez Montalvan Washington Arsenio con documento de identidad No 1710804681, docente de la Universidad Politécnica Salesiana, declaro que bajo mi tutoría fue desarrollado el trabajo de titulación, con el tema: APLICACIÓN MOVIL PARA CLASIFICAR REGIONES EN IMÁGENES MAMOGRAFICAS DICOM, realizado Andrés Alberto Leime Hidalgo, con documento de identificación No 1721225140 y Jorge Oswaldo Toctaguano Puga con documento de identificación No 1723345359, obteniendo como resultado final el trabajo de titulación bajo la opción Proyecto Técnico que cumple con todos los requisitos determinados por la Universidad Politécnica Salesiana.

Quito, 9 marzo del 2022

Atentamente,

A handwritten signature in blue ink, appearing to read 'R. Montalvan', with a horizontal line underneath the name.

Ing. Ramírez Montalvan Washington Arsenio Phd.

1710804681

DEDICATORIA

“Si quieres encontrar los secretos del universo piensa en términos de energía, frecuencia y vibración” Nikola Tesla.

Gracias Andrés por tu perseverancia y esfuerzo que esto sea la puerta para seguir creciendo como persona y profesional. Gracias Mamá por tus enseñanzas por abrir mi mente a nuevos conocimientos cada día. Gracias Papá por tu esfuerzo y dedicación hacia sus hijos por enseñarnos el valor del trabajo y que nada que valga la pena está a la mano todo lo bueno requiere esfuerzo y dedicación, así como a no amilanarnos ante la vida a seguir adelante a pesar de las circunstancias. Gracias David por tu cariño sincero por tu ayuda en mi caminar por ser una pieza fundamental en mi vida. Gracias hermanas por sus consejos por velar por mi bien estar y gracias Glorita por tus consejos por incentivar me a seguir avanzando en el mundo académico a todas estas personas les quedo muy agradecido porque fueron parte crucial para terminar este proyecto. Solamente me resta desearles Paz y Luz en sus vidas.

Andrés Alberto Leime Hidalgo

Tengo muchas personas a las que agradecer y dedicar este logro, pero sobre todo mi Madre, por darme la vida, educación e inteligencia emocional para alcanzar esta meta, por el esfuerzo que realiza día a día y mi admiración total a ella. A todos los que conforman mi familia por su apoyo en momentos difíciles tanto económica como emocional durante toda la carrera. Finalmente, a mi abuelita que es la persona más importante en mi vida por estar siempre presente en todas las etapas que he tenido apoyándome y dándome consejos a diario llevándome hacer una persona de bien.

Jorge Oswaldo Toctaguano Puga

AGRADECIMIENTO

Agradecemos al personal docente y administrativo de la Universidad Politécnica Salesiana por las acciones realizadas en la formación de profesionales competentes y comprometidos con la sociedad, además un especial agradecimiento Washington Ramírez, por habernos compartido sus conocimiento y experiencia en el desarrollo de nuestro proyecto de titulación.

Andrés Alberto Leime Hidalgo

Jorge Oswaldo Toctaguano Puga

ÍNDICE

INTRODUCCIÓN	1
ANTECEDENTES	1
PROBLEMATICA	2
JUSTIFICACIÓN	3
OBJETIVOS	4
Objetivo General.....	4
Objetivo Específicos.....	4
METODOLOGIA DE LA INVESTIGACIÓN	4
CAPITULO 1	7
MARCO TEORICO	7
1.1 ESTADO DEL ARTE	7
1.1.1 Resumen del Estado de Arte	9
1.2 FUNDAMENTACIÓN TEÓRICA	11
1.2.1 Glándulas Mamarias.....	11
1.2.2 Cáncer de Mama.....	12
1.2.3 Lesiones Mamográficas.....	13
1.2.4 Imágenes de Rayos X.....	13
1.2.5 Mamografías.....	14
1.2.6 Clasificación de imágenes médicas.....	19
1.2.7 Procesamiento Digital.....	20

1.2.8	Sistema Operativo CentOS 7.....	20
1.2.9	Java SDK.....	21
1.2.10	Cmake.....	21
1.2.11	QT Creator.....	22
1.2.12	NDK de Android	22
1.2.13	Aplicación móvil	22
1.2.14	Librería DCMTK.....	23
1.2.15	Hybrid Median Filter (HMF)	23
1.2.16	Clahe (CH)	24
1.2.17	Otsu (OT)	26
1.2.18	Canny (CNY)	28
1.2.19	Watershed (WH).....	29
1.2.20	SVM	31
CAPÍTULO 2		32
2.1	MARCO METODOLOGICO	32
2.1.1	Fase 1: Preparación Imagen	33
2.1.2	Fase 2: Preprocesamiento.....	35
2.1.3	Fase 3: Segmentación.....	40
2.1.4	Fase 4: Clasificación	46
CAPÍTULO 3		47
3.1	PLANTEAMIENTO DE LA MEJORA.....	47
3.2	RESULTADOS	47

3.2.1	Data set.....	47
3.2.2	Umbrales	48
3.2.3	Regiones	49
3.2.4	Rendimiento de las técnicas.	49
3.2.5	Tiempo de ejecución	51
3.2.6	Promedio CPU.....	52
3.2.7	Memoria RAM	52
3.2.8	Métricas.....	53
3.2.9	Resultados SVM.....	57
CONCLUSIONES		60
RECOMENDACIONES		61
GLOSARIO DE TÉRMINOS		62
LISTA DE REFERENCIAS		63

ÍNDICE DE TABLAS

Tabla 1 Detalle Recursos para el proyecto	6
Tabla 2 Resumen del Estado del Arte	10
Tabla 3 Características de las lesiones nodulares.....	17
Tabla 4 Características de las lesiones nodulares.....	18
Tabla 5 Parámetros modificables en el algoritmo.....	26
Tabla 6 Umbrales Masas y Microcalcificaciones	38
Tabla 7 Data imágenes	48
Tabla 8 Umbral promedio	48
Tabla 9 Regiones obtenidas.....	49
Tabla 10 Resultados	50
Tabla 11 Resultados Finales.....	56
Tabla 12 Data set Imágenes Dicom.....	58

INDICE DE ALGORITMOS

Algoritmo 1 Lectura imagen DICOM usando DCMTK	34
Algoritmo 2 Hybrid Median Filter	35
Algoritmo 3 Otsu.....	37
Algoritmo 4 Clahe	39
Algoritmo 5 Canny.....	41
Algoritmo 6 Watershed	43
Algoritmo 7 Visualizar Imagen.....	45

ÍNDICE DE FIGURAS

Figura 1 Estructura de la glándula mamarias	12
Figura 2 Macrocalcificaciones y Microcalcificaciones	13
Figura 3 División de planos para análisis de mamas	15
Figura 4 Cuadrantes mamarios.....	15
Figura 5 Morfología de las lesiones nodulares.....	17
Figura 6 BI-RADS Lesiones nodulares.....	19
Figura 7 Flujo HMF	24
Figura 8 Función de transformación del histograma.....	25
Figura 9 Flujo de proceso.....	32
Figura 10 Imagen original librería DCMTK	34
Figura 11 Imagen HMF.....	36
Figura 12 Imagen Clahe	39
Figura 13 Imagen Canny	42
Figura 14 Imagen Watershed	44
Figura 15 Resultados de masas	45
Figura 16 Masas micros con normales	46
Figura 17 Tiempo de ejecución.....	51
Figura 18 Promedio CPU	52
Figura 19 Memoria RAM.....	53
Figura 20 Valores Métrica para HMF	54
Figura 21 Valores métrica Clahe.....	55
Figura 22 Valores PSNR Canny.....	56
Figura 23 Resultados de SVM	59

RESUMEN

El cáncer de mama genera millones de muertes alrededor del mundo todos los años lo cual hace indispensable su pronta detección. Mientras la tecnología avanza se ve la necesidad del uso cotidiano de dispositivos cada vez más pequeños. En el presente trabajo se desarrolló un prototipo móvil que permite clasificar regiones de interés presentes en las imágenes mamográficas DICOM. Se utilizó una data set de 211 imágenes mamografías. El proceso se dividió en cuatro fases: preparación de imágenes, preprocesamiento, segmentación y clasificación. En la fase preparación se usó la librería DCMTK para la lectura y manejo de imágenes. En la fase preprocesamiento con algoritmos como Clahe para la mejora del contraste. Además, la técnica HMF para eliminar el ruido de tipo sal y pimienta. La fase segmentación con Canny se utilizó para la detección de bordes y Watershed para la segmentación. Lo que permitió obtener regiones correspondientes a Masas, Microcalcificaciones y tejidos presentes en la mama. Los resultados de HMF en proporción máxima de señal a ruido promedio de todas las imágenes usadas de 77 dB. El algoritmo Canny presento un 21% de uso en CPU y Watershed uso de Memoria en ejecución de 3709,97 Megabytes (MB). Para luego, ser clasificado mediante Máquinas de Soporte Vectorial (SVM) con resultados de accuracy: 82,43% en masas, 83,78% en micros y 75,36% en masas con micros. Donde la clasificación tiende a bajar para imágenes de tipo masas y micros, y solo masas o micros se mantienen en valores similares.

ABSTRACT

Breast cancer causes millions of deaths around the world every year, which makes early detection essential. As technology advances, the need for the daily use of increasingly smaller devices is seen. In the present work, a mobile prototype was developed that allows classifying regions of interest present in DICOM mammographic images. A data set of 211 mammography images was used. The process was divided into four phases: image preparation, preprocessing, segmentation, and classification. In the preparation phase, the DCMTK library was used for reading and managing images. In the preprocessing phase with algorithms such as Clahe for contrast enhancement. In addition, the HMF technique to eliminate salt and pepper type noise. The segmentation phase with Canny was used for edge detection and Watershed for segmentation. What allowed to obtain regions corresponding to Masses, Microcalcifications and tissues present in the breast. The HMF results in a maximum average signal-to-noise ratio of all images used of 77 dB. The Canny algorithm presented a 21% CPU usage and Watershed Memory usage in execution of 3709.97 Megabytes (MB). To then be classified using Support Vector Machines (SVM) with accuracy results: 82.43% in masses, 83.78% in micros and 75.36% in masses with micros. Where the classification tends to go down for images of the masses and micros type, and only masses or micros remain at similar values.

INTRODUCCIÓN

ANTECEDENTES

La radiología surge el 8 de noviembre de 1895, con el descubrimiento de los Rayos X por Wilhelm Conrad Roentgen, sin embargo, en 1970 se da el apareamiento del estudio digital (Thomas & Banerjee, *The History of Radiology*, 2013). Con el pasar del tiempo su aplicación se inclina a la utilización de diversos equipos tecnológicos en el campo de la medicina. Es así, que basándose en lo expuesto por (Gismondi, 2010), que hace referencia a la definición de Ingeniería Biomédica de la IFMBE (del inglés, International Federation of Medical and Biological Engineering), el procesado digital de imágenes constituye, una de las líneas de generación de conocimiento fundamentales en medicina. A esto se suma los desarrollos tecnológicos presentados en el área, relacionada al análisis de iconografías mamarias principalmente en el desarrollo de la detección asistida por el computador. Donde el desarrollo de softwares está aportando en gran medida a los radiólogos al contar con instrumentos más eficientes para la detección del cáncer de mama. Es así, que los sistemas de mamografías permitan reducir esta brecha con procesos informáticos complejos que ayuden a los especialistas en la toma de decisiones. Especialmente en complejos escenarios de ciertos grupos de población (mujeres jóvenes o mujeres con mamas densas) que tienen una sensibilidad muy reducida, y puedan resultar en cánceres no detectados. (Agarwal, Díaz, Lladó, Hoon Yap, & Martí, 2019)

El presente estudio propone el desarrollo de técnicas optimizadas para la segmentación de regiones en imágenes mamográficas DICOM, utilizando C/C++, que permita eliminar las dependencias con la librería OpenCv. Así mismo, se contempla implementar un algoritmo SVM que permita la clasificación de dichas imágenes. Con la ayuda del sistema operativo Android para aplicaciones móviles en teléfonos inteligentes se pueda presentar resultados confiables en lo que respecta a la localización de tumores cancerígenos de la mama.

PROBLEMÁTICA

Según datos publicados por la Organización Panamericana de la Salud (OPS) y la Organización Mundial de la Salud (OMS), la presencia de nódulos en la sección mamaria es la segunda causa de mortalidad en la población. Es así que en el año 2020 se diagnosticó cáncer de mama a un promedio de 4 millones de personas, de las cuales 1,4 millones perdieron la vida (Organización Panamericana de la Salud, 2021). En el Ecuador, en junio del 2018 según el Ministerio de Salud Pública se presentaron alrededor de 1.287 nuevos casos de atención que diagnosticaban cáncer de mama. Sin embargo, según datos del Instituto Nacional de Estadísticas y Censos, este tipo de cáncer es una de las principales causas de muerte en las mujeres. “Se ha verificado que de las 3.430 defunciones reportadas por esta causa entre el 2012 y 2017, el 99,3% de las personas que fallecieron corresponden al sexo femenino” (Ministerio de Salud Pública, 2018, pág. 2).

Estudios indican que una herramienta importante que permite detectar este tipo de cáncer lo constituyen la prueba mamográfica. De este modo, la mamografía ayuda a la detección temprana y la conclusión de las enfermedades de los senos en las mujeres (Hertel, y otros, 2019). Por lo tanto, se contempla utilizar el tratamiento automático de imágenes de mama que comprende el preprocesamiento, eliminación de ruido, segmentación y métodos de eliminación de fondo. De esta manera, extraer múltiples dominios para una mejor clasificación, utilizando perceptrones multicapa MLP (del inglés, MultiLayer Perceptron) y la Máquinas de Soporte Vectorial SMV (del inglés, Support Vector Machines). Esta tecnología permite presentar resultados que evidencian una superioridad del algoritmo propuesto en términos de sensibilidad, especificidad y precisión (Jaffar, Ahmed, & Hussain, 2009). Sin embargo, con la existencia de gran cantidad de información en distintos formatos y la gran diversidad de fabricantes de equipos médicos, aparece la necesidad de establecer la normativa DICOM (del inglés, Digital Imaging and Communications in Medicine). Por lo tanto, se propone un

protocolo común de comunicación entre los equipos, suministrando comunicación normalizada entre los equipos y brindando un formato colectivo para las imágenes.

JUSTIFICACIÓN

Con los nuevos avances en el ámbito tecnológico relacionado con temas médicos se han desarrollado nuevas técnicas informáticas para el procesamiento de imágenes digitales mamográficas. De tal manera, que su uso permita al especialista en medicina una segunda opinión en la detección de anomalías en la mama (Al Nahid & Kong, 2017). A esto se suma las diversas investigaciones realizadas entorno a la temática, resaltando el proyecto realizado por (Fernández, 2020). Dicho estudio utiliza imágenes DICOM de 3328 x 2560 y 4084 x 3328 pixeles, para identificar la cantidad de regiones que conforman una imagen mamográfica en dispositivos móviles utilizando librerías externas OpenCv. Se observa que los resultados obtenidos en tiempo promedio de procesamiento por cada imagen (Total 67 imágenes) fue 4,965 minutos durante el procesamiento por cada imagen. Concluyendo que se genera un alto consumo de recursos computacionales generados por entrada y salida de datos, compresión y descompresión de imágenes, técnicas de segmentación y la librería OpenCv.

El procesamiento de imágenes médicas DICOM, busca reducir el tiempo de procesamiento mejorando el rendimiento y permite el uso de GPU y CPU en dispositivos pequeños que pueden ayudar a médicos, estudiantes e investigadores en el análisis de dichas imágenes (Székely, Talanow, & Bágyi, 2012). En esta perspectiva su aplicabilidad para la detección y localización del tumor en una etapa temprana es valiosa, al ser la única forma de prevención que conlleve a disminuir la tasa de mortalidad por cáncer de mama. Visto de esta forma proporciona al médico una nueva perspectiva a ser utilizada para consultar con otros colegas que permitan un mejor criterio en la toma de una decisión final.

OBJETIVOS

Objetivo General.

Desarrollar una aplicación utilizando tecnologías Open Source que optimicen recursos computacionales, aplicando técnicas para la captura de regiones y sistematización de datos en imágenes mamográficas DICOM.

Objetivo Específicos.

- Realizar un análisis técnico que contemple el preprocesamiento de imágenes y clasificadores de nódulos utilizadas en mamografías digitales DICOM.
- Optimizar recursos computacionales utilizando técnicas de segmentación y clasificación para aplicaciones móviles.
- Ejecutar el procesamiento de imagen en una aplicación móvil utilizando técnicas para mejorar la detección de anomalías en mamografías digitales DICOM.
- Evaluar los resultados de la aplicación y optimización de recursos computacionales utilizando métricas.

METODOLOGÍA DE LA INVESTIGACIÓN

El método corresponde al analítico que radica en la separación de un todo en partes en las que se pueda conocer sus causas y los efectos que produce su accionar. Para ello, se utiliza la observación que permita conocer el origen del objeto de estudio, de tal manera que se pueda conocer su esencia. Por lo cual, con la utilización de este método parte de conocer el objeto de estudio, para que, mediante similitudes, se pueda formular nuevas teorías. (Labajo, 2017)

Tipo de investigación

El tipo de investigación a utilizar comprende al experimental, el cual consiste que el investigador selecciona una o más variables para realizar su estudio, controlando y manipulando dichas variables para apreciar las conductas observadas. (Murillo, 2019)

Técnicas

El estudio a realizar consiste en el análisis del estado de arte de técnicas que se utilizan en la actualidad para el procesamiento de regiones mamográficas. Siendo la segmentación una etapa importante cuya finalidad es separar las regiones de interés de aquellas que son irrelevantes. Así mismo las técnicas utilizadas para la clasificación de datos en imágenes mamográficas digitales DICOM, teniendo en cuenta que la clasificación de Imágenes es un proceso extenso debido a la cantidad de información asociada con el formato.

La clasificación de tejido mamario basado en el nivel de intensidad del histograma de una mamografía y haciendo uso de características estadísticas. Por tal razón, se plantea utilizar modelos de textura para la captura de la apariencia mamográfica en el interior del pecho basado en valores de características de una mamografía digital. Con el objetivo de clasificar los autores han intentado segmentar en cuatro categorías básicas como graso, graso no comprimido, denso y de alta densidad. Es por ello, que esta categorización ayudaría a un radiólogo a detectar un seno normal de un seno afectado por cáncer a fin de continuar con la investigación (Holalu & Arumugan, 2006). Por consiguiente, se plantea desarrollar una aplicación para dispositivos móviles evitando en lo posible el uso de las librerías de OpenCV utilizadas para el análisis imágenes mamográficas DICOM. En cambio, se plantea remplazar haciendo uso de código nativo o código puro C/C++. De esta manera, ayudaría en la disminución de tiempo valioso al tener los resultados de las imágenes de diagnóstico del paciente en un dispositivo compacto y de fácil acceso. Los recursos que se utilizaron durante el proceso de desarrollo de la investigación y pruebas del mismo se encuentran a detalle en la **¡Error! No se encuentra el origen de la referencia..**

Tabla 1*Detalle Recursos para el proyecto*

Hardware	Uso	Descripción
PC 1	Investigación, Análisis e implementación	Intel i7, Ram 12Gb, HD 500 Tb
PC 2	Investigación, Análisis e implementación	Intel i5, Ram 6Gb, HD 1Tb
Huawei Cel	Pruebas	Huawei Kirin 810, Ram 6Gb, Android 10
Software	Uso	Descripción (Versión)
Qt Creator	Entorno de desarrollo	5.12
C/C++	Programación	9.3.0
Cmake	Compilación	3.17.5
Java	Programación	1.8.0_301
DCMTK	Librería externa	3.6.6
Centos 7	S.O	7.1

Nota: Esta tabla contiene los recursos necesarios para el proyecto. Elaborado por: Los autores.

CAPÍTULO 1

MARCO TEÓRICO

En este capítulo se proporciona un resumen de las técnicas y métodos empleados en el proyecto técnico. Iniciando con la fase de preprocesamiento de imágenes, segmentación y clasificación, así como las métricas empleadas para medir su rendimiento.

1.1 ESTADO DEL ARTE

El presente trabajo de titulación se sustenta en las siguientes investigaciones desarrolladas que tienen relevancia y se encuentran relacionadas a la temática del proyecto técnico.

Fernández (2020), propuso como objetivo general desarrollar un método para reducir regiones obtenidas después de la segmentación que permita mejorar y resaltar las áreas de sospecha de cáncer de mamá. La metodología aplicada corresponde a la cuantitativa y se utiliza la investigación descriptiva para determinar cómo problema principal la reducción de tiempos en los procesos de preprocesamiento de imágenes médicas y en el post procesamiento, utilizando la técnica de Watershed y OpenMP respectivamente. Además, se desarrolla en la plataforma Jade-Leap que permite enviar las imágenes al dispositivo móvil.

Se obtuvo como resultado que del promedio global de segmentos de Watershed con preprocesamiento es de 53% y 47% para Watershed con post procesamiento. Para procesos en paralelo el 57.8% del promedio total de ejecución de la aplicación es para la CPU y el 42.2% corresponde a las GPU. Para el primer escenario se utilizó un 90% de tiempo de CPU, el segundo escenario utilizó el 15% de tiempo de CPU. Es decir, hubo una mejora de 75% comparando los dos escenarios. (Fernández, 2020)

Calle & Chicaiza (2020), en su estudio se plantean como “objetivo general desarrollar un sistema para la clasificación y reconocimiento de nódulos en imágenes mamográficas utilizando procesamiento digital de imágenes y redes neuronales” (Calle & Chicaiza, 2020). Para ello,

utiliza como metodología el enfoque mixto y el tipo de estudio corresponde a descriptivo y correlacional, al definir una hipótesis de investigación. Para empezar, desarrollaron una base de datos en cuanto a las lesiones nodulares, posterior a esto mediante métodos de procesamiento digital se pueda extraer la imagen mamográfica. Utilizaron el lenguaje de programación de software libre Python y la edición se la realiza en Anaconda con la aplicación Jupyter Notebook. Obteniendo como resultados que el perfeccionamiento del procedimiento basado en proceso digital de imágenes y redes neuronales permite la categorización y la inspección de nódulos en las mamografías. Se concluye que con la interfaz gráfica desarrollada proporcionar y presentar de forma sencilla los resultados de identificación y categorización de nódulos mamarios. A esto se suma, el análisis de los parámetros de desempeño de la CNN con 224 imágenes alrededor de 75 por clase, obteniendo con resultados aproximados de un 0,91 de exactitud, una pérdida mínima de 0,23, 0,99 en precisión y 0,99 f1 score.

Finalmente, se expone el trabajo Doctoral en Tecnologías de Información propuesto por Ramírez (2020), cuyo objetivo es proponer un método computacional de segmentación automática de mamografías digitales DICOM en aplicaciones móviles. En donde se establece un método para el procesamiento automático de mamografías DICOM, mediante dos fases la de preprocesamiento y segmentación. Los resultados obtenidos consisten en eliminar algunas variables que por defecto tienen las mamografías digitales de esta manera reducir los falsos positivos detectados. Es así que se llegó a reducir el área de imagen en un 55,18% de la región mamaria del cálculo computacional. Además, las técnicas utilizadas permitieron reducir el ruido y realzar el contraste proporcionado un rendimiento de 54,15 dB y 53,87 dB, encontrando que en el procesamiento de imágenes dos agentes de alta criticidad: el intercambio de imágenes de 2873 x 3636 y las técnicas utilizadas para la segmentación que genera alto cálculo computacional. El autor concluye la gran oportunidad de desarrollar un entorno basado en

agentes utilizando una aplicación móvil, con lo cual se pudo optimizar el uso de recursos computacionales.

1.1.1 Resumen del Estado de Arte

El resumen del Estado del Arte del presente estudio se evidencia en la Tabla 2, en donde se expone las referencias bibliográficas de la investigación

Tabla 2*Resumen del Estado del Arte*

Autor	Performance	Preprocesamiento	Segmentación	Clasificación	Post Procesamiento	Métricas	Base de datos
(Fernández, 2020)	(53% ,47%) Watershed. (57.8%) Procesos en paralelo. (42.2%) CPU.	E/S con OpenCV. Median Filter. Otsu. Morfología matemática con Opening y Closing.	Watershed	N/A	Histogramas similares. HE.	Mean Square Error (MSE). PeakSignaltoNoise Ratio (PSNR).	53 imágenes de INbreast.
(Calle & Chicaiza, 2020)	N/A	Median filter. Thresholding Python. Morfología matemática con dilatación.	Sobel	Red neuronal convolucional basandose en el estandar BIRADS.	N/A	Métrica para CNN matriz de confusión.	Base de datos CBIS-DDSM
(Ramírez, 2020)	Reducción de tiempo, para CPU en 31.23% y para la Ejecución de técnicas el tiempo se reduce en 36.94%.	E/S con OpenCV y Pydicom. Median Filter, Clahe, Otsu, Morfología matemática con dilatación.	Watershed	N/A	Histogram Equalization(HE).	Mean Square Error (MSE). PeakSignaltoNoise Ratio (PSNR).	115 casos proporcionados por INbreast.
(Holalu & Arumugan, 2006)	Proporcionó 96% y 94% de precisión	Fuzzy Filter HE Pectoral Muscle Separation	N/A	SVM, MPL	N/A	Mean, Variance	Imágenes Mamográficas Propias

Nota: Esta tabla contiene un resumen del estado del arte. Elaborado por: los Autores.

1.2 FUNDAMENTACIÓN TEÓRICA

Esta sección describe información relevante sobre conocimientos médicos necesarios para abordar el proyecto. Como son glándulas mamarias, cáncer de mama lesiones mamarias entre otros.

1.2.1 Glándulas Mamarias

Las glándulas mamarias poseen una estructura compleja, ubicada en el pecho y conformada por el tejido conjuntivo, mamario y grasa, como se presenta en la Figura 1. Denominado también como mamas, no posee músculo y se encuentran situadas simétricamente. Es así que, su función principal en la mujer corresponde la nutrición del recién nacido.

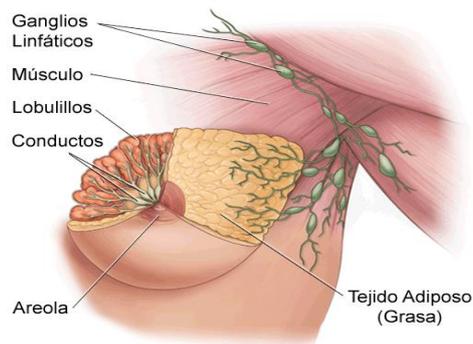
De acuerdo a (Latarjet & Ruiz, 2008):

La mama se encuentra compuesta por 15 y 20 componentes llamados lóbulos, colocados como los pétalos de una margarita, en cada prominencia se cuenta con lobulillos de menor tamaño que terminan en bulbos minúsculos, en donde se genera la leche. Estos elementos se unen mediante canales delicados llamados ductos, y por medio de los mismos se llega al pezón que comprende en un área oscura de la piel nombrada areola.

(pág. 34)

Figura 1

Estructura glándula mamarias



Nota: Información de la estructura de la glándula mamaria. Fuente: (Latarjet & Ruiz, 2008)

1.2.2 Cáncer de Mama.

El aumento a nivel mundial de casos de cáncer de mama (CaMa) se deben a cambios en el sistema reproductivo, influye también el estilo de vida, y la biología de los grupos étnicos. Se conoce que después del cáncer de piel, el cáncer de mama es el cáncer que se establece más comúnmente en las mujeres. Es importante aclarar que este tipo de tumores que afectan a las glándulas mamarias es un padecimiento en la cual las células de la mama se multiplican sin control pudiendo comenzar en cualquier parte de la mama. Dentro de los tipos más comunes de cáncer de mama se expone los siguientes con mayor frecuencia:

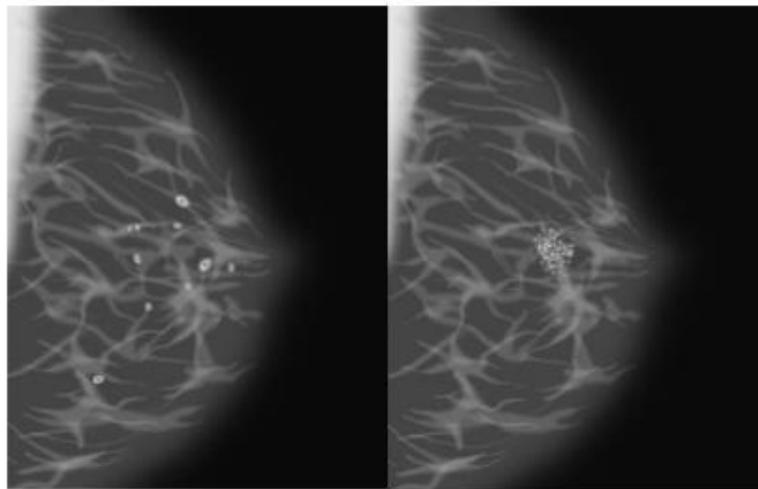
- Carcinoma ductal infiltrante. Aparecen en los conductos, posterior brotan y se multiplican en otros tejidos mamarios, pudiendo generar metástasis (Armitage, Lichter, Allen, & Niederhuber, 2000).
- Carcinoma lobulillar infiltrante. Aparecen en los lobulillos desimanándose en los lobulillos de las mamas, también pueden aparecer en otras partes del cuerpo (Armitage, Lichter, Allen, & Niederhuber, 2000).

1.2.3 Lesiones Mamográficas.

Las alteraciones mamográficas pueden presentarse en forma de macro o microcalcificaciones, conocidos también como nódulos, masas, densidades asimétricas o alteraciones en la estructura de la mama. Inclusive suelen ser cúmulos de calcio que pueden identificarse en la mamografía al tener un contraste mayor. De acuerdo a (Komen, 2006), las macro calcificaciones son depósitos de calcio de gran tamaño y las microcalcificaciones son de pequeño tamaño que en algunos casos suelen indicar presencia de cáncer, como se muestra en la Figura 2.

Figura 2

Macrocalcificaciones y Microcalcificaciones



Nota: Alteraciones mamográficas. Fuente: (Komen, 2006)

1.2.4 Imágenes de Rayos X

Las imágenes de Rayos X fueron descubiertas por el físico alemán Wilhelm Conrad Roentgen exactamente el 8 de noviembre de 1895, al realizar experimentos con tubos de vacío y un generador eléctrico. Se conoce que los rayos X son un tipo de radiación llamada ondas electromagnéticas que muestran el interior del cuerpo humano. Es importante manifestar que sus imágenes son expuestas en diferentes tonos de blanco y negro, porque se ha investigado que otros tejidos impregnan desiguales aumentos de radiación. Se conoce que el calcio en los huesos

es absorbido en los rayos X, apareciendo de un color blanco, mientras que otros tejidos se aprecian un color gris ya que absorben menos color estos son la grasa y otros tejidos blandos, es así que el aire absorbe la menos cantidad, haciendo que los pulmones se ven negros. “La radiación electromagnética, utiliza como método los Rayos X que permiten transmitir una mayor cantidad de energía para atravesar la mayoría de objetos. Por ello, su utilización permite obtener imágenes del cuerpo como tejidos y estructuras óseas dentro del cuerpo” (Thomas & Banerjee, The History of Radiology, 2013).

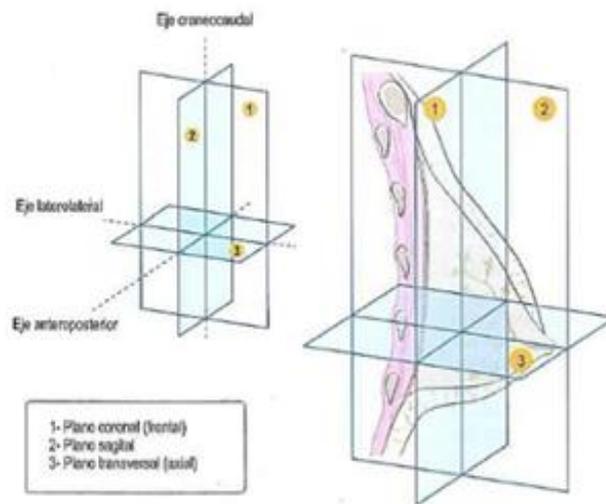
1.2.5 Mamografías

Con el incremento acelerado a nivel mundial en casos particularmente de mujeres relacionados con cáncer de mama, se ha desarrollado la mamografía como técnica de diagnóstico. La cual comprende en obtener una imagen radiológica plana en donde se puede observar el tejido de la mama. De tal manera que se pueda detectar lesiones que pueden terminar en tumores cancerígenos (Asua, 2005). Para ello, estudios previos en lo referente a medicina han determinado que para realizar el análisis de la mama se divide considerar 3 planos como se muestra en la Figura 3:

- Plano transversal o axial
- Plano sagital
- Plano coronal o frontal

Figura 3

División de planos para análisis de mamas

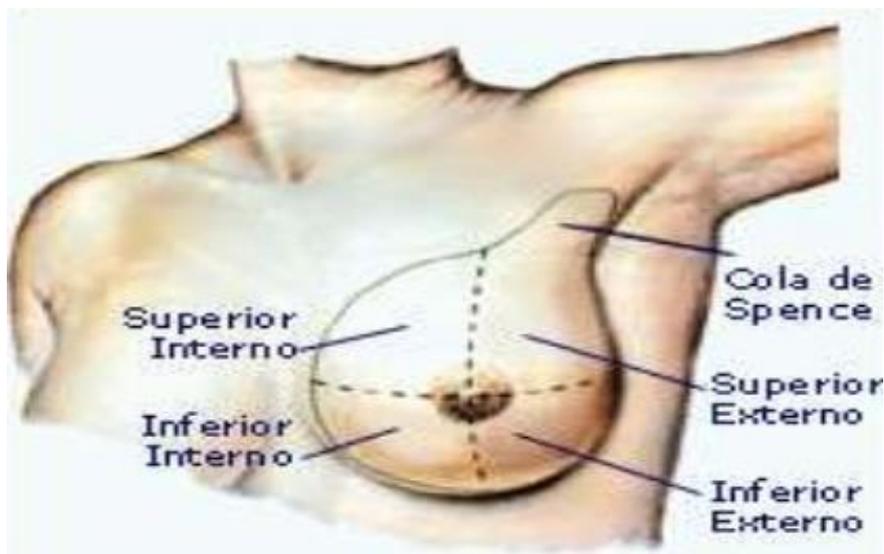


Nota: Análisis Planos de las Mamas. Fuente: (López & Pina, 2016)

Según lo expuesto por (López & Pina, 2016) es necesario dividir en cuatro cuadrantes a la mama, Figura 4.

Figura 4

Cuadrantes mamarios



Nota: Cuadrantes mamarios explicado. Fuente: (López & Pina, 2016)

Las técnicas de imagen en patología mamaria se basan en un estudio convencional en donde se ejecutan dos resonancias, la primera de cráneo-caudal (CC) y segunda de oblicua-medio-lateral (OML). Donde, la ejecución de las imágenes de cada mama es primordial, así se puede disminuir el error de encontrar lesiones en una sola proyección (Álvarez & Cara, 2015). En la última década, la introducción de mamografía digital de campo completo FFDM (del inglés, Full-Field Digital Mammography) ha dado mayores beneficios para detección y diagnósticos de cáncer de mama (Camargo de Siqueira Ferreira, Sá de Camargo Etchebehere, Barbosa, & de Barros, 2018). Sin embargo, en la mayoría de imágenes de mamografías se encuentra gran dificultad en interpretar dichas imágenes debido a la compleja morfología del tejido de la mama y el número de parámetros de imagen que afectan una adecuada resolución (Dos Santos Teixeira, 2013). Siendo importante, implementar un algoritmo de inteligencia artificial con una mayor exactitud de las clasificaciones de imágenes, que brinde un mejor panorama al médico especialista para su posterior análisis, diagnóstico y tratamiento.

Las masas que se forman en cualquiera de la mama corresponden a un bulto o protuberancia con particulares morfología, márgenes y densidad. Es así, que de acuerdo a la publicación presentada por (Pavón, y otros, 2012) un nódulo puede tener la siguiente forma redonda, ovalada, redondeada o irregular. Por otra parte, se cuenta con una clasificación BI-RADS que comprende al análisis en cuanto factores como sus márgenes y densidad, como se puede evidenciar en la Figura 5 y se detalla en la Tabla 3.

Tabla 3

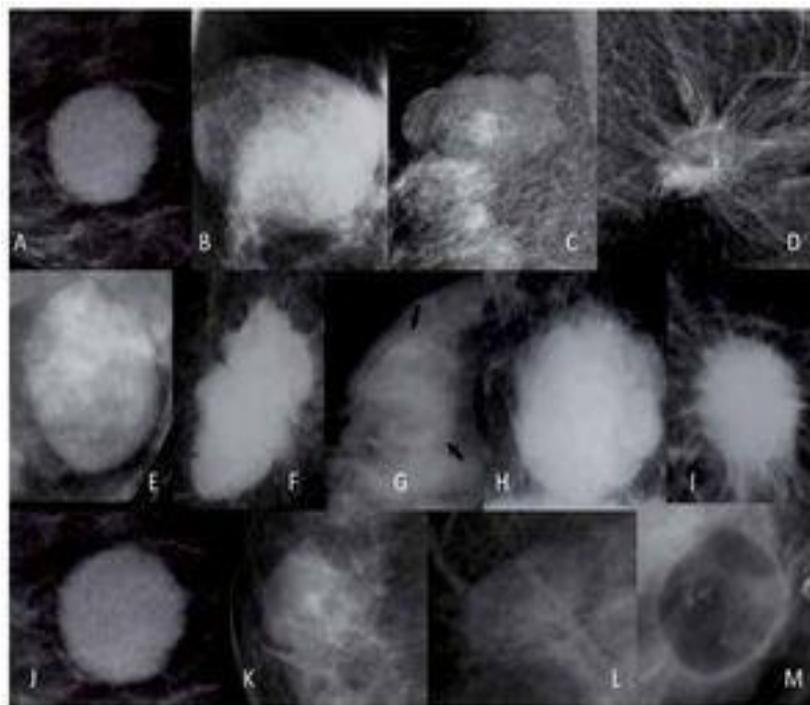
Características de las lesiones nodulares

Característica	Descripción	
MORFOLOGÍA(MO)	A	(MO)Redonda
	B	(MO)Ovoidea
	C	(MO)Lobulada
	D	(MO)Irregular
MÁRGENES(MA)	E	(MA)Circuncritos
	F	(MA)Microlobulados
	G	(MA)Oscurecidos
	H	(MA)Mal definidos
	I	(MA)Espiculados
DENSIDADES(DE)	J	(DE)Alta
	K	(DE)Iso densa
	L	(DE)Sin grasa
	M	(DE)con grasa

Nota: Esta tabla contiene la clasificación de las lesiones nodulares.

Figura 5

Morfología de las lesiones nodulares



Nota: Formas de lesiones nodulares. Fuente: (Pavón, y otros, 2012)

Se ha establecido la clasificación BI-RADS para categorizar a las masas encontradas de tal manera que puedan ser evaluarlas y tener un mejor seguimiento y control. Para ello, se han categorizado de 1 a 6 en función de la probabilidad o riesgo de malignidad, en la Tabla 4, además se exponen ciertas características de los BI-RADS.

Tabla 4

Características de las lesiones nodulares

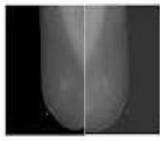
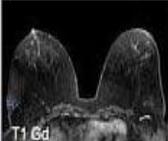
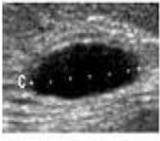
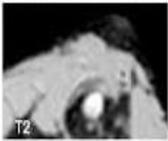
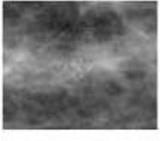
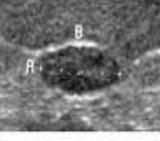
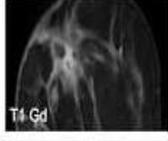
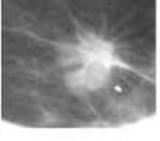
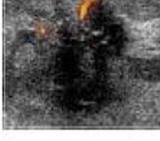
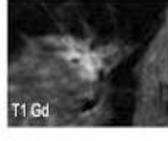
BI-RADS	Descripción	Hallazgo
BI-RADS 0	Prueba incompleta	Las imágenes no se pueden interpretar, se requiere pruebas e imágenes adicionales para una evaluación final.
BI-RADS 1	No hay presencia de cáncer	Los resultados son negativos, sin embargo, realizar exámenes de rutina.
BI-RADS 2	Presencia de masas benignos	Los resultados son normales, sin indicios de cáncer, con presencia de quistes benignos, realizar visitas de rutina
BI-RADS 3	Resultados de la mamografía probablemente sean normales, pero hay un 2% de posibilidades de cáncer	Baja probabilidad de cáncer, se recomienda vistas periódicas cada 6 meses
BI-RADS 4	Posibilidad de cáncer entre un 20 y 35%, se divide en tres categorías: 4A: Baja sospecha de cáncer 4 B: Sospecha moderada 4 C: Alta sospecha	Al existir un hallazgo sospecho de posibilidades de cáncer se debe realizar una biopsia
BI-RADS 5	Alta sospecha de cáncer al menos 95%	Al detectar la presencia de células cancerígenas se debe realizar una biopsia para confirmación de resultados y tratamiento.
BI-RADS	Diagnóstico prescrito de cáncer con resultados de biopsia	Obtención de imágenes mamográficas para comparar como está respondiendo el tratamiento

Nota: Esta tabla contiene el sistema de puntuación BI-RADS de hallazgos anormales

Las lesiones modulares categorizadas por el sistema de puntuación BI-RADS, se presentan en las imágenes mamográficas de la Figura 6.

Figura 6

BI-RADS Lesiones nodulares

BI-RADS Category	A. Mammography	B. Ultrasound	C. MRI	
1				Almost entirely fatty. No abnormality
2				A. Involuting, calcified fibroadenoma B,C. Simple Cyst
3				A. Cluster of punctate calcifications B. Solid mass, most likely fibroadenoma C. Seroma postbiopsy probable inflammatory changes
4				A. Pleomorphic calcifications B. Complex cyst C. Lobulated solid mass, kinetic curve: type II
5				A,B,C. Spiculated mass

Nota: Lesiones nodulares. Fuente: (López & Pina, 2016)

1.2.6 Clasificación de imágenes médicas.

Para clasificar las imágenes médicas se debe considerar el sistema visual que el ser humano tiene. De acuerdo a (Karpathy, 2016) este recibe las ondas electromagnéticas que pertenecen al espectro visible para luego puedan ser interpretadas por el cerebro. Al aplicar en el campo de la medicina los sistemas artificiales permiten que el diagnóstico sea corroborado con la imagen interpretada por el especialista. Para ello, se han utilizado patrones matemáticos empleando diversos métodos analíticos como las redes neuronales. Tal es el caso que se plantea algunos tipos de algoritmos de clasificación como el algoritmo de Canny que se basa en la detección de bordes (Canny, 1986). También se resalta el algoritmo de KNN que se basa en medir la

diferencia entre los valores de pixel para comparar la similitud entre imágenes (Altman, 1992). Finalmente, el modelo de Deep Learnig que comprende en el procesamiento de información no lineal para extraer características particulares y patrones de esta manera clasificarlos.

1.2.7 Procesamiento Digital.

El formato DICOM (del inglés Digital Imaging and Communications in Medicine), corresponde a un archivo formado por un encabezado y un cuerpo de datos de imagen digital. Por lo consiguiente, se puede mencionar que con esta técnica se obtiene sobre una placa dos proyecciones de cada mama en forma simétrica (Ballesteros, 2003). Con el pasar de los años se ha mejorado la tecnología DICOM, permitiendo soportar imágenes, videos, señales e informes estructurados. En la actualidad se cuenta con la versión 3.0, la misma que es aplicable en lo relacionado a las imágenes médicas. Generalmente comprende la transmisión hasta el tratamiento e impresión, sin importar la derivación médica que la expida. A esto se suma que se conoce que los equipos médicos que desarrollan sus procesos con tecnología DICOM pueden obtener imágenes con la capacidad de ser archivadas y visualizadas en un mismo PACS. Sin embargo, la utilización de DICOM 3.0 no cuenta con una garantía de respaldo respecto al sistema de imágenes. (Ballesteros, 2003)

De esta manera, se obtiene la vista cráneo-caudal, en donde se aprecia el cuadrante superior interno de la posición vertical de la mama, mientras que la vista medio-lateral oblicuo proyecta una imagen oblicua cuyo rango de medición esta entre 30° y 60° de la mama.

1.2.8 Sistema Operativo CentOS 7

Dentro de las características que CentOS 7 cuenta como sistema operativo se resalta lo siguiente:

- Único sistema operativo relacionado con el hosting web cPanel.

- Reducción de caídas y errores.
- Código abierto como Apache Web Server, Samba, Sendmail, CUPS, vsFTPd, MySQL y BIND.
- Aumento de rendimiento y mejor equilibrio de carga de los recursos de los equipos
- Mejor acceso de seguridades a todo nivel.
- Soporte a largo plazo (6 años) y seguridad actualizada.
- Mejor estabilidad a largo plazo. (Hosting y Servidores, 2018)

1.2.9 Java SDK

JDK es el kit de desarrollador de Java el cual está formado por varias herramientas, documentos, utilidades y aplicaciones Java. Permite la ejecución de los programas Java (*.class). Incluye varias funciones como son:

- Un (Java Compiler)
- JVM java virtual maquine.
- Supervisor, depurador y documentación.
- GUI fácil de usar
- Acceso a bases de datos remotas (bibliotecas especializadas).

1.2.10 Cmake

Cmake es un conjunto de herramientas de código abierto que facilita el diseñar, construir, probar y empaquetar software Para ello se utiliza archivos de configuración independientes de la plataforma y compiladores simples, y generar makefiles nativos con espacios de trabajo para cualquier entorno (Corporación CMake, 2021). El archivo de configuración básica llamado cmakelists.txt cuenta con la siguiente estructura:

```
cmake_minimum_required(VERSION 3.6.0)
enable_language(ASM_NASM)
add_library(test-yasm SHARED jni/test-yasm.c jni/print_hello.asm)
```

Cmake, se compila con el código ensamblador escrito en YASM con la arquitectura x86 y x86-64. YASM es ensamblaje de carácter abierto, que comprenden a las arquitecturas x86 y x86-64 basado en NASM.

1.2.11 QT Creator

Es un (IDE) de varias plataformas para los desarrolladores de aplicaciones donde puedan creen aplicaciones de escritorio y de dispositivos móviles, como Android y iOS (Corporación Qt Creator, 2021). Cuenta con algunas características que lo hacen rápido y productivo para los desarrolladores:

- “C/C++, QML y ECMAscript
- rápida navegación del código
- Control estático al código y estilo a medida
- Soporte de código
- code folding
- Paréntesis coincidentes y modos de selección” (Corporación Qt Creator, 2021).

1.2.12 NDK de Android

Esta herramienta permite la fácil implementación y compilación de código para aplicativos Android en lenguajes como java, C y C++.Permite la creación de código más rápido y Optimizado. En algunos tipos de apps, permite reutilizar bibliotecas de códigos escritas en este tipo de lenguaje. (Developers, 2021)

1.2.13 Aplicación móvil

Una app (en inglés) corresponde a una aplicación delineada a teléfonos inteligentes u otros elementos móviles. De igual manera, admite ejecutar programas en dispositivos pequeños con

recursos limitados. En todo lo que a su interrelación con la inteligencia artificial (IA) es muy beneficiosa para ser utilizada (Castillo, 2021).

1.2.14 Librería DCMTK

DcmTk es un conjunto de librerías que cuenta en gran parte con el estándar DICOM, que facilitan el envío de imágenes a través de una red. DCMTK se escribe en una mezcla de ANSI C y C++ para lo cual se puede usar para generar los archivos con las librerías CMake. Cuenta con el código fuente completo y es de código abierto. Se puede usar bajo S.O Windows, Unix, incluidos Linux, Solaris, FreeBSD, OpenBSD, MacOS X y NetBSD. Para el uso del código se puede descargar el archivo dcmTk.zip y realizar la configuración que proporcionada en la página oficial de la librería.

1.2.15 Hybrid Median Filter (HMF)

La técnica HMF es un filtro de ventana, para clases no lineales, que eliminan fácilmente el ruido impulsivo mientras se preserva los bordes y tiene una mejor conservación de las esquinas. "Aplicar filtro mediano con máscara cruzada, aplicar filtro mediano con máscara x y tomar la mediana de los resultados obtenidos y el elemento en sí" (Dicom, 2021).

$$\begin{array}{ccc} A & B & C \\ D & E & F \\ G & H & I \end{array}$$

$$h_1 = \text{median}(A, E, I)$$

$$h_2 = \text{median}(C, E, G)$$

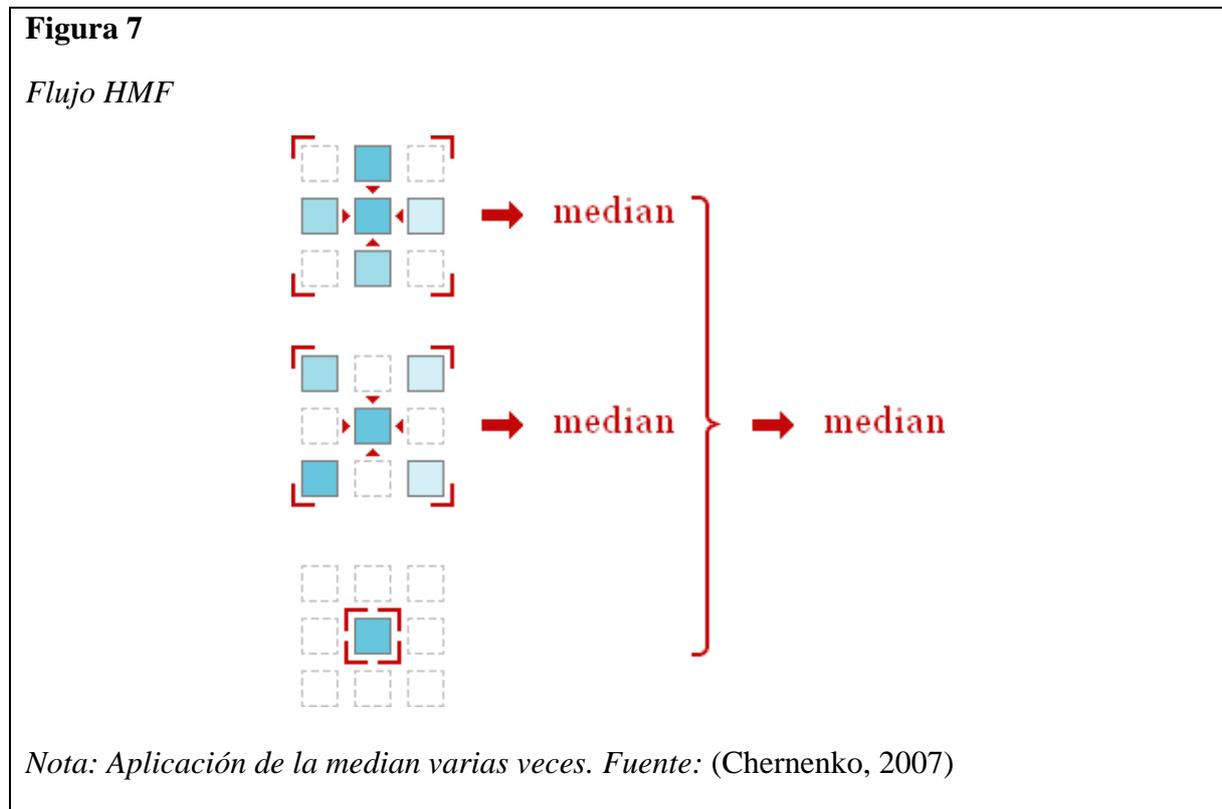
$$h_3 = E$$

$$\text{new pixel value} = \text{median}(h_1, h_2, h_3)$$

La matriz 3x3 hace referencia a la ventana deslizante con 9 valores como píxeles. El elemento E representa el píxel central al que apunta la ventana deslizante. El nuevo elemento valor del

pixel para reemplazar el pixel objetivo se determina a partir de los 3 elementos. Gracias a este método el HMF tiene una mejor característica de conservación de esquinas que el filtro mediano estándar. (Muhammad Sailuddin Darus, 2016)

Como podemos ver en la Figura 7 la idea es aplicar la técnica mediana varias veces cambiando la forma de la ventana y tomando los valores que se obtienen de la mediana.



1.2.16 Clahe (CH)

Clahe es una técnica de limitación de contraste a cada punto de cuadrícula de vecindad dentro de una región específica desde la cual se deriva la transformación. El algoritmo implica la partición de una imagen en escala de grises dada en regiones contextuales y luego ecualiza el histograma de cada región (Zheng & Sun, 2016).

Para obtener el valor final se realiza un mapeo con los pesos de cada zona interpolada siguiendo la fórmula:

$$m(i) = a[b.M_i + (1 - b).M \pm (i)] + [1 - a]. [bM \pm (i) + (1 - b.M + (i))]$$

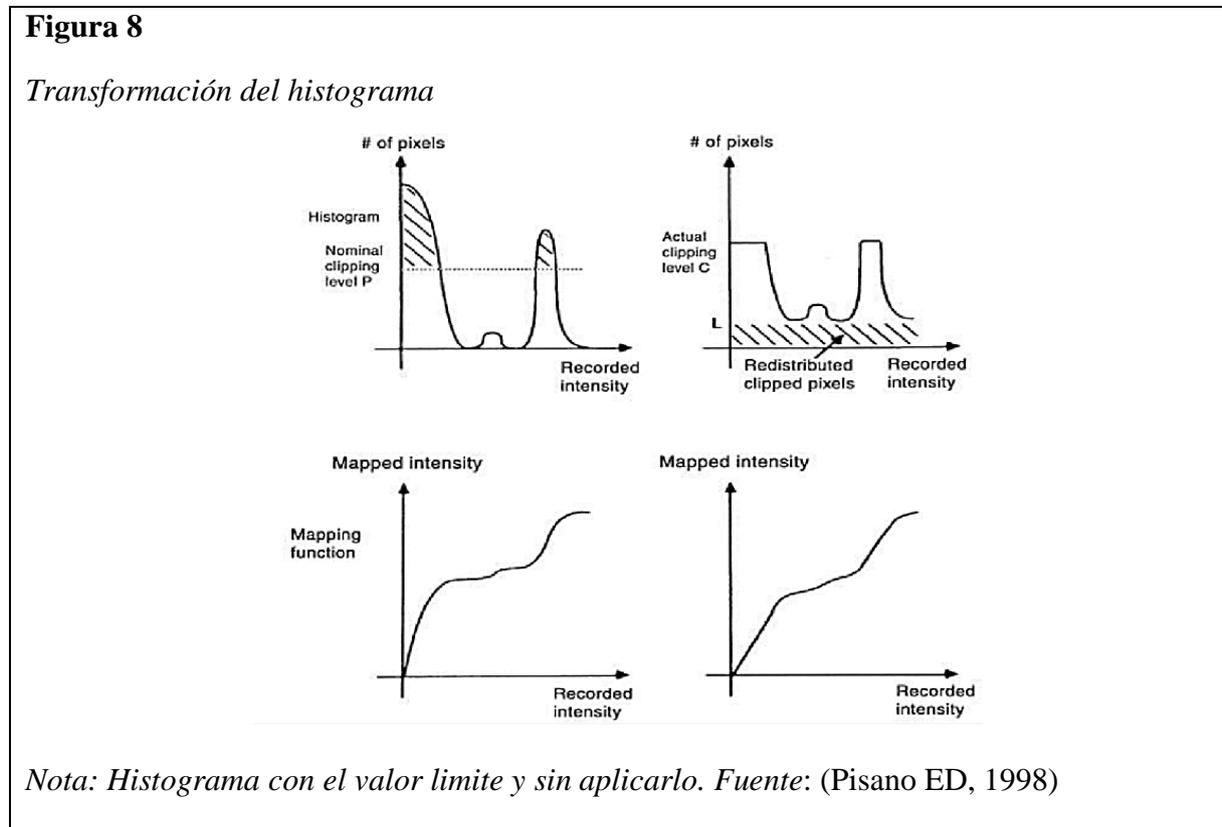
Donde:

$$a = [y \pm y_1]/[y \pm y_1]$$

Y

$$b = [x \pm x_1]/[x \pm x_1]$$

En consecuencia, el CLAHE confina el histograma con un valor predestinado antes de automatizar la función de distribución, la pendiente de la función de transformación se verá modificada al fijar el valor límite. Este valor límite está relacionado con la normalización del histograma, y por tanto depende del tamaño de la región (Yébenes Calvo, 2016). Figura 8.



Las cuantificaciones de ingreso del algoritmo influyen en la obtención de resultados la realizar una buena elección permite detectar de mejor manera las anomalías de lo contrario se puede

empeorar el diagnóstico de la imagen, los parámetros son los que se pueden editar presentados en la Tabla 5.

Tabla 5

Parámetros modificables en el algoritmo.

Parámetro	Valor
Tamaño de las regiones	Dimensiones de regiones.
Valor límite	[0, 1] # límite.
Número de barras del histograma	# de intervalos del HE
Rango	rango de salida
Distribución	distribución del histograma.
Alfa	# de distribución.

Nota: Valores del algoritmo CH. Fuente: (Yébenes Calvo, 2016).

1.2.17 Otsu (OT)

En cuanto al método de umbralización de Otsu se debe manifestar que su criterio respecto al discriminante lineal asume que la imagen consta de un solo objeto primer plano y fondo, y se ignora la heterogeneidad y diversidad del fondo. Es así que Otsu determinó el umbral para tratar de minimizar la superposición de las distribuciones de clases. Por lo tanto, en base a esta conceptualización, el método de Otsu segmenta la imagen en dos regiones claras y oscuras T_0 y T_1 .

Donde:

$$T_0$$

Es un conjunto de niveles de intensidad de 0 a t o en notación de conjunto.

$$T_0 = \{0, 1, \dots, t\}$$

$$T_1 = \{t, t + 1, \dots, 1 - 1, 1\}$$

Donde:

t es el valor umbral

T_0 y T_1 se pueden asignar al objeto y al fondo o viceversa.

De acuerdo a (Yousefi, 2015) “El método de umbral de Otsu escanea todos los valores de umbral posibles y calcula el valor mínimo para los niveles de píxeles a cada lado del umbral”. El objetivo es encontrar el valor umbral con la entropía mínima para la suma del primer plano y el fondo. Es así que este método de Otsu establece como dato principal en lo que respecta la estadística de la imagen donde, para un valor de umbral elegido t . Para luego, calcular el valor de la varianza de los grupos T_0 y T_1 . “El valor de umbral óptimo se calcula minimizando la suma de las varianzas del grupo ponderado, donde los pesos son la probabilidad de los grupos respectivos” (Yousefi, 2015). Dado $p(i)$ como las probabilidades del histograma del valor gris observado.

$$i = 1, \dots, 1$$

$$p_{(j)} = \frac{n\{(r, c) \text{ img}(r - C) \cdot i\}}{(R, C)}$$

Donde:

r, c: es el indice fila y columna

R, C: es el numero fila y columna

Es así que se puede determinar que:

$$wb(t), \mu n(t) \text{ y } \sigma 2b(t)$$

Como el peso, la media y la varianza de la clase T_0 con un valor de intensidad de 0 a t , respectivamente.

$$wf(t), \mu_f(t) \text{ y } \sigma^2_f(t)$$

Como el peso, la media y la varianza de la clase T1 con un valor de intensidad de t+1 a 1, respectivamente. σ^2_w como la suma ponderada de las varianzas del grupo (Qu & Zhang, 2010). El mejor valor de umbral t^* es el valor con la varianza mínima dentro de la clase. Donde la varianza dentro de la clase se define de la siguiente manera:

$$\sigma_w^2 = w_b(t) * \sigma_b^2(t) + w_f(t) * \sigma_f^2(t)$$

1.2.18 Canny (CNY)

Canny desarrolló un enfoque para obtener una ventaja óptima para lidiar con los bordes escalonados. En lo expuesto por (Xu, Varadarajan, & Chakrabar, 2014) el algoritmo de Canny consiste en calcular el gradiente horizontal G_x y gradiente vertical G_y y en cada ubicación de píxel convolucionando con máscaras de degradado. Para ello, se obtiene el cálculo de la magnitud del gradiente G y dirección θ G en cada ubicación de píxel. Se considera que se debe aplicar no máxima Supresión (NMS) para bordes delgados este paso implica calcular la dirección del gradiente en cada píxel.

$$Edge_{Gradient(G)} = \sqrt{G_x^2 + G_y^2}$$

$$Angle(\theta) = \tan^{-1}\left(\frac{G_x}{G_y}\right)$$

Cuando el píxel es la dirección del gradiente es una de las 8 direcciones principales posibles:

$$(0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ)$$

La magnitud del gradiente de este píxel se compara con dos de sus vecinos inmediatos a lo largo la dirección del gradiente y la magnitud del gradiente. Para ello, se establecen en cero si no corresponde a un máximo local para el gradiente direcciones que no coincidan con una de

las 8 principales posibles direcciones, se realiza una interpolación para calcular las gradientes vecinales.

Se debe indicar que el cálculo de umbrales alto y bajo están basados en el histograma de la magnitud del gradiente para toda la imagen. Además, el umbral alto se calcula de tal manera que un porcentaje P de los píxeles totales de la imagen se clasificarían como bordes fuertes. En otras palabras, el umbral alto corresponde al punto en que el valor de la magnitud del gradiente acumulado.

$$G_{\sigma} = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}}$$

La realización de umbralización de histéresis para determinar el mapa de borde, cuando la magnitud del gradiente de un píxel es mayor que el umbral alto, este píxel se considera como un borde fuerte. En el caso que la magnitud del gradiente de un píxel es entre el umbral bajo y el umbral alto, el píxel es etiquetado como un borde débil. A estos bordes fuertes se interpretan como “ciertos bordes”, y pueden ser incluidos inmediatamente en el final imágenes de borde. Los bordes débiles se incluyen si y solo si son conectados a bordes fuertes. (Zhao, Qin, & Wang, 2013)

1.2.19 Watershed (WH)

Esta técnica permite definir la segmentación de imágenes de áreas de gris. Por lo tanto, se comprende que este método de segmentación basado en regiones, divide al dominio de la imagen en aspectos que son vinculados, usualmente se puede aplicar en imágenes 2D y 3D.

El concepto de Watershed procede del campo de la topografía: en un relieve topográfico, las líneas Watershed son las fronteras de separación entre las cuencas de deyección de ríos y lagos. Además, cada cuenca está asociada a un mínimo local de relieve. Se puede

dar una definición rigurosa de la transformación Watershed utilizando los conceptos de distancia topográfica y la teoría de Grafos (Ortuño, y otros, 2001, pág. 123).

Para cualquier conjunto A y cualquier conjunto $B \subset A$ hecho de varios componentes conectados B_i a zona de influencia geodésica $iz_A(B_i)$ o B_i en A es el locus de los puntos de A cuya distancia geodésica a B_i es estrictamente más pequeña que su distancia geodésica a cualquier otro componente de B. Definimos la siguiente recursividad (Y. Zhou, 2012):

$$X_{h_{min}+1} = \overline{F_{h_{min}+1}} = MYON_{h_{min}}$$

$$X_{h+1} = MIN_h \cup YOZ_{\overline{F_{h+1}}}(X_h)$$

Dónde:

$$h_{min}$$

Es el valor gris más bajo de F, donde $IZ_{\overline{F_{h+1}}}(X_h)$ es la unión de las zonas de influencia geodésica de los componentes conectados de X_h en $\overline{F_{h+1}}$ y donde MIN_h es la unión de mínimos de con nivel de gris igual a h. Las líneas divisorias de aguas son el complemento de $X_{h_{max}+1}$ (Y. Zhou, 2012).

Watershed se plantea como un sistema de transformación de imágenes que cambia la escala de grises dando una definición morfológica para el caso discreto (y aplicable por tanto al caso de las imágenes digitales). Se conceptualiza como una constructiva que extiende las cuencas mediante la simulación de un proceso de inundación a partir de los mínimos locales “Se han propuesto distintos algoritmos eficientes para hallar la transformación Watershed en imágenes digitales multinivel” (Ortuño, y otros, 2001). A estos se les asigna una fórmula específica a los píxeles integrantes correspondientes a las Watershed, que forman el límite de apartamiento entre regiones Watershed. A esto se suma que cada una de las etiquetas correspondiente a estas regiones deben tener un valor identificativo que facilite el tratamiento (Ortuño, y otros, 2001).

1.2.20 SVM

SVM, corresponde al sistema de aprendizaje para clasificar datos en dos grupos utilizando un espacio de características de alta dimensión. SVM tiene una característica que no es propiedad de common máquina de aprendizaje, que está en proceso de encontrar el mejor hiperplano para generar el tamaño máximo de margen entre la entrada tamaño en lugar de lineal al espacio usando reglas del kernel. (Amat, 2017).

Máquinas de Soporte Vectorial, proporciona un aprendizaje de clasificación modelo de análisis y un algoritmo en lugar de un modelo de regresión y un algoritmo. Usa el modelo matemático simple $y = wx + \gamma$. y lo manipula para permitir la aplicación lineal división principal

$$y = wx + \gamma.$$

Para esto se cuenta con la Máquinas de Soporte Vectorial la misma que puede dividirse en lineal y no lineal. Se llama máquina de soporte de vector lineal si el dominio de datos se puede dividir linealmente para separar las clases en el original y dominio.

Si el dominio de datos no se puede dividir linealmente y si se puede transformar un espacio llamado espacio de características donde el dominio de datos se puede dividir linealmente para separar las clases, entonces se llama máquina de soporte de vector no lineal. Por lo tanto, los pasos en la Máquinas de Soporte Vectorial lineal son: el mapeo del dominio de datos en un conjunto de respuestas y la división del dominio de datos. Máquinas de Soporte Vectorial no lineales son: el mapeo del dominio de datos a una característica espacio de tura usando una función kernel, el mapeo del dominio del espacio de característica (Suthaharan, 2016).

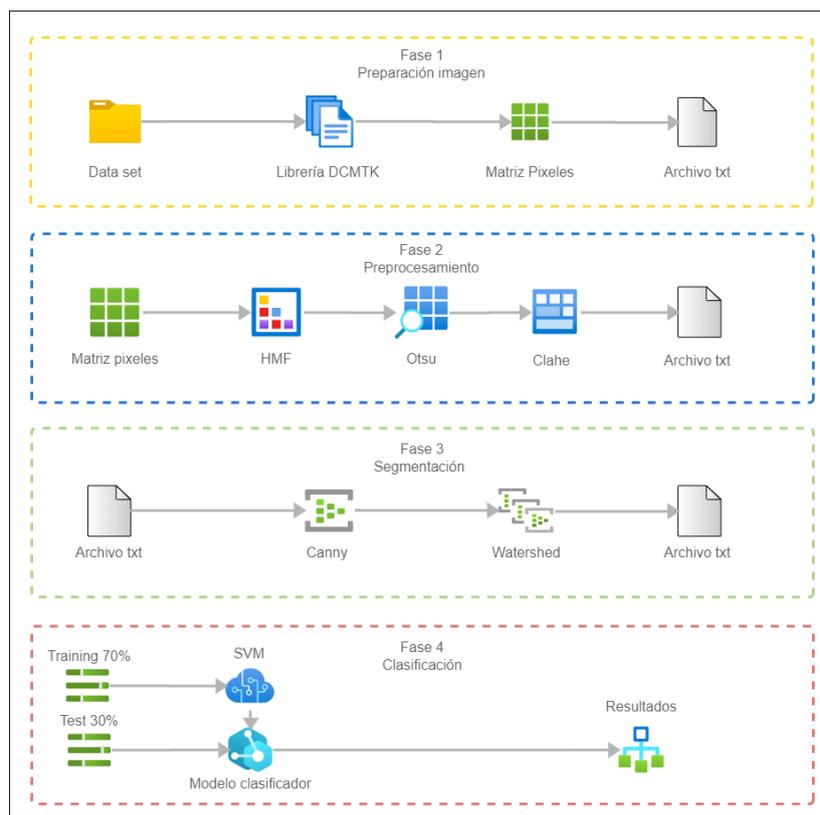
CAPÍTULO 2

2.1 MARCO METODOLÓGICO

En el presente capítulo se explican las fases para llegar a la clasificación de imágenes mamográficas DICOM. Para ello, se muestran las técnicas usadas, como se presenta en la Figura 9 divididas en 4 fases. Fase 1 preparación de imagen donde se implementa la lectura y extracción de píxeles con la ayuda de la librería DCMTK. Fase 2 preprocesamiento, técnicas como Hybrid Median Filter (HMF), Otsu (OT) y Clahe (CH) donde se logra la mejora de la imagen en comparación con la original. Fase 3 segmentación donde con la ayuda de técnicas como Canny (CNY) y Watershed (WH) se obtiene las zonas de interés. Fase 4 clasificación donde usamos Máquinas de Soporte Vectoria (SVM) para finalizar el análisis.

Figura 9

Flujo de proceso



Nota: Fases de la aplicación. Elaborado por: Los Autores

2.1.1 Fase 1: Preparación Imagen

En la fase 1 se realiza la configuración del archivo `cmakelists.txt` para incluir las librerías DCMTK al proyecto en QT Creator y ser usado en el llamado para el análisis de la imagen DICOM ver Anexo A.. Incluyendo solo las librerías a utilizar notando que uno de los llamados más importantes y siempre necesario cuando se hace uso de esta librería es la `osconfig.h` que tiene la configuración inicial para todas las demás. Ver Anexo B.

Para proceder se inicia enviándole a la librería la dirección en donde se encuentra alojada la imagen. Después se almacena en la variable `Z`, el cual va a obtener el conjunto de datos Dicom que va a permitir manejar los datos de la imagen en función de los requerimientos que se necesita ver en el Algoritmo 1. Además, como se aprecia específicamente en la línea 4 se realiza un condicional para saber si la imagen que ingreso es monocromática y si es diferente de null. Una vez que se valida que la direcciones es la adecuada se obtiene los bits que tiene la imagen con el código de la línea 6 y de acuerdo con el número de bit le asignamos el número máximo en la escala de grises con el que puede trabajar la imagen Dicom que está ingresando.

Para obtener los datos de la imagen se realizó el uso de una librería perteneciente a DCMTK llamada `DicomImage`, la cual permite obtener todos los datos la imagen Dicom. Se envía el path de dirección de la imagen para ser guardado en un puntero de tipo `DicomImage` el cual tendrá la información completa. Para obtener la matriz de pixeles de la imagen, ejecutamos el código de la línea 12 donde se guarda en un puntero `X` de tipo `unit16` para poder usarlo en las diferentes técnicas de procesamiento de imágenes.

Algoritmo 1

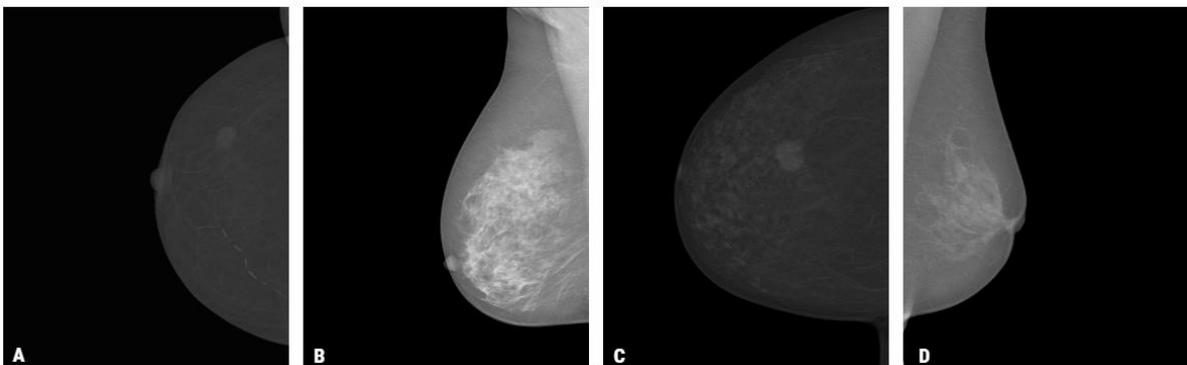
Lectura imagen DICOM usando DCMTK

```
1: Entrada: Imagen  $\rightarrow X$ 
2: Salida: pixeldata  $\rightarrow Y$ 
3: dataset  $\leftarrow X$ 
4: dataset  $\rightarrow Z$ 
5: Si ( $Z \neq \text{null}$  and  $Z = \text{mono.dicom}$ )
6: bits imagen  $\rightarrow E$ 
7:  $W \leftarrow E$ 
8:  $W \leftarrow \text{dataset.(X)}$ 
9: Fase 2
10:  $Y \leftarrow W$ 
11:  $Y \rightarrow \text{bitcount}$ 
12:  $M \leftarrow \text{dataset.dicom}$ 
13:  $X \leftarrow M(Y)$ 
```

Por último, en esta fase se puede generar un archivo .txt o csv, para visualizar los datos de pixeles de mejor forma en un texto plano o matriz. Para tener una vista de la imagen original la propia librería DCMTK nos permite generar una imagen tipo .bmp para ver los resultados en otro formato distinto al dcm. En la Figura 10 se muestra ejemplos de las imágenes mamográficas DICOM usadas en el proyecto antes del procesamiento realizado con el uso de la librería DCMTK. Donde A es masas, B es microcalcificaciones, C son masas con microcalcificaciones y D es una imagen normal.

Figura 10

Imagen original librería DCMTK



Nota: Imagen original. Elaborado por: Los Autores

2.1.2 Fase 2: Preprocesamiento

Esta fase consiste en realizar un preprocesamiento de la imagen, para mejorar la calidad y de esta manera avanzar a la siguiente fase. Para ello, hacemos uso del algoritmo llamado Hybrid Median Filter (HMF). El cual ayuda a reducir el ruido de tipo sal y pimienta que afecta principalmente en la detección de bordes. El llamado a la técnica se realiza pasando 3 parámetros, g que es un puntero de tipo Uint16 que contiene la imagen original en pixeles, w el ancho de la imagen y h el alto de la imagen, donde se realiza en recorrido de la imagen con una ventana de 3×3 . La variable k contendrá la imagen resultante del método HMF, como se puede notar en Algoritmo 2 .

Algoritmo 2

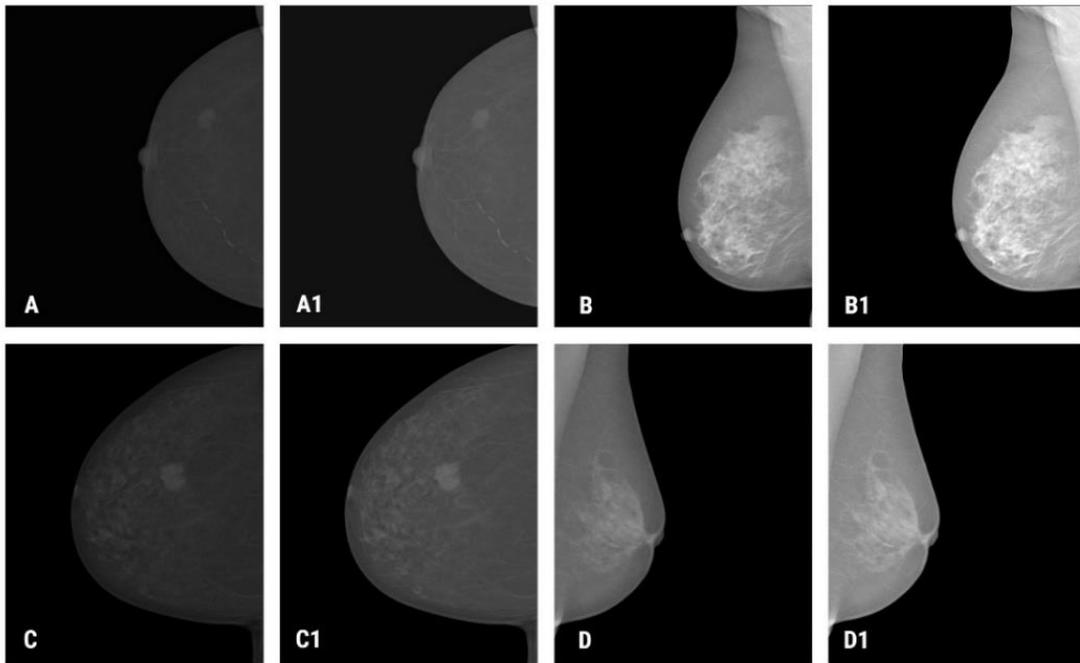
Hybrid Median Filter

```
1: Entrada  $g \rightarrow$  imagen ruidosa,  $w \rightarrow$  width,  $h \rightarrow$  height
2: Salida  $k \rightarrow$  imagen sin ruido
3:  $k \leftarrow g$ 
4:  $i \rightarrow 1$ 
5: for ( $i < w$ ) recorre  $w$ 
6:  $w[i] = w[i+1] + w[\text{index}[i]]$ 
7: while ( $2i-1 \leftarrow w$ )
8:  $g \leftarrow \text{median}([2w-1] \times [2h-1])$ 
9:  $g \leftarrow (g+h)/2$ 
10:  $i \leftarrow i+1$ 
11: return  $k$ ;
```

Para la Figura 11 se aprecia el procesamiento realizado para los 4 tipos de imágenes al aplicar HMF. Donde A es masas y $A1$ es el resultado de A aplicado HMF, B es microcalcificaciones y $B1$ es B aplicado HMF, C es masas con microcalcificaciones y $C1$ es C aplicado HMF, D es normal y $D1$ es D aplicado HMF.

Figura 11

Imagen HMF



Nota: Imagen HMF. Elaborado por: Los Autores

Posteriormente se ejecuta Otsu para encontrar el umbral óptimo para cada imagen, valor que se utilizó en la técnica de Clahe. Al ejecutar Otsu se encontró inconvenientes con el umbral, ya que para algunos casos daba como resultado una imagen con tonalidades muy oscuras o muy claras, además de pérdida de regiones de interés, es así que se obtiene una muestra de iconografías de cada clase, para obtener el valor más repetido en los píxeles de cada imagen. Los valores de los umbrales se completan con el histograma como se aprecia en el Algoritmo 3, se incrementa la suma de todos los valores de píxeles, que se utiliza para calcular el valor medio del nivel de gris de toda la imagen como vemos en la línea 7. La variación máxima entre grupos se establece inicialmente una vez finalizada toda la aplicación del algoritmo de Otsu. Estos valores fueron agrupados para aplicar la operación matemática mediana y promedio a cada grupo de datos, obteniendo como resultado un umbral medio de 1768 y promedio de 1803

para el grupo de masas, en el grupo de microcalcificaciones el umbral medio fue de 1431 y promedio de 1680 esto se puede observar en Tabla 6.

Algoritmo 3

Otsu

-
1. **Otsu (X, M)**
 2. **Entrada:** imagen de entrada $\rightarrow X$
 3. **Salida:** Umbral optimo $\rightarrow M$
 4. $P(1, \emptyset) \leftarrow 0;$
 5. $S(1, \emptyset) \leftarrow 0;$
 6. For $v \leftarrow 0$ a $X_{\max} - 1$
 7. $P(1, v+1) \leftarrow P(1, v) + X_{v+1};$
 8. $S(1, v+1) \leftarrow S(1, v) + (1, v)X_{v+1};$
 9. End for
 10. For $v \leftarrow 1$ a X_{\max}
 11. For $u \leftarrow 1$ a V
 12. $H(u, v) \leftarrow S(u, v) | P(u, v);$
 13. fin for
 14. fin for
 15. $S_{\max} \leftarrow 0, 0;$
 16. For $\Sigma (t_1, t_2, \dots, t_i, \dots, t_{m-1}) \leq t_1 < \dots < t_{m-1} < X_{\max}$
 17. If $((m)^2 > S_{\max})$
 18. $S_{\max} \leftarrow (m)^2;$
 19. $M \leftarrow (t_1, \dots, t_i, \dots, t_{m-1});$
 20. fin if
 21. fin for;
-

Tabla 6*Umbrales Masas y Microcalcificaciones*

Descripción Imagen	Número más Repetido	Umbral Otsu	Suma y Promedio		
Masas					
20587810_MLO_L_BiR3.dcm	1511	3068	2290	Mediana de todos los valores	1521
20588308_MLO_L_BiR3.dcm	1497	2995	2246	Mediana de más repetidos	1497
20588680_MLO_L_BiR3.dcm	1253	2180	1717	Mediana de los Umbrales	2265
22580419_MLO_L_BiR2.dcm	1482	2267	1875	Mediana de la suma y promedio	1877
22678694_MLO_L_BiR3.dcm	1495	2263	1879	Mediana General	1768
22670620_CC_R_BiR2.dcm	1514	2464	1989	Promedio de todos los valores	1803
22580192_CC_R_BiR3.dcm	1470	2414	1942	Promedio de más repetidos	1480
20587758_CC_L_BiR3_M.dcm	1497	2141	1819	Promedio de los Umbrales	2125
20588334_CC_L_BiR3_M.dcm	1527	727	1127	Promedio de la suma y promedio	1803
22580367_CC_L_BiR2.dcm	1557	729	1143	Promedio General	1803
Microcalcificaciones					
20587544_MG_R_CC_ANON.dcm	1369	722	1046	Mediana de todos los valores	1400
20587054_MG_R_CC_ANON.dcm	1336	2709	2023	Mediana de más repetidas	1353
20587148_MG_R_CC_ANON.dcm	1140	2427	1784	Mediana de los Umbrales	2459
20587294_MG_R_CC_ANON.dcm	1150	2762	1956	Mediana de la suma y promedio	1897
20587836_MG_R_CC_ANON.dcm	1395	2578	1987	Mediana General	1431
20588458_MG_R_CC_ANON.dcm	1442	2235	1839	Promedio de todos los valores	1680
22427682_MG_R_CC_ANON.dcm	1232	704	968	Promedio de más repetidos	1311
22579847_MG_R_CC_ANON.dcm	1218	682	950	Promedio de los Umbrales	2049
20587174_MG_L_CC_ANON.dcm	1420	2491	1956	Promedio de la suma y promedio	1680
20587466_MG_L_CC_ANON.dcm	1404	3181	2293	Promedio General	1680

Nota: Esta tabla contiene los umbrales óptimos.

Clahe se usó para generar un contraste, considerando que la intensidad del píxel se transforma así a un valor dentro del rango de visualización que mejore la calidad de la imagen. Donde solicita el ingreso de los siguientes parámetros que se muestran en el Algoritmo 4. En la línea 3 se cambia el tamaño I a $M \times M$ generando un histograma de $m \times m$, esto se multiplica por el límite de clip obteniendo los píxeles para x,y . Con la utilización de Clahe para mejorar el contraste de la imagen se igualan los píxeles de la imagen en base un umbral óptimo.

Algoritmo 4

Clahe

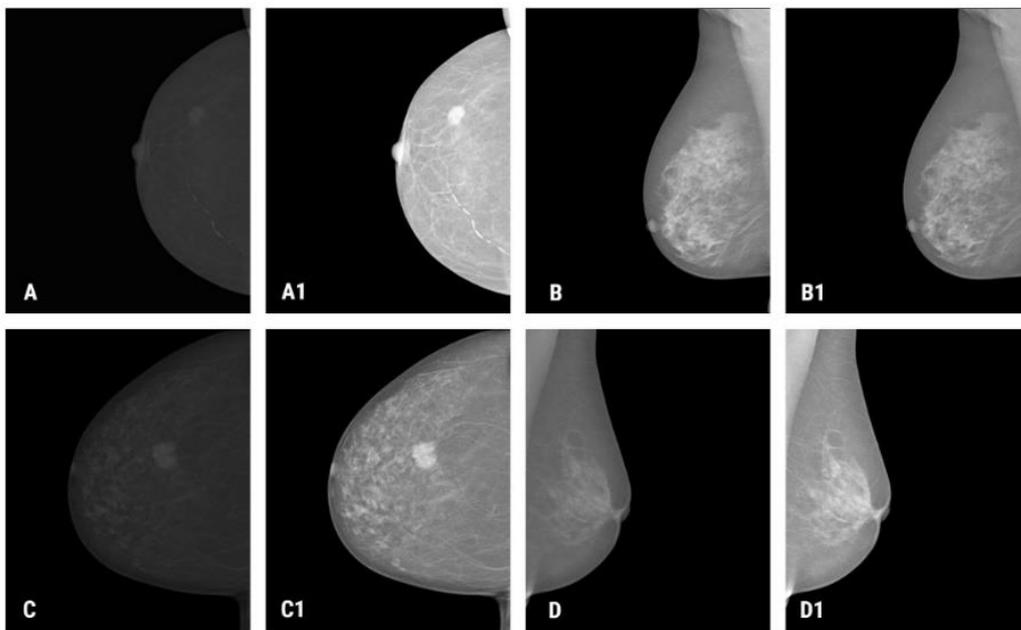
```
1: Entrada: I ← Imagen original;
2: Salida: Ic ← CLAHE imagen procesada;
3: I → (n) fichas; n) ←  $\frac{MxM}{mxm}$ ;
4: Hn ← histograma(n);
5: CL ← Ncl x Navg;
6: Navg ←  $\frac{Nx x Ny}{Ngray}$ ;
7: Ngray → CL
8: Nx, Ny → x, y;
9: NCI ← 0.002
10: Recorte de Hn usando CL;
11:  $\frac{N\Sigma cl}{Ngray}$  → Ncp píxeles → distribución sobre los píxeles restantes;
12: CLAHE(n) ← Hn
13: Ic ← CLAHE(n)
```

Para la Figura 12

Imagen ClaheFigura 12 podemos apreciar el procesamiento realizado para los 4 tipos de imágenes al aplicar CH. Donde A es masas y A1 es el resultado de A aplicado CH, B es microcalcificaciones y B1 es B aplicado CH, C es masas con microcalcificaciones y C1 es C aplicado CH, D es normal y D1 es D aplicado CH.

Figura 12

Imagen Clahe



Nota: Imagen Clahe. Elaborado por: Los Autores.

2.1.3 Fase 3: Segmentación

La fase de segmentación inicia con la detección de bordes para reducir la cantidad de datos que se tiene que procesar en una imagen. Como vemos en el Algoritmo 5, se inició con el paso del resultado de la técnica Clahe donde se lee el archivo .txt que es la salida del algoritmo utilizado para Clahe y almacenar en la variable Gp que es de tipo Uint16. También enviamos los datos de ancho y largo (W,H), para inicializar la variable MR que va a tener el mismo tamaño de la matriz resultante de Clahe como se ve en la línea 2, vamos comparando los valores del umbral si este es mayor o igual se tiene que considera una alta posibilidad que sea un posible borde como se muestra en la línea 11, si son menores que el umbral los valores son suprimidos ver línea 17,18. Al finalizar de recorrer la matriz GP se recibe una salida mediante la variable MR. Este valor que devuelve se encuentra en un fichero llamado salidacanny.txt, posteriormente los datos del .txt son almacenado en una variable de tipo Uint6 y esta variable será la entrada para el algoritmo de WH.

Algoritmo 5

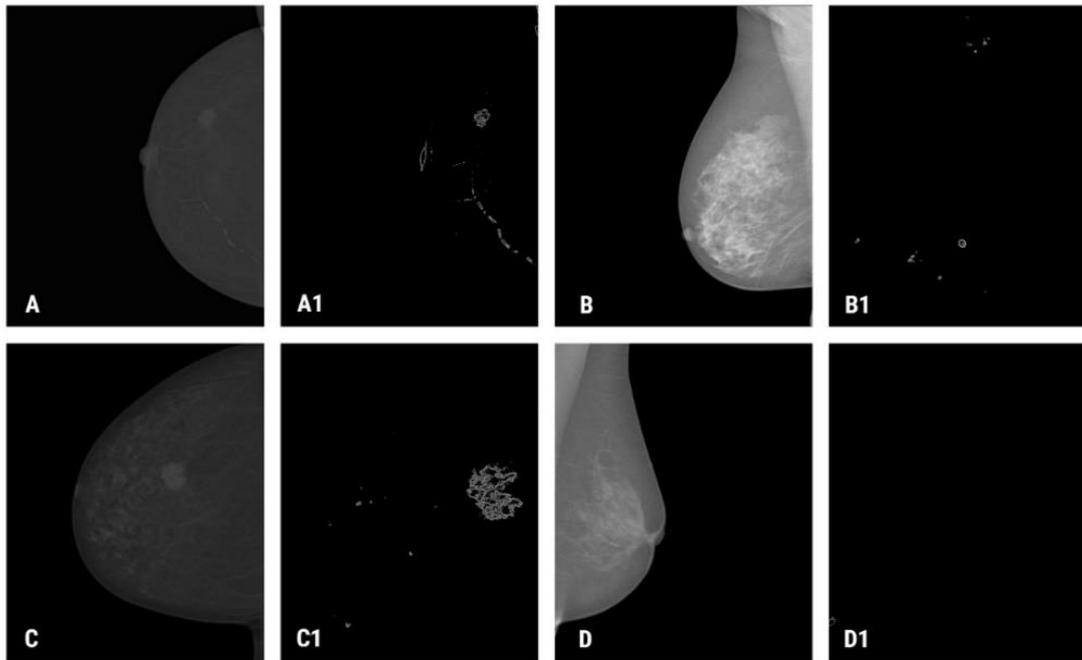
Canny

```
1: Entrada: Dataset( Gp, W,H,Gp1,Gp2)
2: Salida: MR
3: MR[W*H]
4: función NON-MAXIMUM SUPPRESSION(Gp)
5: si  $Gp \geq Gp1$ ,  $Gp \geq GP2$  entonces
6:  $Gp \rightarrow edge$ 
7:  $Gp \rightarrow$  Suprimido
8: finalizar si
9: función final
10: función DOUBLE-THRESHOLD(Gp)
11: si  $Gp \geq HighThreshold$  entonces
12:  $Gp \rightarrow StrongEdge$ 
13: finalizar si
14: if  $LowThreshold \leq Gp \leq HighThreshold$  entonces
15:  $Gp \rightarrow HeakEdge$ 
16: finalizar si
17: si  $Gp \leq LowThreshold$  entonces
18:  $Gp \rightarrow$  Suprimido
19: finalizar si
20: función final
21: función SUPRIMIR PUNTOS DE UMBRAL BAJO AISLADOS(Gp)
22: si  $Gp == LowThreshold$  entonces
23:  $Gp \rightarrow StrongEdge$ 
24:  $MR[] < GP$ 
25: Caso contrario
26:  $Gp \rightarrow$  suprimido
27: finalizar si
28: función final
29: retorna MR
```

Para la Figura 13 se puede apreciar el procesamiento realizado para los 4 tipos de imágenes al aplicar CNY. Donde A es masas y A1 es el resultado de A aplicado CNY, B es microcalcificaciones y B1 es B aplicado CNY, C es masas con microcalcificaciones y C1 es C aplicado CNY, D es normal y D1 es D aplicado CNY.

Figura 13

Imagen Canny



Nota: Imagen Canny aplicado el algoritmo. Elaborado por: Los Autores

Con resultado del algoritmo de Canny se asigna los valores a la matriz `imageArray` que es la entrada para la función `Watershed` que es un puntero de tipo `Uint16` para transformar a la matriz `imageArray` en un puntero llamado `Canny` como se aprecia en el

Algoritmo 6. En este parte de código se envía al puntero llamado `Canny` también el ancho y la altura de imagen que se está utilizando y va a regresar en la misma variable la imagen detectando los segmentos de la imagen.

Algoritmo 6

Watershed (La Serna Palomino & Garcia Hilares, 2011)

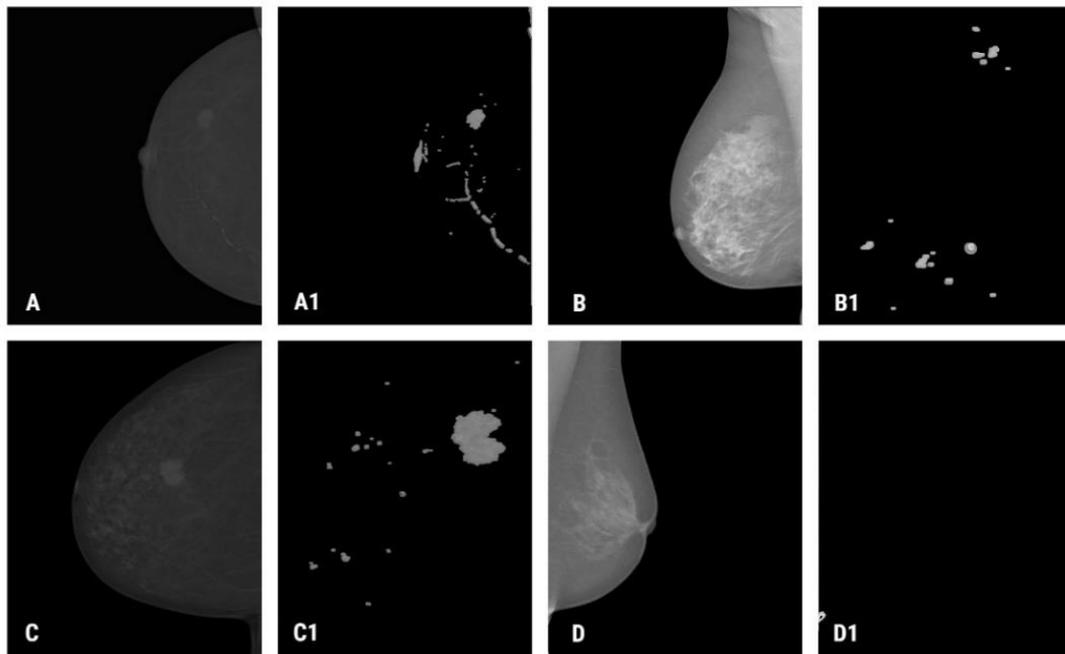
```
1: Entrada: Puntero de imagen canny
2: Salida: Puntero de salida
3: # define MASK -2 /* valor inicial del nivel del Umbral */
4: # define WSHED 0 /* valor de los pixeles que pertenecen a los watersheds */
5: # define INIT -1 /* valor inicial de im */
6: /* Estos pixeles son accesados directamente a través del arreglo ordenado */
7: im (p) MASK;
8: if existe p' N (p) tal que im (p') > 0 or im (p') = WSHED { im (p) 1; fifo_agregar (p);
9: Actual_dist 1; fifo_agregar (ficticio_pixel);
10: repetir indefinidamente {p fifo_primer ();
11: if p = ficticio_pixel {
12: if fifo_vacio ()= true then BREAK;
13: else { fifo_agregar (ficticio_pixel );
14: actual_dist actual_dist + 1;
15: p fifo_primer ();
16: For every pixel p' N (p) {
17: if im (p') < actual_dist and (im (p') > 0 or im d 0 0
18: (p') = WSHED { /* i.e., p' ya pertenece a un basin etiquetado o a el watersheds */
19: if im (p') > 0 {
20: if im (p) = MASK or im (p)
21: -input: im, decimal image;
22: -output: im , image of the labeled watersheds;
23: 0 = WsHeD then
24: im (p) im (p');
25: else if im (p) im 0 (p') * Inicializaciones:
26: -Value INIT que es asignado a cada pixel de im :
27: then
28: im (p) WsHeD;
29: p D , im (p) = INIT; else if im (p) = MASK then im (p)
30: -etiqueta_actual 0;
31: -actual_dist: integer variable
32: 0 0 WsHeD
33: else if im (p') = MASK and im (p') = 0 {
34: 0 d-im : imagen temporal (trabajo ) de distancias inicializado a 0;
35: im (p') actual_dist + 1; fifo_agregar (p');
36: Ordenar los pixeles de im
37: de sus valores de gris.
38: de acuerdo al incremento min max son designados como los valores de niveles /* chequear si nuevo
39: minimo ha sido de gris mas bajo y mas alto respectivamente. descubierto */
40: For every pixel p such that im (p) = h {
41: For h hmin to hmax i
42: Im (p) 0; /* la distancia asociada h*/
43: /* geodesic SKIZ de nivel h - 1 dentro del nivel con p is inicializado a 0 */
44: if im (p) = MASK {
45: For every pixel p tal que im (p) = h { etiqueta_actual etiqueta_actual + 1;
46: fifo_agregar (p); im
```

```
46: (p) etiqueta_acwhile fifo_vacio () = false {
47: p' fifo_primerero ();
48: For every pixel p'' N (p') {
49: if im (p'') = MASK {
50: fifo_agregar (p'');
51: im (p'') etiqueta_actual ; }
```

Para la Figura 14 se representa el procesamiento realizado para los 4 tipos de imágenes al aplicar WH. Donde A es masas y A1 es el resultado de A aplicado WH, B es microcalcificaciones y B1 es B aplicado WH, C es masas con microcalcificaciones y C1 es C aplicado WH, D es normal y D1 es D aplicado WH.

Figura 14

Imagen Watershed



Nota: Imagen Watershed aplicado el algoritmo. Elaborado por: Los Autores

Una vez finalizada la operación se trata la imagen resultante para que se pueda apreciarla en un formato txt o csv. De igual forma con la librería DCMTK se puede visualizar como una imagen tipo .bmp. La variable b contiene el resultado de la ejecución final y está en vector como podemos ver en el Algoritmo 7.

Algoritmo 7

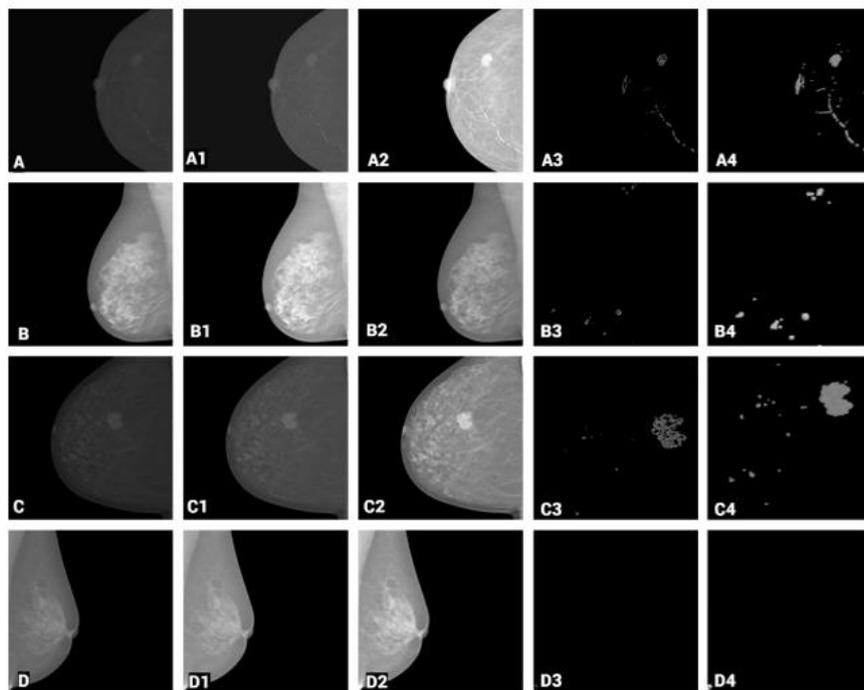
Visualizar Imagen

```
1: Entrada: Entrada Imagen → g
2: Salida: Imagen bmp → b
3: If (g = null)
4: Caso contrario
5: g → (dicom.getdtaset) Uso librería DCMTK
6: b ← g.img
```

La Figura 15 muestra de izquierda a derecha el tratamiento de la imagen antes y después de realizar la ejecución. Como ejemplo tomamos una imagen de cada tipo en este caso A son masas, B son microcalcificaciones, C son masas con microcalcificaciones y D son normales si tomamos el primer rango a la izquierda tenemos A que es la original, A1 es la imagen aplicada HMF, A2 es la imagen aplicada CH, A3 es la imagen aplicada CNY y por último A4 es la imagen aplicada WH. Lo mismo aplica para cada tipo de imagen.

Figura 15

Resultados de masas



Nota: Tratamiento de imágenes. Elaborado por: Los Autores

Se denota en la imagen el resultado de la ejecución al aplicar las técnicas mencionadas y de forma separada en las zonas de interés necesarias para el posterior análisis en SVM.

2.1.4 Fase 4: Clasificación

“SVM comprende a un algoritmo de aprendizaje supervisado que se utiliza en muchos problemas de clasificación y regresión, incluidas aplicaciones médicas de procesamiento de señales, procesamiento del lenguaje natural y reconocimiento de imágenes” (Calle & Chicaiza, 2020).

Para visualizar los resultados obtenidos al ejecutar el clasificador se realiza el análisis del accuracy, en el cual se suman los TP con los que se cuenta en su totalidad. Donde se obtiene como consecuencia la proporción de probabilidades acertadas en la ejecución de la aplicación.

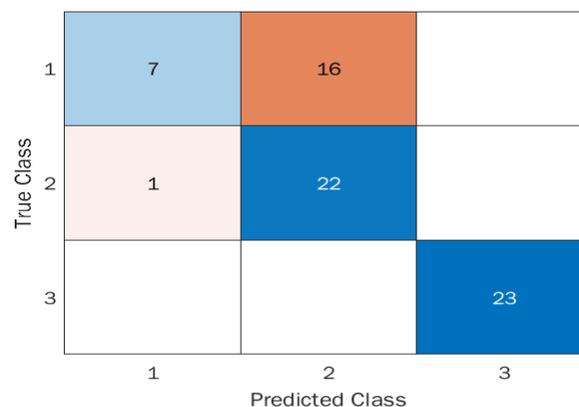
Para ello se dividió las imágenes con esta configuración:

- Conjunto de imágenes dentro de SVM 70% train y 30% test
- Kernel SVM
- Configuración del Kernel lineal

Para la Figura 16 se puede visualizar la matriz de confusión el resultado obtenido para imágenes tratadas.

Figura 16

Masas micros con normales



Nota: Resultados de clasificación. Elaborado por: Los Autores

CAPÍTULO 3

3.1 PLANTEAMIENTO DE LA MEJORA

Ante la problemática planteada se vio la necesidad de la implementación de mejoras en el rendimiento del programa presentado por (Fernández, 2019), remplazando las librerías OpenCv por lenguaje puro C/C++, además de la aplicación de SVM para la clasificación de las imágenes DICOM de esta manera se logra una optimización de recursos del programa.

Considerando los dispositivos móviles (teléfonos inteligentes, tabletas, entre otros.) facilitan la comunicación, acceso a datos y compartir información para la población en la última década y en el área médica facilitar el intercambio de estudios para obtener segundas opiniones, visualización de estudios e informes por parte de los médicos junto a la cama (European Society of Radiology (ESR), 2018).

3.2 RESULTADOS

Del proceso realizado en las 4 fases mencionadas se presenta los resultados obtenidos, así como métricas para evaluar la eficiencia de las técnicas aplicadas.

3.2.1 *Data set.*

Para la ejecución de la aplicación se utilizó una data set de 211 imágenes mamografías en formato DICOM que contiene además metadatos relacionados con el paciente. Está dividida en 105 casos con vista craneocaudal (CC) y 106 casos de Medio lateral Oblicuo (MLO) pudiéndose notar la presencia de lesiones como masas, calcificaciones, microcalcificaciones (MCs) y mamas normales como se puede ver en la Tabla 7.

Tabla 7*Data imágenes*

Detalle		Vista	#Img
masas	CC	L	5
		R	3
	MLO	L	7
		R	4
MCs	CC	L	24
		R	30
	MLO	L	22
		R	31
masas y MCs	CC	L	15
		R	14
	MLO	L	15
		R	14
normal	CC	L	9
		R	5
	MLO	L	8
		R	5

Nota: Esta tabla contiene un resumen de las imágenes de la data set para el proyecto.

Elaborado por: Los autores

3.2.2 Umbrales

Para la umbralización se aplicó Otsu a las imágenes y los valores promedio obtenidos de cada grupo en el cual está dividida la base de datos (masas, microcalcificaciones, etc.) se presentan en la Tabla 8.

Tabla 8*Umbral promedio*

Detalle	Tipo	Umbrales obtenidos en OTSU				
		Vista	Masas	MicroCal	MasasyMicro	Normal
Masa	CC	L	1105,75	2037,38	2037,38	1727
		R	2133,5	2053,13	2053,13	1891,75
	MLO	L	1519	1885	2068,27	3038,8
		R	733	1889,44	1859,5	2321,75

Nota: Esta tabla contiene Umbrales óptimos. Elaborado por: Los autores

3.2.3 Regiones

De cada imagen se obtuvo regiones a través del algoritmo de Watershed para posteriormente por medio de una clasificación manual se dividió en regiones de interés(regI), con masas(regM), con microcalcificaciones(regMcs) y tejidos propios de la mama(tpMa) ver Tabla 9.

Tabla 9

Regiones obtenidas

Detalle		Vista	#Img	# Regiones Obtenidas	#regI	#regM	regMCs	tpMa
masas	CC	L	5	39	7	7	0	32
		R	3	43	13	13	0	30
	MLO	L	7	40	4	4	0	36
		R	4	55	5	5	0	50
MCs	CC	L	24	51	38	0	38	13
		R	30	66	58	0	58	8
	MLO	L	22	66	49	0	49	17
		R	31	128	86	0	86	42
masas y MCs	CC	L	15	65	40	15	35	25
		R	14	73	54	14	40	19
	MLO	L	15	55	24	13	11	31
		R	14	80	29	14	15	51
normal	CC	L	9	15	7	0	0	8
		R	5	20	9	0	0	11
	MLO	L	8	11	5	0	0	6
		R	5	15	3	0	0	12

Nota: Esta tabla contiene las regiones obtenidas. Elaborado por: Los autores

3.2.4 Rendimiento de las técnicas.

Los resultados obtenidos son en base al cálculo por ejecución de cada imagen por separado, se puede notar que los resultados varían dependiendo de la imagen en proporción a su ancho y largo, así como a la cantidad de bit de la imagen. Por tal motivo, se realizó un análisis a nivel de porcentaje total por bloque de ejecución de varias imágenes. Ver Tabla 10.

Tabla 10*Resultados*

Detalle		Lectura Imagen			Hybrid Median Filter			Clahe			Canny			Watershed		
		T (sg)	RAM (Kb)	CPU (%)	T (sg)	RAM (Kb)	CPU (%)	T (sg)	RAM (Kb)	CPU (%)	T (sg)	RAM (Kb)	CPU (%)	T (sg)	RAM (Kb)	CPU (sg)
Masa	CC	1,04	556051,00	13,82	2,24	556051,00	26,27	6,17	556051,00	31,27	6,20	579368,00	26,15	1,96	798851,00	18,72
		1,39	315106,00	25,47	2,77	315106,00	35,41	8,08	315106,00	40,03	8,08	389810,00	28,46	2,29	673776,00	25,76
	MLO	1,36	759779,20	12,93	2,57	759779,20	25,92	8,10	759779,20	30,90	6,86	801842,40	26,92	2,06	1033198,40	17,99
		1,38	313978,00	20,40	2,80	313978,00	32,84	8,66	313978,00	38,05	7,82	388908,00	25,88	2,22	673684,00	18,00
MCs	CC	1,43	1936172,00	17,21	2,60	1936172,00	30,67	8,65	1936172,00	36,52	7,71	1986076,00	34,46	2,20	2229077,54	27,31
		2,00	1083900,50	21,87	2,48	1083900,50	31,77	6,79	1083900,50	36,30	7,67	1121605,00	37,83	2,06	1348496,00	27,14
	MLO	1,33	1271512,44	18,65	2,50	1271512,44	28,59	8,77	1271512,44	37,17	7,52	1308414,67	36,32	2,09	1534014,22	28,64
		1,38	1282591,11	24,61	2,67	1282591,11	33,66	8,75	1282591,11	44,54	7,75	1321477,78	39,53	2,19	1561754,22	30,30
Masas y MCs	CC	1,43	1936172,00	17,21	2,60	1936172,00	30,67	8,65	1936172,00	36,52	7,71	1986076,00	34,46	2,20	2229077,54	27,31
		2,00	1083900,50	21,87	2,48	1083900,50	31,77	6,79	1083900,50	36,30	7,67	1121605,00	37,83	2,06	1348496,00	27,14
	MLO	1,39	2049239,64	18,88	2,86	2049239,64	30,48	10,70	2049239,64	36,69	8,62	2099434,91	34,71	2,33	2377379,64	26,32
		1,86	1595312,40	20,31	2,85	1595312,40	34,37	8,79	1595312,40	35,42	8,56	1655515,60	34,86	2,34	1926213,60	29,38
Normal	CC	4,31	807576,00	12,75	2,57	807576,00	24,13	7,95	807576,00	29,53	7,45	855192,00	25,32	2,17	1112829,60	17,55
		1,37	557235,00	17,83	2,46	557235,00	25,84	6,55	557235,00	31,34	6,93	609809,00	26,02	2,07	861250,00	16,66
	MLO	1,47	869359,20	10,84	2,78	869359,20	25,70	9,83	869359,20	28,96	8,04	938428,80	25,90	2,25	1222186,40	18,29
		1,39	619424,00	12,43	2,72	619424,00	26,09	8,02	619424,00	32,30	7,71	676517,00	25,13	2,20	960792,00	18,57

Nota: Esta tabla contiene los recursos que uso cada técnica. Elaborado por: Los autores

3.2.5 Tiempo de ejecución

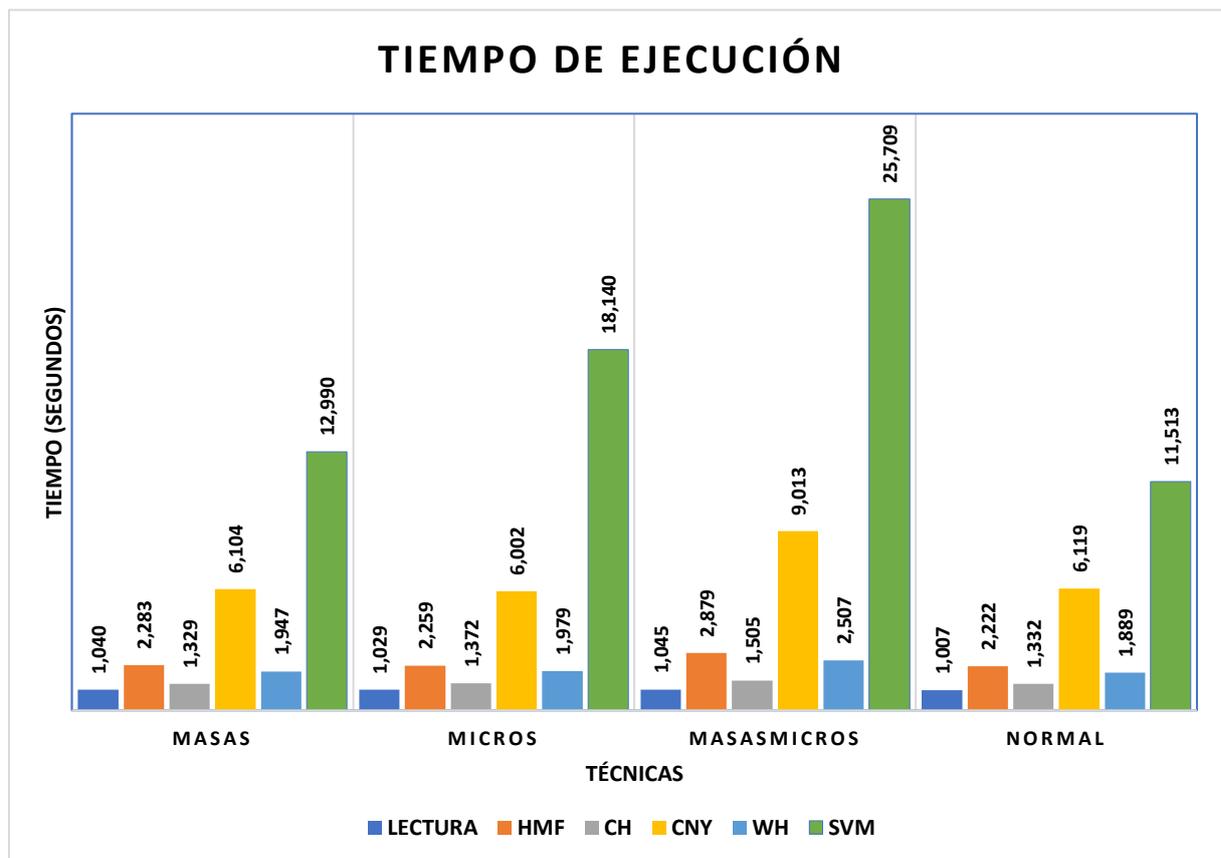
Para el análisis de los resultados se decidió mostrar los tiempos de ejecución de cada técnica, como se puede apreciar en la Figura 17 en función del tipo de imagen en este caso se tiene imágenes de tipo Masas, Micros, MasasMicros y Normales.

Donde se nota que el tiempo de ejecución más alto se tiene en las imágenes que cuentan con masas y micros obteniendo 2,8 segundos para la técnica de HMF, 1,5 segundos para Clahe, 9 segundos en Canny y 2,5 segundos en Watershed, mientras que las imágenes con menos tiempos de ejecución son las normales.

De igual manera se aprecia que entre todas las imágenes la técnica que más tiempo de ejecución toma es la llamada Canny que cuenta con valores altos en todas las imágenes ejecutadas.

Figura 17

Tiempo de ejecución

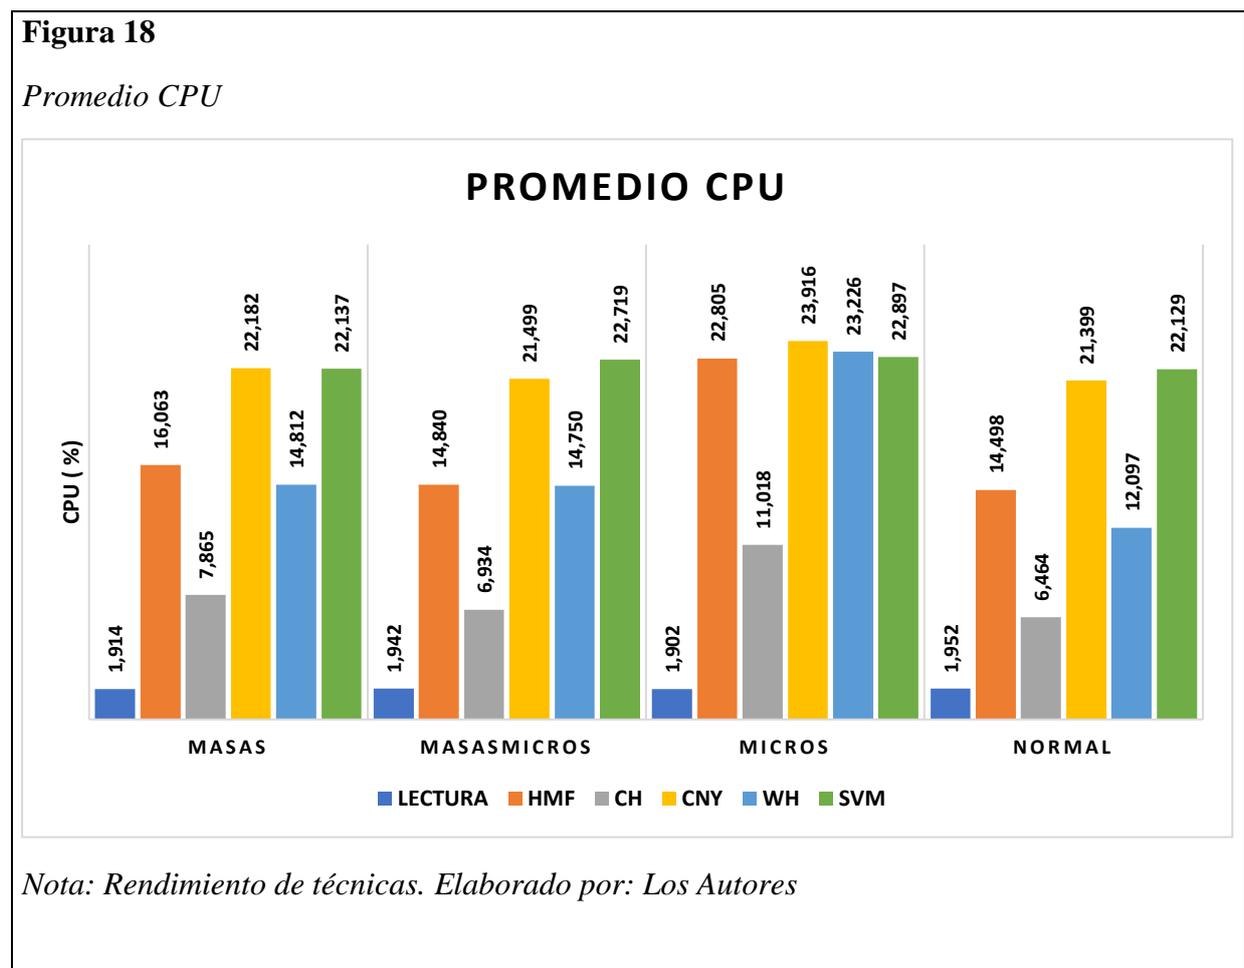


Nota: Rendimiento de técnicas. Elaborado por: Los Autores

3.2.6 Promedio CPU

El consumo promedio de CPU se puede visualizar en la Figura 18 donde se obtiene que las imágenes tratadas con las diferentes técnicas las de mayor consumo son dos Watershed con 23,91% en su pico más alto y Canny con 23,26%.

Se puede acotar que los dos picos más altos de consumo se encuentran al tratar las imágenes que cuentan con microcalcificaciones donde los datos de consumo suben en todas las técnicas en comparación con las otras imágenes.



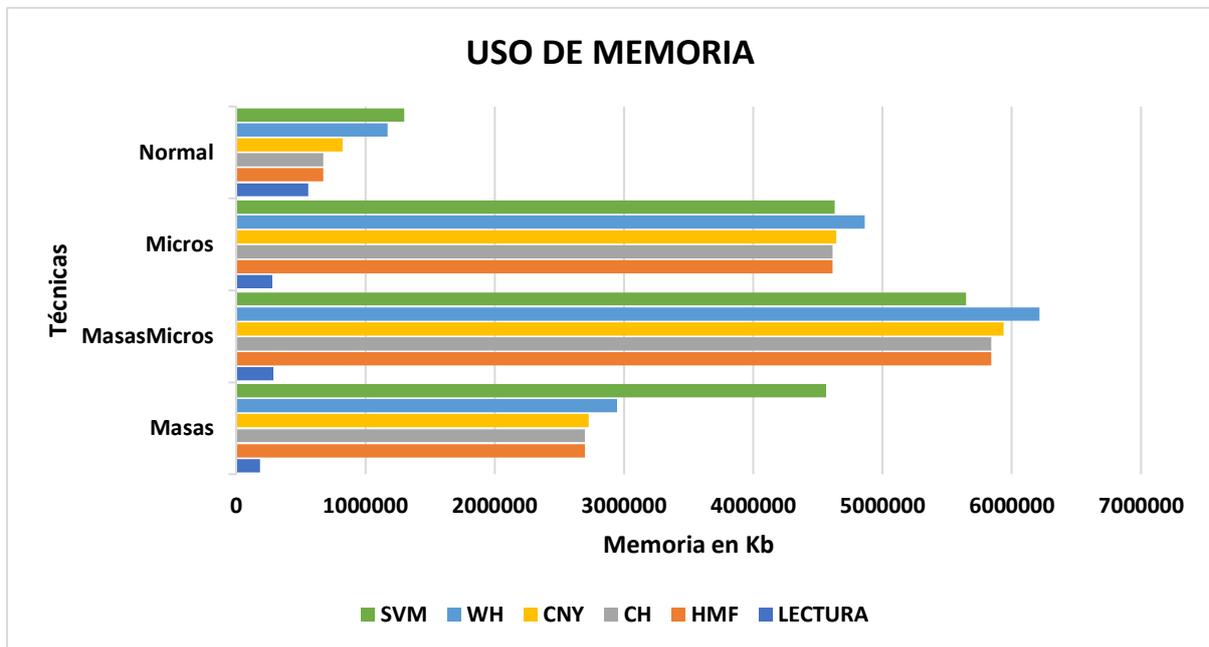
3.2.7 Memoria RAM

En la Figura 19 se puede visualizar el uso de memoria al momento de procesar las imágenes y cómo se aprecia tiene valores altos al usar representaciones de tipo MasasMicros con valores

para las técnicas que llegan a los 6029,64 Mb. El valor máximo para imágenes normales es alcanzado en un 1145,85 Mb, donde se aprecia la diferencia en uso.

Figura 19

Memoria RAM



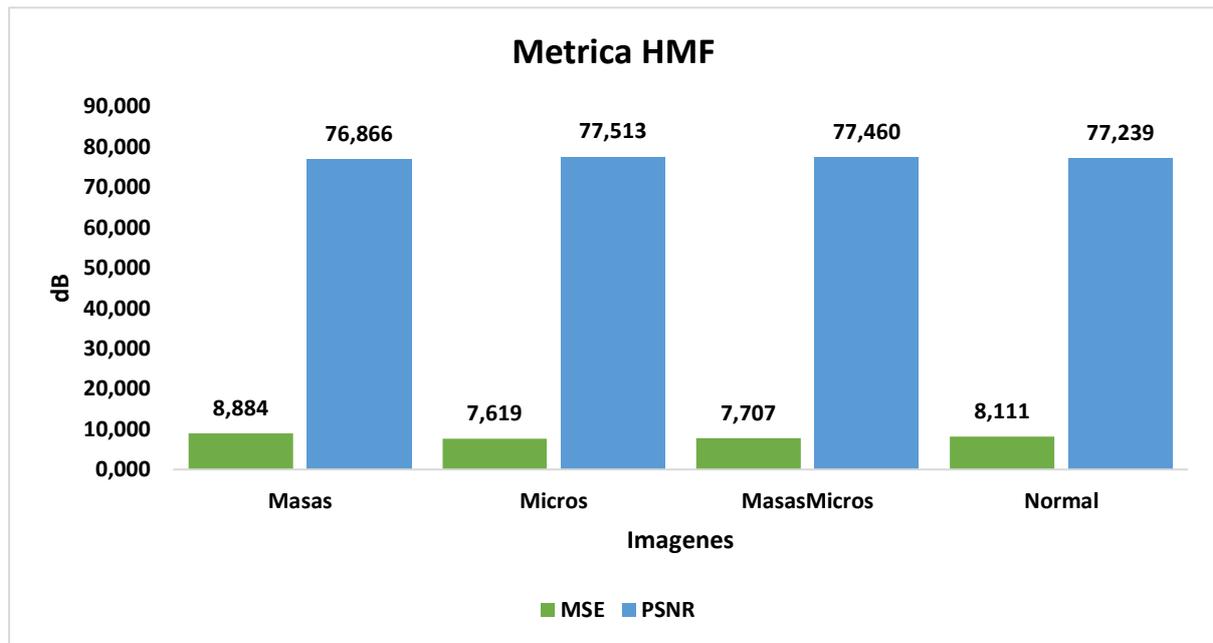
Nota: Rendimiento de técnicas. Elaborado por: Los Autores

3.2.8 Métricas

En la Figura 20 se puede visualizar que tomando como base los resultados obtenidos en el trabajo de (Lbachir, 2017) donde los valores para un rango aceptable están entre el 30dB y 92,8 dB como valor para la métrica de PSNR utilizando median filter para nuestro caso los valores se encuentran entre 76,86 dB y 77,23 dB que son valores por encima de la media logrando una mejora al aplicar esta técnica.

Figura 20

Valores para HMF

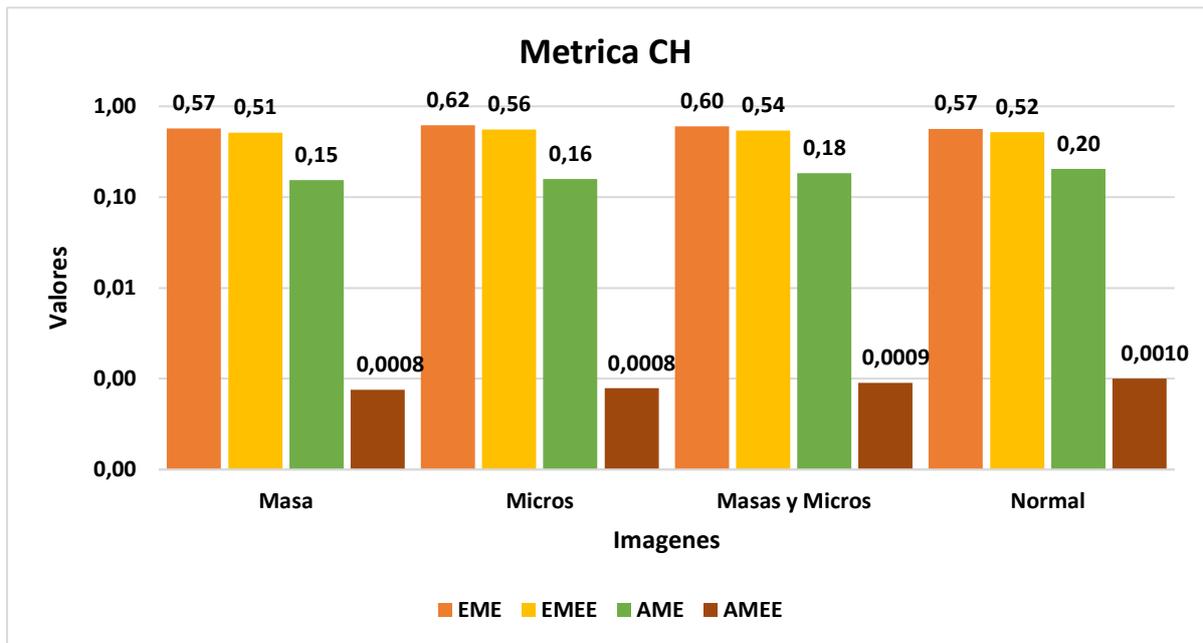


Nota: Métricas. Elaborado por: Los Autores

Mientras los valores para la métrica EME y EMME en la técnica Clahe se encuentran en valores aceptables, mientras más altos significa que la información de la imagen mejoro tendiendo a 1 es decir se logra un mejor contraste para los diferentes tipos de imágenes masas, micros, masasmicros y normales como vemos en la Figura 21. Para AME y AMEE los valores altos significa que las imágenes contienen un fondo no uniforme. Los valores bajos de resultados son correctos ya que tienden a 0.

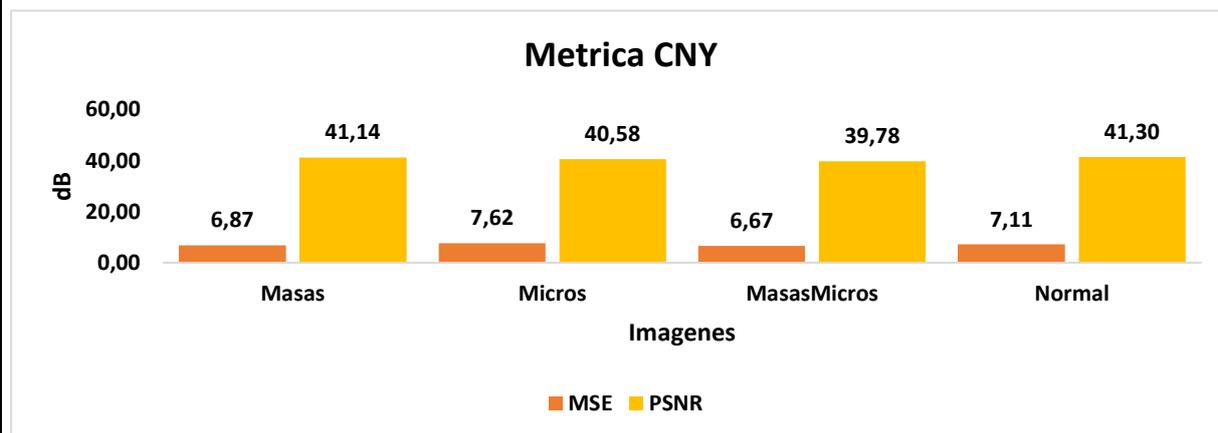
Figura 21

Valores Clahe



Nota: Métricas para la técnica Clahe. Elaborado por: Los Autores

En la Figura 22 se presenta los valores para los diferentes tipos de imágenes, donde se mantienen en un rango de 39 dB a 41,5 dB que son aceptables respecto a los valores de la métrica de PSNR.

Figura 22*Valores PSNR Canny**Nota: Métricas para el algoritmo Canny. Elaborado por autores*

En esta parte se presenta los resultados de las métricas obtenidos de las técnicas HMF, CNY y CH divididas en todos los tipos de imágenes tratadas. Los valores obtenidos son altos y similares ver Tabla 11. Por esto se nota una mejora del contraste ya que Clahe muestra un buen desempeño.

Tabla 11*Resultados Finales*

Detalle		HMF		CH				CNY	
		MSE	PSNR	EME	EMEE	AME	AMEE	MSE	PSNR
Masa	CC	4,155	80,213	0,502	0,433	0,004	0,0002	3,68	80,67
		13,584	75	0,561	0,516	0,117	0,0006	13,8	74,93
	MLO	6,672	78,155	0,702	0,62	0,28	0,0014	4,37	79,92
		19,126	73,513	0,532	0,478	0,217	0,0011	19,01	73,54
MCs	CC	3,215	82,657	0,705	0,639	0,081	0,0004	2,99	81,58
		7,226	78,291	0,454	0,405	0,103	0,0005	3,48	80,91
	MLO	9,499	76,803	0,766	0,7	0,194	0,001	4,51	79,78
		10,596	76,486	0,543	0,493	0,258	0,0013	9,48	76,56
Masas y MCs	CC	3,215	82,657	0,705	0,639	0,081	0,0004	1,44	84,74
		7,226	78,291	0,454	0,405	0,103	0,0005	6,67	78,09
	MLO	12,648	76,576	0,762	0,691	0,298	0,0015	9,86	76,39
		11,919	76,012	0,491	0,44	0,255	0,0012	5,48	78,94

Nota: Esta tabla contiene los resultados de las métricas para el proyecto. Elaborado por: Los autores

3.2.9 Resultados SVM

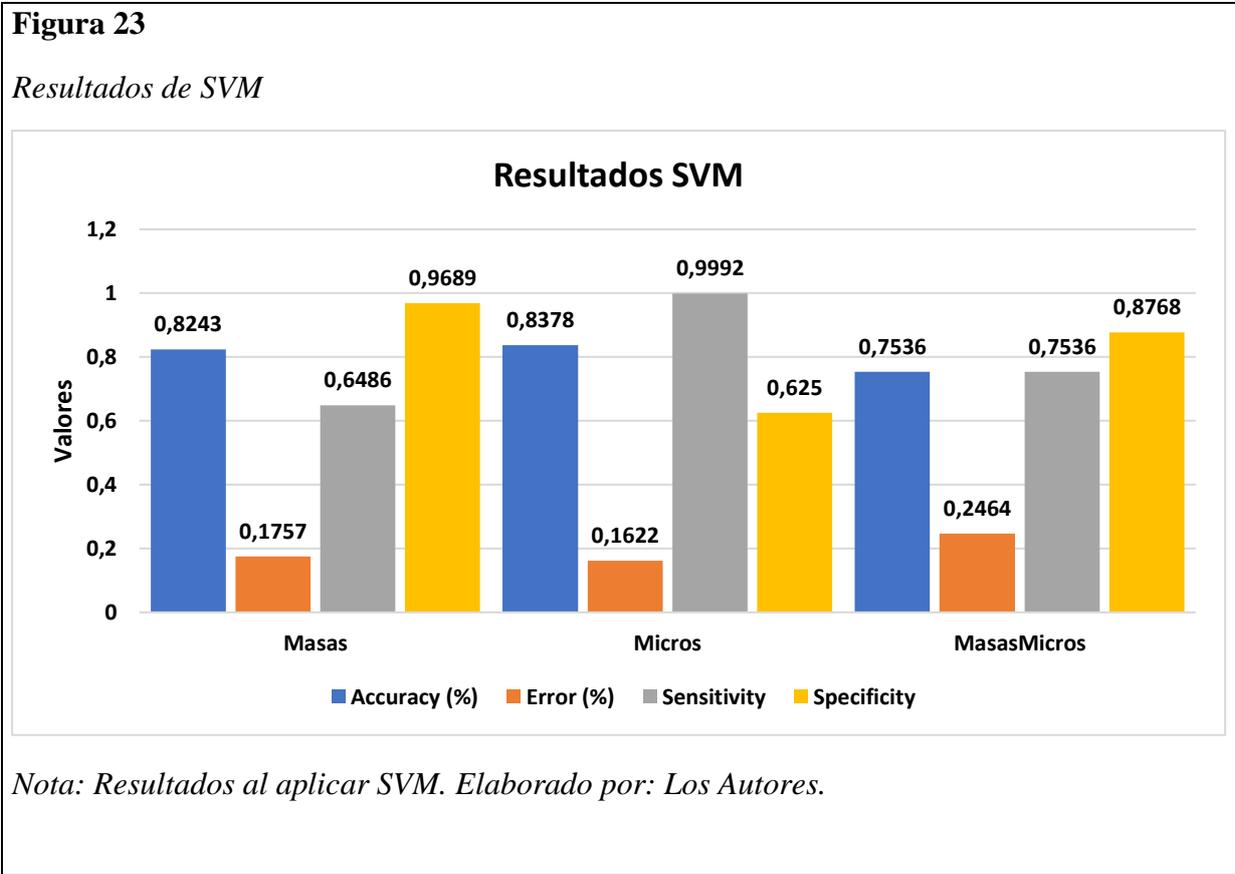
En SVM se trabajó con imágenes DICOM de mamas normales, con presencia solo de masas, con presencia de solamente microcalcificaciones e imágenes con presencia de masas y microcalcificaciones en la misma mama. De los resultados obtenidos en el procesamiento se hizo una selección manual de las regiones con las mejores características para el entrenamiento y así se les asignó etiquetas 1 masas, 2 masas y micro calcificaciones y 3 microcalcificaciones. Se dividieron según la Tabla 12.

Tabla 12*Data set Imágenes Dicom*

Detalle		Vista	#Img	# Regiones Obtenidas	#regI	#regM	regMCs	tpMa	Regiones Usadas en SVM	Train	Test	Etiqueta
masas	CC	L	5	39	7	7	0	32	7	2	5	1
		R	3	43	13	13	0	30	13	4	9	1
	MLO	L	7	40	4	4	0	36	4	1	3	1
		R	4	55	5	5	0	50	5	2	4	1
MCs	CC	L	24	51	38	0	38	13	19	6	13	2
		R	30	66	58	0	58	8	18	5	13	2
	MLO	L	22	66	49	0	49	17	19	6	13	2
		R	31	128	86	0	86	42	19	6	13	2
masas y MCs	CC	L	15	65	40	15	35	25	19	6	13	3
		R	14	73	54	14	40	19	18	5	13	3
	MLO	L	15	55	24	13	11	31	19	6	13	3
		R	14	80	29	14	15	51	19	6	13	3

Nota: Esta tabla contiene el data set de SVM para el proyecto. Elaborado por: Los autores

Obteniendo de acuerdo a la clasificación en SVM de las imágenes los resultados que se presentan en la Figura 23, en la cual se detallan la información de la ejecución con datos relevantes como Accuracy, Error, Sensitivity y Specificity que puedan servir para el análisis de resultados.



Donde se puede notar que los datos obtenidos al clasificar con SVM las imágenes, donde se genera un mayor porcentaje de Accuracy es en las imágenes de tipo microcalcificaciones con un 83,78 % así como un error de 0,1622 %.

Mientras que las imágenes más complejas como son las que contiene los dos tipos masas y microcalcificaciones nuestro Accuracy baja a 75,36 % dando como resultado un error de 0,2464 %.

CONCLUSIONES

- En base a los resultados que se obtuvieron mediante las métricas PSNR se consiguió un valor medio de 77 db (decibeles), el cual se considera optimo según el artículo (Ilhame, Rachida, Imane, & Saadia, 2017), en el clasificador la exactitud promedio de las imágenes utilizadas fue de 0,81 un porcentaje de error general de 0,195 sensibilidad de 0,80 y una especificidad promedio de 0.82, considerando que la exactitud, sensibilidad, especificidad son mejores cuanto más próximos a uno son.
- En los resultados obtenidos en la métricas de procesamiento del dispositivo se pudo apreciar un desempeño promedio de 14,86% del recurso, siendo la Técnica de Canny , la que posee los valores más elevados en el uso de recursos computacionales al presentar un 21% de uso del procesador, para el uso de memoria del dispositivo en la ejecución el uso promedio de las técnicas fue de 3477,44 Megabytes(MB), siendo Watershed la técnica con mayor uso de recursos Memoria con 3709,97 Megabytes y Hybrid Median Filter y Clahe las técnicas con menor uso de recurso de Memoria con 3375,26 MB.
- Para la mejora del tratamiento se utilizó HMF para eliminación de Ruido para posteriormente aplicar Clahe, la cual mejora el contraste de la imagen y así posteriormente con la obtención de un umbral óptimo de la imagen y enviar la imagen resultante de los procesos anteriores a la técnica de Canny la cual permite la detección de bordes y watershed para la realización de una correcta segmentación de la Imagen de mama para obtener las regiones de interés mejorando así la inicial al aplicar técnicas de preprocesamiento.

RECOMENDACIONES

- Para futuros desarrollos de aplicaciones médicas se lograría una mejor obtención de resultados si se cuenta con la asesoría de un profesional de la salud que tenga conocimientos sobre el tema de la aplicación, en este caso de cáncer de mama. Debido a que si bien los desarrolladores pueden adquirir conocimiento sobre el trabajo médico que están realizando no se compara con la experticia de un profesional al momento de reconocimiento de masa y microcalcificaciones en la base de datos con las que se trabaja y así poder lograr resultados más eficientes.
- La clasificación de imágenes es un proceso el cual consume gran cantidad de recursos computacionales, por lo que se puede considerar la posibilidad del desarrollo del clasificador en un servidor con los recursos suficientes para esta tarea. De esta manera la aplicación que se está desarrollando solamente consuma los servicios que esta ofrece y así disminuir aún más los tiempos de respuesta de la aplicación que se está desarrollando.

GLOSARIO DE TÉRMINOS

CR.- Clasificar Regiones

HMF. – Hybrid Median Filter

CH. - Clahe

OT. – Otsu

WH. – Watershed

CNY. - Canny

CPU. - Unidad central de procesamiento

DICOM. - Digital Imaging and Communications in Medicine

IM. - Imágenes Mamográficas

IMD. - Imágenes Médicas DICOM

GPU. - Unidad de procesamiento de gráficos

OPS. - Organización Panamericana de la Salud

OMS. - Organización Mundial de la Salud

SVM. – Support vector machine

SVH. - Sistema visual humano

LISTA DE REFERENCIAS

- Agarwal, R., Díaz, O., Lladó, X., Hoon Yap, M., & Martí, R. (Jul-Sep de 2019). Automatic mass detection in mammograms using deep convolutional neural networks. *Journal of Medical Imaging*, 10.
- Al Nahid, A., & Kong, Y. (31 de 12 de 2017). Involvement of Machine Learning for Breast Cancer Image Classification: A Survey. *Computational and Mathematical Methods in Medicine*, 29.
- Altman, N. S. (1992). An introduction to kernel and nearest-neighbor nonparametric regression. *The American Statistician*, 175-185.
- Álvarez, M., & Cara, M. (2015). Introducción al diagnóstico por imagen de la mama. *Radiología Básica de la mama*, 1-21.
- Amat, J. (Abril de 2017). *Máquinas de Soporte Vectorial (Support Vector Machines, SVMs)*. Recuperado el 12 de Diciembre de 2021, de https://www.cienciadedatos.net/documentos/34_maquinas_de_vector_soporte_support_vector_machines
- Armitage, J., Lichter, Allen, & Niederhuber, J. (2000). *Clinical Oncology*. Virginia: Churchill Livingstone.
- Asua, J. (2005). Mamografía y detección precoz del cáncer de mama. *Revista Española Salud Pública*, 517-520.
- Ballesteros, F. (2003). Desarrollo de aplicaciones DICOM para la gestión. . *Revista Cubana de Informática Médica*, 111-124.

- Calle, B., & Chicaiza, J. (2020). *Sistema para clasificación y reconocimiento de nódulos en imágenes mamográficas utilizando procesamiento digital de imágenes y redes neuronales*. Quito: Universidad de las Fuerzas Armadas ESPE.
- Camargo de Siqueira Ferreira, C., Sá de Camargo Etchebehere, E., Barbosa, J. L., & de Barros, N. (2018). Suspicious amorphous microcalcifications detected on full-field digital mammography: correlation with histopathology. *Radiologia Brasileira*, 87-94.
- Canny, J. (1986). A Computational Approach To Edge Detection, . *IEEE Trans. Pattern Analysis and Machine Intelligence*, 679-698.
- Castillo, D. (2021). Aplicaciones móviles en la promoción de la salud en el Campus de la Universidad Autónoma de Chiriquí. *Revista Plus Economía*, 14-18. Obtenido de <http://revistas.unachi.ac.pa/index.php/pluseconomia/article/view/477>
- Chernenko, S. (2007). <http://www.librow.com/articles/article-8>. Obtenido de Hybrid median filter: <http://www.librow.com/articles/article-8>
- Corporación CMake. (2021). *CMake*. Recuperado el 1 de Diciembre de 2021, de <https://www.ecured.cu/CMake>
- Corporación Java. (2021). *¿Qué es Java?* Recuperado el 12 de Diciembre de 2021, de <https://www.java.com/es/download/help/develop.html>
- Corporación Qt Creator. (5 de Junio de 2021). *Qt Creator/es*. Recuperado el 4 de Diciembre de 2021, de https://wiki.qt.io/Qt_Creator/es
- Developers. (26 de Abril de 2021). *Cómo comenzar a usar el NDK*. Obtenido de <https://developer.android.com/ndk/guides?hl=es-419>
- Dicom. (31 de Mayo de 2021). *DCMTK - DICOM Toolkit*. Obtenido de <https://dicom.offis.de/dcmTk.php.en>

- Dos Santos Teixeira, R. F. (2013). *Automatic Analysis of Mamography images: Classification of Breast density*. Porto: Universidade do Porto.
- Elmoufidi, A., Khalid, E. F., Jain, S., & Sekkaki, A. (2016). Automatic Diagnosing of Suspicious Lesions in Digital Mammograms. *International Journal of Advanced Computer Science and Applications*, 510-518.
- Embong, R., & Anuar, S. R. (2018). Structuring Elements in the Watershed Algorithm for the Segmentation of Mammography Images. *TENCON 2018 - 2018 IEEE Region 10 Conference*, 2144-2147.
- European Society of Radiology (ESR). (2018). ESR paper on the proper use of mobile devices in radiology. *Insights Imaging* 9, 247–251. Obtenido de <https://bibliotecas.ups.edu.ec:2582/10.1007/s13244-017-0589-7>
- Fernández, A. (2020). Construcción de un prototipo de agentes para dispositivos móviles que permita segmentar imágenes médicas y realizar procesos paralelos multicore utilizando CPU'S Y GPU'S. *Revista Técnica de la Facultad de Ingeniería Universidad del Zulia*, 40-47.
- Flores, R., & Fernández, J. (2008). *Las Redes Neuronales Artificiales Fundamentos teóricos y aplicaciones prácticas*. Madrid: Netbiblo S.L.
- Gismondi, G. (2010). Ingeniería Biomédica. *Revista Ciencia y Cultura N.24*, 99-118.
- Hertel, M., Marija, J., Michael, G., Kappler, S., Nanke, R., Mertelmeier, T., . . . Radicke, M. (2019). Concept for fast breast cancer ultrasound screening in addition to mammography – first clinical results. *IEEE International Ultrasonics Symposium (IUS)*, 1437-1439.

- Holalu, S., & Arumugan, K. (2006). Computer aided decision system for early detection of breast cancer. *The Indian Journal of Medical Research*, 149/154.
- Hosting y Servidores. (21 de Mayo de 2018). *Servidores Linux: Ventajas del sistema operativo CentOS 7*. Recuperado el 14 de Diciembre de 2021, de <https://www.internetya.co/servidores-linux-ventajas-del-sistema-operativo-centos-7/>
- Ilhame, A., Rachida, E.-s., Imane, D., & Saadia, T. (2017). A new mammogram preprocessing method for. *International Conference on Computer Systems and Applications*, 166-171.
- Jaffar, M. A., Ahmed, B., & Hussain, A. (2009). Clasificación basada en características de múltiples dominios de imágenes de mamografías utilizando SVM y MLP. *Cuarta Conferencia Internacional sobre Computación, Información y Control Innovadores (ICICIC)*, 1301-1304.
- Jiménez, S. (2018). *Clasificación de imágenes médicas mediante redes convolucionales*. Madrid: Universidad Autónoma de Madrid.
- Karpathy, A. (2016). *Redes neuronales convolucionales para el reconocimiento visual*. Recuperado el 2 de Octubre de 2021, de <http://cs231n.github.io/classification/>, CS231n: Convolutional neural
- Komen, S. (2006). *Las calcificaciones en el seno*. Recuperado el 6 de Octubre de 2021, de https://ww5.komen.org/upliadedFiles/_Komen/Content/About_Breast+cancer/Tools_and_Resources/Translated_Materials/Breast%20Calcifications+SPA%20KO2048%20FINAL%201-16%20HR.pdf

- La Serna Palomino, N., & Garcia Hilares, N. (2011). Implementación del algoritmo Watershed para el análisis de imágenes médicas. *REVISTA DE INVESTIGACIÓN DE SISTEMAS E INFORMÁTICA*, 67-74.
- Labajo, E. (2017). *El Método Científico (I) Generalidades*. Recuperado el 12 de Noviembre de 2021, de <https://www.ucm.es/data/cont/docs/107-2017-02-08-El%20M%C3%A9todo%20Cient%C3%ADfico%20I.pdf>
- Latarjet, M., & Ruiz, A. (2008). *Anatomía Humana 4ta edición*. Madrid: Médica Panamericana.
- Lbachir, I. A.-S. (2017). A New Mammogram Preprocessing Method for Computer-Aided Diagnosis Systems. *2017 IEEE/ACS 14th International Conference on Computer Systems and Applications (AICCSA)*, 166-171.
- López, J., & Pina, L. (2016). *Manual de Radiología Mamaria*. Médica Panamericana.
- Ministerio de Salud Pública. (2018). *Cifras de Ecuador – Cáncer de Mama*. Recuperado el 1 de Octubre de 2021, de <https://www.salud.gob.ec/cifras-de-ecuador-cancer-de-mama/>
- Montenegro, J. (2014). *Aplicación móvil para la consulta y visualización de imágenes usando el protocolo de comunicación DICOM*. Recuperado el 1 de Diciembre de 2021, de <https://bibliotecadigital.univalle.edu.co/bitstream/handle/10893/15785/0516502.pdf?sequence=1&isAllowed=y>
- Muhammad Sailuddin Darus, S. N. (2016). Modified Hybrid Median Filter for Removal of Low Density Random-Valued Impulse Noise in Images. *International Conference on Control System, Computing and Engineering*, 25-27.

- Murillo, J. (2019). *Método de investigación de enfoque experimental*. Recuperado el 1 de Noviembre de 2021, de <https://www.postgradoune.edu.pe/pdf/documentos-academicos/ciencias-de-la-educacion/10.pdf>
- Open Source Computer Vision. (2021). *Tutorial_code*. Recuperado el 30 de Diciembre de 2021, de https://docs.opencv.org/3.4/d9/d47/samples_2cpp_2tutorial_code_2features2D_2Homography_2homography_from_camera_displacement_8cpp-example.html
- Organización Panamericana de la Salud. (2021). *Día Mundial contra el Cáncer 2021*. Recuperado el 1 de Octubre de 2021, de <https://www.paho.org/es/campanas/dia-mundial-contra-cancer-2021-yo-soy-voy>
- Ortuño, E., Malpica, M., Reig, S., Martínez, R., Desco, M., & Santos, A. (2001). Algoritmo Morfológico de Segmentación de Imágenes de Resonancia Magnética Normales Ponderadas en T1. *CASEIB*, 205-208.
- Pavón, C., Villaseñor, Y., Cruz, R., Aguilar, L., Pérez, M., & Pérez, I. (2012). Nódulos, caracterización y categorización. *GAMO Vol 11*, 260-268.
- Pisano ED, Z. S. (1998). Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms. *J Digit Imaging*, 193-200.
- Qu, Z., & Zhang, L. (2010). Research on Image segmentation Based on the Improved Otsu Algorithm. *Second International Conference on Intelligent Human-Machine Systems and Cybernetics*, 228-231.
- Ramírez, W. (2020). *Procesamiento Automático de Imágenes Digitales Mamográficas DICOM*. México: Universidad de Guadalajara.

- Reyes, O., Mejia, M., Useche, & Juan. (2019). Técnicas de inteligencia artificial utilizadas en el procesamiento de imágenes y su aplicación en el análisis de pavimentos. *Escuela de Ingeniería de Antioquia*, 189-207.
- Santamaría, L. Á. (2019). Reconocimiento de patrones en imágenes médicas por medio de redes neuronales convolucionales. (*Maestro en Ciencias de la Computación*). Benemérita Universidad Autónoma de Puebla, Puebla.
- Securitytrooper. (9 de Febrero de 2018). *Smush Image 2.7.4.1 Directory Traversal CVE-2017-15079*. Recuperado el 12 de Diciembre de 2021, de <https://securitytrooper.com/smush-image-2-7-4-1-directory-traversal-cve-2017-15079>
- Suthaharan, S. (2016). Support Vector Machine. *Data Classification, Integrated Series in Information Systems*, 207-235.
- Székely, A., Talanow, R., & Bágyi, P. (2012). Smartphones, tablets and mobile applications for radiology. *European Journal of Radiology*, 1-10.
- Thomas, A., & Banerjee, A. (2013). *The History of Radiology*. Oxford: Oxford University Press.
- Thomas, A., & Banerjee, A. (2013). *The History of Radiology*. United Kingdom: Oxford University.
- Xizhen, S., Wei, Z., Yiling, G., & Shengyang, Y. (2021). Edge detection algorithm of plant leaf image based on improved Canny . *6th International Conference on Intelligent Computing and Signal Processing (ICSP)*, 342-345.
- Xu, Q., Varadarajan, S., & Chakrabar, C. (2014). A Distributed Canny Edge Detector: Algorithm and FPGA Implementation. *Transactions on Image Processing*, 1-16.

- Y. Zhou, H. R. (2012). Segmentation Method for Rock Particles Image Based on Improved Watershed Algorithm. *International Conference on Computer Science and Service System*, 347-349.
- Yébenes Calvo, B. (2016). *Realce de imágenes mamográficas mediante técnicas basadas en histograma para su clasificación.(Proyecto Fin de Carrera / Trabajo Fin de Grado)*. Universidad Politécnica de Madrid, Madrid.
- Yousefi, J. (2015). Binarización de imágenes utilizando el algoritmo de umbralización de Otsu. *Research Gate*, 1-5.
- Zhao, H., Qin, G., & Wang, X. (2013). Improvement of Canny Algorithm Based on Pavement Edge Detection. *Congress on Image and Signal Processing*, 964-967.
- Zheng, L. S., & Sun, S. (2016). Underwater image enhancement algorithm based on CLAHE and USM. *IEEE International Conference on Information and Automation (ICIA)*, 585-590.

Anexo A

Instalación de dependencias

Para el desarrollo de la aplicación se debe instalar las siguientes dependencias, como Cmake, que corresponde a una herramienta multiplataforma de generación o automatización de código. Esta es una suite separada y de más alto nivel que el sistema make común de Unix, siendo similar a las autotools. Mediante el uso del terminal se instala la versión 3, la cual es compatible para las librerías Dcmtk usando el comando *yum install cmake3*.

Para la configuración del entorno se usa el siguiente comando que permite la instalación de todas sus librerías y dependencias.

```
yum install java-1.8.0-openjdk-devel GCC
```

Para obtener la librería Java JDK, la colección de compiladores GNU incluye interfaces para C, C ++, Objective-C, Fortran, Ada, Go y D, así como bibliotecas para estos lenguajes (libstdc ++, ...). GCC se escribió originalmente como el compilador del sistema operativo GNU. El sistema GNU fue desarrollado para ser un software 100% libre, gratuito en el sentido de que respeta la libertad del usuario. *yum -y install gcc*.

Las librerías requeridas para el funcionamiento son:

- SDK
- NDK
- OPENSLL

Una vez instalado todas estas dependencias se dirige al entorno de desarrollo Qt para poder hacer el llamado y el posterior uso de las mismas. Para lo cual, se direcciona a Tools Opciones Devices que se encuentren correctamente instaladas. Posterior se debe hacer el llamado desde la ventana a donde se encuentren alojadas las dependencias.

Configuración de dispositivo virtual

Se crea un dispositivo virtual para comprobar que todo se ha instalado correctamente para lo que se procede a ir al menú del programa Qt Tools/options/devices/Android y seleccionando create new AVD y las características que va a tener el dispositivo virtual. Una vez elegido los parámetros de preferencia se acepta y el procesamiento aparecerá en la sección de AVD Manager. Se ejecuta un aplicativo de prueba para ver su funcionamiento básico, de esta manera se deba arrojar el siguiente resultado, el cual dependerá de las características que se han señalado anteriormente.

Anexo B

Librería Dcmtk

Para la instalación se ejecutó los siguientes comandos a través del ingreso por terminal a la dirección donde se extrajo el tar.gz:

```
mkdir dcmtk-3.6.6-build
```

```
cd dcmtk-3.6.6-build
```

```
cmake ../dcmtk-3.6.6
```

```
make -j8
```

```
make DESTDIR=../dcmtk-3.6.6-install instal
```

Se utiliza para la lectura de las imágenes ya que son imágenes con ese estándar DICOM y está desarrollado en código C++. Para ello, se debe configurar el archivo cmakeLists.txt del proyecto qt para el uso de las librerías. Este archivo CmakeLists.txt contiene un conjunto de directivas e instrucciones que describen los archivos fuente y los destinos del proyecto (ejecutable, biblioteca o ambos).

```
find_package(DCMTK REQUIRED)
```

```
include_directories(${DCMTK_INCLUDE_DIRS})
```

```
target_link_libraries(Prueba1 ${DCMTK_LIBRARIES})
```